

Analyse du post-traitement par transformation quantile-quantile pour le pré- et post-traitement de prévisions hydrologiques

par

Lucas GODMER

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE
AVEC MÉMOIRE EN GÉNIE DE LA CONSTRUCTION
M. Sc. A.

MONTRÉAL, LE 18 MARS 2024

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Lucas Godmer, 2024



Cette licence [Creative Commons](https://creativecommons.org/licenses/by-nc-nd/4.0/) signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette œuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'œuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE :

M. Richard Arsenault, directeur de mémoire
Département de génie de la construction à l'École de technologie supérieure

Mme Annie Poulin, codirectrice de mémoire
Département de génie de la construction à l'École de technologie supérieure

M. Mathieu Lapointe, président du jury
Département de génie de la construction à l'École de technologie supérieure

M. Jean-Luc Martel, membre du jury
Département de génie de la construction à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 15 MARS 2024

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Au seuil de cette étape importante de ma vie académique, je tiens à exprimer ma gratitude profonde et sincère à toutes les personnes qui ont éclairé mon chemin avec leur savoir, leur soutien et leur amour. Parmi elles, Richard se distingue par son aide inestimable et sa patience exemplaire. Son accompagnement a été plus qu'une guidance; il a été une véritable lumière dans les moments d'incertitude, m'offrant des orientations précises et des conseils judicieux qui ont façonné la trajectoire de ce travail. Sa persévérance et son engagement envers l'excellence ont été pour moi une source d'inspiration constante.

Je dois une fière chandelle à ma compagne, Camille, dont le soutien a été le pilier de mon équilibre émotionnel et intellectuel. Dans les tourbillons de doutes et les marées d'incertitudes, elle a été mon phare, m'offrant un havre de paix et de réconfort. Sa présence à mes côtés est bien plus qu'un soutien; c'est une source d'amour inépuisable, d'encouragements sans cesse renouvelés, et d'une compréhension profonde de mes luttes et de mes aspirations.

À mes parents, ces héros discrets et inconditionnels, je dédie une gratitude infinie. Leur foi en moi et leur amour indéfectible ont été le socle sur lequel j'ai pu construire mes rêves et affronter les défis de ce voyage académique. Leur soutien constant, loin d'être un simple encouragement, a été le vent sous mes ailes, me propulsant vers des horizons que je n'aurais jamais cru atteindre.

Et comment oublier mes amis, ces compagnons de route précieux, dont le soutien, la compréhension et la joie de vivre ont apporté lumière et couleur à ce parcours parfois semé d'embûches. Leur présence, tant dans les moments de labeur que de détente, a tissé autour de moi un réseau de sécurité affective, me rappelant que la joie et la réussite sont aussi faites de partages et de solidarité.

À tous, je vous offre mes remerciements les plus chaleureux, pour avoir été ma constellation dans la nuit de mes recherches, guidant chacun de mes pas vers ce moment de réalisation. Votre

VI

dévouement, votre amour et votre foi en moi sont les véritables fondations sur lesquelles repose ce travail. Je vous suis éternellement reconnaissant.

Analyse du post-traitement par transformation quantile-quantile pour le pré- et post-traitement de prévisions hydrologiques

Lucas GODMER

RÉSUMÉ

Cette étude explore l'amélioration des prévisions météorologiques et hydrologiques probabilistes à court terme à travers des traitements statistiques, s'inscrivant dans l'objectif crucial de gestion optimale des ressources hydriques et de prévention des risques liés aux phénomènes extrêmes. L'étude porte sur les prévisions générées par huit modèles hydrologiques conceptuels globaux pour 42 bassins versants québécois, utilisant l'algorithme Covariance Matrix Adaptation Evolution Strategy (CMA-ES) pour la calibration. Les prévisions s'appuient sur des données météorologiques d'ensemble et sont enrichies par une assimilation de données, formant un ensemble de 1250 scénarios hydrologiques. L'accent est mis sur les pré et post-traitements des données par Quantile Mapping (QM) avec une sélection de données de calibration par fenêtre glissante, évalués via le Continuous Ranked Probability Score (CRPS).

Les résultats révèlent que le prétraitement améliore considérablement les prévisions de température, mais impacte faiblement les précipitations. De plus, les avantages du prétraitement se propagent faiblement après simulation par les modèles hydrologiques. Inversement, le post-traitement entraîne des modifications substantielles des débits simulés, avec des impacts tant positifs que négatifs. Le post-traitement au QM améliore les performances de modèles moins précis, mais peut légèrement détériorer celles des modèles les plus performants. Sur les 42 bassins étudiés, les prévisions brutes restent supérieures pour 16 d'entre eux, soulignant qu'aucune méthode de traitement ne se distingue uniformément parmi les modèles et bassins étudiés. La méthode de sélection des données utilisée pour le QM suggère que des fenêtres plus larges (± 30 jours) offrent des corrections plus efficaces. Cependant, l'étude révèle aussi des limitations cruciales, notamment la quantité limitée de données disponibles. Ainsi, le choix initial d'un nombre élevé de quantiles pour le QM, par rapport aux données disponibles, met en lumière une considération méthodologique essentielle. Reconnaisant cela, un nombre réduit de quantiles aurait été plus adéquat vu la limitation des données. Cette réalisation met en évidence l'importance de l'adéquation entre les méthodes statistiques et le volume de données, et suggère que des stratégies alternatives pourraient être explorées dans des recherches futures face à de telles limitations. Bien que l'étude démontre la capacité des traitements statistiques à ajuster et améliorer les prévisions hydrologiques, elle met également en lumière la complexité inhérente à la prédiction des régimes hydriques et les défis liés aux méthodes de traitement statistique. Ces observations encouragent une approche plus ciblée et une réflexion critique sur le choix des méthodes en fonction des caractéristiques spécifiques de chaque bassin versant et des données disponibles.

Mots-clés : traitement statistique, quantile mapping, prévision d'ensemble, simulation hydrologique

Analysis of quantile-quantile transformation for pre- and post-processing of hydrological forecasts

Lucas GODMER

ABSTRACT

This study delves into the enhancement of short-term probabilistic meteorological and hydrological forecasts through statistical treatments, aimed at optimal water resource management and risk prevention associated with extreme events. The study focuses on forecasts produced by 8 lumped conceptual rainfall-runoff models for 42 Quebec watersheds, employing the Covariance Matrix Adaptation Evolution Strategy (CMA-ES) algorithm for calibration. The forecasts rely on ensemble meteorological data, and they are enriched through data assimilation, culminating in a set of 1250 hydrological scenarios. Emphasis is placed on the pre- and post-processing of data using Quantile Mapping (QM) with a sliding window approach for calibration data selection, assessed through the Continuous Ranked Probability Score (CRPS).

The findings show that pre-processing considerably improves temperature forecasts but has a minimal impact on precipitation. Additionally, the benefits of pre-processing weakly propagate following simulation by the hydrological models. Conversely, post-processing leads to substantial alterations in simulated flows, with both positive and negative impacts. Post-processing with QM enhances the performance of less accurate models but can slightly degrade the performance of the most efficient models. Among the 42 basins studied, raw forecasts remain superior for 16, indicating that no single treatment method distinctly outperforms across the analysed models and basins. The data selection method used for QM indicates that wider windows (± 30 days) provide more effective corrections. However, the study also uncovers critical limitations, notably the limited quantity of available data. Consequently, the initial choice of a high number of quantiles for QM, relative to the available data, underscores a crucial methodological consideration. Acknowledging this, a reduced number of quantiles would have been more appropriate given the data limitations. This realization highlights the importance of matching statistical methods with the volume of available data and suggests that alternative strategies might be explored in future research to overcome such limitations. Although the study demonstrates the ability of statistical treatments to adjust and enhance hydrological forecasts, it also sheds light on the inherent complexity of predicting hydrological regimes and the challenges associated with statistical treatment methods. These observations encourage a more targeted approach and critical reflection on the choice of methods based on the specific characteristics of each watershed and the available data.

Keywords: statistical processing, quantile mapping, ensemble prediction, hydrological simulation

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE	3
1.1 Introduction.....	3
1.2 Modélisation météorologique	3
1.3 Modélisation hydrologique	4
1.4 Prévisions hydrologiques déterministes et probabilistes	5
1.5 Incertitudes et biais liés aux prévisions hydrométéorologiques	6
1.6 Méthodes de réduction des biais liés aux prévisions hydrologiques	7
1.6.1 Assimilation de données	7
1.6.2 Post-traitement statistique.....	9
1.6.2.1 Prétraitement des prévisions météorologiques.....	11
1.6.2.2 Effets du prétraitement des prévisions météorologiques sur les prévisions hydrologiques.....	13
1.6.2.3 Post-traitement des prévisions hydrologiques	15
1.7 Objectifs de la présente étude	16
CHAPITRE 2 MÉTHODOLOGIE	17
2.1 Secteur à l'étude.....	17
2.2 Description de la méthode de calcul de l'évapotranspiration potentielle	20
2.3 Description de la méthode de séparation des précipitations	21
2.4 Description du modèle de suivi du couvert neigeux.....	22
2.5 Description des modèles hydrologiques	22
2.5.1 CEQUEAU	23
2.5.2 GR5dt.....	23
2.5.3 HBV	24
2.5.4 HYMOD	25
2.5.5 IHACRES	25
2.5.6 MOHYSE.....	26
2.5.7 SIMHYD.....	27
2.5.8 TOPMODEL.....	28
2.6 Calibration des modèles hydrologiques	28
2.7 Description de la méthode d'assimilation de données.....	30
2.8 Description de la méthode de post-traitement	31
2.9 Mesures de performance des prévisions	35
2.9.1 Continuous Ranked Probability Score (CRPS).....	35
2.9.2 Continuous Ranked Probability Skill Score (CRPSS).....	37
2.9.3 Diagrammes de Talagrand	37

CHAPITRE 3	RÉSULTATS	41
3.1	Prétraitement des prévisions météorologiques.....	41
3.1.1	Performances globales du prétraitement des prévisions météorologiques.....	41
3.1.1.1	Performances globales du prétraitement des prévisions de précipitations.....	42
3.1.1.2	Performances globales du prétraitement des prévisions de température	44
3.1.2	Performances du prétraitement des prévisions météorologiques par pas de temps et saisons	46
3.1.2.1	Performances du prétraitement des prévisions de précipitations par pas de temps et saisons.....	46
3.1.2.2	Performances du prétraitement des prévisions de température par pas de temps et saisons	48
3.2	Performances des prévisions hydrologiques.....	50
3.2.1	Calibration des modèles hydrologiques.....	50
3.2.2	Performances globales des prévisions hydrologiques post-traitées par méthodes	52
3.2.3	Performances globales des prévisions hydrologiques post-traitées pour différents horizons prédictifs.....	54
3.2.4	Hydrogrammes prévisionnels des prévisions hydrologiques brutes, prétraitées et post-traitées pour des bassins particuliers	57
3.2.5	Performances des prévisions hydrologiques prétraitées et post-traitées pour des bassins particuliers.....	62
3.2.5.1	Cas où les prévisions brutes restent meilleures, bassin n°1 : Châteauguay	62
3.2.5.2	Cas où les prévisions prétraitées sont meilleures, bassin n°34 : Batiscan	65
3.2.5.3	Cas où les prévisions post-traitées sont meilleures, bassin n°12 : Massawipi	67
3.2.5.4	Cas où les prévisions post-traitées sont meilleures, bassin n°26 : Ouareau	69
3.3	Meilleurs couples (modèle hydrologique — méthode)	71
3.4	Fiabilité des prévisions brutes, pré et post-traitées	74
CHAPITRE 4	DISCUSSION	79
4.1	Disparité entre les performances des modèles hydrologiques	79
4.2	Efficacité des méthodes de prétraitement et post-traitement en fonction des caractéristiques des bassins versants.....	80
4.3	Taille des fenêtres glissantes.....	82
4.4	Effets du prétraitement sur les prévisions météorologiques	83
4.5	Amélioration des prévisions hydrologiques à la suite du prétraitement et du post-traitement	84
4.5.1	Variabilité dans la qualité des prévisions hydrologiques à la suite du prétraitement	85

4.5.2	Variabilité dans la qualité des prévisions hydrologiques à la suite du post-traitement	87
4.6	Périodes déficitaires en débits observées.....	90
4.7	Limitations et ouverture.....	91
CONCLUSION		95
RECOMMANDATIONS		97
ANNEXE I	INFORMATIONS SUPPLÉMENTAIRES SUR LES PÉRIODES DE CALIBRATION ET D'APPLICATION DU TRAITEMENT	99
ANNEXE II	BOÎTES À MOUSTACHES EN MATÉRIEL SUPPLÉMENTAIRE	101
ANNEXE III	DIAGRAMMES DE TALAGRAND EN MATÉRIEL SUPPLÉMENTAIRE	103
LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES.....		105

LISTE DES TABLEAUX

	Page
Tableau 2.1 Récapitulatif des caractéristiques des bassins versants à l'étude.....	19
Tableau 3.1 Scores NSE des modèles hydrologiques pour la méthode de calibration.....	51

LISTE DES FIGURES

		Page
Figure 2.1	Carte des bassins versants à l'étude.....	18
Figure 2.2	Représentation schématique du processus de sélection des données par fenêtre glissante	34
Figure 2.3	Représentation graphique du calcul du CRPS	36
Figure 2.4	Exemples de formes typiques des diagrammes de Talagrand	38
Figure 3.1	Cartes thermiques représentant les CRPSS médians des prévisions de précipitations prétraitées pour des tailles de fenêtre différentes et des horizons prédictifs regroupés.....	43
Figure 3.2	Cartes thermiques représentant les CRPSS médians des prévisions de température prétraitées pour des tailles de fenêtres différentes et des horizons prédictifs regroupés.....	45
Figure 3.3	CRPS moyens pour chaque horizon prédictif (« lead-time ») qui composent les prévisions de précipitations, chaque graphe représente une saison particulière de l'année 2020, pour le bassin n°31	47
Figure 3.4	CRPS moyens pour chaque horizon prédictif (« lead-time ») qui composent les prévisions de température, chaque graphe représente une saison particulière de l'année 2020, pour le bassin n°31	49
Figure 3.5	Cartes thermiques représentant les CRPSS médians des prévisions post-traitées à l'horizon prédictif (« lead-time ») 48 h, avec des tailles de fenêtre différentes	53
Figure 3.6	Cartes thermiques représentant les CRPSS des prévisions post-traitées par la méthode QM30 à différents horizons prédictifs (« lead-time »)	55
Figure 3.7	Hydrogrammes prévisionnels des prévisions brutes, prétraitées et post-traitées face aux observations pour le bassin n°1 aux horizons prédictifs 24 h et 192 h	57
Figure 3.8	Hydrogrammes prévisionnels des prévisions brutes, prétraitées et post-traitées face aux observations pour le bassin n°34 aux horizons prédictifs 24 h et 192 h	58

Figure 3.9	Hydrogrammes prévisionnels des prévisions brutes, prétraitées et post-traitées face aux observations pour le bassin n°12 aux horizons prédictifs 24 h et 192 h	59
Figure 3.10	Hydrogrammes prévisionnels des prévisions brutes, prétraitées et post-traitées face aux observations pour le bassin n°26 aux horizons prédictifs 24 h et 192 h	60
Figure 3.11	Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques pour le bassin n°1 sur l'année 2020 à différents horizons prédictifs de 24 h à 240 h	64
Figure 3.12	Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques pour le bassin n°24 sur l'année 2020 à différents horizons prédictifs de 24 h à 240 h	65
Figure 3.13	Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques pour le bassin n°12 sur l'année 2020 à différents horizons prédictifs de 24 h à 240 h	67
Figure 3.14	Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques pour le bassin n°26 sur l'année 2020 à différents horizons prédictifs de 24 h à 240 h	69
Figure 3.15	Histogramme empilé comptant le nombre de bassins où les couples {modèle hydrologique, méthode} sont les meilleurs	71
Figure 3.16	Carte indiquant pour chaque bassin quel couple {modèle hydrologique, méthode} est le meilleur	73
Figure 3.17	Diagrammes de Talagrand pour les prévisions brutes, prétraitées et post-traitées de l'année 2020 par les huit modèles hydrologiques au bassin n°26 à l'horizon prédictif (lead time) 48 h	75
Figure 3.18	Diagrammes de Talagrand pour les prévisions brutes, prétraitées et post-traitées de l'année 2020 par les huit modèles hydrologiques au bassin n°26 à l'horizon prédictif (lead time) 192 h	76

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

ABDU	Average Bin Distance to Uniformity
BV	Bassin Versant
CEHQ	Centre d'Expertise Hydrique du Québec
CEQUEAU	Modèle hydrologique développé par Girard, Morin, & Charbonneau, 1972 à <i>l'Institut National de la Recherche Scientifique — Eau, Terre et Environnement</i> (INRS — eau)
CMA-ES	Covariance Matrix Adaptation Evolution Strategy
CRPS	Continuous Ranked Probability Score
CRPSS	Continuous Ranked Probability Skill Score
DJF	Décembre Janvier Février
ECMWF	European Center for Medium-ranged Weather Forecast
EnKF	Ensemble Kalman Filter
EPS	Ensemble Prediction System
ERA5	ECMWF 5 th generation ReAnalysis
ETP	EvapoTranspiration Potentielle
GR5dt	Modèle hydrologique adapté de GR4J (Génie Rural à 4 paramètres Journalier), initialement développé par Olivera Nascimento (1995). Adapté au laboratoire HC3 de l'École de technologie supérieure de Montréal
HBV	Modèle hydrologique « Hydrologiska Byråns Vattenbalansavdelning » développé par Bergström & Forsman (1973) à la <i>Swedish Meteorological and Hydrological Institute</i> (SMHI)
HM	Modèle Hydrologique
HYMOD	Modèle hydrologique « HYdrological MODel » développé par Boyle (2001)
IHACRES	Modèle hydrologique « Identification of Unit Hydrographs and Component flows from Rainfall, Evaporation and Streamflow data » développé par Jakeman (1990)

JJA	Juin Juillet Août
KS	Kolmogorov-Smirnov
MAM	Mars Avril Mai
MOHYSE	Modèle hydrologique « MODèle HYdrologique Simplifié à l'Extrême » développé par Fortin & Turcotte (2007)
NSE	Nash-Sutcliffe Efficiency coefficient
QM	Quantile Mapping
SIMHYD	Modèle hydrologique « SIMple HYDrology », version simplifiée du modèle HYDROLOG initialement développé par Porter (1972)
SON	Septembre Octobre Novembre
TOPMODEL	Modèle hydrologique « TOPography-based hydrological MODEL » développé par Beven & Kirby (1979)
UTC	Universal Time Coordinated

INTRODUCTION

L'hydrologie, science centrée sur l'étude du cycle de l'eau, porte principalement dans l'analyse des mouvements de l'eau au sein d'un bassin versant. Sa portée dépasse largement la simple étude des cours d'eau, offrant des perspectives essentielles pour la prise de décisions stratégiques, indispensables à une gestion durable des territoires. En fournissant des informations vitales sur l'état des ressources en eau, elle permet d'optimiser leur utilisation dans des domaines tels que l'agriculture, la production hydroélectrique, la mitigation des risques liés aux crues, et bien d'autres.

Les modèles hydrologiques, instruments clés dans la représentation du cycle de l'eau, varient grandement en complexité. De simples conceptualisations primaires à des modélisations physiques sophistiquées, ces modèles sont essentiels pour prévoir les débits d'une rivière et l'état hydrique d'un territoire à partir des conditions météorologiques de celui-ci. Cependant, la modélisation hydrologique n'est pas exempte de défis. La complexité inhérente aux phénomènes hydrologiques, qui se manifestent à diverses échelles, imposent nécessairement des simplifications et troncatures dans leurs représentations au sein d'un modèle hydrologique. Ces simplifications entraînent nécessaires des biais et erreurs au sein des simulations proposées par un modèle.

De plus, notamment pour pouvoir effectuer des prévisions, un modèle hydrologique travaille de pair avec des prévisions météorologiques. Celles-ci ne sont pas exemptes de biais et erreurs, car elles proviennent également de modèles, qui sont par définition des approximations de la réalité. Pour faire face à cette variabilité et aux incertitudes futures, des prévisions probabilistes ont été développées. Ces prévisions sont basées sur une série de scénarios probables, elles visent à gérer l'incertitude inhérente aux prévisions météorologiques et hydrologiques, tout en reconnaissant les limites de ces méthodes.

Dans le contexte de ces défis qui s'imposent à l'hydrologue, il est nécessaire de corriger au maximum les biais et approximations présentes dans ces prévisions. Un biais, défini comme

une erreur systématique, peut être quantifié en analysant les erreurs observées dans des simulations historiques. Ainsi, il est possible d'utiliser des méthodes de post-traitement pour corriger les simulations futures. Cette méthode vise à affiner les prévisions en modifiant les sorties des modèles selon les tendances des erreurs passées dans le but de réduire les incertitudes et renforcer la fiabilité des prévisions étayant les prises de décisions.

Structurée en six chapitres, cette étude couvre une revue de la littérature, une description du site étudié, la collecte et l'analyse des données, la revue de la méthodologie utilisée, ainsi qu'une analyse et une discussion des résultats. Les conclusions et recommandations qui en découlent visent à offrir une interprétation des résultats et des pistes d'approfondissement sur le sujet d'une méthode de post-traitement appliquée aux prévisions météorologiques et hydrologiques probabilistes.

CHAPITRE 1

REVUE DE LITTÉRATURE

1.1 Introduction

L'objectif de ce chapitre est de situer la présente étude dans le contexte de la littérature sur la prévision hydrologique. Il aborde le processus de prévision hydrologique, englobant les sources de prévisions météorologiques, la calibration des modèles hydrologiques et l'assimilation des données. Ensuite, le post-traitement statistique des données sera examiné au travers des travaux précédents. Enfin, les objectifs du projet seront définis, établissant le cadre des analyses à venir.

1.2 Modélisation météorologique

Un modèle météorologique est une série d'équations visant à décrire l'atmosphère et son évolution. Il s'agit d'une représentation simplifiée de la réalité ne considérant souvent que les phénomènes prépondérants agissant sur le système étudié (Sorooshian, 2008). En pratique, dans un modèle météorologique, l'atmosphère est décrite par un maillage à trois dimensions : latitude, longitude et altitude. Chaque point de ce maillage décrit l'état de l'atmosphère à un instant donné, c'est-à-dire les valeurs de température, d'humidité, de vitesse du vent, etc. À partir de ces données, le modèle météorologique est capable, en appliquant les équations de conservation de la masse, de l'énergie et de la quantité de mouvement, ainsi qu'à l'aide des algorithmes et paramétrisations avec lesquels il a été construit, d'estimer les interactions entre ces points et ainsi leurs états futurs au pas de temps qui a été défini par le modèle.

Ainsi, un modèle météorologique permet de faire des prévisions quant à l'état futur de l'atmosphère et des phénomènes qui adviendront, comme les précipitations ou la température de l'air à une altitude donnée, par exemple. La mise en action d'un modèle météorologique, implique de simuler l'état de l'atmosphère dans le monde entier, ce qui requiert ainsi des puissances de calcul prodigieuses. D'après (Shukla et al., 2010), le facteur de la puissance de

calcul disponible est souvent le facteur limitant vis-à-vis de la résolution spatiale, c'est-à-dire la finesse du maillage, mais également en ce qui concerne la durée jusqu'à laquelle la prédiction peut être émise. Cuo et al. (2011) expliquent qu'en pratique, seuls deux des quatre objectifs recherchés chez une prévision météorologique sont atteints par ces modèles, à savoir : une haute résolution spatiale, un long horizon prédictif, un long historique d'activité et un grand nombre de membres d'ensemble dans le cas d'une prévision probabiliste.

1.3 Modélisation hydrologique

Un modèle hydrologique (HM) est lui aussi constitué d'une série d'équations, dans le but de décrire les phénomènes liés au cycle de l'eau à partir de données météorologiques. Les intrants les plus courants pour un HM sont les quantités de précipitation ainsi que la température de l'air dans le bassin versant (BV). Les simulations réalisées par ces modèles permettent ainsi d'avoir un aperçu sur l'état hydrologique du BV étudié, comme la situation des nappes phréatiques, le plus important étant souvent le débit d'eau à l'exutoire du BV (on parle de relation pluie-débit). Les informations fournies par les simulations hydrologiques permettent alors d'étayer des prises de décisions concernant par exemple les secteurs de l'agriculture ou la production d'énergie hydroélectrique.

D'après Sorooshian (2008), un HM est souvent caractérisé par deux aspects majeurs. La première est la façon dont il représente les processus hydrologiques : un modèle peut être physique, c'est-à-dire qu'il utilise les équations établies par les lois de la physique, ou il peut être empirique, aussi appelé « boîte noire ». Ce dernier cas signifie qu'il est capable de simuler un débit à l'exutoire du bassin étudié, mais les équations et variables internes qu'il utilise n'ont pas nécessairement de sens physique. Enfin, un HM peut être conceptuel. Un tel modèle s'approche d'un modèle empirique dans le sens où ses variables internes n'ont pas de réalité physique. Un modèle conceptuel propose néanmoins une séparation des différents phénomènes du cycle de l'eau en son sein, notamment grâce à sa structure en réservoirs censée représenter l'apport et l'état de différentes zones du sol ayant une influence sur le débit d'un cours d'eau, ainsi que les équations dites « semi-empiriques » qui composent le modèle. Ces équations ont

une base physique, mais nécessitent d'être adaptées au bassin étudié par le biais de la calibration de paramètres qui sont propres au bassin et aux événements déjà observés chez celui-ci. On parle ainsi de « boîte grise » (Devia, Ganasri, & Dwarakish, 2015).

La seconde caractéristique majeure d'un HM est la façon dont il représente l'espace étudié : un modèle peut être global, c'est-à-dire qu'il considère le BV étudié comme une seule et même entité homogène. À l'inverse, un modèle peut être distribué, c'est-à-dire qu'il dispose de la capacité de découper le BV étudié en plusieurs entités avec des caractéristiques différentes agissant sur les processus hydrologiques, comme le type de sol ou l'altitude.

1.4 Prévisions hydrologiques déterministes et probabilistes

Les prévisions déterministes ont été le premier type de prévision hydrologique à être développé. Elles étaient composées d'une unique prévision, un seul scénario possible. Cela constitue le point faible majeur des prévisions déterministes, car elles ne montrent pas la variabilité des processus hydrologiques. De plus, les prévisions déterministes donnent aux utilisateurs une fausse impression de certitude en les laissant croire que les prévisions sont exactes. Pour cette raison, les prévisions hydrologiques probabilistes ont été développées afin de fournir une gamme de résultats possibles en fonction de différents scénarios, appelés les membres d'un ensemble de prévisions. Cela reflète ainsi les incertitudes intrinsèques aux processus hydrologiques et offre une vision plus réaliste de la situation à venir.

Une méthode pour produire des prévisions probabilistes consiste à fournir à un HM plusieurs membres d'un ensemble de prévisions météorologiques. Le HM simule alors chacun des membres de la prévision météorologique fournie et produit enfin une prévision hydrologique d'ensemble, comportant autant de membres que la prévision météorologique initiale. Leutbecher (2005) met en avant la méthode des « vecteurs singuliers » pour générer en amont les différents membres d'une prévision météorologique d'ensemble. Cette méthode consiste à appliquer des perturbations dans les conditions initiales d'une première prévision météorologique dite de « contrôle », soit une prévision avec des conditions initiales

correspondant aux observations. La méthode des vecteurs singuliers permet de choisir des perturbations « optimales » à appliquer aux conditions initiales, de telle manière à ce que la dispersion des scénarios générés à partir de ces perturbations couvre la plage d'erreurs préalablement identifiée pour une prévision déterministe.

Une autre méthode pour produire une prévision d'ensemble consiste à utiliser l'assimilation de données. Cette méthode permet d'ajuster les paramètres et les variables internes d'un HM. Si un ensemble d'états différents peut être défini pour un HM en amont d'une prévision, il est alors possible de réaliser la prévision hydrologique en utilisant les mêmes entrées météorologiques, mais en changeant l'état du modèle à chaque nouvelle simulation. On obtient ainsi une prévision d'ensemble, avec un membre par état assimilé au modèle. Plus de détails sur l'assimilation de données sont fournis à la section 1.6.1.

1.5 Incertitudes et biais liés aux prévisions hydrométéorologiques

Par définition, la réalisation d'une prévision comporte des incertitudes, en particulier lorsque cette prévision concerne un système chaotique, comme l'atmosphère dans le cas d'une prévision hydrométéorologique. Troin et al. (2021) expliquent que deux types majeurs d'incertitudes sont présents dans toutes les étapes d'une prévision hydrométéorologique. D'une part, il y a les incertitudes épistémiques, qui sont liées à un « manque de savoir, d'informations », c'est-à-dire les imperfections des modèles dues à une connaissance ou une représentation incomplète de la réalité. D'autre part, il y a les incertitudes dites aléatoires, qui sont liées à la nature chaotique des événements météorologiques, mais aussi aux éventuelles erreurs de mesure (Roundy et al. 2019).

D'après Troin et al. (2021) et Roundy et al. (2019), sur toute la chaîne de prévision hydrologique, les sources d'incertitudes épistémiques proviennent de trois sources majeures. Tout d'abord, elles peuvent provenir des conditions initiales (météorologiques et hydrologiques) d'une simulation, qui prennent source dans les erreurs de mesure lors de relevés ou même dans une absence de relevé des états du BV. Dans ce cas, les conditions peuvent être

déduites à partir de réanalyses (simulations à l'aide d'observations passées) ou de prévisions météorologiques. Ensuite, elles peuvent provenir des biais inhérents et systématiques des modèles météorologiques, qui sont dus à leur structure même, c'est-à-dire les équations et méthodes choisies pour construire le modèle, ainsi que les jeux de paramètres qui sont non calibrés ou qui peuvent rapidement devenir « obsolètes ». Enfin, les modèles hydrologiques comportent également des biais liés à leur structure, c'est-à-dire la vision tronquée qu'ils représentent de la réalité, notamment à cause du fait que seuls les phénomènes hydrologiques considérés comme prépondérants y sont représentés ou bien que les phénomènes modélisés le soient d'une manière trop simpliste. Les biais peuvent également provenir du manque éventuel de données disponibles pour la calibration des paramètres, ou encore l'équivalence entre les jeux de paramètres (également appelée « équifinalité »), pour un modèle conceptuel (K. Beven & Binley, 1992).

1.6 Méthodes de réduction des biais liés aux prévisions hydrologiques

À la vue des nombreuses sources d'incertitudes et biais qui interviennent et s'accumulent tout au long de la chaîne de prévision hydrologique, de nombreuses méthodes ont été développées afin de les réduire et ainsi améliorer la qualité des prévisions émises par les simulations. En effet, il est capital d'avoir une estimation suffisamment fidèle des événements à venir afin de pouvoir prendre les bonnes décisions, en particulier lorsqu'elles concernent la mitigation des risques liés à des catastrophes naturelles telles que les inondations.

1.6.1 Assimilation de données

Les prévisions à court et moyen terme (de quelques heures à une dizaine de jours) par modèles numériques sont souvent considérées comme un « problème de conditions initiales ». En effet, plus la portée des prévisions est courte, plus il est important de décrire au mieux l'état présent du système que l'on étudie. C'est pourquoi une étape clé de la chaîne de prévisions hydrométéorologiques est l'assimilation de données.

L'assimilation de données intervient avant le début d'une simulation numérique. L'objectif est de renseigner les conditions initiales d'une simulation, en mettant à jour les variables internes d'un modèle. Ainsi, l'assimilation va permettre de correspondre au mieux aux observations faites dans le réel, en tenant compte des erreurs commises par les observations et les variables internes du modèle. L'assimilation de données peut également agir sur les intrants d'un modèle, ses paramètres et même ses extrants (Pu & Kalnay 2018). Les avantages de l'assimilation de données sur les extrants des modèles météorologiques et donc la qualité des prévisions ont été observés et démontrés de nombreuses fois par le passé, ce qui en fait une étape presque indissociable de la chaîne de prévision, en particulier lors de l'étape des prévisions météorologiques (Bauer, Thorpe, & Brunet, 2015 et Pu & Kalnay, (2018). En effet, l'implémentation des techniques modernes comme l'assimilation variationnelle à quatre dimensions (Simmons & Hollingsworth, 2002) a marqué un tournant dans le domaine des prévisions météorologiques par modèles numériques (Bauer et al., 2015).

Bien que, d'après Verkade et al. (2013), la qualité des prévisions hydrologiques est étroitement liée aux conditions initiales. Toutefois, Troin et al. (2021) expliquent qu'il y a peu d'applications opérationnelles de l'assimilation de données au niveau des modèles hydrologiques. Cela s'explique en raison du manque de données, mais également à cause de la complexité des phénomènes hydrologiques. Par exemple, il est possible de noter les problèmes de mémoire, c'est-à-dire les problèmes liés à la taille et la nature des bassins (concernant leur capacité de stockage, leur temps de concentration et la lenteur des phénomènes hydrologiques), qui peuvent ne pas être pris en compte par un modèle à cause de sa structure.

En effet, comme l'expliquent de Lavenne et al. (2022), la réponse ou le comportement d'un BV à des précipitations sont majoritairement conditionnés par son « humidité », c'est-à-dire la quantité d'eau stockée dans le bassin, elle-même conditionnée par les événements précédents pouvant remonter à plusieurs années, d'où la capacité de « mémorisation » d'un BV. Ainsi, le peu de systèmes opérationnels implémentant l'assimilation de données pour leurs modèles hydrologiques assimilent généralement uniquement les débits et niveaux de neige. Cependant, l'assimilation de données basée sur les ensembles est très prometteuse pour améliorer la qualité

des prévisions hydrologiques, en agissant sur une variété d'aspects d'un modèle tels que leurs variables d'état, leurs paramètres ou encore leur structure même (Troin et al., 2021). Ceci est possible entre autres grâce à des techniques comme le filtre de Kalman Ensembliste (EnKF), mais également grâce aux avancées des techniques de mesures, notamment par satellite (Jiang & Wang, 2019).

1.6.2 Post-traitement statistique

Selon Wood & Schaake (2008), malgré les efforts réalisés en amont de la génération d'une prévision, notamment par le biais de l'assimilation de données, il est reconnu que les données de prévisions simulées brutes ne peuvent pas être directement utilisées pour des applications concrètes telles que la prise de décisions pour la gestion d'un territoire. C'est alors que le post-traitement intervient et s'inscrit comme une étape très importante pour l'émission d'une prévision hydrologique. Il est utilisé dans de nombreux systèmes de prévisions hydrologiques pour corriger les prévisions provenant à la fois des simulations météorologiques, c'est-à-dire pour les données de précipitations et de température, mais également celles provenant des simulations hydrologiques.

Comme l'expliquent Crochemore et al. (2016), le principal défi pour le post-traitement est d'améliorer la fiabilité des prévisions tout en maintenant son degré de certitude, c'est-à-dire augmenter la capacité d'une prévision à être cohérente, en moyenne, avec la réalité dans différentes situations tout en maintenant le degré de certitude avec lequel une prévision annonce un évènement. Crochemore et al. (2016) expliquent qu'en pratique, une caractéristique recherchée dans une prévision est améliorée au détriment de l'autre, ce résultat est aussi montré dans l'étude de Wood & Schaake (2008).

De nombreuses méthodes de post-traitement ont été développées au fil du temps, dont l'une d'entre elles est le post-traitement statistique, une technique qui vise à ajuster les prévisions du modèle à l'aide de données observées ou historiques. Cette méthode se décline en plusieurs techniques, dont la correction de quantiles, qui est l'une des plus courantes. Cette méthode

produit de bons résultats tout en étant relativement simple à implémenter, en particulier pour les méthodes de quantile mapping non paramétriques, flexibles par nature, telle que la méthode des quantiles empiriques (Enayati et al. 2021). Elle consiste à ajuster les prévisions, pour que leur distribution corresponde aux quantiles observés dans les données historiques.

Cette méthode peut être appliquée aux prévisions météorologiques ainsi qu'aux prévisions hydrologiques. Par exemple, si les prévisions du modèle sont systématiquement inférieures aux observations historiques, on parle ici de biais négatif. La correction de quantile augmentera la valeur des quantités prévues pour les amener à correspondre aux quantiles observés. Pour ce faire, il est nécessaire de rassembler des prévisions qui ont été faites par le passé, ainsi que les événements qui ont réellement été observés, d'où le fait qu'un long historique de prévision est une caractéristique recherchée chez un modèle météorologique (Cuo et al., 2011). Comme expliqué par Li et al. (2017) et Scheuerer & Hamill (2015), cette caractéristique met en lumière une faiblesse des méthodes statistiques non paramétriques : elles dépendent exclusivement des données disponibles. Ainsi, certains événements extrêmes comme de grands volumes de précipitations peuvent ne pas être traités comme il se doit par des méthodes statistiques à cause du manque d'événements comparables dans les observations. Li et al. (2017) ajoutent que la plupart des méthodes de post-traitement traditionnelles agissent principalement sur les moyennes des prévisions plutôt que sur les valeurs extrêmes (en effet, il convient d'abord de corriger ces biais), ce qui ajoute à la faiblesse de ces méthodes pour prédire les événements extrêmes.

Crochemore et al. (2016) montrent cependant que les méthodes de post-traitement statistiques peuvent grandement bénéficier d'une sélection préalable des données avec lesquelles elles sont calibrées. Plus précisément lorsqu'il s'agit de post-traiter des prévisions émises pour une période de l'année donnée, calibrer la méthode de post-traitement sur les données historiques et prévisions précédentes se trouvant dans cette même période, permet à celle-ci d'améliorer grandement ses performances. De fait, les données sélectionnées sont bien plus cohérentes avec le contexte de la prévision que les données de l'année complète. L'étude indique également que d'autres techniques de sélection des données historiques pourraient être

utilisées, comme celles se basant sur des indices climatiques, c'est-à-dire des relevés et observations « simples » qui caractérisent un aspect particulier de l'état du climat à un moment donné, comme la pression atmosphérique au niveau de la mer à un endroit précis ou encore « El Niño — 3.4 ». De nombreuses études, telles que celle présentée par Werner et al. (2004), montrent qu'il existe des relations de corrélation entre les fluctuations des précipitations ou températures et ces indices pour certaines régions du monde. Crochemore et al. (2016) suggèrent ainsi qu'une sélection des données historiques basée sur ces indices climatiques pour l'entraînement de méthodes de post-traitement statistique pourraient améliorer leur action sur les prévisions.

Du point de vue d'une simulation hydrologique, on parle de « prétraitement » lors du post-traitement statistique des intrants des simulations hydrologiques, c'est-à-dire pour le post-traitement des données météorologiques et de « post-traitement » pour le post-traitement statistique des extrants des simulations hydrologiques, c'est-à-dire les simulations de débits.

1.6.2.1 Prétraitement des prévisions météorologiques

Le quantile mapping est à la fois utilisé pour la correction de biais des modèles climatologiques (sur le temps long) et pour la correction des modèles météorologiques (événements ponctuels sur le temps court). Dans la littérature, les observations et conclusions sur l'utilisation du quantile mapping sont similaires pour ces deux types de modèle. En ce qui concerne le prétraitement des prévisions météorologiques, Zhao et al. (2017) et Li et al. (2017) ont conclu que bien que le quantile mapping soit une méthode très efficace pour corriger les biais liés aux prévisions de précipitations, elle dépend fortement de la corrélation entre les prévisions brutes et les observations. Une corrélation positive indique que les prévisions suivront l'évolution des observations, tandis qu'une corrélation négative indique que les prévisions suivront l'évolution inverse des observations. Une corrélation nulle indique que les évolutions entre les prévisions et les observations ne sont pas associées. Si les prévisions brutes de précipitations n'ont pas de forte corrélation positive avec les observations, le prétraitement par quantile mapping risque de produire des prévisions encore moins précises que les prévisions brutes. Bien qu'une forte

corrélation soit assurée entre les prévisions brutes et les observations, il n'est pas garanti que le prétraitement améliorera les capacités de prévision de précipitations (Zhao et al., 2017).

Enayati et al. (2021) montrent que, parmi dix différentes méthodes de quantile mapping, le quantile mapping empirique, ainsi que sa variante dite « robuste », est le plus performant dans la correction de biais des précipitations, en comparaison à d'autres méthodes de quantile mapping comme les méthodes avec fonctions de transformations paramétriques. Dans cette même étude, les auteurs observent que toutes les méthodes de quantile mapping sont suffisamment acceptables pour le prétraitement des prévisions de température. Ils précisent que cela est principalement dû au fait que les performances des modèles météorologiques et climatiques sont bien meilleures en ce qui concerne la simulation de la température par rapport aux précipitations. Cette caractéristique des modèles météorologiques est également relevée dans l'étude de Verkade et al. (2013).

Cependant, il existe d'autres méthodes que le quantile mapping pour la correction de biais des prévisions météorologiques, comme les méthodes de prétraitement conditionnelles, basées sur la théorie de Bayes. Comme l'explique Krzysztofowicz (2004), celles-ci ont pour but d'estimer la distribution de probabilité des événements futurs, à partir des prévisions émises par les modèles numériques. Plutôt que de corriger directement les prévisions émises par le modèle en se basant sur la climatologie, la méthode va davantage tenir compte des observations qui précèdent la prévision. Une autre méthode est le prétraitement basé sur des régressions logistiques (Wilks, 2009), celle-ci étant capable de déterminer la probabilité d'événements binaires, comme par exemple déterminer si une quantité de précipitations dépassera un certain seuil ou non. L'avantage majeur de ces méthodes sur le quantile mapping provient de leur nature paramétrique, en particulier leur version « étendue », c'est-à-dire que l'utilisation de ces méthodes revient à faire l'hypothèse que la variable à prédire suit une loi de probabilité particulière. L'objectif de ces méthodes est de déterminer les paramètres de cette loi. Connaître les paramètres de cette loi de probabilité théorique permet alors d'obtenir la fonction de distribution de probabilité, continue, suivie par la variable.

Ainsi, comme l'expliquent Scheuerer & Hamill (2015), il est possible d'extrapoler les relations entre les observations et prévisions déterminées dans les contextes d'évènement modéré, aux évènements extrêmes. Ainsi, le post-traitement basé sur les régressions logistiques permet d'obtenir de bien meilleurs résultats dans le cadre de prévisions traitant d'évènements extrêmes, et ce, en nécessitant une quantité potentiellement moins importante de données que les méthodes non paramétriques.

Cependant, les auteurs mettent en garde sur cette caractéristique des méthodes paramétriques. En effet, pour profiter des avantages de ces méthodes, il est nécessaire de choisir la loi de probabilité adéquate à la variable modélisée. Scheuerer & Hamill (2015) et Li et al. (2017) montrent d'ailleurs que les lois retenues dans les techniques développées implémentées par Wilks (2009) (régression logistique étendue) qui choisit des distributions logistiques censurées et Slougher et al. (2007) (approche bayésienne) qui choisissent la distribution gamma dans le cas de précipitations non nulles, sont quelque peu adaptées pour modéliser la loi de probabilité suivie par les quantités précipitations, bien que différentes. Effectivement, comme l'expliquent Slougher et al. (2007), la précipitation occupe une place particulière parmi les variables aléatoires, sa distribution présente probabilité élevée pour des valeurs de précipitation égales à zéro, affiche une asymétrie marquée. : elle ne suit pas de loi de probabilité « évidente » comme la température dont la loi normale représente sa distribution de manière adéquate.

1.6.2.2 Effets du prétraitement des prévisions météorologiques sur les prévisions hydrologiques

Dans leur étude, Crochemore et al. (2016) observent que la correction des biais des prévisions de précipitations conduit toujours à une amélioration des prévisions hydrologiques. Les auteurs suggèrent même que de faibles améliorations dans les prévisions de précipitations se traduisent par des améliorations encore plus grandes dans les prévisions hydrologiques, ou au moins équivalentes en ce qui concerne la correction de biais comme les sur ou sous-estimations des variables météorologiques. En termes d'amélioration des caractéristiques des prévisions, Li et al. (2018) indiquent que le prétraitement des prévisions de précipitation présente un impact non négligeable sur l'amélioration de la fiabilité et le degré de certitude des prévisions

hydrologiques. Ils notent que le prétraitement des prévisions hydrologiques conduit à une amélioration de la précision des prévisions, c'est-à-dire la proximité entre le débit prédit et celui réellement observé ainsi que leur qualité globale de manière générale.

Cependant, comme l'indiquent Verkade et al. (2013), les améliorations du prétraitement des prévisions de précipitations n'ont ni un effet immédiat, ni proportionnel sur les prévisions hydrologiques. Zalachori et al. (2012) remarquent qu'il est possible que les corrections réalisées sur les prévisions de précipitations puissent ne pas se propager dans les prévisions hydrologiques. Ils conseillent fortement d'appliquer un post-traitement aux simulations hydrologiques. En effet, d'après Verkade et al. (2013), le temps à partir duquel les précipitations prétraitées agiront sur les prévisions hydrologiques, dépend notamment de la taille du bassin, en particulier de son temps de concentration. Celui-ci se définit comme le temps que passe une goutte d'eau tombée au point le plus éloigné de l'exutoire du bassin à l'atteindre, ou encore la capacité du bassin à stocker les précipitations dans son couvert neigeux.

De ce fait, les bassins versants de petite taille, avec des capacités de stockage plus faibles, bénéficieront d'un effet plus rapide (à des horizons de temps courts), du prétraitement des données météorologiques sur leurs prévisions hydrologiques tandis que les bassins de grande taille en bénéficieront à des horizons de temps plus longs. Dans leur étude, Verkade et al. (2013) expliquent que la faible propagation des améliorations des prévisions météorologiques sur les prévisions hydrologiques est due à une perte de la covariance spatio-temporelle des prévisions météorologiques à la suite de leur prétraitement. Effectivement, selon Clark et al. (2004), les modèles hydrologiques sont très sensibles à la covariance spatiale, la persistance temporelle ou encore la relation entre les variables de précipitation et de températures. Les variables météorologiques étant souvent corrigées de manière indépendante, la cohérence entre elles est brisée. Les modèles hydrologiques étant calibrés à l'aide d'observations intègrent en leur sein cette cohérence, ainsi elle se doit d'être préservée à la suite du prétraitement.

Des méthodes ont été développées pour préserver la covariance spatio-temporelle des prévisions météorologiques d'ensemble telles que le « Schaake Shuffle ». Clark et al. (2004). Crochemore et al. (2016) et Verkade et al. (2013) indiquent aussi que le prétraitement de prévisions de température est très pertinent en particulier en période d'étiage, c'est-à-dire en période de sécheresse et souvent estivales, où l'évapotranspiration joue un rôle crucial dans le cycle de l'eau.

1.6.2.3 Post-traitement des prévisions hydrologiques

Après avoir étudié la propagation des améliorations induites par le post-traitement statistique des données météorologiques sur les simulations hydrologiques, Zalachori et al. (2012) concluent dans leur cas que : si la correction des incertitudes des prévisions météorologiques est très importante, l'étape de la modélisation hydrologique reste une des principales sources d'incertitudes dans la chaîne de prévisions hydrologiques. Les améliorations faites sur les intrants des modèles hydrologiques sont susceptibles de ne pas se propager dans le produit final qu'est la prévision hydrologique. Crochemore et al. (2016) et Li et al. (2017) concluent que même après avoir prétraité les prévisions météorologiques, les données issues des simulations hydrologiques ont toujours besoin d'être post-traitées, le seul traitement des données météorologiques ne suffisant pas à obtenir des prévisions hydrologiques de confiance. Selon Kang et al. (2010), si un seul post-traitement doit être retenu, c'est le post-traitement des prévisions hydrologiques qu'il faut privilégier pour l'utilisation des prévisions à des fins opérationnelles. Ceci est vrai en particulier pour les saisons sèches, car dans celles-ci, les incertitudes hydrologiques sont beaucoup plus importantes que les incertitudes météorologiques. Li et al. (2017) et Zalachori et al. (2012) annoncent cependant que les meilleurs résultats de prévisions sont obtenus en traitant à la fois les intrants et les extrants des prévisions hydrologiques.

En ce qui concerne le quantile mapping, Kang et al. (2010) annoncent que cette technique a de bonnes performances pour le pré et post-traitement des données utilisées dans les prévisions hydrologiques. Cependant, ses performances sont moindres en ce qui concerne les valeurs

extrêmes. W. Li et al. (2017) indiquent cependant que le post-traitement par quantile mapping n'est pas satisfaisant dans les cas où les prévisions brutes souffrent de problèmes de fiabilité, ou encore si elles sont moins performantes que la climatologie. Selon Madadgar, Moradkhani, & Garen (2014), le quantile mapping fait des « correspondances aveugles ». En effet, le quantile mapping ne fait correspondre que les distributions cumulatives des prévisions et des observations, construites indépendamment et donc sans tenir compte des couples « observation-simulation » pour une prévision donnée. Cette caractéristique peut alors conduire à des erreurs commises par la méthode qui peut parfois produire des prévisions moins bonnes que les prévisions brutes. Il est possible que le post-traitement par quantile mapping corrige les débits « dans la mauvaise direction », par exemple en diminuant la valeur d'une prévision ayant sous-estimé les événements réels, ou encore en augmentant tellement une prévision ayant sous-estimé la réalité que la prévision corrigée en vient à surestimer les événements réels avec une erreur encore plus grande que l'initiale. Les auteurs indiquent que ce cas de figure est plus susceptible de survenir lorsque les distributions cumulatives des prévisions brutes et des observations sont proches et se croisent, comme dans le cas de simulations produites par des modèles hydrologiques bien calibrés.

1.7 Objectifs de la présente étude

L'objectif principal de cette étude est d'améliorer la qualité des prévisions hydrologiques d'ensemble à l'aide d'une méthode de post-traitement statistique. Cet objectif se décompose en plusieurs étapes : (1) la quantification des effets du post-traitement sur les prévisions météorologiques, (2) la mesure des conséquences du post-traitement des prévisions météorologiques sur les simulations hydrologiques, et (3) la quantification des effets du post-traitement sur les prévisions de débit issues de simulations hydrologiques alimentées par des prévisions météorologiques brutes. Cette étude est réalisée dans le contexte de 42 bassins versants présents dans la province de Québec, dont les données météorologiques sont issues de l'organisme *European Center of Medium – Range Weather Forecasts* (ECMWF) et alimentent 8 modèles hydrologiques conceptuels globaux.

CHAPITRE 2

MÉTHODOLOGIE

Dans ce chapitre seront détaillés le secteur à l'étude ainsi que les méthodes mises en œuvre afin d'atteindre les objectifs définis précédemment. Les différents éléments de la chaîne de prévisions hydrologiques compris dans cette étude seront présentés, c'est-à-dire les différents modèles hydrologiques utilisés et leur calibration, mais également les méthodes d'assimilation de données et de post-traitement statistique utilisées. Enfin, il s'agira de présenter les différents tests statistiques destinés à estimer les performances des prévisions.

2.1 Secteur à l'étude

Les bassins versants de la présente étude sont situés au sud de la province de Québec, Canada et dans la partie nord de l'État du Vermont, États-Unis. 42 bassins versants dans cette région sont étudiés, leur superficie s'étend sur plusieurs ordres de grandeur, allant de 24 km² pour le plus petit d'entre eux à 7930 km² pour le plus grand, la superficie moyenne des 42 bassins est de 1500 km². Ces bassins versants sont principalement des bassins forestiers et agricoles, peu ou non urbanisés. La Figure 2.1 montre la carte des bassins versants à l'étude, le Tableau 2.1 détaille les caractéristiques de ces bassins. Les bassins plus foncés désignent des bassins imbriqués. C'est-à-dire des bassins liés aux affluents de rivières qui sont également compris dans la présente étude.

Les données météorologiques proviennent des réanalyses ERA5 (Fifth generation of European ReAnalysis), proposées par ECMWF (*European Center of Medium – Range Weather Forecasts*). Ces données ont été agrégées au pas de temps 6 h, de 1981 à 2020. Les données hydrométriques proviennent des stations du CEHQ (*Centre d'Expertise Hydrique du Québec*) elles aussi agrégées au pas de temps de 6 h. Ces données ont été utilisées comme observations pour la calibration des modèles hydrologiques et de la méthode de pré et post-traitement étudiée.

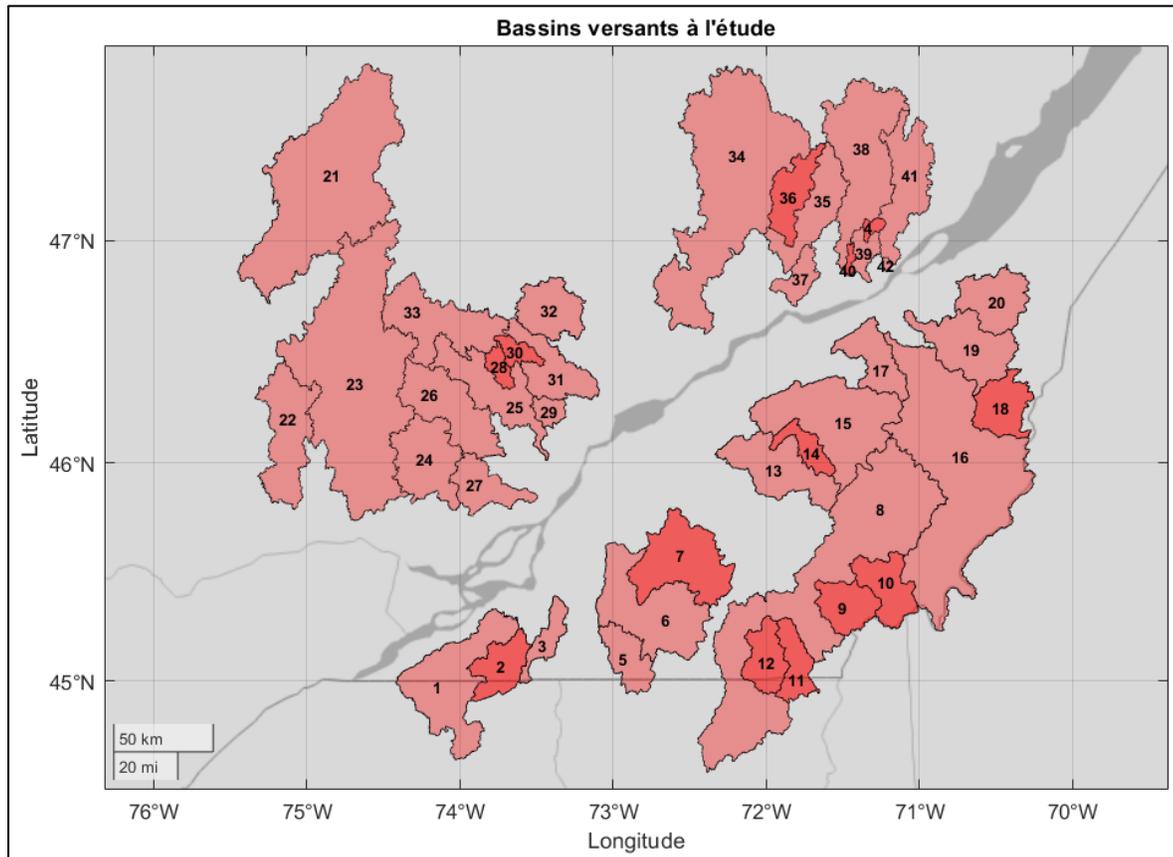


Figure 2.1 Carte des bassins versants à l'étude

Les prévisions météorologiques proviennent de l'EPS (Ensemble Prediction System) de ECMWF, modèle global avec une résolution spatiale de 18 km environ. Seules les températures et précipitations au pas de temps de 6 h sont utilisées dans cette étude. Les prévisions sont composées de 50 membres et l'horizon prédictif maximal est de 10 jours (40 pas de temps), une prévision est réalisée chaque jour entre les années 2015 et 2020. Il est important de noter que les prévisions météorologiques sont émises au fuseau horaire UTC-0, tandis que les observations sont disponibles au fuseau horaire UTC-5. Ainsi, un décalage d'une heure est présent entre les prévisions météorologiques et les observations à chaque pas de temps. Le Tableau 2.1 présente les caractéristiques principales des bassins versants à l'étude.

Tableau 2.1 Récapitulatif des caractéristiques des bassins versants à l'étude

Num.	ID station	Nom	Lon. (°)	Lat. (°)	S (km ²)	P _{moy} (mm)	T _{moy} (mm)	Q _{moy} (m ³ /s)	Dispo.
1	30905	Châteauguay	-73,76	45,33	2492	1114	7,30	27,1	76%
2	30907	Des Anglais	-73,82	45,16	642	1156	7,28	6,2	78%
3	30421	Acadie	-73,37	45,39	367	1113	7,73	4,3	70%
4	50916	Des Hurons	-71,36	47,00	76	1549	3,74	3,6	67%
5	30424	Aux Brochets	-73,05	45,16	584	1159	7,24	8,5	73%
6	30345	Yamaska	-72,94	45,63	3334	1157	6,87	66,4	73%
7	30304	Noire	-72,91	45,50	1505	1167	6,69	27,2	76%
8	30208	St-François	-71,89	45,41	7930	1223	5,66	161,3	73%
9	30234	Eaton	-71,65	45,47	646	1270	5,31	12,8	66%
10	30282	Au Saumon	-71,39	45,58	769	1300	5,04	17,7	68%
11	30215	Coaticook	-71,90	45,28	514	1221	5,45	9,7	71%
12	30220	Massawipi	-71,96	45,28	610	1152	6,11	10,9	100%
13	30103	Nicolet	-72,31	46,06	1550	1295	6,16	35,6	69%
14	30106	Bullstrode	-71,98	46,07	344	1354	5,58	8,6	99%
15	24014	Bécancour	-72,10	46,20	2163	1336	5,52	55,0	67%
16	23402	Chaudière	-71,21	46,59	5820	1199	4,83	121,9	66%
17	23401	Beaurivage	-71,29	46,66	708	1324	5,73	16,2	64%
18	23422	Famine	-70,64	46,17	696	1167	4,64	16,8	65%
19	23303	Etchemin	-71,07	46,69	1152	1354	4,22	28,2	62%
20	23106	Du Sud	-70,76	46,82	821	1242	4,46	19,5	64%
21	40624	Du Lièvre	-75,31	46,79	4560	1202	3,18	105,7	65%
22	40406	Petite Nation	-75,09	45,79	1331	1081	4,88	21,6	84%
23	40204	Rouge	-74,69	45,74	5479	1169	4,09	118,1	66%
24	40110	Du Nord	-74,01	45,80	1163	1278	4,56	23,5	68%
25	52219	L'Assomption	-73,43	46,01	1286	1118	4,20	24,0	64%
26	52212	Ouareau	-73,70	46,03	1263	1215	3,87	27,5	65%
27	52233	De l'Achigan	-73,49	45,85	632	1176	5,21	13,4	68%
28	52228	Noire	-73,65	46,34	188	1091	3,78	3,5	61%
29	52401	Bayonne	-73,39	46,16	194	1119	5,30	3,6	62%
30	52606	Mastigouche	-73,46	46,44	205	1116	3,87	4,0	71%
31	52601	Maskinongé	-73,10	46,30	1017	1141	3,96	19,6	69%
32	52805	Du Loup	-73,19	46,60	769	1093	3,77	15,1	59%
33	50119	Matawin	-73,91	46,68	1387	1128	3,39	27,1	62%
34	50304	Batiscan	-72,40	46,59	4504	1339	3,51	119,4	63%
35	50408	Ste-Anne	-71,87	46,85	1546	1578	2,62	70,2	61%
36	50409	Bras du Nord	-71,85	46,98	646	1560	2,48	27,2	62%
37	50702	Portneuf	-71,84	46,73	328	1455	4,72	10,4	64%
38	50801	Jacques-Cartier	-71,53	46,89	1997	1503	1,76	87,1	61%
39	50904	St-Charles	-71,32	46,82	365	1451	4,66	12,0	66%
40	50915	Nelson	-71,43	46,87	58	1485	4,56	1,8	66%
41	51001	Montmorency	-71,15	46,90	1107	1441	2,22	50,7	63%
42	54001	Beauport	-71,21	46,86	24	1535	3,78	0,9	69%

Dans le Tableau 2.1, « Num » désigne le numéro de bassin, identifiant le bassin dans la présente étude. « ID station » désigne l'identifiant de la station hydrométrique mesurant le débit à l'exutoire du BV. « Lon. » et « Lat. » désignent respectivement les coordonnées des stations hydrométriques en degrés. « S » désigne la superficie en km². « P_{moy} », « T_{moy} » et « Q_{moy} » désignent respectivement les moyennes du cumul des précipitations annuelles, la moyenne des températures annuelles et la moyenne de débits annuels, calculés au cours des années 2015 à 2020. « Dispo. » désigne la fraction où les données d'observations hydrologiques sont disponibles pour un bassin au cours des années 2015 à 2020.

Des informations supplémentaires sur les caractéristiques des bassins versants sont disponibles en annexe, dans le Tableau I-A-1.

2.2 Description de la méthode de calcul de l'évapotranspiration potentielle

La méthode pour le calcul de l'évapotranspiration potentielle à laquelle sont soumis les bassins versants est la méthode développée par Oudin et al. (2005). Les auteurs montrent qu'avec un modèle de calcul d'évapotranspiration simple, basé uniquement sur le rayonnement solaire et la température moyenne, il est possible de produire de très bonnes données destinées à l'alimentation de modèles hydrologiques. Ces modèles simples sont alors capables d'améliorer les performances des simulations hydrologiques pour les modèles hydrologiques conceptuels globaux en comparaison à des modèles d'évapotranspiration plus complexes. Ce modèle de calcul de l'évapotranspiration est alors retenu pour la suite de la présente étude, le modèle est au pas de temps $dt = 6$ h.

Le modèle d'évapotranspiration développé par Oudin et al. (2005) est le suivant :

$$ETP = \frac{Re}{\lambda * \rho} * \frac{T_m + 5}{100} \quad \text{si } T_m + 5 > 0 \quad \text{et } ETP = 0 \quad \text{sinon} \quad (2.1)$$

Où ETP est le taux d'évapotranspiration potentielle en mm.h⁻¹, Re est le rayonnement solaire en MJ.m⁻².h⁻¹, λ est la chaleur latente de vaporisation de l'eau en MJ.kg⁻¹, ρ la masse volumique de l'eau en kg.m⁻³, T_m est la température moyenne sur dt en °C et dt est le pas de temps de la simulation, ici $dt = 6$ h.

2.3 Description de la méthode de séparation des précipitations

Les données de précipitations fournies par l'organisme ECMWF sont uniquement exprimées par leur quantité, c'est-à-dire la hauteur d'eau qui tombe sur la zone étudiée. En revanche, la nature des précipitations n'est pas précisée, qu'elles soient liquides ou solides. De ce fait, il est nécessaire de mettre en place une méthode pour déterminer la nature des précipitations. La méthode utilisée dans cette étude est telle que décrite par l'US Army Corps of Engineers (1956) aussi nommée méthode de l'intervalle « USACE » par Valery (2010). La méthode USACE définit un intervalle de températures pour lequel les précipitations sont mixtes, c'est-à-dire composées à la fois de pluie et de neige. Au-dessous de cet intervalle, les précipitations sont totalement solides et au-dessus de celui-ci les précipitations sont totalement liquides. Formellement, la méthode se déroule comme suit :

$$\text{si } T_m > T_{pluie} : \text{Pluie} = \text{Précipitations} \text{ et } \text{Neige} = 0 \quad (2.2)$$

$$\text{si } T_m < T_{neige} : \text{Pluie} = 0 \text{ et } \text{Neige} = \text{Précipitations} \quad (2.3)$$

$$\text{si } T_m \in [T_{neige} ; T_{pluie}] : \text{Pluie} = \text{Précipitations} * \frac{T_m - T_{neige}}{T_{pluie} - T_{neige}} \quad (2.4)$$

$$\text{et } \text{Neige} = \text{Précipitations} - \text{Pluie} \quad (2.5)$$

Avec T_m la température moyenne au pas de temps considéré en °C, T_{pluie} le seuil au-dessus duquel les précipitations sont totalement liquides, T_{neige} le seuil au-dessous duquel les précipitations sont totalement solides, les seuils T_{neige} et T_{pluie} sont fixés respectivement à -1°C et +3°C

2.4 Description du modèle de suivi du couvert neigeux

Le modèle de suivi de couvert neigeux utilisé dans la présente étude se base sur le modèle CemaNeige initialement développé par Valery (2010). Le modèle CemaNeige, ayant pour intrants les précipitations neigeuses et la température moyenne au cours du pas de temps considéré, comprend trois paramètres fixes. Un paramètre relatif à la température de fonte (fixé à 0°C) un paramètre de taux de fonte minimal (égal à 10 % du taux de fonte) et un paramètre seuil à partir duquel le bassin est considéré comme totalement couvert de neige (égal aux neuf dixièmes du cumul annuel moyen de neige tombant sur le bassin). Le modèle comporte également deux paramètres libres à optimiser pour représenter au mieux le BV étudié : le facteur de fonte en [mm/°C] ainsi qu'un coefficient de pondération de l'état thermique du manteau, qui a pour effet de modérer ou non l'effet de la température de l'air au pas de temps actuel par rapport à l'état thermique du manteau neigeux au pas de temps précédent. Le modèle fonctionnant initialement au pas de temps journalier a été légèrement modifié pour fonctionner au pas de temps sous-journalier (pas de temps de 6 h). Il est également adapté au sud-ouest du Québec : un secteur peu montagneux. En effet, le modèle CemaNeige propose initialement un découpage du BV étudié en cinq lames d'égales surfaces et d'altitudes différentes. La version utilisée ici est « globale », ne considérant qu'une unique lame pour la modélisation de la région étudiée.

2.5 Description des modèles hydrologiques

Bien que certains modèles hydrologiques soient équipés de leurs propres routines de calcul de fonte de neige ou d'évapotranspiration, des versions modifiées de celles-ci sont utilisées dans la présente étude, faisant en sorte que les intrants des modèles sont toujours l'évapotranspiration potentielle et les précipitations équivalentes. Ces dernières représentent donc la somme des précipitations liquides et de l'eau liquide provenant de la fonte de neige simulée par les modules présentés précédemment. En d'autres termes, seules les fonctions de production de chaque modèle seront présentées ici.

2.5.1 CEQUEAU

CEQUEAU est un modèle conceptuel semi-distribué tel qu'initialement développé à l'*Institut National de la Recherche Scientifique — Eau, Terre et Environnement* (INRS — eau) (Girard, Morin, & Charbonneau, 1972). Une version modifiée de celui-ci est utilisée dans cette étude et se rapproche de la version proposée par Perrin (2002), rendant le modèle conceptuel global. Cette version va permettre de diminuer le nombre de réservoirs représentant le BV de quatre à deux, restreignant ainsi le nombre de paramètres du modèle à neuf.

Les deux réservoirs qui représentent le BV étudié aux yeux du modèle sont organisés comme suit : le réservoir « sol » simulant les phénomènes de surface comme le ruissèlement et une partie de l'évapotranspiration. Plusieurs sorties sont liées à ce réservoir afin de simuler différents phénomènes de faible profondeur grâce à quatre paramètres : sa capacité maximale, des constantes et seuils de vidange ainsi qu'un seuil d'infiltration. Les différents débits provenant de ces sorties participent au bilan des écoulements. Le réservoir « sol » est connecté au réservoir « eau souterraine » par un cinquième paramètre conditionnant cette vidange et simulant les phénomènes d'infiltration. Le réservoir « eau souterraine » comporte deux sorties, l'une simulant le débit hypodermique et l'autre le débit de base. Ce réservoir est aussi soumis à une part d'évapotranspiration. Ces écoulements sont calculés à partir de quatre paramètres régissant les seuils et constantes de vidange du réservoir. Le bilan de tous les écoulements provenant des deux réservoirs est ensuite réalisé et retardé d'un certain nombre de pas de temps, ce nombre est un paramètre du modèle.

2.5.2 GR5dt

Le modèle GR5dt est une version modifiée du modèle conceptuel global du Génie Rural à 4 paramètres Journalier (GR4J). Initialement développé par de Olivera Nascimento (1995) sous la forme « GR4J », un paramètre de percolation a été ajouté dans le réservoir « sol » afin d'adapter le pas de temps auquel fonctionne le modèle. De plus, « dt » indique le fait que le pas de temps n'est pas nécessairement journalier. La version utilisée du modèle a été développée au sein du laboratoire HC3 de l'École de technologie supérieure de Montréal.

Le modèle représente le BV étudié par trois réservoirs : un réservoir « sol » alimenté par une partie de la « pluie nette » c'est-à-dire la pluie brute diminuée de l'évapotranspiration potentielle. Le réservoir « sol » se vide dans le réservoir « eaux souterraines ». Cette vidange est calculée à partir du niveau du réservoir et de deux paramètres que sont la capacité du réservoir « sol » et un paramètre de percolation. Le réservoir « eaux souterraines » simule quant à lui les débits de base de façon linéaire, déterminé à partir du niveau actuel du réservoir et d'un paramètre lié à sa vidange. La part restante de la pluie nette est alors séparée et retardée par un hydrogramme unitaire dont la constante de temps est un paramètre du modèle. Une partie de la pluie alimente le débit à l'exutoire sous couvert d'un paramètre d'échanges souterrains agissant sur le réservoir de routage et l'autre partie alimente directement le réservoir de routage, sa capacité et un paramètre d'échanges souterrains régissent sa vidange en fonction de son niveau suivant une loi quadratique. Les débits provenant de la vidange du réservoir souterrain, du réservoir de routage et de la part restante de la pluie nette (ruissèlement) sont alors sommés pour obtenir le débit à l'exutoire du bassin.

2.5.3 HBV

Le modèle HBV (Hydrologiska Byråns Vattenbalansavdelning) est un modèle conceptuel global initialement développé par Bergström & Forsman (1973) à la *Swedish Meteorological and Hydrological Institute* (SMHI), à Norrköping, Suède. Une version modifiée de ce modèle est utilisée ici telle que décrite par Perrin (2002). 9 paramètres sont nécessaires pour décrire le BV simulé par ce modèle, ceux-ci régissent et mettent en relation 3 réservoirs.

Le réservoir « sol » où sont interceptés les intrants qui sont les précipitations ainsi que l'évapotranspiration potentielle, 3 paramètres lui sont liés : sa capacité, un seuil pour l'évapotranspiration, un exposant permettant de calculer son taux de vidange vers le réservoir intermédiaire. Le réservoir intermédiaire simule quant à lui les phénomènes de ruissèlement, de débits de subsurface et de percolation profonde, 5 paramètres lui sont liés : son seuil d'écoulement, sa constante de vidange supérieure (générant le débit de ruissèlement), sa constante de vidange inférieure (générant le débit de subsurface) ainsi que son coefficient de

percolation traduisant l'infiltration depuis ce réservoir vers le réservoir souterrain. Le réservoir souterrain est quant à lui décrit uniquement par son coefficient de vidange, générant le débit de base. Un bilan de ces trois débits est alors réalisé et réparti selon un hydrogramme unitaire triangulaire dont le temps de base est un paramètre du modèle.

2.5.4 HYMOD

HYMOD (Hydrological MODel) est un modèle conceptuel global développé par Boyle (2001). Ce modèle utilise cinq paramètres mettant en relation cinq réservoirs pour simuler le BV étudié.

Le modèle comprend un réservoir « sol » d'interception des intrants où les phénomènes d'évapotranspiration et de ruissèlement sont simulés grâce à trois paramètres que sont la capacité maximale, le degré de variabilité spatiale de l'humidité du sol et un facteur de distribution de la pluie nette parmi les réservoirs suivants. Les réservoirs suivants sont répartis en deux groupes : un premier groupe de trois réservoirs de routage en série, dont le temps de séjour est identique pour les trois et constitue un paramètre du modèle, qui simule les phénomènes de « décharge rapide » tels que le ruissèlement en surface. Le dernier réservoir simule quant à lui les phénomènes de « décharge lente » tels que les débits de base, son temps de séjour est plus long et constitue le dernier paramètre de cet HM. Le bilan des débits générés par ces deux réservoirs est alors réalisé pour calculer le débit à l'exutoire du bassin.

2.5.5 IHACRES

IHACRES (Identification of Unit Hydrographs and Component flows from Rainfall, Evaporation and Streamflow data) est un modèle conceptuel global initialement développé par Jakeman (1990). Ce modèle comporte sept paramètres et trois réservoirs pour simuler le débit à l'exutoire du BV observé.

Trois paramètres permettent de calculer la portion des quantités de précipitations qui seront stockées dans le réservoir de suivi de l'humidité en fonction notamment des pluies et états

d'humidité précédents, ce réservoir simule les phénomènes d'évapotranspiration. La portion restante des précipitations qui constitue « pluie efficace » alimentant l'écoulement du bassin, est séparée et dirigée vers deux hydrogrammes unitaires, équivalents à des réservoirs de routage grâce à un paramètre de partage des écoulements. Ces deux hydrogrammes sont liés à deux paramètres représentant leur constante de temps, l'un représente les écoulements « rapides » comme les phénomènes de ruissèlement de surface, l'autre représente les écoulements « lents » tels que le débit de base. Le bilan des débits en sortie de ces deux réservoirs de routage est ensuite retardé par un délai qui est un paramètre du modèle, afin de simuler le débit à l'exutoire du BV.

2.5.6 MOHYSE

MOHYSE (MOdèle HYdrologique Simplifié à l'Extrême) est un HM conceptuel global initialement développé par Fortin & Turcotte (2007). Une version modifiée du modèle est utilisée ici. Cette version modifiée de MOHYSE utilise 7 paramètres et deux réservoirs pour simuler le BV étudié.

Les précipitations peuvent être séparées en deux portions, l'une alimentant un réservoir représentant la zone « vadose » par infiltration, qui représente les phénomènes de « subsurface » c'est-à-dire les phénomènes se produisant dans la zone du sol non saturée en eau. Le réservoir de la zone vadose est lié à un paramètre représentant son taux de remplissage maximal, c'est-à-dire le taux d'infiltration maximale, toute quantité d'eau en excès sera redirigée directement vers le bilan des écoulements et représente les phénomènes d'écoulements de surface. Le réservoir de la zone vadose est lié à trois autres paramètres : l'un est un coefficient d'ajustement de l'évapotranspiration, destiné au calcul de ce phénomène, un autre est le coefficient de vidange de la zone vadose vers le cours d'eau (bilan des écoulements). Le troisième paramètre définit le coefficient de vidange du réservoir « vadose » vers le réservoir « aquifère » qui désigne la zone du sol plus profonde saturée en eau. Le réservoir « aquifère » est quant à lui lié à un unique paramètre représentant son coefficient de vidange, simulant le débit de base, vers le bilan des écoulements. Le bilan des écoulements

constitué des quantités d'eau provenant du ruissèlement de surface, de la zone « vadose » et de la zone « aquifère » est ensuite routé suivant un hydrogramme unitaire dont la forme est définie par deux paramètres du modèle afin d'obtenir le débit à l'exutoire du BV.

2.5.7 SIMHYD

SIMHYD (SIMple HYDrology) est un HM conceptuel global, il est une version simplifiée du modèle HYDROLOG initialement développé par Porter (1972). Il est composé de sept paramètres et quatre réservoirs afin de décrire les phénomènes hydrologiques présents dans le BV.

Le premier réservoir, le réservoir dit d'interception, dont la capacité maximale constitue un des paramètres du modèle, est alimenté par les intrants que sont les précipitations et l'évapotranspiration potentielle, l'eau en excès de ce réservoir constitue les précipitations nettes. Une fonction d'infiltration calcule la portion des précipitations nettes qui s'infiltré dans le sol à partir de deux paramètres : un coefficient lié à l'infiltration ainsi que du niveau relatif du réservoir de suivi d'humidité du bassin (le niveau maximal du réservoir de suivi d'humidité étant un paramètre du modèle), la portion des précipitations nettes restante constitue le ruissèlement de surface. L'eau infiltrée est alors séparée en trois portions par une fonction « humidité du sol ». Une portion est dirigée vers le réservoir d'eaux souterraines, une autre vers le réservoir de suivi d'humidité du sol et la dernière constitue l'écoulement hypodermique. Les portions sont calculées à partir de trois paramètres : une constante liée à la recharge du réservoir d'eaux souterraines, une constante liée à l'écoulement épidermique et le niveau relatif du réservoir de suivi d'humidité. L'eau contenue dans le réservoir de suivi d'humidité est soumise au phénomène d'évapotranspiration, l'eau en excès du réservoir est dirigée vers le réservoir d'eau souterraine. Le débit de base provenant du réservoir d'eaux souterraines est alors calculé à partir du niveau du réservoir et d'une constante constituant un paramètre du modèle. Le ruissèlement, l'écoulement épidermique et le débit de base sont alors sommés et passent par un réservoir de routage dont la constante de vidange constitue un des paramètres du modèle.

2.5.8 TOPMODEL

TOPMODEL (TOPography-based hydrological MODEL) est un HM conceptuel global initialement développé par Beven & Kirkby (1979). Il est composé de trois réservoirs et de sept paramètres pour simuler les phénomènes hydrologiques d'un BV.

Un premier réservoir d'interception est alimenté par les intrants que sont les précipitations ainsi que l'évapotranspiration potentielle. Ce réservoir d'interception est lié à un paramètre régissant sa capacité maximale et une partie des phénomènes d'évapotranspiration est simulée au niveau de ce réservoir. À partir de deux paramètres, l'un lié à la topographie du bassin et l'autre régissant la vidange du réservoir « eau souterraine », la pluie en excès du réservoir d'interception est séparée en deux parties. Une partie est dirigée par infiltration vers un réservoir « eau souterraine ». L'autre partie de la pluie en excès est quant à elle redirigée vers un réservoir de routage quadratique, représentant les phénomènes de ruissèlement, dont la capacité représente un des paramètres du modèle. Le réservoir « eau souterraine » est quant à lui lié à trois paramètres : un paramètre lié à sa vidange, un second paramètre lié à l'évapotranspiration. Ces deux paramètres permettent de calculer l'évapotranspiration à laquelle est soumis le réservoir d'infiltration. Un troisième paramètre lié au réservoir d'infiltration est son paramètre de vidange exponentielle, l'eau vidangée va alors alimenter le cours d'eau accompagnée par le débit de ruissèlement de surface. La somme est retardée d'un certain nombre de pas de temps, ce nombre est un paramètre du modèle.

2.6 Calibration des modèles hydrologiques

Un HM conceptuel peut se résumer en une série d'équations « modulables » grâce à des paramètres. Il existe de nombreuses méthodes pour calibrer un modèle, c'est-à-dire déterminer les paramètres optimaux pour décrire les caractéristiques d'un BV aux yeux du modèle. La méthode retenue dans la présente étude est la méthode « CMA-ES » (Covariance Matrix Adaptation Evolution Strategy) initialement développée par Hansen & Ostermeier (2001). Un avantage majeur de cet algorithme est sa simplicité d'utilisation, en effet, il obtient de très bonnes performances sans nécessiter un réglage préalable de ses hyperparamètres. Les

hyperparamètres sont les paramètres régissant le fonctionnement de l'algorithme d'optimisation et donc sa capacité à trouver un jeu de paramètres optimal d'un HM. Cette particularité de CMA-ES provient du fait de sa robustesse face à un problème mal conditionné. Un problème est dit mal conditionné lorsqu'une très faible variation dans les données d'entrée provoque une très grande variation du résultat en sortie. Dans le cas d'un problème d'optimisation d'un HM, cela signifierait qu'une très petite variation d'un paramètre change énormément la valeur des débits qu'il va simuler sans vraie tendance apparente. Cette particularité rend la convergence de la fonction-objectif vers son minimum global, ou un minimum local, plus complexe. Un jeu de paramètres est dit optimal pour un modèle lorsque l'on considère que la fonction-objectif, obtenue en comparant les résultats de la simulation réalisée par le modèle et les données mesurées dans la réalité, a atteint son minimum global.

Dans le cas de cette étude, la fonction-objectif retenue est le Nash-Sutcliffe Efficiency coefficient (NSE). Il est régulièrement utilisé pour mesurer l'efficacité d'une prédiction générée par un HM, et par conséquent pour calibrer les modèles hydrologiques. Il est établi selon l'équation 3.6 :

$$NSE = 1 - \frac{\sum_{t=1}^T (Q_o^t - Q_s^t)^2}{\sum_{t=1}^T (Q_o^t - \overline{Q_o})^2} \quad (2.6)$$

Avec Q_o^t le débit observé au pas de temps t , Q_s^t le débit simulé au pas de temps t et $\overline{Q_o}$ la moyenne des débits observés entre le premier pas de temps et le dernier pas de temps T .

Pour la calibration des modèles hydrologiques, une méthode différente de la méthode traditionnellement utilisée du « split-sample » est utilisée. La méthode « split-sample » consiste à calibrer les modèles hydrologiques sur une période définie et effectuer la validation sur une autre période indépendante de la première. L'étape de validation consiste principalement à vérifier si les paramètres des modèles, une fois calibration faite, ne sont pas victimes de surajustement (ou « overfitting »). Si c'est le cas, cela signifie que les paramètres des modèles conviennent uniquement aux données sur lesquelles ils ont été calibrés, mais ont de très

mauvaises performances lorsqu'ils sont confrontés à des données nouvelles, ils ne sont pas robustes et doivent être recalibrés. Arsenault, Brissette, & Martel (2018), argumentent que, malgré le fait que la validation puisse offrir une certaine intuition sur la validité ou non des paramètres calibrés, cette méthode pour attester les performances de la calibration n'est pas exempte de dérives potentielles.

D'une part, elle dépend exclusivement de la sélection de la période pour la validation. Ainsi cette période doit être choisie avec grand soin, car si elle est trop atypique, elle peut donner une image trompeuse des performances réelles du modèle. Ceci peut également mener au rejet de « bons » paramètres qui pourraient être très performants dans des situations inédites. D'autre part, l'inconvénient majeur de cette méthode est qu'une quantité non négligeable des données disponibles est dédiée à la période de validation, et ainsi ne peut pas servir à la calibration des modèles. Arsenault et al. (2018) montrent d'ailleurs que la robustesse d'un jeu de paramètre d'un modèle est très fortement corrélée à la longueur de la période utilisée pour les calibrer. Ainsi, comme préconisé dans cette étude, toutes les données disponibles sont utilisées pour la calibration plutôt que de suivre la méthode traditionnelle du « split-sample ».

D'après D. N. Moriasi et al. (2007), un jeu de paramètres d'un modèle est considéré comme ayant une performance modérée si ses simulations obtiennent un NSE entre 0.5 et 0.6, de bonnes performances pour un NSE inférieur à 0.7, très bonnes pour un NSE inférieur à 0.85 et excellentes au-delà. Des NSE inférieurs à 0.3 sont jugés insatisfaisants.

2.7 Description de la méthode d'assimilation de données

L'assimilation de données est effectuée à l'aide du filtre de Kalman Ensembliste (EnKF). Le EnKF est reconnu pour ses applications fructueuses dans le domaine de l'hydrologie et dans les systèmes de prévision. D'abord des perturbations sont ajoutées dans les données météorologiques observées pour créer un ensemble d'états initiaux du modèle. À partir de ces données météorologiques perturbées, les débits sont simulés et propagés dans le temps, permettant de déterminer les incertitudes associées aux variables internes telles que les niveaux

d'eau dans différents réservoirs du modèle. À partir de ces informations et des observations de débits, EnKF détermine un ensemble d'états probables du système, qui représentent différents scénarios possibles compte tenu des incertitudes dans les données d'entrée et la structure du modèle. À chaque nouvelle observation disponible, de nouveaux états sont déterminés par EnKF. 25 jeux de variables internes sont générés à partir de cette méthode dans la présente étude. Ainsi, ces 25 membres obtenus par assimilation sont combinés aux 50 membres qui composent les prévisions météorologiques, produisant 1250 membres pour chaque prévision hydrologique.

2.8 Description de la méthode de post-traitement

Pour le post-traitement des prévisions générées par les modèles hydrologiques étudiés, la méthode de quantile mapping (QM), ou correction par transformation quantile-quantile, ou encore « quantile to quantile transform », est utilisée. Le QM vise à faire correspondre la fonction de distribution cumulative des prévisions générées par les modèles hydrologiques avec la fonction de distribution cumulative des données observées. Les quantiles sont des points de coupe qui segmentent une distribution en intervalles continus avec des proportions égales de l'ensemble des données. Pour clarifier, on peut dire que les quantiles sont des marqueurs de position qui divisent un jeu de données en parties équivalentes selon leur fréquence ou leur ordre. Par exemple pour un découpage en 100 quantiles (nommés « centiles »), le 25e centile, aussi connu comme le premier quartile, correspond au point de la distribution au-dessous duquel on trouve un quart des observations. De même, le 75e centile, ou troisième quartile, est le point au-dessous duquel se trouvent trois quarts des observations.

La méthode de quantile mapping empirique est utilisée ici, telle que décrite par Enayati et al. (2021). Pour ce faire, l'algorithme de QM (à 100 quantiles) va, pour chaque pas de temps et chaque membre, identifier les centiles des prévisions hydrologiques ainsi que les centiles des données observées. Afin de faire correspondre les fonctions de distribution cumulatives des deux jeux de données, l'algorithme va ensuite déterminer une correction à appliquer à chaque centile de la prévision afin qu'il soit égal au centile d'observation de même rang. Ensuite, la

correction préalablement déterminée pour chaque centile est appliquée aux prévisions, en fonction du centile auquel elles appartiennent. Formellement, la méthode se déroule comme suit :

$$x_{QM,m}(t) = F_o^{-1}(F_s(x_s(t))) \quad (2.7)$$

Avec $x_{QM,m}(t)$ la prédiction réalisée suite au post-traitement par quantile mapping au pas de temps t et membre m , F_o^{-1} l'inverse de la fonction de distribution cumulative des données observées par le passé, F_s la fonction de distribution cumulative des données de simulation et $x_s(t)$ la prédiction réalisée par le modèle hydrologique au pas de temps t .

Le post-traitement par quantile mapping est appliqué à la fois sur les prévisions météorologiques, c'est-à-dire les températures et les précipitations, et sur les prévisions hydrologiques en sortie des modèles hydrologiques présentés précédemment. Différentes méthodes de correction sont appliquées en fonction de la nature des prévisions à post-traiter. En effet, pour la température, c'est une correction « additive » qui est appliquée : pour deux centiles de même rang parmi les données observées et les données de prévisions brutes passées, on mesure la différence entre la température initialement prévue par le modèle météorologique et les températures réellement observées. On obtient alors une constante de correction pour ce centile, puis on additionne cette constante de correction aux températures brutes à post-traiter. Pour les précipitations et les débits à post-traiter, c'est le ratio entre les prévisions réalisées par le passé et les données réelles que l'on calcule, on obtient alors un facteur de correction pour un centile donné, que l'on multiplie aux données de prévisions de température, la même méthode est réalisée pour les débits.

Formellement, pour un pas de temps t et un centile c la méthode se déroule comme suit :

1) Températures :

$$corr_{T_c}(t) = x_{T_{o,c}} - x_{T_{s,c}}(t) \quad (2.8)$$

Puis

$$x_{T_{QM,c}}(t) = corr_{T_c}(t) + x_{T_s}(t) \quad (2.9)$$

2) Précipitations et débits :

$$corr_{P_c}(t) = \frac{x_{P_{o,c}}}{x_{P_{s,c}}(t)} \quad (2.10)$$

Puis

$$x_{P_{QM,c}}(t) = corr_{P_c}(t) * x_{P_s}(t) \quad (2.11)$$

Avec :

$$x_{T_{s,c}}(t) \leq x_{T_s}(t) < x_{T_{s,c+1}}(t) \quad (2.12)$$

Et

$$x_{P_{s,c}}(t) \leq x_{P_s}(t) < x_{P_{s,c+1}}(t) \quad (2.13)$$

Notons que, pour définir les coefficients de correction, quelle que soit la grandeur à corriger, toutes les données sont utilisées pour la calibration, sauf une année. En effet, les données disponibles pour l'étude s'étendent du 1^{er} janvier 2015 au 31 décembre 2020. Le choix a été fait de définir les coefficients de correction à partir des données présentes entre le 1^{er} janvier 2015 et le 31 décembre 2019, c'est la phase de « calibration » de la méthode. Les coefficients de correction alors définis pour chaque centile sont alors appliqués aux prévisions faites lors de l'année 2020.

Afin d'isoler de manière plus précise les données de calibration, étant donné la nature à court terme des prédictions, la méthode de sélection par « fenêtre glissante » est utilisée. Cette méthode consiste à, pour chaque jour de prévision, calculer les coefficients de correction à partir d'une plage de données composée d'un certain nombre de jours présents autour du jour de prévisions. Le nombre de jours dépend justement de la taille de la fenêtre glissante, une fenêtre glissante de W jours, va sélectionner les W jours avant et après le jour de prévision, avec le jour de l'année pour lequel est établi la sélection de données au centre de la plage, pour chaque année disponible pour la calibration. Schématiquement, la méthode se déroule comme suit :

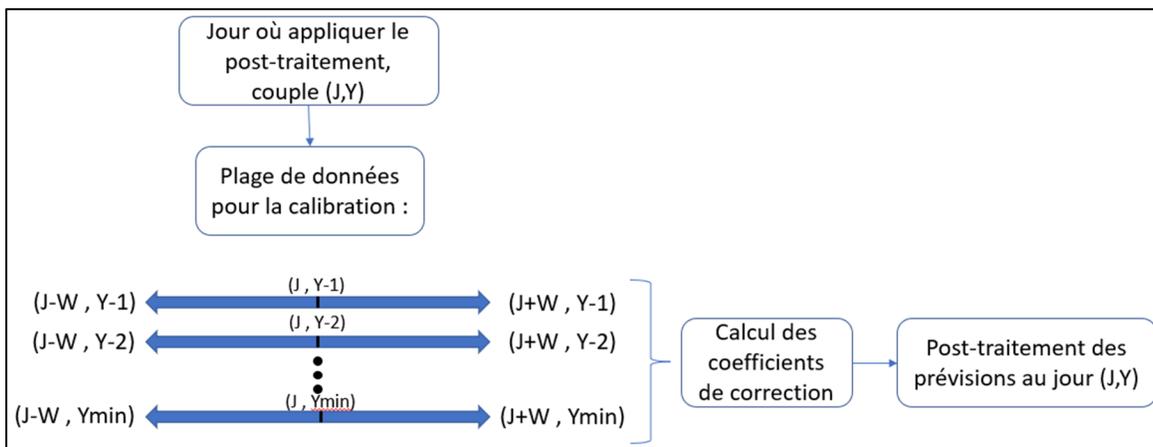


Figure 2.2 Représentation schématique du processus de sélection des données par fenêtre glissante

Dans la présente étude, $J \in [1,366]$ le jour de l'année ; $W \in \{10, 15, 20, 30\}$ la taille de la fenêtre, $Y = 2020$ l'année d'application de la méthode et $Y_{min} = 2015$, soit la première année de calibration. À titre d'exemple, pour le 40^e jour de l'année dans le contexte d'une correction par fenêtre glissante de 30 jours, le calcul des coefficients de correction sera effectué à partir des données de prévisions et d'observations présentes entre les 10^e et 70^e jours des années précédentes.

2.9 Mesures de performance des prévisions

Cette section présente les différentes métriques utilisées pour l'évaluation des performances des prévisions brutes, prétraitées et post-traitées. Dans un premier temps, le CRPS sera présenté, ensuite le CRPSS et enfin les diagrammes de Talagrand suivront.

2.9.1 Continuous Ranked Probability Score (CRPS)

Afin de mesurer les performances des prévisions émises par le modèle climatique, ainsi que celles des prévisions émises par les modèles hydrologiques, le CRPS (Continuous Ranked Probability Score) est utilisé. Le CRPS peut être vu comme une généralisation de l'erreur quadratique adaptée à des prévisions probabilistes. Le CRPS mesure la précision des prévisions, c'est-à-dire à quel point les prévisions émises par les modèles sont proches des événements qui sont réellement observés, il est exprimé dans la même unité que la variable observée. Le calcul du CRPS revient à, en pratique, pour chaque pas de temps d'une prévision, comparer la fonction de distribution cumulative empirique construite à partir des valeurs prédites par chacun des membres à la fonction de distribution empirique de l'observation à cette date (un unique échelon). Le CRPS a des valeurs comprises entre 0 et l'infini, une valeur de 0 correspond à une prévision parfaitement précise (tous les membres prédisent exactement ce qui a été observé), à l'image d'une erreur quadratique nulle lorsque l'on compare une prévision déterministe aux événements réellement observés, un CRPS non nul permet alors de quantifier l'erreur commise par les prévisions.

Bien qu'il mesure la précision des prévisions, tout comme l'erreur quadratique, le CRPS est aussi influencé par la distribution des membres d'une prévision. Il donne alors des indices sur la fiabilité (correspondance entre les probabilités prévues et fréquences réellement observées pour un événement), l'acuité ou « sharpness » (étalement de la distribution des membres) et d'autres caractéristiques liées à la distribution des membres d'une prévision probabiliste.

Formellement, le CRPS d'une prévision se calcule comme suit :

$$CRPS(F, obs) = \int_{-\infty}^{+\infty} (F(x) - \mathbb{1}(x - obs))^2 dx \quad (2.14)$$

Avec F la fonction de distribution cumulative associée à la prévision probabiliste, $\mathbb{1}$ la fonction de Heavyside où $\mathbb{1}(x) = 1$ si $x \geq 0$; $\mathbb{1}(x) = 0$ si $x < 0$. En pratique $x \in [\min(\text{prévisions}, \text{obs}), \max(\text{prévisions}, \text{obs})]$.

Graphiquement, calculer le CRPS revient à calculer l'aire quadratique entre les fonctions de distributions cumulatives empiriques des prévisions et des observations.

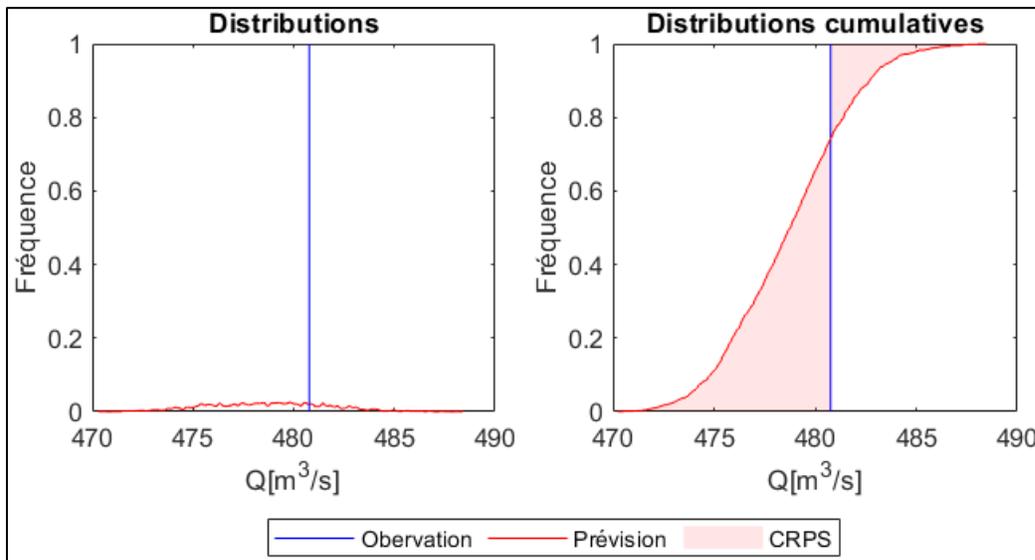


Figure 2.3 Représentation graphique du calcul du CRPS. À gauche : distribution de probabilités d'une observation (en bleu) et d'une prévision probabiliste (en rouge). À droite : Fonction de distribution cumulative (en bleu) d'une observation et d'une prévision probabiliste (en rouge), la zone rouge pâle représente le calcul du CRPS

2.9.2 Continuous Ranked Probability Skill Score (CRPSS)

Pour comparer deux prévisions issues de systèmes différents, il existe le « score de compétence » (« skill score ») qui mesure les performances d'une prévision par rapport à une prévision de référence sous le prisme de la métrique utilisée. L'expression générale d'un score de compétence est la suivante :

$$Skill\ Score = \frac{Score_{prévision} - Score_{référence}}{Score_{parfait} - Score_{référence}} \quad (2.15)$$

Ainsi il est possible de calculer le CRPSS (Continuous Ranked Probability Skill Score) à partir des CRPS des prévisions pré et post-traitées en prenant comme référence les prévisions brutes (n'ayant subi ni prétraitement et ni post-traitement au QM). Un CRPS parfait étant nul, l'expression du CRPSS est la suivante :

$$CRPSS_{QM} = 1 - \frac{CRPS_{QM}}{CRPS_{brute}} \quad (2.16)$$

De ce fait, un CRPSS égal à 1 indique une prévision parfaite par rapport à la référence (ou plus simplement une prévision parfaite, le CRPS de la prévision étant nul). Un CRPSS nul indique que les compétences de la prévision pré ou post-traitée ne voient pas d'amélioration, au regard du CRPS, par rapport à la prévision de référence. Un CRPSS négatif signifie une baisse de compétence de la prévision après traitement par rapport à la prévision brute.

2.9.3 Diagrammes de Talagrand

Un outil fréquemment utilisé pour évaluer la fiabilité d'une prévision est l'histogramme de rang, également appelé diagramme de Talagrand (Talagrand & Vautard, 1997). Dans le contexte des prévisions d'ensemble, la fiabilité fait référence à la capacité d'une prévision d'ensemble à représenter adéquatement la fréquence des événements tels qu'ils sont effectivement observés. Cette concordance assure que la distribution des prévisions émises par l'ensemble représente

avec justesse la distribution réelle des résultats. Cette caractéristique est intrinsèquement liée à la capacité de l'ensemble des prévisions à saisir correctement l'incertitude des phénomènes prédits. Cela est mesuré par la dispersion appropriée des prévisions : la variabilité au sein de l'ensemble doit refléter de manière fidèle la variabilité et l'étendue des résultats possibles, conformément à la distribution observée des évènements.

Le diagramme de Talagrand est construit de la manière suivante : pour une prévision émise, les valeurs de chacun des membres de la prévision d'ensemble sont regroupées par « bacs », définis en calculant les déciles de la distribution de chacun des membres (premier bac : 0-10 % des valeurs prédites, deuxième bac, 11-20 % et ainsi de suite). Puis on identifie dans quel bac se trouve l'observation réelle correspondante à la prévision. Le diagramme de Talagrand est alors généré en comptabilisant le nombre de fois que les observations tombent dans chaque bac à travers toutes les prévisions. La forme de l'histogramme révèle la fiabilité des prévisions. La Figure 2.4 représente les formes typiques d'un diagramme de Talagrand.

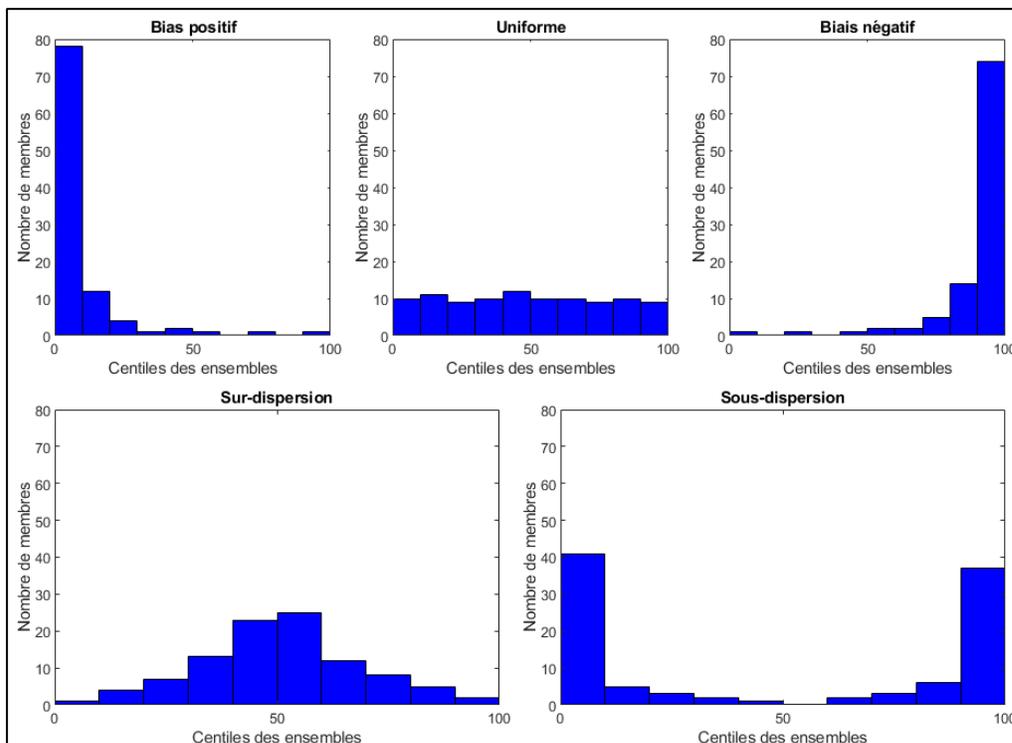


Figure 2.4 Exemples de formes typiques des diagrammes de Talagrand

Dans un diagramme de Talagrand idéal, où les prévisions de l'ensemble sont parfaitement fiables, nous nous attendons à une distribution uniforme des rangs observés, ce qui serait représenté par une ligne droite horizontale dans le diagramme. Cela signifie que les observations ont autant de chances de se situer dans n'importe quel décile de l'ensemble des prévisions, indiquant une bonne dispersion des prévisions de l'ensemble. Un diagramme en forme de « U » indique que les observations se retrouvent souvent en dehors des limites des prévisions de l'ensemble, suggérant que l'ensemble est trop serré ou sous-dispersif. À l'opposé, un diagramme en forme de dôme centré, suggère que les observations se retrouvent fréquemment au milieu de l'ensemble, ce qui indique une surdispersion des prévisions. Des diagrammes asymétriques indiquent quant à eux des prévisions biaisées. Une asymétrie vers la gauche indique un biais positif (les observations sont très régulièrement parmi les membres les plus faibles), tandis qu'une asymétrie vers la droite indique un biais négatif des prévisions (les observations sont très régulièrement parmi les membres les plus élevés).

Pour permettre une meilleure interprétation des diagrammes de Talagrand, deux mesures sont aussi employées. L'une est le score ABDU (Average Bin Distance to Uniformity), qui quantifie l'écart moyen des fréquences observées par rapport à une distribution uniforme dans chaque bac (Arsenault, Latraverse, & Duchesne, 2016). Un score ABDU faible indique que la distribution des rangs observés est proche d'une distribution uniforme.

Formellement, le score ABDU est calculé de la manière suivante :

$$ABDU = \frac{1}{M} \sum_{k=1}^N \left| s_k - \frac{M}{N} \right| \quad (2.17)$$

Avec M le nombre total de paires prévision-observation, N le nombre total de bacs et s_k le nombre d'observations tombant dans $k^{\text{ième}}$ bac. Le ratio $\frac{M}{N}$ représente alors le nombre d'observations dans chaque bac pour représenter une distribution parfaitement uniforme dans le diagramme de Talagrand.

Un autre test statistique est le test de Kolmogorov-Smirnov. Le test de Kolmogorov-Smirnov est un test statistique non paramétrique qui compare une distribution échantillonnée à une distribution de référence, dans ce cas, une distribution uniforme. Ainsi l'hypothèse nulle pour ce test est la suivante : « la distribution représentée dans le diagramme de Talagrand est issue de l'échantillonnage d'une loi uniforme ». Un p-value élevé ne rejette pas l'hypothèse que la distribution représentée dans le diagramme de Talagrand testé est uniforme, sans pour autant la confirmer, ici le seuil est $p = 0.05$.

CHAPITRE 3

RÉSULTATS

Ce chapitre présente les résultats à la suite de l'application des pré et post-traitements par quantile mapping empirique. Il débute par la présentation des résultats de la calibration des modèles hydrologiques, suivie de l'évaluation des performances du prétraitement pour les prévisions météorologiques. Par la suite, il analyse les performances des prévisions hydrologiques en utilisant d'une part les prévisions météorologiques prétraitées en entrée, et d'autre part les prévisions météorologiques brutes avec un post-traitement basé sur leurs extrants.

3.1 Prétraitement des prévisions météorologiques

Les prévisions météorologiques qui alimentent les modèles hydrologiques sont composées de deux variables : les prévisions de précipitations et les prévisions de température. Les prévisions ayant subi un prétraitement sont les prévisions de l'année 2020. La méthode de prétraitement par quantile mapping empirique a été calibrée à l'aide des années 2015 à 2019. Pour un jour de prévision, la correction par quantile est calibrée en récoltant les données d'observations et de prévisions autour de ce jour dans les années passées. La plage de récolte des données autour de ce jour est de plus ou moins 10, 15, 20 ou 30 jours. La mention « QM10 » fait référence à la méthode calibrée avec 21 jours (± 10 jours) prélevés dans les années 2015 à 2019, la mention « QM15 » fait référence à la méthode calibrée avec 31 jours (± 15 jours), et ainsi de suite.

3.1.1 Performances globales du prétraitement des prévisions météorologiques

Les Figures 3.1 et 3.2 sont des cartes thermiques qui représentent les performances de la méthode de prétraitement par quantile mapping empirique sur les prévisions météorologiques. Dans ces deux figures, les performances globales des quatre méthodes sont évaluées sur l'année 2020 au complet, soit 366 jours. Les horizons prédictifs ont été regroupés par paquets de 24 h, soit 4 pas de temps, pour les horizons les plus proches. Les horizons prédictifs au-delà

de 144 h (soit 6 jours) ont été regroupés par paquets de 48 heures, soit 8 pas de temps. Ici, les performances des différentes méthodes de sélection des données par fenêtre glissante sont mesurées avec le CRPSS médian, calculé entre les prévisions météorologiques prétraitées et brutes. Ces cartes thermiques montrent les performances, au regard du CRPSS, des prévisions de précipitations prétraitées par rapport aux performances des prévisions de précipitations brutes. En bleu, les CRPSS médians des prévisions prétraitées sont positifs, indiquant une amélioration induite par le prétraitement sur les prévisions de précipitations. À l'inverse, les teintes rougeâtres (CRPSS médians négatifs) indiquent une détérioration de la précision des prévisions prétraitées par rapport aux prévisions brutes.

3.1.1.1 Performances globales du prétraitement des prévisions de précipitations

À la vue des valeurs extrêmes indiquées sur l'échelle des teintes, les changements de performances médianes induites par le prétraitement sont peu notables. En effet, on observe un CRPSS médian minimal de -0.12 et un CRPSS maximal de +0.11 sur ces cartes thermiques. De plus, on remarque de très faibles différences entre les performances des différentes fenêtres glissantes.

Cependant, on peut voir une tendance se dessiner : plus la fenêtre glissante est grande, meilleures sont les prévisions prétraitées. Ainsi, la méthode calibrée avec une fenêtre glissante de ± 30 jours (QM30) induit tout de même des performances légèrement meilleures que les autres. En ce qui concerne les horizons prédictifs, les effets induits par le prétraitement ne sont pas homogènes. En effet, pour la plupart des bassins, on observe une détérioration globale des prévisions sur le très court terme (6-24 h). Seuls les bassins n°9 à 13, 17 à 19, 22, 24, 26 et 29 à 31 (soit 14 bassins sur 42, soit 33 %) voient leurs CRPSS de prévisions de précipitations devenir positifs et supérieurs à 0.01. À des horizons prédictifs plus éloignés, entre 30 et 96 h, les CRPSS sont positifs pour la majorité des bassins, avec les valeurs les plus élevées pour les bassins précédemment cités. C'est à ces horizons que le prétraitement obtient les meilleures performances, avec des CRPSS proches, voire supérieurs à 0.1. Ainsi, 8 bassins (soit 19 %)

obtiennent des CRPSS supérieurs à 0.05 aux horizons entre 30 et 48 h, 10 bassins (soit 24 %) aux horizons entre 54 et 72 h, et 5 bassins (soit 12 %) aux horizons entre 78 et 96 h.

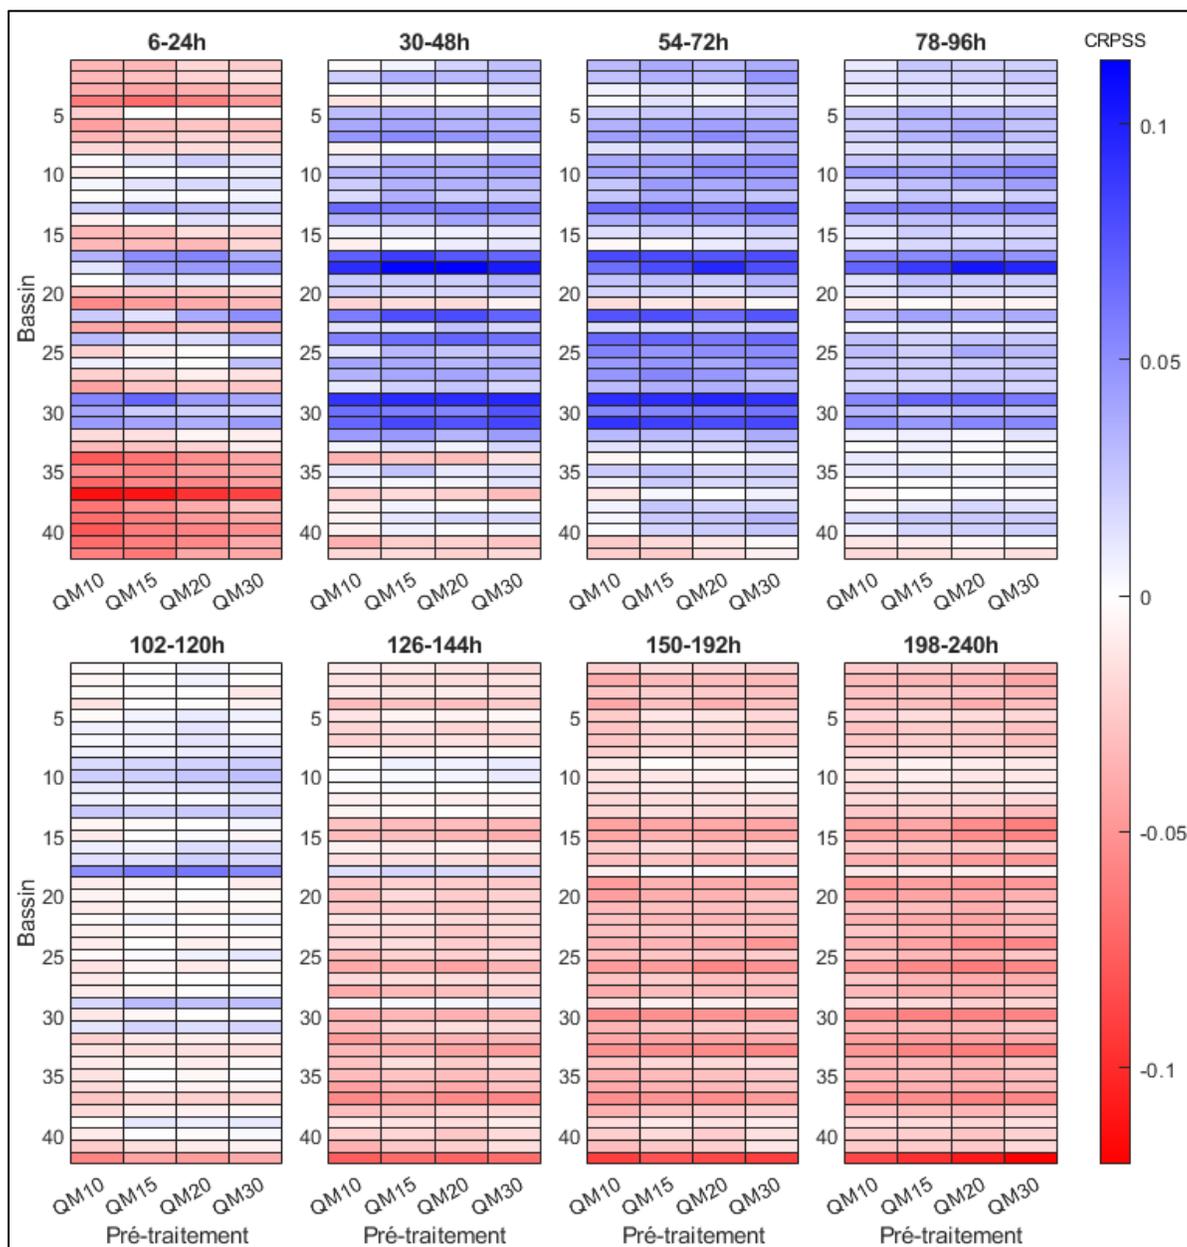


Figure 3.1 Cartes thermiques représentant les CRPSS des prévisions de précipitations prétraitées pour des tailles de fenêtre différentes et des horizons prédictifs regroupés, les teintes rouges représentent des CRPSS négatifs, les teintes bleues des CRPSS positifs

Aux horizons compris entre 102 et 120 h, la tendance commence à s'inverser, le prétraitement induit de très faibles changements de performances, comme le montrent les CRPSS médians qui sont très proches de 0 (27 bassins, soit 64 %). Il existe quelques exceptions pour certains bassins pour lesquels le prétraitement a obtenu des CRPSS positifs au très court terme (6 à 24 h) et qui voient leurs performances très légèrement améliorées (11 bassins, soit 26 % pour lesquels $CRPSS > 0.01$). Aux horizons au-delà de 126 h, la majeure partie des bassins voient leurs prévisions soit détériorées, soit inchangées ($-0.01 < CRPSS < 0.01$). Seul le bassin n°18 obtient un CRPSS supérieur à 0.01 pour les horizons prédictifs compris entre 126 et 144 h. Au-delà, les performances médianes des prévisions prétraitées sont soit inchangées ($-0.01 < CRPSS < 0.01$) soit détériorées, avec des CRPSS inférieurs à -0.01.

3.1.1.2 Performances globales du prétraitement des prévisions de température

En observant les valeurs extrêmes indiquées sur l'échelle des teintes, nous constatons que les performances médianes des prévisions de température s'améliorent constamment, voire restent inchangées. En effet, les CRPSS médians minimaux et maximaux atteignent respectivement -0.0045 et 0.6425. De même que pour les prévisions de précipitations, il est possible de noter que les différences entre les performances obtenues par le QM sont faibles en fonction de la taille de la fenêtre glissante utilisée lors du prétraitement des prévisions de température. La tendance demeure la même : plus la fenêtre glissante est grande, meilleures sont les performances des prévisions prétraitées.

Cependant, il est important de souligner que même si les prévisions de température s'améliorent de manière constante grâce au prétraitement, cette amélioration n'est pas uniforme. D'une part, les meilleures performances sont obtenues à très court terme, puis les améliorations deviennent de moins en moins importantes à mesure que l'horizon prédictif s'éloigne. Des améliorations notables ($CRPSS > 0.05$) sont constatées pour tous les bassins jusqu'à l'horizon 102-120 h. Ensuite, 35 bassins (soit 83 %) obtiennent des CRPSS supérieurs à 0.05 aux horizons compris entre 126 et 144 h, 11 bassins (soit 26 %) aux horizons entre 150 et 192 h, et 6 bassins (soit 14 %) aux horizons entre 198 et 240 h. D'autre part, les améliorations

induites par le prétraitement dépendent des bassins étudiés. Les plus grandes améliorations sont observées pour les bassins 39, 40 et 42, quel que soit l'horizon prédictif. En général, le classement d'un bassin par rapport aux autres en matière de CRPSS reste le même, quelle que soit la période prédictive. Cette caractéristique est également constatée dans les prévisions de précipitations.

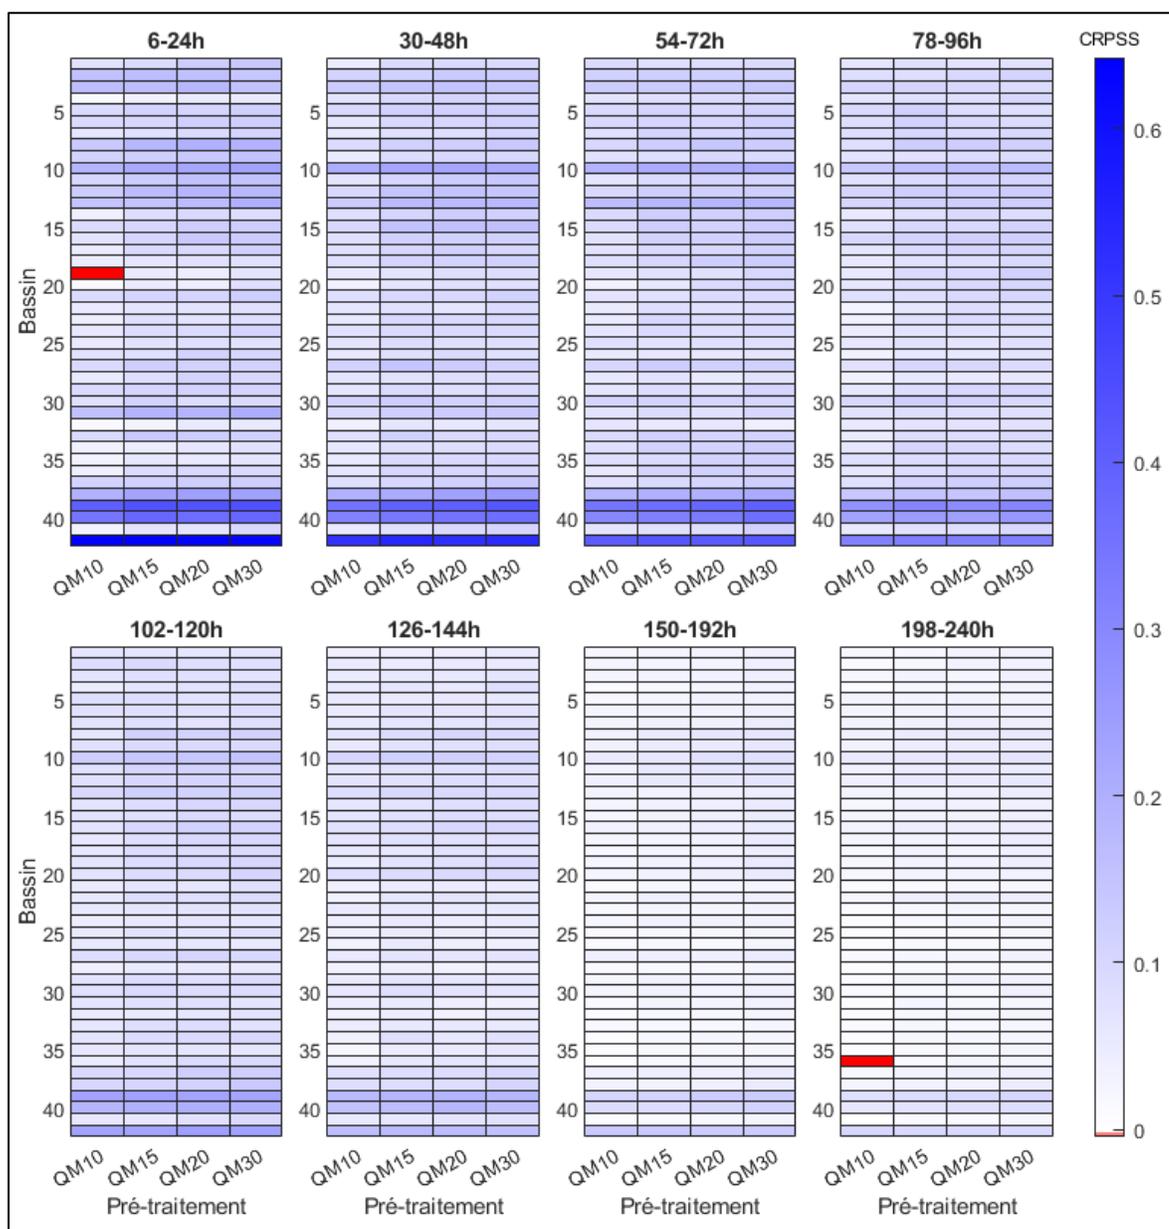


Figure 3.2 Cartes thermiques représentant les CRPSS des prévisions de température prétraitées pour des tailles de fenêtres différentes et des horizons prédictifs regroupés, les teintes rouges représentent des CRPSS négatifs, les teintes bleues des CRPSS positifs

3.1.2 Performances du prétraitement des prévisions météorologiques par pas de temps et saisons

Les valeurs de précipitations et de températures changeant chaque saison, une représentation des performances des méthodes de prétraitement est proposée en fonction des saisons. En effet, un grand nombre de variables (humidité, irradiation solaire, etc.) prenant des valeurs très différentes en fonction des saisons, il se peut que les prévisions de précipitations et de température démontrent une plus ou moins bonne précision en fonction des saisons. Les Figures 3.3 et 3.4 représentent, pour un bassin particulier, les performances moyennes au regard du score CRPS des prévisions brutes et post-traitées pour chaque saison et chacun des quarante pas de temps de 6 h que constituent les prévisions (allant de 6 h à 240 h, soit 10 jours). Les saisons se décomposent comme suit : DJF (hiver, Décembre-Janvier-Février), MAM (printemps, Mars-Avril-Mai), JJA (été, Juin-Juillet-Août) et SON (automne, Septembre-Octobre-Novembre). Le cas particulier du bassin n°31 est présenté ici, cependant il n'est pas nécessairement représentatif des phénomènes observés chez tous les bassins de la présente étude.

3.1.2.1 Performances du prétraitement des prévisions de précipitations par pas de temps et saisons

La Figure 3.3 représente les performances moyennes des prévisions de précipitations brutes et post-traitées par pas de temps et par saisons. Les courbes noires en pointillés représentent les CRPS des prévisions brutes, les courbes bleues représentent les CRPS des prévisions post-traitées par la méthode QM10, les courbes rouges QM15, les courbes jaunes QM20 et les courbes mauves QM30.

D'après les courbes des CRPS moyens, on observe dans un premier temps une claire instabilité concernant la justesse des prévisions brutes et post-traitées au printemps et à l'été. Celles-ci sont particulièrement flagrantes en été, faisant varier les CRPS moyens des prévisions de près de 0.5 mm (environ 50 % du CRPS moyen maximum en été) en seulement deux pas de temps (12 h) à partir de l'horizon 72 h. Un cycle de période 24 h (quatre pas de temps) s'installe alors

dans les performances des prévisions. En été et au printemps, les pics de CRPS se produisent à chaque multiple de 4 pas de temps, à $t+48$ h, $t+72$ h, $t+96$ h et ainsi de suite. Cela signifie qu'ils se produisent toujours pour les événements à 18 h, heure réelle. Ces instabilités sont également présentes à l'automne, quoique moins marquées. Cependant, en automne, ce cycle de période 24 h voit ses pics se produire à partir de l'horizon 84 h, c'est-à-dire pour des événements à 6 h heure réelle.

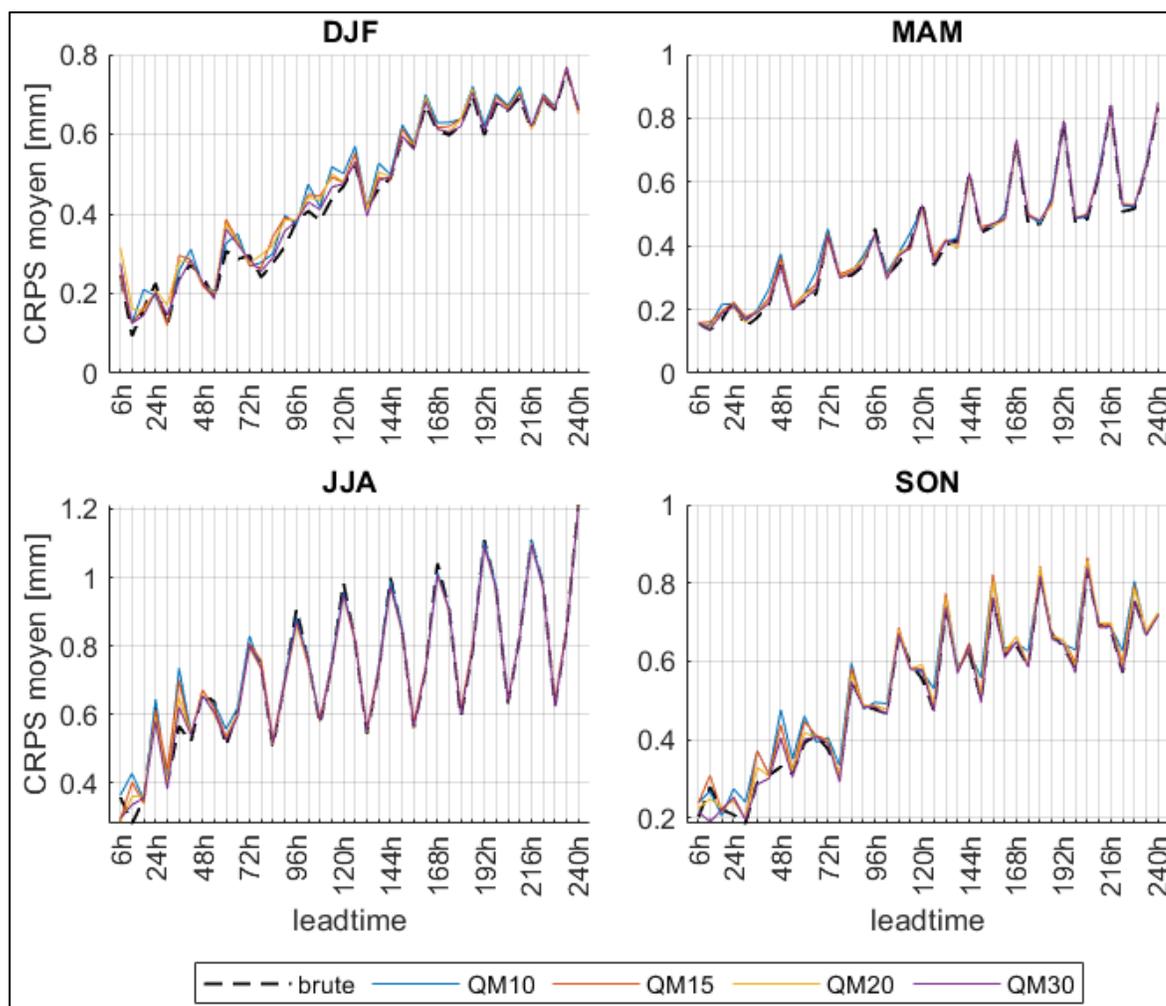


Figure 3.3 CRPS moyens pour chaque horizon prédictif (« lead-time ») qui composent les prévisions de précipitations, chaque graphe représente une saison particulière de l'année 2020, pour le bassin n°31. Les courbes en pointillés noirs représentent les observations, les courbes bleues, les prévisions prétraitées avec la méthode QM10, en rouge QM15, en jaune QM20 et en mauve QM30

Dans le cas du bassin n°31, le prétraitement a tendance, en moyenne, à augmenter le CRPS aux horizons prédictifs les plus courts, tandis que de légères diminutions sont observables à des horizons bien ciblés et cycliques également. En été, ces améliorations ont lieu tous les 24 h à partir de l'horizon 96 h pour toutes les méthodes sauf la méthode QM10. En automne, celles-ci ont lieu toutes les 24 h à partir de l'horizon 78 h, seulement pour la méthode QM30. Comme observé précédemment en Figure 3.1, les meilleures améliorations et les plus faibles détériorations sont obtenues pour la méthode QM30.

3.1.2.2 Performances du prétraitement des prévisions de température par pas de temps et saisons

La Figure 3.4 représente les performances moyennes des prévisions de température brutes et post-traitées par pas de temps et par saisons. Les courbes noires en pointillés représentent les CRPS des prévisions brutes, les courbes bleues représentent les CRPS des prévisions post-traitées par la méthode QM10, les courbes rouges QM15, les courbes jaunes QM20 et les courbes mauves QM30.

Nous observons, tout comme pour les prévisions de précipitations en Figure 3.3, une certaine instabilité dans les performances des prévisions de température brutes en Figure 3.4, notamment pendant l'automne et l'hiver. Cependant, nous notons que ces instabilités sont bien moins prononcées que celles observées pour les précipitations. En automne, nous constatons que le cycle est présent sur toute la longueur des prévisions, tandis qu'en hiver, il apparaît à partir de l'horizon 72 h. On attribue ces cycles concernant les performances des prévisions de température plus facilement à la capacité du modèle climatique à effectuer des prévisions de jour ou de nuit, alors que pour les précipitations, cette caractéristique n'est pas aussi évidente. Comme montré en Figure 3.2, il y a effectivement des améliorations considérables apportées par le prétraitement, quelle que soit la fenêtre.

Toutefois, on constate que le prétraitement ne montre pas la même efficacité pour toutes les saisons. Effectivement, les performances des prévisions post-traitées par rapport aux prévisions brutes sont particulièrement notables en été et en automne. Ces améliorations dues

au prétraitement sont spécifiquement importantes pour les horizons prédictifs courts. En automne, nous observons une diminution des CRPS d'une valeur entre 25 % et 50 % jusqu'à un horizon 120 h. Cependant, le gain en précision diminue au-delà de 120 h, se restreignant à des valeurs entre 5 % et 20 %. De plus, les horizons prédictifs de 120 h, 144 h, 168 h, 192 h, 216 h et 240 h ne connaissent aucune amélioration notable via le prétraitement. En été, cette absence d'améliorations via le prétraitement à ces horizons précis survient dès le début des prévisions, à chaque multiple de 24 h. Nous remarquons que la nature cyclique des performances des prévisions est atténuée par le prétraitement jusqu'à l'horizon 48 h, puis exacerbée par le prétraitement au-delà de cet horizon.

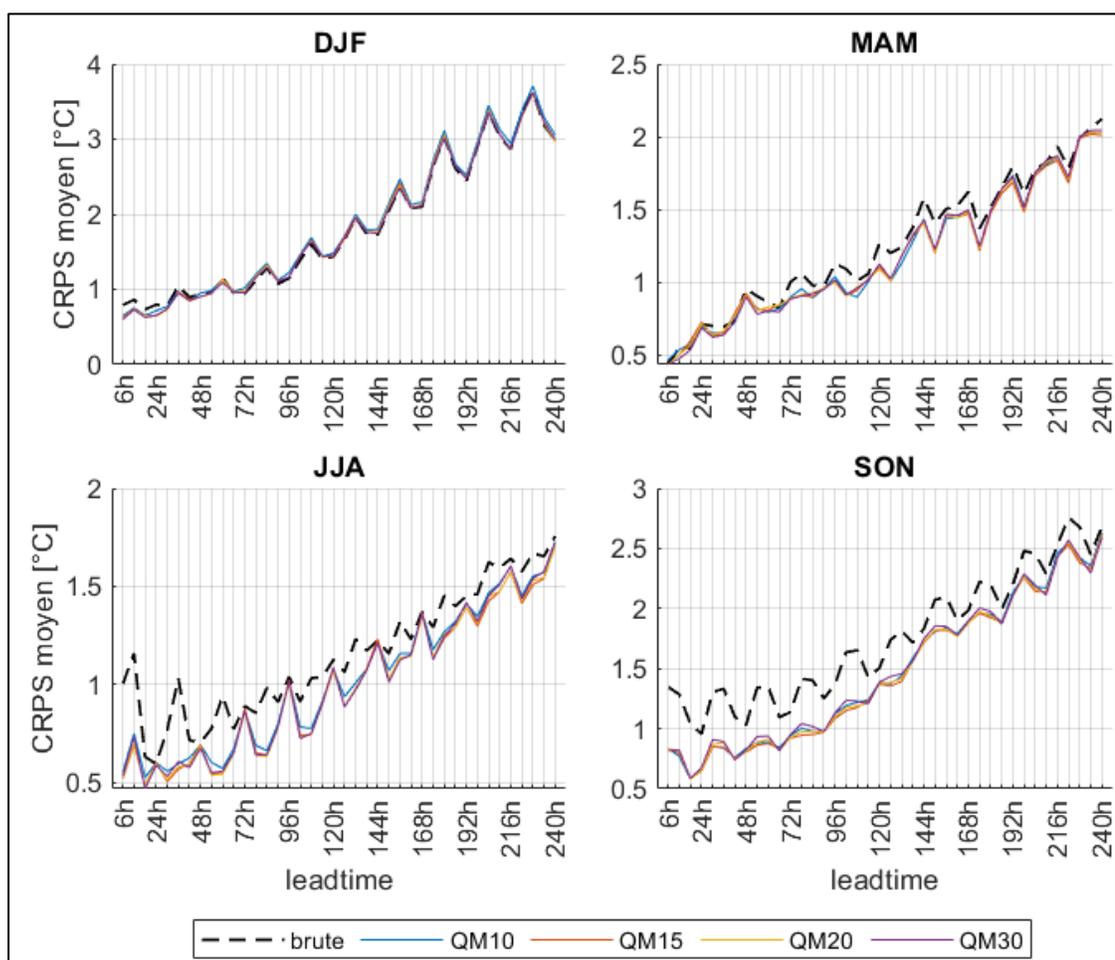


Figure 3.4 CRPS moyens pour chaque horizon prédictif (« lead-time ») qui composent les prévisions de température, chaque graphe représente une saison particulière de l'année 2020, pour le bassin n°31. Les courbes en pointillés noirs représentent les observations, les courbes bleues, les prévisions prétraitées avec la méthode QM10, en rouge QM15, en jaune QM20 et en mauve QM30

Au printemps, les améliorations sont très faibles ; les seules améliorations remarquables se trouvent entre les horizons de 48 h et 168 h, mais les diminutions du CRPS moyen ne dépassent pas les 10 %. Concernant l'hiver, très peu ou aucune amélioration n'est apportée par le prétraitement.

Comme le suggérait la Figure 3.2, nous ne distinguons pas de différence notable entre les performances des différentes méthodes de prétraitement. Les courbes représentant les CRPS moyens des prévisions post-traitées sont confondues, quels que soient la saison et l'horizon prédictif.

3.2 Performances des prévisions hydrologiques

Tel qu'il a été décrit précédemment, les prévisions hydrologiques sont obtenues en effectuant des simulations à partir de prévisions météorologiques. Cette section présente les résultats des simulations hydrologiques à partir de huit modèles ayant d'une part comme intrants les prévisions météorologiques prétraitées, et d'autre part les prévisions météorologiques brutes. Les simulations ayant comme intrants les prévisions météorologiques brutes voient leurs extrants (les débits simulés) post-traités de la même manière que précédemment. Cela signifie que pour une prévision hydrologique à un jour donné de l'année 2020, une correction par quantile mapping empirique est calibrée à partir d'une fenêtre autour de ce jour avec un rayon de plus ou moins 10, 15, 20 ou 30 jours dans les années 2015 à 2019.

3.2.1 Calibration des modèles hydrologiques

Le Tableau 3.1 présente les scores NSE des huit modèles hydrologiques à la suite de l'étape de calibration telle que définie précédemment. Pour les cases en rouge, $NSE < 0,3$, en jaune $0,3 < NSE < 0,5$, en blanc $0,5 < NSE < 0,6$, en vert $0,6 < NSE < 0,7$, en bleu $0,7 < NSE < 0,85$ et en mauve $NSE > 0,85$.

Tableau 3.1 Scores NSE des modèles hydrologiques pour la méthode de calibration

Num	S (km ²)	CEQUEAU	GR5dt	HBV	HYMOD	IHACRES	MOHYSE	SIMHYD	TOPMODEL
1	2492	0,64	0,7	0,75	0,72	0,7	0,72	0,72	0,69
2	642	0,64	0,67	0,7	0,68	0,7	0,69	0,69	0,7
3	367	0,65	0,64	0,69	0,68	0,66	0,65	0,66	0,65
4	76	0,36	0,19	0,39	0,35	0,35	0,34	0,34	0,35
5	584	0,64	0,72	0,72	0,71	0,68	0,69	0,7	0,68
6	3334	0,68	0,73	0,72	0,72	0,69	0,7	0,72	0,69
7	1505	0,62	0,7	0,7	0,69	0,67	0,69	0,7	0,67
8	7930	0,76	0,76	0,73	0,72	0,73	0,73	0,74	0,73
9	646	0,65	0,69	0,67	0,65	0,64	0,64	0,66	0,64
10	769	0,72	0,77	0,74	0,75	0,7	0,74	0,76	0,72
11	514	0,65	0,68	0,65	0,65	0,64	0,65	0,66	0,64
12	610	0,72	0,74	0,72	0,68	0,7	0,71	0,71	0,72
13	1550	0,64	0,73	0,72	0,71	0,66	0,69	0,7	0,69
14	344	0,6	0,68	0,66	0,66	0,6	0,63	0,64	0,65
15	2163	0,77	0,81	0,79	0,79	0,75	0,77	0,78	0,78
16	5820	0,74	0,79	0,77	0,78	0,73	0,77	0,78	0,76
17	708	0,68	0,77	0,76	0,75	0,71	0,73	0,75	0,73
18	696	0,7	0,69	0,71	0,7	0,64	0,68	0,7	0,69
19	1152	0,75	0,76	0,76	0,76	0,7	0,74	0,76	0,75
20	821	0,7	0,42	0,76	0,75	0,7	0,75	0,74	0,76
21	4560	0,65	0,19	0,64	0,66	0,61	0,67	0,71	0,19
22	1331	0,82	0,8	0,82	0,78	0,75	0,81	0,8	0,71
23	5479	0,8	0,82	0,83	0,83	0,75	0,82	0,85	0,8
24	1163	0,8	0,8	0,81	0,81	0,76	0,81	0,82	0,8
25	1286	0,8	0,83	0,8	0,82	0,76	0,8	0,81	0,78
26	1263	0,81	0,82	0,81	0,81	0,77	0,79	0,81	0,79
27	632	0,73	0,78	0,79	0,79	0,75	0,76	0,79	0,77
28	188	0,77	0,78	0,78	0,79	0,73	0,75	0,78	0,75
29	194	0,71	0,69	0,67	0,71	0,62	0,67	0,71	0,69
30	205	0,79	0,8	0,78	0,79	0,73	0,78	0,8	0,78
31	1017	0,76	0,74	0,76	0,75	0,67	0,74	0,77	0,72
32	769	0,8	0,82	0,8	0,8	0,78	0,79	0,82	0,78
33	1387	0,74	0,77	0,78	0,79	0,72	0,76	0,76	0,73
34	4504	0,76	0,79	0,77	0,78	0,74	0,79	0,8	0,72
35	1546	0,71	0,72	0,7	0,71	0,63	0,7	0,71	0,7
36	646	0,75	0,74	0,74	0,74	0,68	0,73	0,75	0,74
37	328	0,7	0,67	0,68	0,68	0,62	0,67	0,69	0,68
38	1997	0,63	0,2	0,64	0,64	0,56	0,61	0,65	0,6
39	365	0,73	0,45	0,73	0,71	0,67	0,71	0,73	0,69
40	58,4	0,67	0,7	0,7	0,68	0,68	0,73	0,7	0,65
41	1107	0,66	0,67	0,66	0,66	0,58	0,63	0,66	0,65
42	24	0,55	0,27	0,58	0,54	0,48	0,25	0,54	0,54

Le Tableau 3.1 révèle que le bassin n°4 (76 km²) se distingue par des scores de Nash-Sutcliffe (NSE) inférieurs à 0,5 pour l'ensemble des huit modèles hydrologiques de l'étude. Cependant, les scores NSE excèdent régulièrement 0,6 pour la plupart des autres bassins quel que soit le HM (29 % des couples {HM, BV} entre 0,6 et 0,7 ; 56 % supérieurs à 0,7), indiquant de très

bonnes performances des jeux de paramètres pour tous les modèles. Les modèles GR5dt, HBV et SIMHYD se démarquent en obtenant les scores NSE les plus élevés pour respectivement 16, 10 et 9 bassins. En revanche, les modèles IHACRES et TOPMODEL ne surpassent jamais les autres en termes de NSE pour aucun des bassins analysés. Tout comme le bassin n°4, tous les HM calibrés ont davantage de difficultés à simuler les débits du bassin n°42 (très petit bassin, 24 km²).

3.2.2 Performances globales des prévisions hydrologiques post-traitées par méthodes

La Figure 3.5 est composée de huit cartes thermiques qui représentent les CRPSS médians des prévisions hydrologiques post-traitées. Pour un horizon prédictif donné, ici 48 h, une carte thermique est associée à chaque HM. Chaque ligne représente les CRPSS des prévisions post-traitées pour un des 42 bassins versants étudiés et chaque colonne la taille de fenêtre de la méthode de post-traitement par QM. Les teintes bleues indiquent une amélioration des prévisions post-traitées par rapport aux prévisions brutes, c'est-à-dire un CRPSS médian positif. Les teintes rouges indiquent une détérioration des prévisions post-traitées par rapport aux prévisions brutes, c'est-à-dire un CRPSS médian négatif. Un seul horizon prédictif est présenté ici, mais des résultats similaires, au regard de la comparaison entre les différentes tailles de fenêtres, sont obtenus pour chacun des 40 horizons prédictifs de la présente étude.

D'après les résultats présentés en Figure 3.5, pour un horizon prédictif et un modèle donné, les performances des prévisions hydrologiques varient peu en fonction de la méthode de post-traitement. En effet, pour un bassin donné, les CRPSS médians des prévisions post-traitées sont très similaires. On observe cependant qu'une tendance se dessine pour la plupart des bassins : plus la fenêtre sélectionnée pour le post-traitement est grande, meilleures sont les prévisions. En effet, dans le cas où les prévisions sont globalement améliorées, c'est-à-dire pour un CRPSS médian positif, les plus grandes améliorations sont souvent obtenues pour la méthode QM30. De même lorsque les performances des prévisions post-traitées sont détériorées, les plus faibles détériorations sont obtenues pour la méthode QM30.

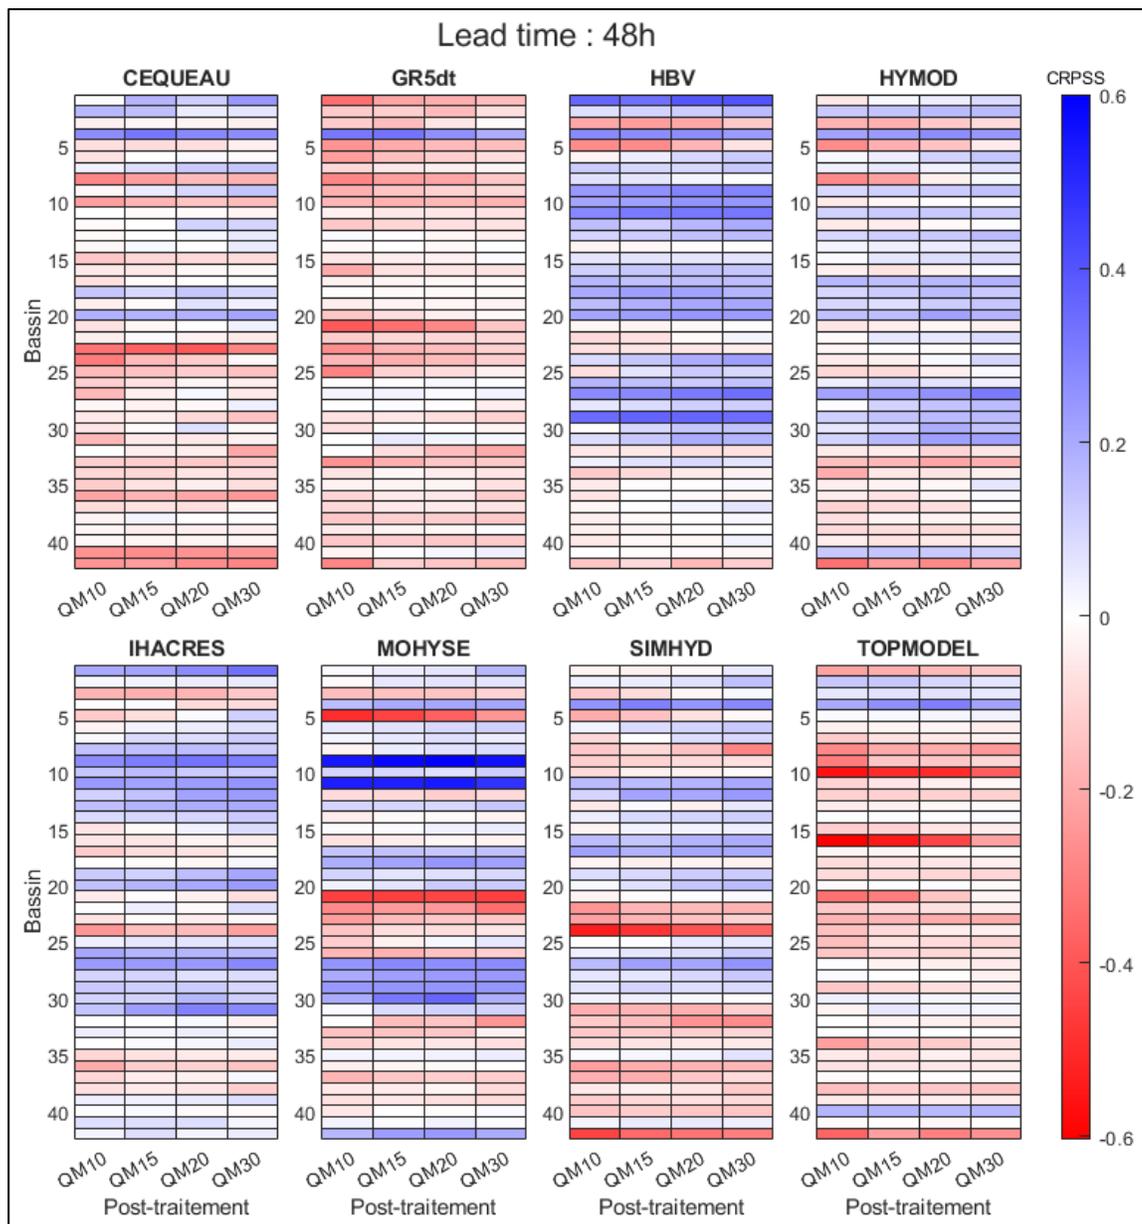


Figure 3.5 Cartes thermiques représentant les CRPSS des prévisions post-traitées à l'horizon (« lead-time ») 48 h, avec des tailles de fenêtre différentes (en colonne) et les 42 bassins (en ligne) de la présente étude, les teintes rouges représentent des CRPSS négatifs, les teintes bleues des CRPSS positifs

Dans certains cas, la méthode QM30 parvient même à produire des améliorations, bien que faibles, des prévisions alors que les méthodes à plus courtes fenêtres les détériorent. C'est le cas par exemple chez les prévisions du modèle CEQUEAU (bassin 8, 19, 28), GR5dt, bassin

41, HBV (bassins 22 37 et 40), HYMOD (bassins 22, 24 et 35), MOHYSE (bassin 25) et plus encore. Cependant, l'inverse peut également se produire, mais pour un nombre plus faible de bassins. C'est le cas pour les prévisions de la plupart des modèles pour le bassin 32 par exemple. Compte tenu de ces observations, pour certains cas particuliers, la méthode QM30 s'avère moins adaptée que les méthodes à plus courtes fenêtres au regard du CRPSS médian. Cependant pour la majorité des couples {HM ; BV}, cette méthode reste celle ayant eu les meilleures performances. Il est également attendu que la méthode QM améliore les performances moyennes des prévisions, mais ceci peut être réalisé au détriment de certains cas d'application où les modèles étaient déjà performants et la méthode QM applique un changement pour faire diverger la prévision qui était déjà satisfaisante.

3.2.3 Performances globales des prévisions hydrologiques post-traitées pour différents horizons prédictifs

La Figure 3.6 est composée de huit cartes thermiques qui représentent les CRPSS médians des prévisions hydrologiques post-traitées. Pour la méthode QM30, une carte thermique est associée à chaque HM. Chaque ligne représente les CRPSS des prévisions post-traitées pour un des 42 bassins versants étudiés et chaque colonne un horizon prédictif donné. Ici, les horizons étudiés sont les horizons 1 jour (24 h), 3 jours (72 h) 6 jours (144 h) et 10 jours (240 h). Les teintes bleues indiquent une amélioration des prévisions post-traitées par rapport aux prévisions brutes, c'est-à-dire un CRPSS médian positif. Les teintes rouges indiquent une détérioration des prévisions post-traitées par rapport aux prévisions brutes, c'est-à-dire un CRPSS médian négatif.

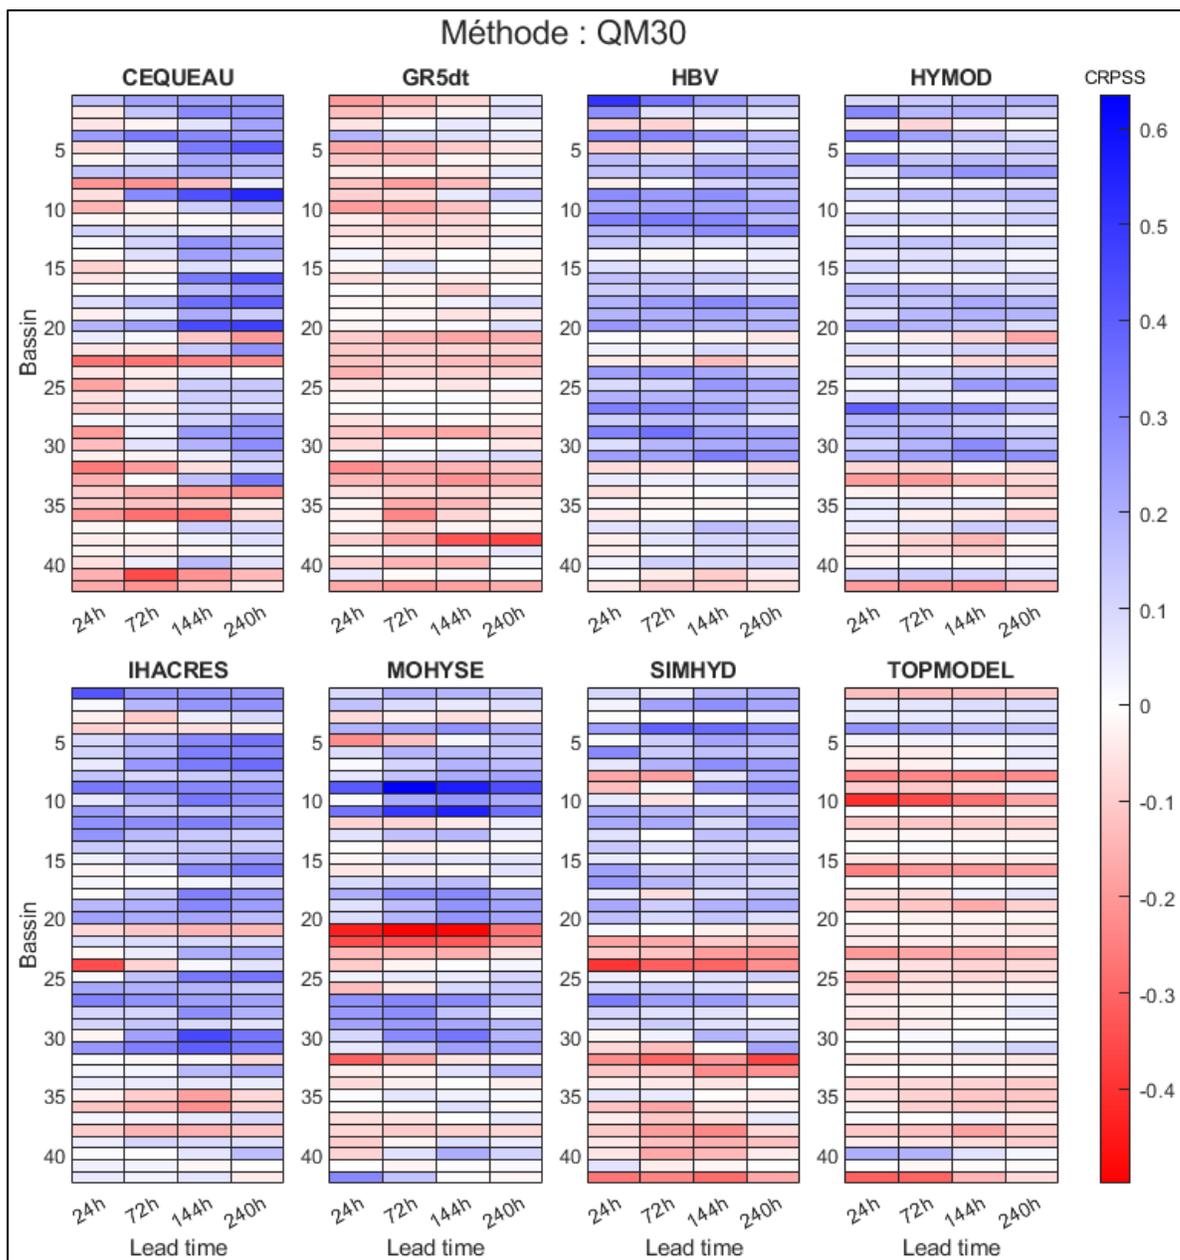


Figure 3.6 Cartes thermiques représentant les CRPSS des prévisions post-traitées par la méthode QM30 à différents horizons prédictifs (« lead-time », en colonne), et les 42 bassins (en ligne) de la présente étude, les teintes rouges représentent des CRPSS négatifs, les teintes bleues des CRPSS positifs

D'après la Figure 3.6, nous constatons que les performances des prévisions hydrologiques post-traitées varient considérablement en fonction du bassin et du HM. Pour un même bassin, nous observons que certains modèles hydrologiques présentent une nette amélioration de leurs performances médianes, tandis que d'autres voient leurs performances rester inchangées ou même se détériorer. Cependant, nous remarquons que, dans la grande majorité des cas, les tendances sont cohérentes, peu importe l'horizon prédictif. Par exemple, si le CRPSS est amélioré pour l'horizon prédictif de 24 h, il est très probable qu'il le soit également à l'horizon prédictif de 240 h.

Parmi les huit modèles analysés dans cette étude, nous constatons que cinq modèles (HBV, HYMOD, IHACRES, MOHYSE, SIMHYD) enregistrent une amélioration de leurs performances médianes dans plus de la moitié des bassins étudiés, et ce, à tous les horizons prédictifs, qu'ils soient très courts (24 h) ou plus longs (240 h). Les modèles GR5dt et TOPMODEL, en revanche, voient leurs performances médianes se détériorer ou rester inchangées dans la plupart des bassins.

Le modèle CEQUEAU, quant à lui, présente des variations dans les performances médianes de ses prévisions qui dépendent de l'horizon prédictif. Pour les bassins 25 à 30 et le bassin 32, les performances à court terme (24 et 72 h) se détériorent, avec des CRPSS négatifs de l'ordre de -0.1 à -0.3. Pour les horizons prédictifs plus longs, nous observons en revanche des améliorations des CRPSS médians, de l'ordre de 0.2 à 0.5, grâce aux prévisions post-traitées. Ce phénomène est également observé dans les prévisions des autres modèles, mais pour une variété moins importante de bassins. Le cas inverse, où les CRPSS passent de positifs à négatifs de manière notable, est observé, mais dans une moindre mesure. Le cas le plus marquant concerne les prévisions du modèle TOPMODEL pour le bassin 40.

3.2.4 Hydrogrammes prévisionnels des prévisions hydrologiques brutes, prétraitées et post-traitées pour des bassins particuliers

Les Figures 3.7, 3.8, 3.9 et 3.10 présentent les hydrogrammes prévisionnels des prévisions brutes, prétraitées (Météo QM) et post-traitées (Q_{sim} QM). Seules les moyennes des 1250 membres de chaque prévision sont représentées. Les hydrogrammes sont représentés à deux horizons prédictifs distincts, 24 et 192 h pour quatre bassins différents : 1 la rivière Châteauguay ; 34 : la rivière Batiscan ; 12 : la rivière Massawipi et 26 : la rivière Ouareau. Une prévision par jour de l'année 2020 est représentée, les volumes (Q) sont affichés en m³/s.

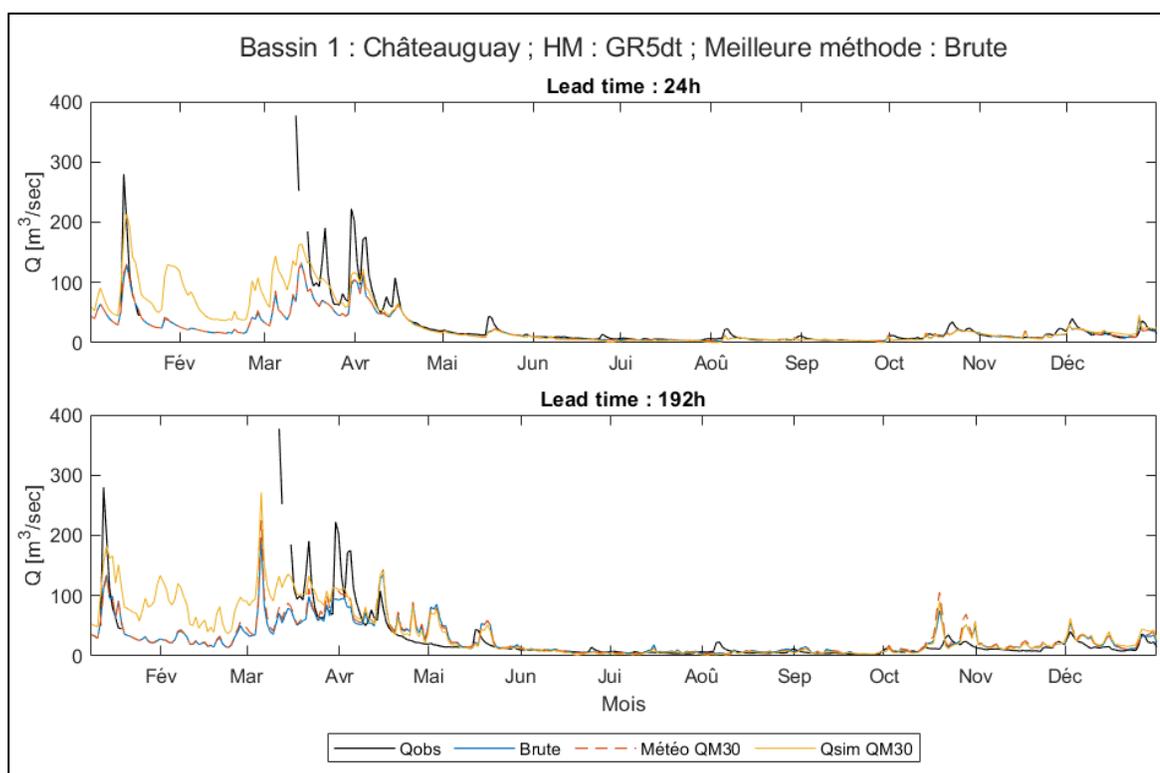


Figure 3.7 Hydrogrammes prévisionnels des prévisions brutes (en bleu), prétraitées (Météo QM30, en pointillés rouges) et post-traitées (QM30, en jaune) face aux observations (en noire) pour le bassin n°1. En haut, les prévisions sont à l'horizon prédictif (« lead-time ») 24 h, en bas l'horizon prédictif 192 h

Le choix du HM dont les prévisions sont représentées est basé sur le critère suivant : chaque jour où une prévision est émise, pour un bassin et une méthode donnée, le CRPS moyen des prévisions sur les 40 horizons prédictifs est calculé pour chacun des huit modèles

hydrologiques. Ainsi pour chaque couple {HM, méthode} étudié, on obtient chaque jour de l'année 2020 un CRPS « moyen » quotidien. Sur l'ensemble de l'année 2020, la médiane de ces CRPS quotidiens est déterminée pour chaque modèle. Le couple {HM, méthode} dont la médiane des CRPS quotidiens est la plus faible est sélectionné et jugé le meilleur selon ce critère.

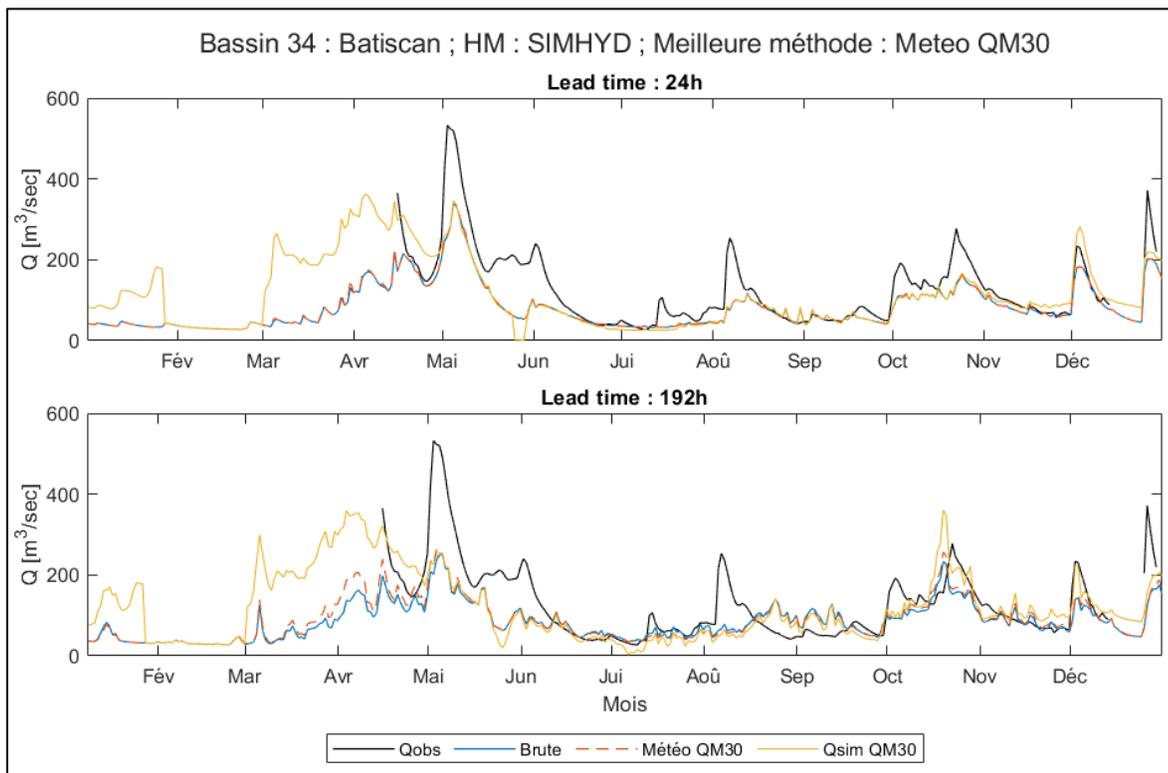


Figure 3.8 Hydrogrammes prévisionnels des prévisions brutes (en bleu), prétraitées (Météo QM30, en pointillés rouges) et post-traitées (QM30, en jaune) face aux observations (en noire) pour le bassin n°34. En haut, les prévisions sont à l'horizon prédictif (« lead-time ») 24 h, en bas l'horizon prédictif 192 h

Comme il a été défini précédemment, seules les méthodes « QM30 » sont représentées pour le prétraitement et le post-traitement. Trois cas particuliers sont représentés ici : un cas pour lequel les prévisions brutes restent les meilleures prévisions, un cas pour lequel les prévisions prétraitées sont les meilleurs et un cas pour lequel les prévisions post-traitées sont les meilleures.

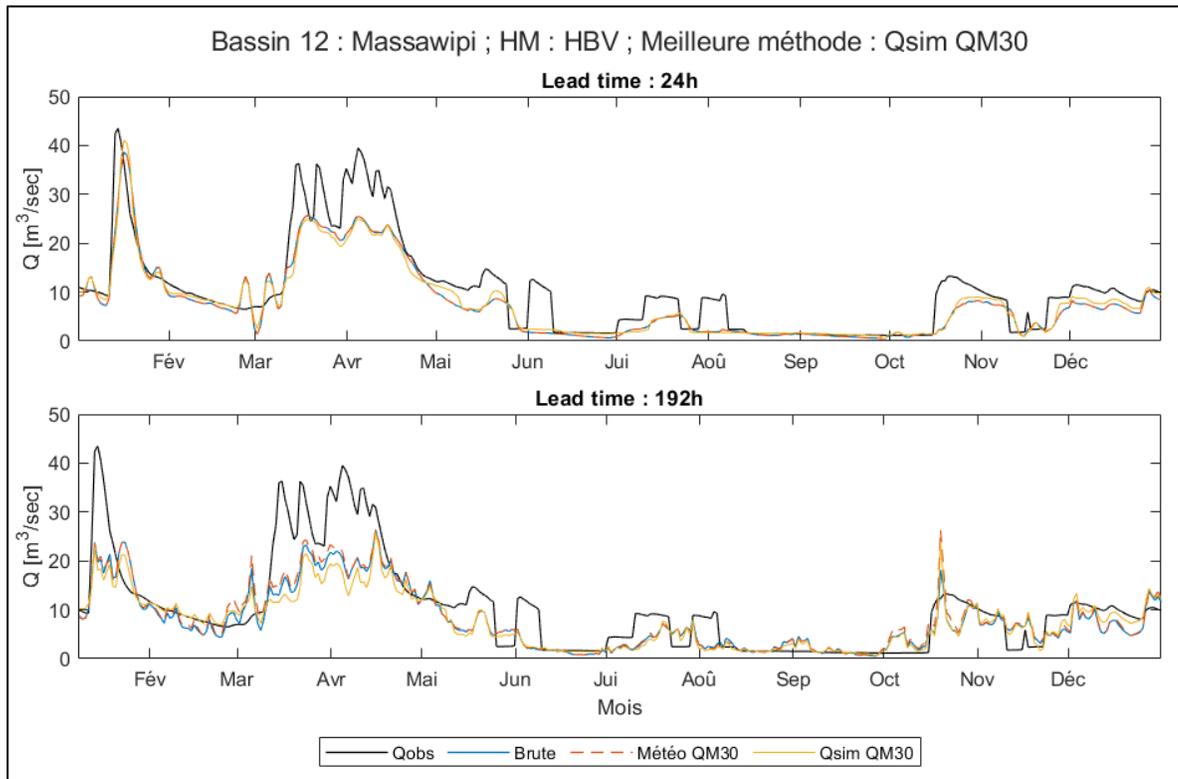


Figure 3.9 Hydrogrammes prévisionnels des prévisions brutes (en bleu), pré-traitées (Météo QM30, en pointillés rouges) et post-traitées (QM30, en jaune) face aux observations (en noire) pour le bassin n°12. En haut, les prévisions sont à l'horizon prédictif (« lead-time ») 24 h, en bas l'horizon prédictif 192 h

En examinant les hydrogrammes prévisionnels des Figures 3.7 à 3.10, nous remarquons que les prévisions brutes tendent clairement à sous-estimer les crues printanières. Cette tendance est d'autant plus marquée pour les horizons prédictifs longs (ici 192 h), et cela se vérifie pour chaque bassin examiné. De plus, les crues plus modérées survenues au deuxième semestre de l'année 2020 sont également sous-estimées aux horizons prédictifs courts. Toutefois, certaines crues, telles que celle de mi-octobre dans les bassins 12 et 34, sont surestimées par les prévisions brutes aux horizons prédictifs plus éloignés. En particulier pour le bassin 34, nous observons que la phase de récession de mi-août est nettement surestimée aux horizons prédictifs éloignés. Par ailleurs, les prévisions brutes ne détectent aucun signe avant-coureur de ce gonflement de mi-août.

Concernant le prétraitement, son influence sur les prévisions est limitée. Les prévisions ajustées après prétraitement restent très proches, voire identiques, aux prévisions brutes, surtout aux horizons prédictifs courts. Pour les horizons prédictifs plus éloignés, les différences deviennent légèrement plus marquées.

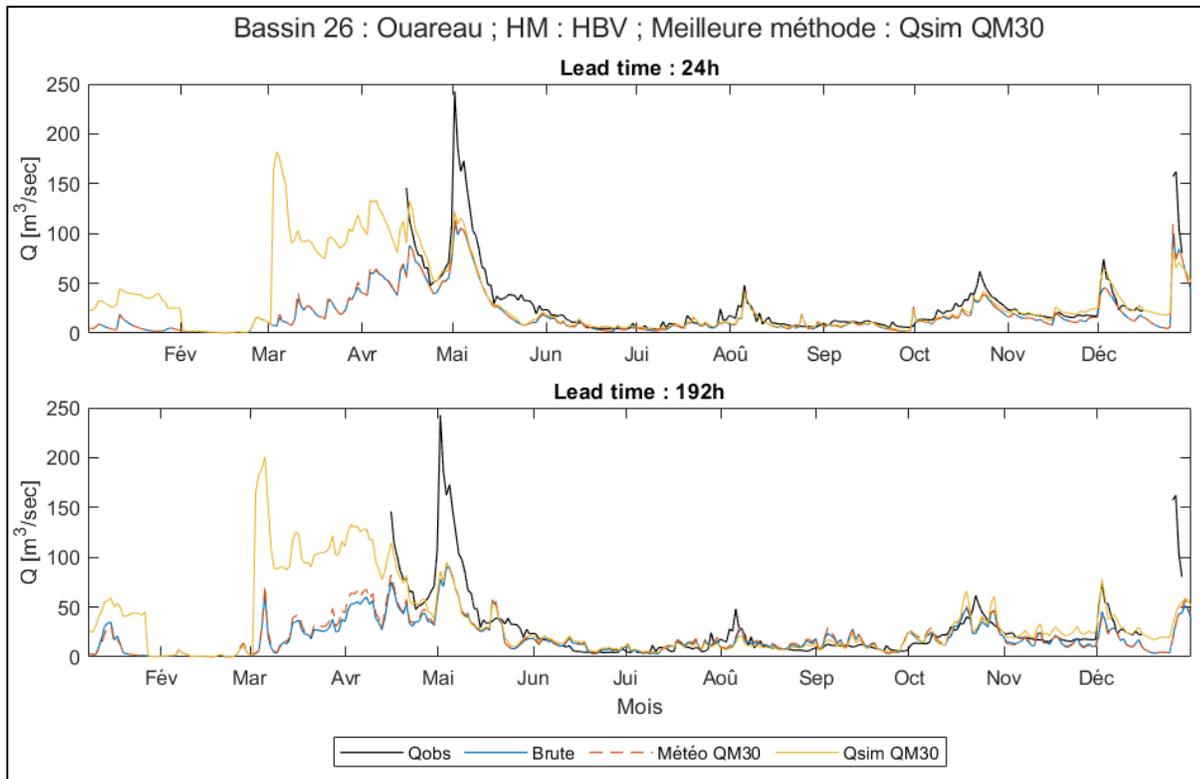


Figure 3.10 Hydrogrammes prévisionnels des prévisions brutes (en bleu), prétraitées (Météo QM30, en pointillés rouges) et post-traitées (QM30, en jaune) face aux observations (en noire) pour le bassin n°26. En haut, les prévisions sont à l'horizon prédictif (« lead-time ») 24 h, en bas l'horizon prédictif 192 h

Le post-traitement, quant à lui, a un impact plus prononcé sur les prévisions et réussit, dans certains cas, à corriger les volumes sous-estimés ou surestimés par les prévisions brutes. Cependant, ce processus n'est pas exempt de défauts. Parfois, le post-traitement tend à exacerber les erreurs des prévisions brutes, en sous-estimant ou surestimant davantage des prévisions déjà faibles ou élevées par rapport aux observations. De plus, des artefacts notables apparaissent dans les bassins où les observations ne sont pas disponibles (ici les bassins 1, 26 et 34). Pendant ces périodes, généralement en hiver, le post-traitement génère des prévisions

dont le volume est multiplié par un facteur 5 à 10 d'un jour à l'autre, sans qu'il y ait de réels signes avant-coureurs dans les prévisions brutes. Cet effet est particulièrement visible pour les bassins 34, entre février et mars et 26 entre mars et mi-avril. Les prévisions pour le bassin 12 ne présentent pas ces caractéristiques, car 100 % des observations de débits sont disponibles. Il est d'ailleurs le seul bassin de l'étude sans données manquantes dans ses débits observés. En effet, les débits de cette rivière sont fortement contrôlés, ce qui implique une connaissance des débits en tout temps. Les paliers présents notamment aux mois de juin, juillet et août témoignent d'ailleurs du contrôle actif réalisé sur cette rivière.

Bien que les prévisions brutes respectent généralement la synchronicité des crues, les modèles, y compris après le post-traitement, éprouvent souvent des difficultés à estimer correctement les volumes. Cependant, en ce qui concerne les premières crues de l'année, les pics sont mieux modélisés par les prévisions post-traitées que par les autres (bassin 1 : mi-janvier ; bassin 26 : mi-avril ; bassin 34 : mi-avril), bien que les décrues soient surestimées durant ces périodes pour les bassins 1 et 34. En revanche les crues liées à la fonte des neiges en mai, sont toujours largement sous-estimées pour les bassins 12, 26 et 34.

3.2.5 Performances des prévisions hydrologiques prétraitées et post-traitées pour des bassins particuliers

Dans cette partie, les Figures 3.11, 3.12, 3.13 et 3.14 représentent d'une part, en haut, les CRPS des prévisions brutes, prétraitées (« Météo QM ») et post-traitées (« Qsim QM ») des prévisions hydrologiques pour un bassin et un HM particulier. D'autre part, en bas, les CRPSS des prévisions prétraitées et post-traitées. Ces scores sont représentés sous la forme de boîtes à moustache pour dix horizons prédictifs différents allant de 24 h à 240 h. Pour la représentation des CRPS, les valeurs extrêmes au-delà de la plus grande moustache ne sont pas représentées. Pour la représentation des CRPSS, les valeurs en deçà de « -1 » ne sont pas représentées. Des CRPSS inférieurs à « -1 » indiquent des performances très médiocres des prévisions pré et post-traitées par rapport aux prévisions brutes. Les représentations ont ainsi été restreintes de cette manière afin d'apporter une meilleure visibilité sur la majeure partie des distributions des performances, car certaines valeurs extrêmes peuvent aller bien au-delà.

3.2.5.1 Cas où les prévisions brutes restent meilleures, bassin n°1 : Châteauguay

Pour le bassin n°1, ni le prétraitement ni le post-traitement (respectivement « Météo QM30 » et « Qsim QM30 ») n'ont produit des prévisions meilleures que les prévisions brutes lorsque l'on considère l'étendue complète de leur horizon prédictif.

En ce qui concerne les prévisions prétraitées, aucune différence notable (supérieure à 10 %) entre leurs CRPS médians et ceux des prévisions brutes n'est constatée pour les horizons prédictifs allant de 24 h à 216 h. La seule différence notable se situe à l'horizon 240 h, où les CRPS médians des prévisions brutes sont inférieures à ceux des prévisions prétraitées de 15 %. La différence de performances entre les prévisions brutes et prétraitées réside dans la distribution des CRPS qui est plus étalée vers les valeurs de CRPS élevées que celle des prévisions brutes. Cette différence de précision est de plus en plus marquée à mesure que l'horizon prédictif est éloigné. Les CRPSS médians donnent des indications similaires sur les performances des prévisions prétraitées. Pour les horizons prédictifs courts, inférieurs à 96 h, les CRPSS indiquent des performances très similaires entre les deux méthodes. Un quart des

CRPSS à l'horizon 96 h sont situés entre 0.09 et 0.28 indiquant de faibles améliorations, tandis qu'un autre quart des CRPSS est situé entre -0.05 et -0.24, indiquant de faibles détériorations. Au-delà de cet horizon, les distributions des CRPSS des prévisions post-traitées s'étalent davantage, bien que toujours centrées sur « 0 ». La portion basse des CRPSS indique des détériorations plus importantes que les améliorations que le prétraitement produit, c'est-à-dire une distribution légèrement asymétrique en faveur des CRPSS négatifs. En effet, à l'horizon 240 h, la valeur minimale (min) et le premier quartile (Q1) des CRPSS sont égaux à -0.61 et -0.18 tandis que le troisième quartile (Q3) et la valeur maximale sont égaux à 0.10 et 0.42.

Les CRPS médians des prévisions brutes sont toujours inférieurs aux CRPS des prévisions post-traitées jusqu'à l'horizon 192 h. De l'horizon 24 h à 144 h, les prévisions brutes obtiennent des CRPS médians entre 30 % et 45 % plus faibles que les prévisions post-traitées. À l'horizon 168 h, cet écart tombe à 18 % puis, 9 % à l'horizon 192 h. Au-delà de cet horizon, il n'y a pas de différence notable entre les CRPS des prévisions brutes et post-traitées. Pour les horizons prédictifs allant jusqu'à 192 h, les distributions des CRPS des prévisions post-traitées sont bien plus étalées vers des valeurs supérieures. Cette différence s'estompe à l'horizon 216 h pour enfin s'inverser à l'horizon 240 h. Les CRPSS indiquent également de très mauvaises performances des prévisions post-traitées pour les horizons prédictifs jusqu'à 144 h. En effet, les CRPSS médians sont tous négatifs pour ces horizons : -0.19 pour l'horizon 24 h à -0.07 pour l'horizon 144 h. De plus, les distributions sont lourdement asymétriques vers des valeurs négatives (à l'horizon 24 h, min = -2.24 et Q1 = -0.83). À l'horizon 144 h, min = -1.92 et Q1 = -0.61. Ces valeurs de CRPSS indiquent des performances très médiocres des prévisions post-traitées par rapport aux prévisions brutes. À partir des horizons 168 h et 192 h, les CRPSS médians deviennent nuls, mais présentent toujours une lourde asymétrie vers les valeurs négatives (min = {-1.7 ; -1.67} et Q1 = {0.52 ; -0.46} respectivement). Aux horizons 216 h et 240 h, les CRPSS médians sont très légèrement positifs, mais leur distribution présente toujours une grande asymétrie en faveur des CRPSS négatifs (min = {-1.25 ; -1.23} et Q1 = {-0.38 ; -0.32} respectivement).

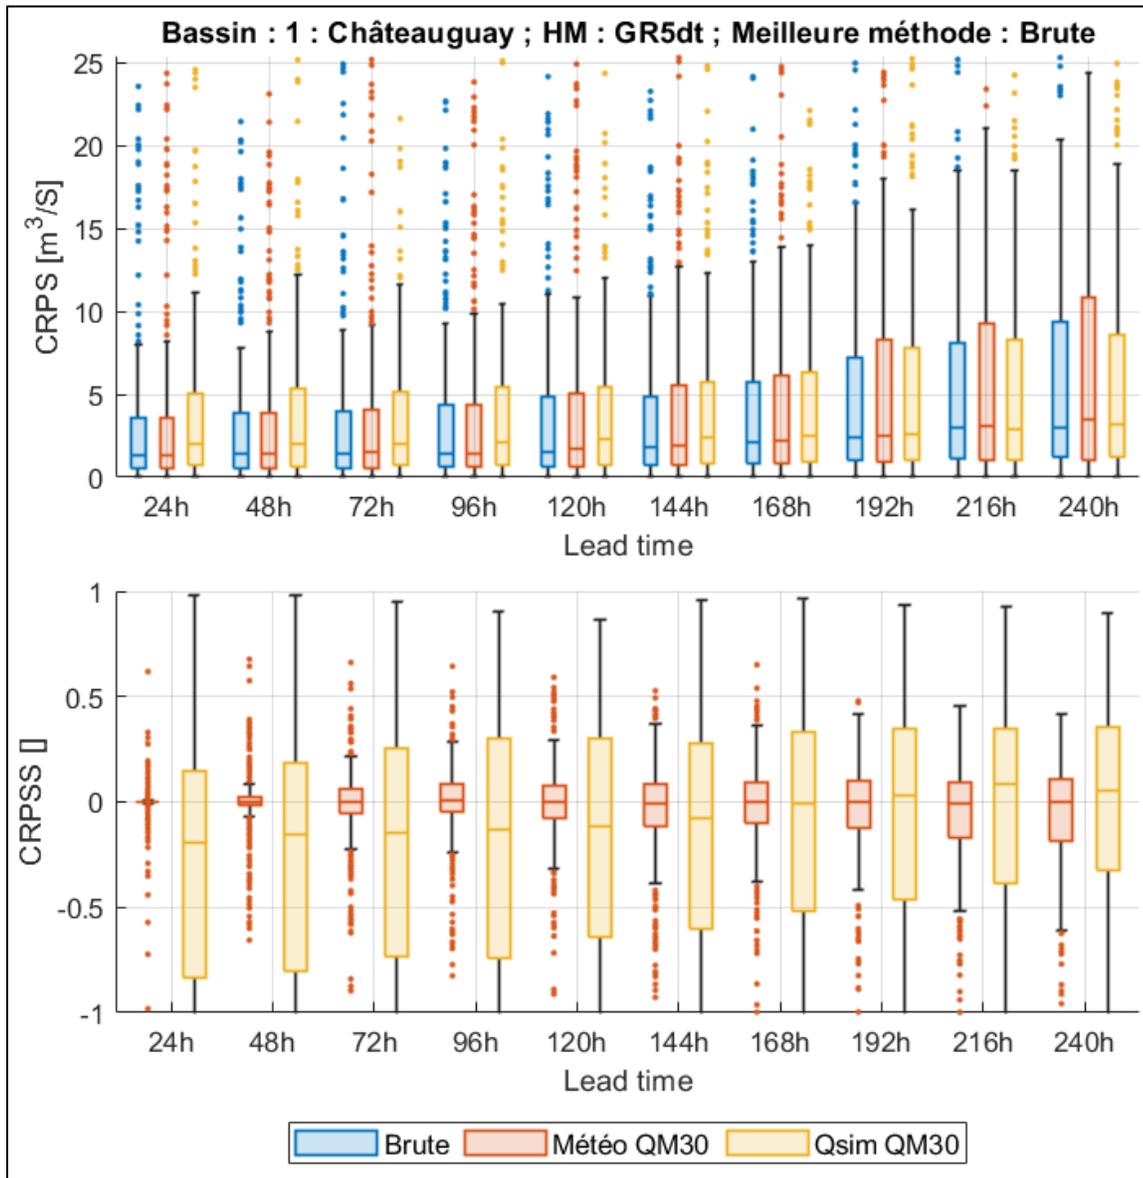


Figure 3.11 Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques pour le bassin n°1 sur l'année 2020. En haut : CRPS des prévisions brutes (en bleu), prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h. En bas : boîtes à moustaches des CRPSS des prévisions prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h

3.2.5.2 Cas où les prévisions prétraitées sont meilleures, bassin n°34 : Batiscan

Pour le bassin n°34, le prétraitement a obtenu les meilleures performances sur l'étendue complète des horizons prédictifs.

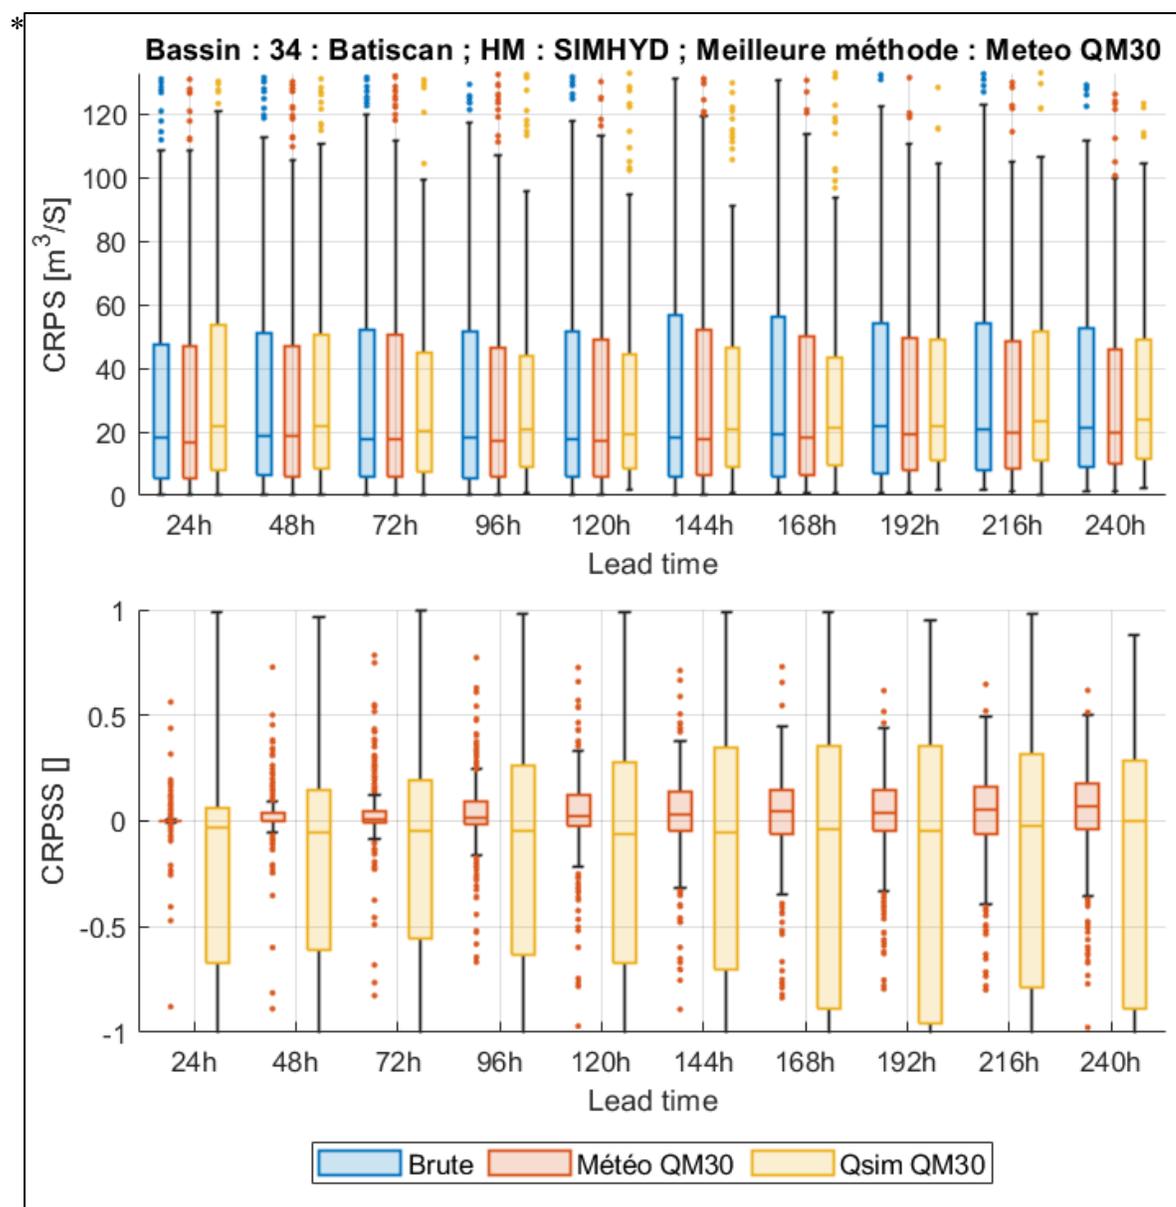


Figure 3.12 Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques pour le bassin n°34 sur l'année 2020. En haut : CRPS des prévisions brutes (en bleu), prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h. En bas : boîtes à moustaches des CRPSS des prévisions prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h

Concernant les CRPS des prévisions prétraitées, ces derniers affichent des performances légèrement supérieures pour chaque horizon prédictif. Bien que les CRPS médians des prévisions prétraitées soient légèrement inférieurs à ceux des prévisions brutes (diminution de 0 à 12 %), les distributions des CRPS des prévisions prétraitées sont plus restreintes vers les valeurs plus faibles. Néanmoins, les diminutions des CRPS restent marginales. Les CRPSS révèlent également des améliorations pour les prévisions prétraitées, particulièrement visibles à mesure que l'horizon prédictif s'éloigne. Pour les horizons de 24 h à 72 h, la totalité des CRPSS se situe entre -0.08 et 0.12 pour l'horizon de 72 h, à l'exception de quelques valeurs extrêmes. À partir de l'horizon de 96 h, les CRPSS médians augmentent progressivement avec l'éloignement de l'horizon, allant de 0.016 à 96 h à 0.07 à 240 h. En plus de cette légère amélioration des CRPSS médians, les distributions s'étalent légèrement tout en restant symétriques. À 96 h, $Q1 = -0.014$ et $Q3 = 0.09$, tandis qu'à 240 h, $Q1$ est de -0.04 et $Q3$ de 0.18, indiquant généralement de meilleures performances pour les prévisions prétraitées comparées aux prévisions brutes.

En ce qui concerne les prévisions post-traitées, les CRPS médians sont toujours supérieurs à ceux des prévisions brutes de 10 % à 20 %, quelle que soit l'étendue de l'horizon prédictif. Les écarts les plus importants sont observés pour les horizons prédictifs rapprochés. De plus, les distributions des CRPS des prévisions post-traitées sont plus concentrées vers des valeurs plus basses que celles des autres prévisions. Cependant, les CRPSS des prévisions post-traitées indiquent une détérioration des prévisions pour tous les horizons. Effectivement, bien que les médianes soient proches de zéro, quoique légèrement négatives, leurs distributions sont nettement asymétriques en faveur des CRPSS négatifs. Pour toute l'étendue des prédictions, les $Q1$ sont toujours inférieurs à -0.55, allant jusqu'à -0.95, tandis que les $Q3$ ne dépassent pas 0.35.

3.2.5.3 Cas où les prévisions post-traitées sont meilleures, bassin n°12 : Massawipi

Pour le bassin n°12 « Massawipi » qui est une rivière fortement contrôlée, les prévisions post-traitées se révèlent nettement supérieures.

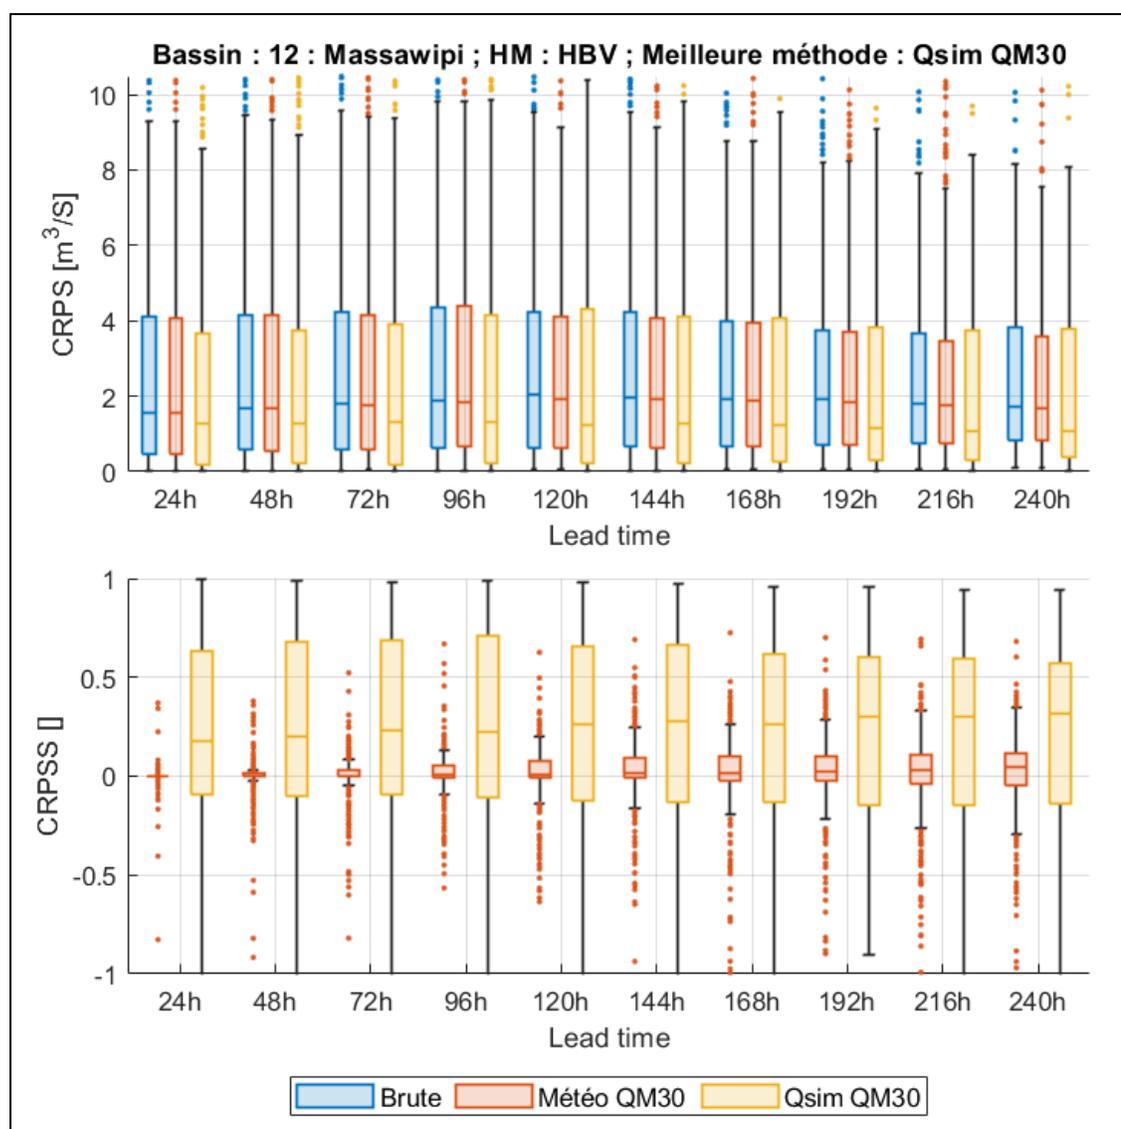


Figure 3.13 Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques pour le bassin n°12 sur l'année 2020. En haut : CRPS des prévisions brutes (en bleu), prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h. En bas : boîtes à moustaches des CRPSS des prévisions prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h

Nous constatons une baisse substantielle des CRPS médians par rapport aux prévisions brutes à chaque horizon prédictif, avec une diminution qui s'accroît à mesure que l'horizon s'éloigne (réduction de 20 % à l'horizon 24 h et de 37 % à l'horizon 240 h). Toutefois, même si les CRPS médians des prévisions post-traitées sont systématiquement plus faibles que ceux des prévisions brutes en augmentant l'horizon, la distribution de ces CRPS ne suit pas toujours cette tendance. Effectivement, jusqu'à l'horizon 96 h, les distributions des CRPS sont moins dispersées vers les valeurs élevées. Mais au-delà de cet horizon, les prévisions post-traitées tendent à montrer des CRPS élevés plus fréquemment, ou à une fréquence équivalente, par rapport aux prévisions brutes.

Les CRPSS confirment que le post-traitement apporte des améliorations considérables. Les CRPSS médians des prévisions post-traitées sont de 0.17 à l'horizon 24 h, et de 0.32 à l'horizon 240 h. Leurs distributions se concentrent majoritairement sur des valeurs positives des CRPSS, même si les Q1 restent négatifs et tendent à devenir plus négatifs à mesure que l'horizon s'allonge (Q1=-0.1 à l'horizon 24 h ; Q1=-0.14 à l'horizon 240 h).

Le prétraitement contribue également à l'amélioration des prévisions, bien que de manière moins marquée que le post-traitement. Les distributions des CRPS des prévisions prétraitées restent presque identiques à celles des prévisions brutes jusqu'à l'horizon 216 h. Cependant, au-delà de cet horizon, les distributions des CRPS des prévisions prétraitées se resserrent légèrement vers les valeurs basses. Les avantages du prétraitement sont plus visibles à travers les CRPSS, en particulier aux horizons plus éloignés. Ils atteignent leur apogée à l'horizon 240 h avec un CRPSS médian de 0.04, Q1 = -0.05 et Q3 = 0.11. Toutefois, les CRPSS demeurent nuls jusqu'à l'horizon 72 h.

3.2.5.4 Cas où les prévisions post-traitées sont meilleures, bassin n°26 : Ouareau

L'analyse des performances des méthodes de pré et post-traitement dans le cas où le post-traitement obtient les meilleurs résultats est aussi proposé pour une rivière dont le débit est plus faiblement contrôlé : le bassin n°26 de la rivière Ouareau.

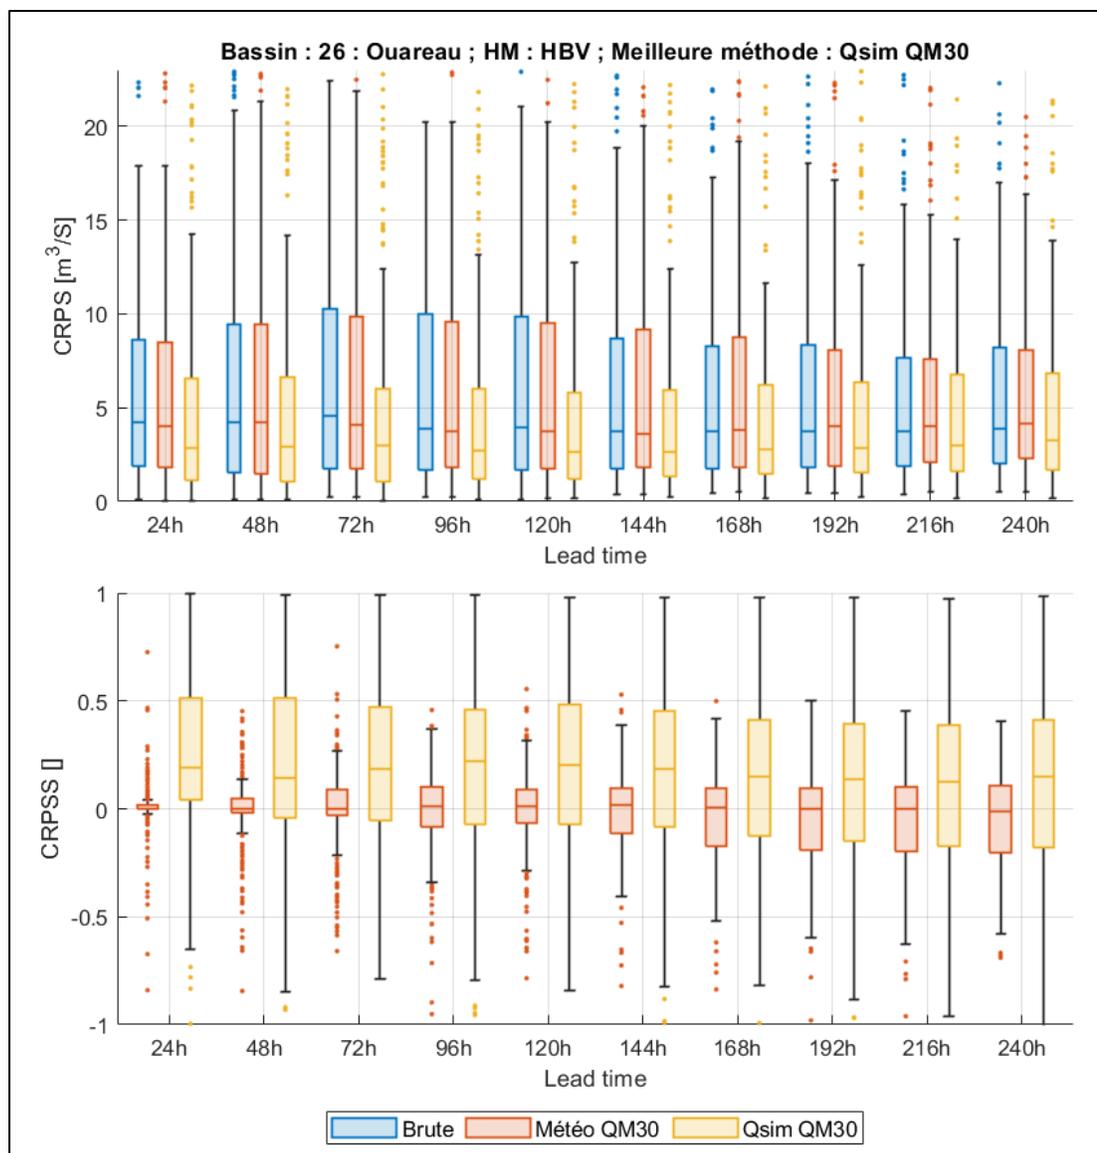


Figure 3.14 Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques pour le bassin n°26 sur l'année 2020. En haut : CRPS des prévisions brutes (en bleu), prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h. En bas : boîtes à moustaches des CRPSS des prévisions prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h

Tout comme dans le cas du bassin n°12, nous observons une diminution majeure des CRPS des prévisions à la suite du post-traitement. Cette diminution s'atténue à mesure que l'horizon prédictif est éloigné (réduction de 33 % des CRPS médians à l'horizon 24 h, 15 % à l'horizon 240 h). Le post-traitement affiche également de réels bénéfices dans les distributions des CRPS : celles-ci sont drastiquement restreintes vers les CRPS les plus faibles. La tendance concernant les CRPS médians est aussi observée dans leurs distributions : les distributions des CRPS des prévisions brutes et post-traitées sont d'avantages proches à mesure que l'horizon prédictif augmente.

Nous constatons aussi les améliorations drastiques du post-traitement en observant les CRPSS, dont les distributions sont majoritairement positives. Les CRPSS médians sont compris entre des valeurs de 0.14 (obtenu à l'horizon 48 h) à 0.22 (à l'horizon 96 h). Pour ces valeurs médianes, nous ne constatons aucune tendance haussière ou baissière monotone avec l'horizon prédictif. En effet : les CRPSS médians diminuent de l'horizon 24 h à 48 h puis augmentent jusqu'à l'horizon 96 h pour enfin légèrement diminuer jusqu'à l'horizon 216 h. Cependant les distributions des CRPSS ont tendance à se déplacer vers les valeurs négatives à mesure que l'horizon prédictif est éloigné, sans pour autant s'étaler dans leur majeure partie (à 24 h : $Q1 = 0.04$; $Q3 = 0.51$, à 240 h : $Q1 = -0.18$; $Q3 = 0.41$). Certaines fortes détériorations, bien que rares, sont toujours observées à tous horizons prédictifs comme en témoignent les moustaches inférieures avoisinant les « -1 ».

Le prétraitement ne montre pas de réelles améliorations des prévisions pour le bassin 26. Les CRPS médians connaissent une infime diminution dans les horizons prédictifs les plus proches. Cependant à partir des horizons entre 144 h et 168 h, les prévisions sont détériorées avec une légère augmentation des CRPS médians. Nous observons également ces résultats avec les distributions des CRPSS, qui sont plus étalées vers les valeurs négatives à partir de l'horizon 144 h, bien que les CRPSS médians soient nuls quel que soit l'horizon prédictif.

3.3 Meilleurs couples (modèle hydrologique — méthode)

L'histogramme dans la Figure 3.15 recense les performances optimales englobant tous les modèles et toutes les méthodes dans chaque bassin. Pour un bassin donné, les médianes CRPS quotidiennes sont déterminées pour les prévisions émises par chaque couple {HM ; méthode}. Le couple {HM ; méthode} ayant la médiane la plus basse est considéré comme le meilleur couple.

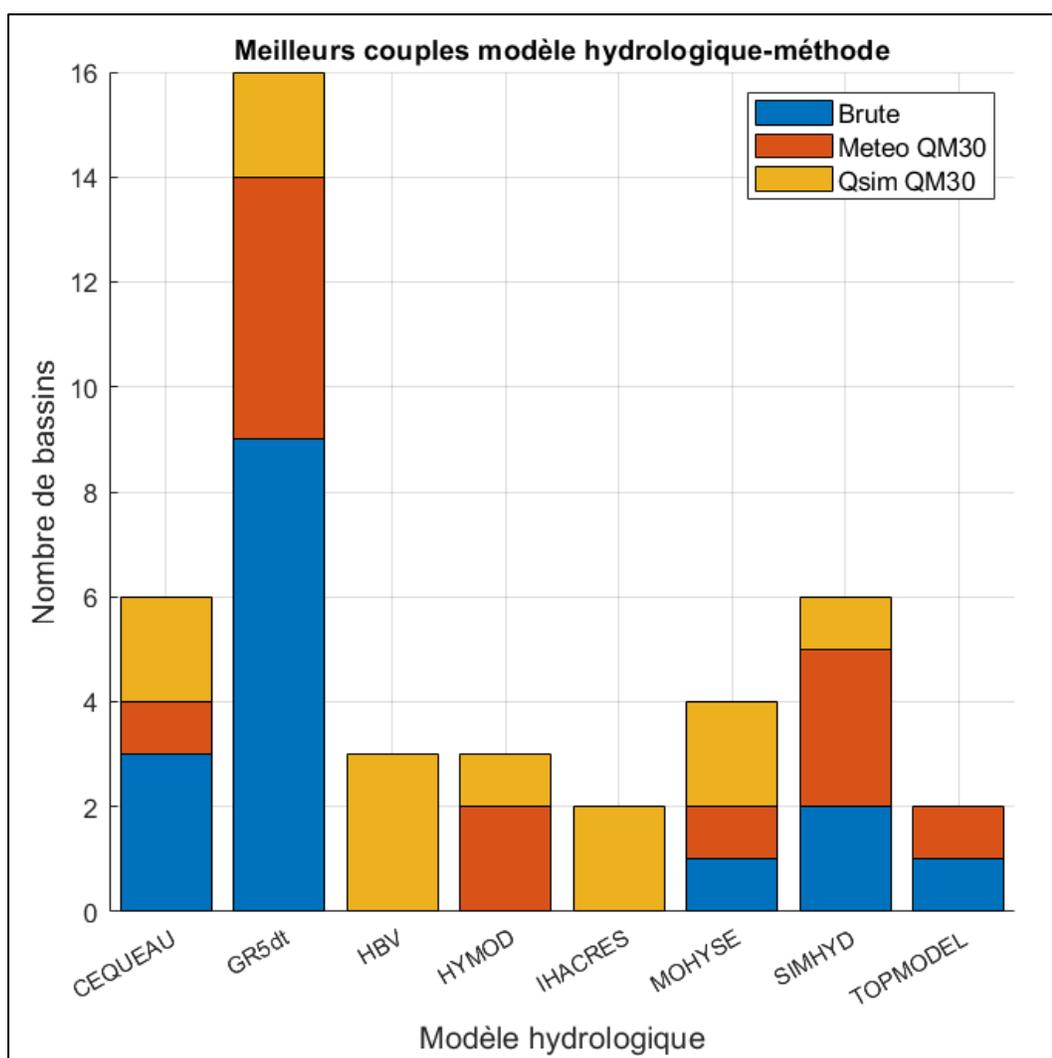


Figure 3.15 Histogramme empilé comptant le nombre de bassins où les modèles hydrologiques (en abscisse) sont les meilleurs. Les méthodes avec lesquelles ceux-ci ont obtenu les meilleures performances sont en bleu pour les prévisions brutes, en rouge pour les prévisions prétraitées (Météo QM30) et en jaune pour les prévisions post-traitées (Qsim QM30)

Au regard de la sélection par la médiane des CRPS quotidiens, le modèle GR5dt affiche les meilleures performances pour le plus grand nombre de bassins (16 bassins), toutes méthodes confondues. En effet, pour les prévisions brutes, GR5dt est le meilleur dans la grande majorité des cas (56 %, 9 bassins). Ses prévisions prétraitées sont meilleures dans 31.5 % des cas (5 bassins), et les prévisions post-traitées dans 12.5 % des cas (2 bassins).

Pour les modèles CEQUEAU et TOPMODEL, lorsqu'ils sont les plus performants, leurs performances brutes dominent dans 50 % des cas. Plus précisément, CEQUEAU se distingue dans 3 bassins sur 6 et TOPMODEL dans 1 bassin sur 2. Pour le modèle SIMHYD, les prévisions brutes sont les meilleures dans 33 % des cas, soit 2 bassins sur 6, tandis que pour MOHYSE, ses prévisions brutes sont les meilleures dans 25 % des cas, soit 1 bassin sur 4.

Les méthodes de pré et post-traitement montrent un avantage évident pour les modèles HBV, HYMOD et IHACRES. Ces modèles voient systématiquement leurs performances brutes surpassées par d'autres couples {HM ; méthode}. Toutefois, après les corrections de biais par la méthode QM, ces trois modèles parviennent à produire des prévisions meilleures que les autres. Pour le modèle HBV, les meilleures prévisions sont obtenues dans 3 bassins, toutes issues du post-traitement. Quant à HYMOD, il se distingue dans 2 bassins avec les prévisions prétraitées et dans 1 bassin avec les prévisions post-traitées. Pour IHACRES, les performances les plus élevées pour les deux bassins concernés sont obtenues après le post-traitement.

La carte en Figure 3.16 montre pour les simulations issues du modèle GR5dt, le couple {HM, méthode} ayant obtenu les meilleurs résultats du point de vue de la médiane des CRPS quotidiens.

Dépendamment de la taille des bassins, certaines méthodes montrent de meilleures performances que d'autres. Pour les bassins de petite taille (<500 km², n=10), les prévisions brutes se révèlent les plus performantes dans 50 % des cas. Les prévisions prétraitées suivent de près avec 40 % des cas. Seul un bassin, le bassin 30 avec le modèle CEQUEAU, enregistre ses meilleures performances avec les prévisions post-traitées.

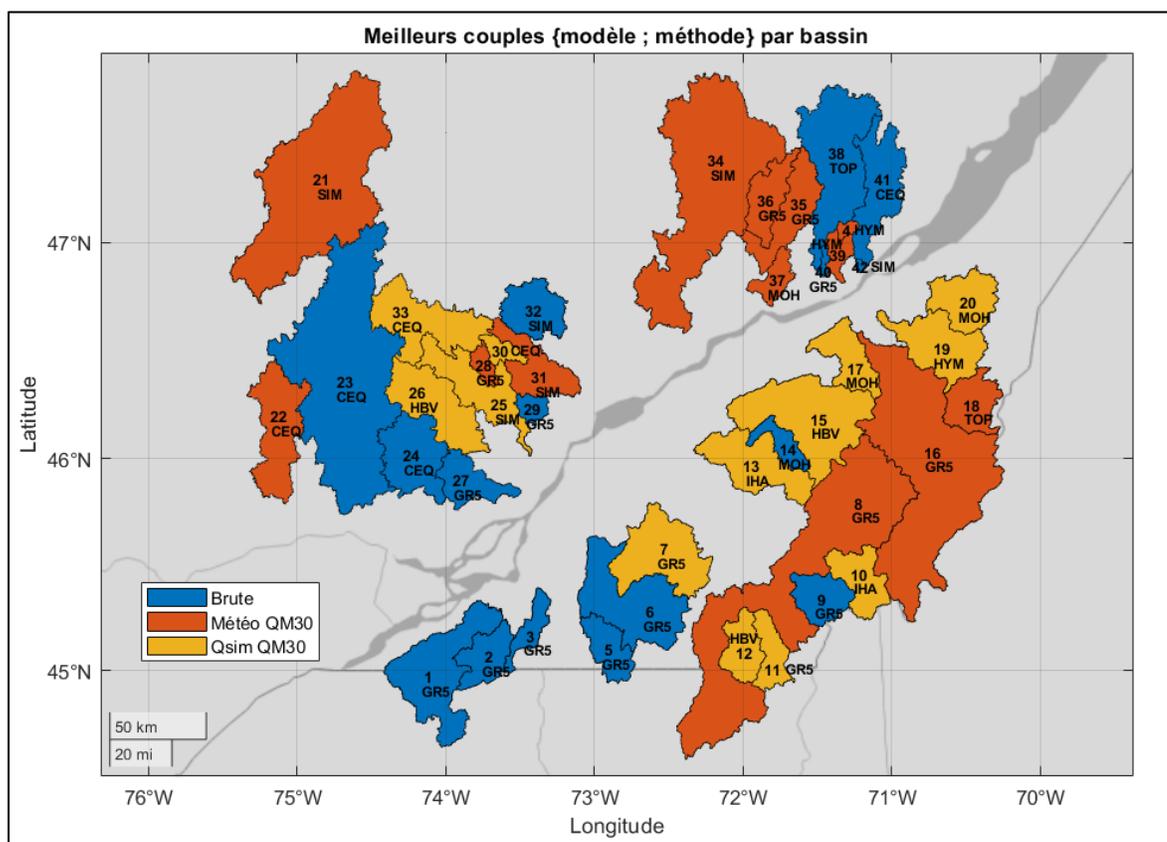


Figure 3.16 Carte indiquant pour chaque bassin quel modèle hydrologique est le meilleur. Les méthodes avec lesquelles le modèle a obtenu les meilleures performances remplissent le bassin en bleu pour les prévisions brutes, en rouge pour les prévisions prétraitées (Météo QM30) et en jaune pour les prévisions post-traitées (Qsim QM30)

Dans le cas des bassins de taille moyenne (entre 500 et 2000 km², n=25), les prévisions brutes dominent dans 32 % des cas (8 bassins), tandis que les prévisions prétraitées et post-traitées se distinguent respectivement dans 25 % (5 bassins) et 48 % (12 bassins) des cas.

Pour les bassins de grande taille ($>2000 \text{ km}^2$, $n=7$), les prévisions brutes obtiennent les meilleures performances dans 43 % des cas (3 bassins), et les prévisions prétraitées dans 57 % des cas (4 bassins). Aucun des grands bassins ne voit ses meilleures performances issues des prévisions post-traitées. Il est important de souligner que, pour les bassins situés au Nord (au-delà de 46.75°N), aucune prévision post-traitée ne se révèle meilleure que les autres méthodes, indépendamment de la taille du bassin. Parmi ces 11 bassins « nordiques », 7 affichent des performances supérieures avec les prévisions prétraitées et 4 avec les prévisions brutes. En outre, les bassins situés sous 46.75°N , dont les prévisions brutes sont jugées les plus performantes, se trouvent majoritairement au Sud et à l'ouest de la carte. À l'inverse, les bassins situés à l'est tendent à enregistrer des performances optimales avec le prétraitement et le post-traitement.

3.4 Fiabilité des prévisions brutes, pré et post-traitées

Les Figures 3.17 et 3.18 représentent les diagrammes de Talagrand des prévisions hydrologiques issues des huit modèles pour le Bassin n°26 de la rivière Ouareau aux horizons prédictifs 48 h (Figure 3.17) et 192 h (Figure 3.18). Chaque ligne représente les diagrammes de Talagrand d'un HM (par souci d'encombrement, les HM sont désignés par les trois premières lettres de leur acronyme), chaque colonne la méthode avec laquelle sont générées les prévisions (Brute, Météo QM30 et Q_{sim} QM30). Les diagrammes de Talagrand en bleu signifient que l'hypothèse nulle citée en section 3.8.3 n'est pas rejetée par le test de KS (c'est-à-dire $p > 0.05$).

À l'horizon prédictif 48 h, aucun HM ne génère de prévisions fiables, quelle que soit la méthode utilisée. Une analyse des diagrammes de Talagrand montre une sous-dispersion importante dans tous les modèles, avec des formes qui s'éloignent considérablement d'une distribution uniforme, indiquant également un biais négatif prononcé. Les scores ABDU et les p-values du test de Kolmogorov-Smirnov (KS) révèlent que le prétraitement ne modifie pas notablement la forme des diagrammes de Talagrand. Le post-traitement, bien qu'ayant un effet légèrement plus perceptible, notamment un gain léger gain en symétrie pour les prévisions

issues des modèles GR5dt, HBV et HYMOD. Ce modeste gain se manifeste cependant dans les valeurs quasi inchangées des scores ABDU et des p-values. Cette caractéristique des diagrammes de Talagrand, montrant une sous-dispersion et un biais négatif, est commune à tous les bassins pour les horizons prédictifs les plus courts, généralement inférieurs à 96 h, quels que soient le HM ou la méthode de traitement employés.

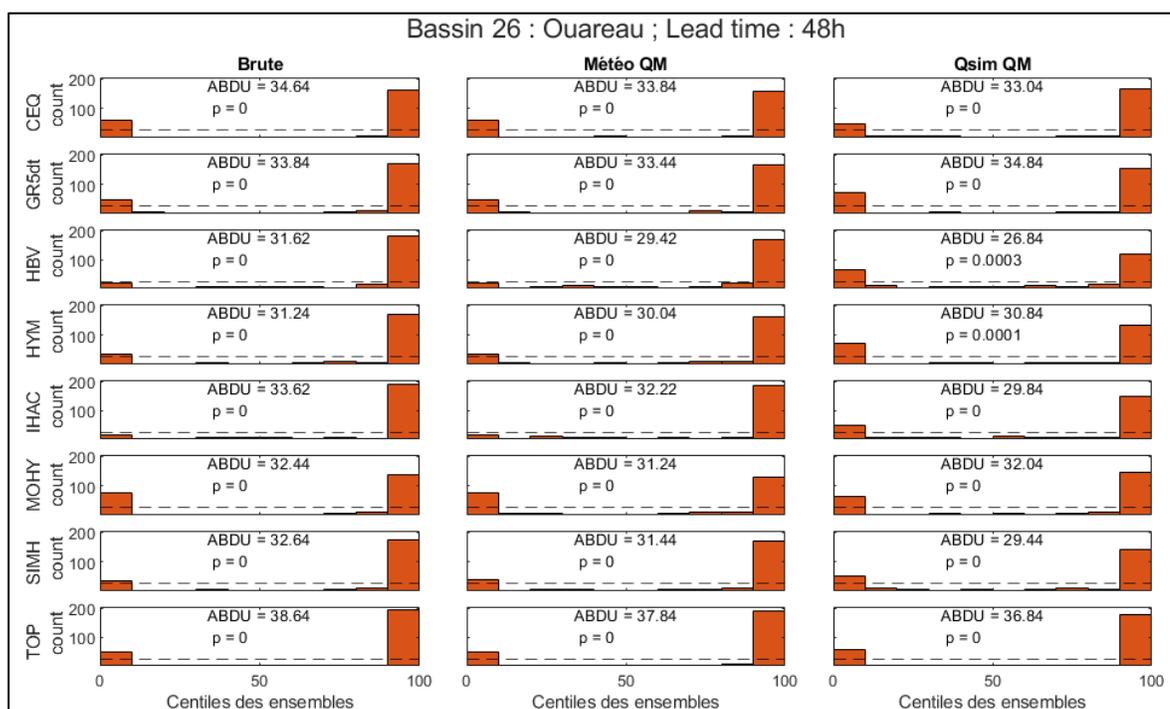


Figure 3.17 Diagrammes de Talagrand pour les prévisions brutes, prétraitées et post-traitées de l'année 2020 par les huit modèles hydrologiques au bassin n°26 à l'horizon prédictif (lead time) 48 h. En rouge, le test de Kolmogorov-Smirnov rejette l'hypothèse d'uniformité, en bleu elle n'est pas rejetée

Aux horizons prédictifs éloignés, comme le montre la Figure 3.18, les diagrammes de Talagrand révèlent des caractéristiques plus diversifiées des prévisions. Selon les modèles hydrologiques, les prévisions issues du prétraitement et du post-traitement peuvent varier remarquablement par rapport aux prévisions brutes.

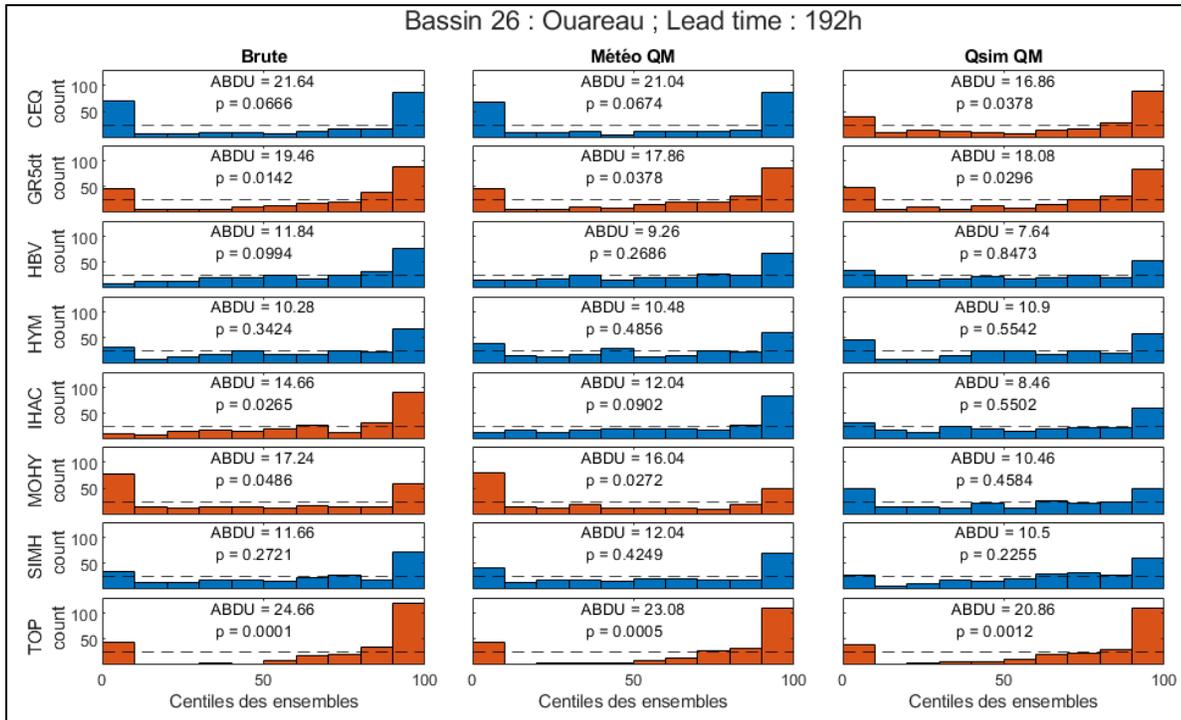


Figure 3.18 Diagrammes de Talagrand pour les prévisions brutes, prétraitées et post-traitées de l'année 2020 par les huit modèles hydrologiques au bassin n°26 à l'horizon prédictif (lead time) 192 h. En rouge, le test de Kolmogorov-Smirnov rejette l'hypothèse d'uniformité, en bleu elle n'est pas rejetée

Concernant le prétraitement, il corrige efficacement les biais négatifs du modèle HYMOD en rectifiant la dysmétrie de son diagramme de prévisions brutes. Bien que le modèle SIMHYD voie son biais corrigé dans une certaine mesure, avec une augmentation de son p-value, mais aussi une légère hausse de son score ABDU, une asymétrie persiste. Cependant, les biais marqués négativement de HBV et IHACRES restent, même si leurs diagrammes de prévisions affichent une diminution des scores ABDU et une augmentation des p-value, suggérant un progrès vers l'uniformité. Cela s'applique aussi à GR5dt, qui semble moins biaisé que les deux modèles précédents. Néanmoins, le prétraitement ne montre aucune amélioration notable pour les prévisions générées par MOHYSE et TOPMODEL.

Le post-traitement, de son côté, entraîne des modifications considérables dans les distributions représentées par les diagrammes de Talagrand. Des améliorations sont particulièrement

notables pour les prévisions des modèles HBV, IHACRES et MOHYSE. Pour ces modèles, les biais semblent entièrement corrigés, se traduisant par une nette augmentation des p-values et une réduction importante des scores ABDU. HBV bénéficie le plus du post-traitement, avec une distribution presque parfaitement uniforme. HYMOD présente également une amélioration de sa distribution, visible par une hausse notable de son p-value, bien qu'accompagnée d'une très légère augmentation de l'ABDU. Les prévisions de SIMHYD montrent une amélioration en termes d'ABDU, mais celles-ci s'accompagnent d'une asymétrie accrue et donc d'une baisse du p-value associé. CEQUEAU, quant à lui, voit ses prévisions se détériorer ; malgré une réduction de l'ABDU, une asymétrie est introduite par le post-traitement, semblant ajouter un biais négatif aux prévisions. Peu de changements sont observés pour GR5dt et TOPMODEL, bien que leurs scores ABDU aient légèrement diminué et leurs p-values augmentés. Même si le post-traitement corrige efficacement les biais dans les prévisions de certains modèles, une sous-dispersion notable persiste dans les prévisions de tous les modèles.

CHAPITRE 4

DISCUSSION

Ce chapitre discute des performances des prévisions présentées précédemment au regard des outils utilisés. Il apporte des pistes d'explications et justification des phénomènes et caractéristiques des divers éléments de l'étude ayant mené à ces résultats. Enfin seront abordées les limitations de la présente étude ainsi que des recommandations pour des travaux futurs portant sur le sujet du pré et post-traitement statistique de prévisions hydrologiques.

4.1 Disparité entre les performances des modèles hydrologiques

Dans la présente étude, au regard des médianes des CRPS quotidiens, le modèle GR5dt se distingue par son efficacité tout en étant le moins complexe, avec seulement 5 paramètres. Il domine dans la majorité des bassins, bien que bénéficiant peu des méthodes de pré et post-traitement. Effectivement, ses meilleures performances s'observent avec ses prévisions brutes dans plus de la moitié des cas où il excelle par rapport aux autres modèles. La Figure 3.6 révèle que les prévisions de GR5dt, déjà performantes en brut et pendant la calibration, tendent à se dégrader après pré- et post-traitement. Néanmoins, GR5dt présente souvent une sous-dispersion marquée dans la plupart des bassins. Les méthodes de pré et post-traitement améliorent légèrement la fiabilité du modèle à des horizons prédictifs éloignés, mais détériorent sa précision en termes de médiane des CRPS quotidiens.

CEQUEAU et SIMHYD, dotés de structures plus complexes (9 et 7 paramètres respectivement), se placent en seconde position *ex æquo* en nombre de bassins dominés, avec des performances variables selon les méthodes. MOHYSE arrive en troisième place. D'autres modèles plus complexes comme HBV (9 paramètres) et IHACRES (7 paramètres) bénéficient grandement du post-traitement, atteignant leurs meilleures performances par cette méthode, bien que se distinguant dans un nombre restreint de bassins. Les diagrammes de Talagrand de la Figure 3.18 montrent toutefois que les prévisions de HBV sont les plus fiables après post-traitement, avec une amélioration notable de la fiabilité également observée pour IHACRES,

SIMHYD et MOHYSE. En revanche, TOPMODEL affiche de faibles performances avec ses prévisions brutes, qui se détériorent ou sont très faiblement corrigées après post-traitement, ne se démarquant que dans un nombre très restreint de bassins. Ses prévisions sont souvent parmi les plus biaisées ou sous-dispersées pour tous les bassins étudiés.

Ainsi, même si les méthodes de post-traitement peuvent améliorer les performances médianes d'un modèle dans certains bassins, comme montré en Figure 3.6, il est fréquent que la précision de ces prévisions, en termes de médiane des CRPS quotidiens, ne dépasse pas celles des prévisions brutes du modèle le plus performant. Parfois, un modèle avec de bonnes performances en prévisions brutes peut même voir sa précision globale se détériorer après post-traitement, alors que la fiabilité peut s'améliorer. Ces résultats sont également observés par Wood & Schaake (2008) et Crochemore et al. (2016). Des modèles avec une précision plus modeste peuvent bénéficier d'une amélioration tant en précision qu'en fiabilité suite aux pré et post-traitements. Des boîtes à moustaches représentant les CRPS et CRPSS pour un modèle et un bassin donné, ainsi que des diagrammes de Talagrand pour ces mêmes bassins, viennent étayer ces observations dans les annexes, celles-ci montrent les performances de modèles ayant démontré une très bonne fiabilité pour les bassins n°7 et 10. La Figure A II-1 montre les performances du modèle HBV au bassin n°7, la Figure A II-2 montre les performances du modèle HYMOD au bassin n°10. Les Figures A III-1 et A III-2 montrent les diagrammes de Talagrand de tous les couples {HM ; méthode} pour les deux bassins cités précédemment.

4.2 Efficacité des méthodes de prétraitement et post-traitement en fonction des caractéristiques des bassins versants

En examinant uniquement les prévisions brutes, il n'apparaît pas de supériorité marquée d'un modèle sur les autres selon les caractéristiques d'un bassin. Même si GR5dt se distingue dans un grand nombre de bassins, ces derniers diffèrent considérablement en taille et en localisation. Cependant, en se concentrant les meilleurs couples {modèle ; bassin}, on peut observer certaines tendances, notamment dans la carte de la Figure 3.18.

Pour les bassins les plus au Nord (latitude supérieure à 46.75°N), le prétraitement fournit les meilleures prévisions pour la majorité des bassins. Cette performance pourrait s'expliquer par

une modélisation plus précise des températures, facteur crucial dans ces régions où les stocks de neige sont plus importants.

En revanche, sous la latitude de 46.75°N , les prévisions post-traitées se montrent souvent supérieures pour les bassins près du fleuve Saint Laurent. Ce constat pourrait résulter de chutes de neige moins conséquentes dans ces zones, rendant le prétraitement moins influent. Cependant, cette tendance ne s'applique pas aux bassins plus au sud, où les prévisions brutes prédominent. Pour ces bassins, GR5dt produit systématiquement les prévisions les plus précises en brut. À l'est, loin du fleuve Saint Laurent, les prévisions prétraitées s'avèrent supérieures. À l'ouest, ce sont les prévisions brutes et post-traitées qui l'emportent.

La taille des bassins semble influencer davantage la qualité des méthodes de pré et post-traitement que la localisation. Comme précisé en section 4.3, le post-traitement excelle particulièrement dans les bassins de taille moyenne (500 à 2000 km^2), tandis que les prévisions brutes et prétraitées sont préférables pour les petits ($<500 \text{ km}^2$) et grands bassins ($>2000 \text{ km}^2$). Les petits bassins, plus sensibles aux conditions météorologiques en raison de leur réactivité, et les grands bassins, avec leur complexité hydrologique propre, ne semblent pas bénéficier du post-traitement. La calibration des modèles hydrologiques semble en effet mieux capturer la complexité des grands bassins, tandis que le post-traitement tend à détériorer les performances.

Pour les bassins de taille moyenne, le post-traitement se révèle efficace, se positionnant (de justesse) comme la méthode de choix pour ces bassins. Il semble que le compromis entre réactivité importante aux conditions météorologiques et complexité hydrologique crée un contexte idéal pour le post-traitement. Cette hypothèse est renforcée par une certaine concordance entre les observations durant la période de calibration et l'application des méthodes pour bon nombre de ces bassins, sujet qui sera approfondi dans la section 5.5.2.

4.3 Taille des fenêtres glissantes

La méthode QM, utilisée pour les prétraitements et post-traitements, présente des performances optimales lorsqu'elle est appliquée avec une fenêtre glissante plus large (± 30 jours).

Pour le prétraitement des précipitations, l'impact de la taille de la fenêtre est particulièrement notable, comme le démontre la Figure 3.1. Les précipitations, par leur grande variabilité temporelle, présentent d'importantes fluctuations d'une année à l'autre, même à l'échelle de la semaine ou du mois. Une fenêtre de post-traitement trop restreinte risque alors de ne pas capturer adéquatement cette variabilité interannuelle, menant souvent à une détérioration plutôt qu'à une amélioration des prévisions.

Quant aux prévisions de température, leur variabilité annuelle est bien moindre. Contrairement aux précipitations, caractérisées par leur discontinuité et leur variabilité, les températures affichent une régularité plus marquée. La Figure 3.2 indique que la taille des fenêtres (de ± 10 à ± 30 jours) a peu d'impact sur la performance globale du prétraitement des températures. Bien que des fenêtres plus étroites pourraient théoriquement saisir mieux les variations saisonnières, ce sont en fait les fenêtres plus larges qui offrent de légèrement meilleures performances.

Pour le post-traitement, comme l'illustre la Figure 3.5, l'utilisation de fenêtres plus larges est également bénéfique pour la majorité des couples {HM ; BV}. Cette efficacité s'explique en partie par la variabilité interannuelle d'évènements spécifiques, comme les crues printanières au Québec, qui peuvent fluctuer de ± 30 jours. Cette variabilité, bien que décroissante au fil des années (Mazouz, Assani, Quessy, & Légaré, 2012), nécessite l'emploi d'une fenêtre suffisamment large pour ne pas omettre des périodes de crues exceptionnellement précoces ou tardives. Cette nécessité s'applique à toute l'année, compte tenu de la variabilité annuelle des régimes hydrologiques dans la région, même si cette variabilité est moins prononcée en termes de volume que pour les crues printanières.

L'efficacité limitée du prétraitement pourrait aussi résulter de la faible quantité de données utilisées pour calibrer la méthode. Par exemple, avec une fenêtre de plus ou moins 10 jours (méthodes « QM10 »), seulement 21 points de données par année sont disponibles pour le prétraitement. Sur cinq ans, cela représente 105 paires observation-prévision (années 2015 à 2019 pour la calibration des méthodes de post-traitement). Ce nombre d'années est bien inférieur à la dizaine, vingtaine ou même trentaine d'années habituellement utilisées dans les études sur le traitement statistique des prévisions météorologiques et hydrologiques (Piani, Haerter, & Coppola (2010), Heo, Ahn, Shin, Kjeldsen, & Jeong (2019), Whan, Zscheischler, Jordan, & Ziegel (2021)). Ainsi, seulement 105 paires observation-prévision pourraient ne pas être suffisantes pour représenter de manière précise les distributions des variables telles que les précipitations ou les débits à un jour donné.

4.4 Effets du prétraitement sur les prévisions météorologiques

Les meilleurs résultats en termes d'améliorations avec le critère du CRPSS sont observés pour les températures. Par conséquent, d'importants avantages auraient pu être escomptés pour les prévisions hydrologiques, notamment parce que des prévisions de température plus précises facilitent une modélisation plus exacte des phénomènes d'évapotranspiration par le module d'ETP. En effet, l'ETP est souvent le facteur déterminant sur les volumes d'eau disponibles et les débits durant les périodes chaudes. Malgré les hautes valeurs de CRPSS relevées pour les prévisions de température dans la majorité des bassins, cette amélioration en termes de performance ne se traduit pas avec la même ampleur sur les scores CRPSS des simulations hydrologiques. Cette situation pourrait être due au fait que les prévisions brutes de la plupart des modèles affichent déjà d'excellentes performances en période d'étiage, comme le montrent les Figures 3.7 à 3.10.

Le déficit en termes de performances des prévisions brutes est plus prononcé au début du printemps, lors des crues engendrées par la fonte des neiges. Effectivement, les bassins étudiés, situés dans la province de Québec, subissent majoritairement la fonte des neiges à cette période. Par conséquent, une prévision précise des températures permet de modéliser plus

adéquatement l'apport en eau que représente la fonte des neiges. C'est notamment le cas pour plusieurs bassins, en particulier ceux situés plus au nord : leurs prévisions de température peuvent être notablement améliorées au printemps. Les performances des prévisions de précipitations sont quant à elles quasi inchangées, bien qu'elles connaissent de légères améliorations sur le court terme (horizons prédictifs allant de 30 h et 96 h), puis légèrement empirées à plus long terme (horizons prédictifs entre 126 et 240 h).

Aussi, le prétraitement n'est pas parvenu à corriger le cycle présent dans les prévisions de précipitations. Ce cycle peut principalement être expliqué par le fait qu'un décalage de 1 h est présent entre les observations et les prévisions proposées par ECMWF (les observations ont 1 h d'avance sur les prévisions de ECMWF). Pour les températures, ce retard ne cause pas de différence majeure, bien qu'un cycle moins marqué soit observé dans les erreurs commises par les prévisions de température. En revanche, pour les précipitations, cet écart cause de réelles différences dans les prévisions en particulier, car c'est le cumul des précipitations sur 6 h sur lequel se basent les prévisions. Ainsi, une prévision de précipitations « parfaite » prédira nécessairement un volume différent que celui réellement observé, et cette erreur se répercute dans la prévision au pas de temps suivant. De plus, un biais connu des modèles de prévisions météorologiques est lié au cycle jour-nuit, le cycle « diurne ». Pour le modèle proposé par ECMWF, les biais sont plus importants pour les prévisions de nuit que de jour (Haiden et al. 2018).

4.5 Amélioration des prévisions hydrologiques à la suite du prétraitement et du post-traitement

Bien que, pour la plupart des couples HM-bassin de cette étude, les prévisions hydrologiques pré et post-traitées voient leurs précisions médianes améliorées, celles-ci ne démontrent pas nécessairement des améliorations des prévisions sur tous les plans. En effet, même si une prévision gagne à être plus précise, c'est-à-dire que la valeur de débits prédite par une prévision post-traitée est plus proche de la réalité que celle émise par une prévision brute, d'autres aspects tout aussi importants d'une prévision sont à prendre en compte. Parmi ces aspects se trouve la fiabilité des prévisions, un modèle fiable est indispensable pour assister à toute prise de

décision. Des décisions prises sur des prévisions trompeuses issues d'un modèle manquant de fiabilité pourraient entraîner des conséquences dramatiques, dans le cas d'inondations par exemple.

4.5.1 Variabilité dans la qualité des prévisions hydrologiques à la suite du prétraitement

Comme l'indiquent les Figures 3.11 à 3.14, le prétraitement a un effet très limité sur les prévisions hydrologiques. En effet, d'une part, la précision médiane des prévisions à la suite du prétraitement est quasiment inchangée, et d'autre part, la variance des CRPS et CRPSS est très faible, indiquant un effet quasi nul sur la précision des prévisions hydrologiques. Tout comme l'ont observé Verkade et al. (2013), les potentiels bénéfiques induits par le prétraitement se propagent difficilement depuis les intrants vers les extrants des modèles hydrologiques. De plus, dans la plupart des cas, pour une prévision améliorée, une autre est détériorée avec un même ordre de grandeur. Les résultats présentés mettent en lumière les effets très faibles du prétraitement sur les prévisions hydrologiques. Bien que les prévisions de précipitations soient très peu influencées par le prétraitement, il est constaté que les seules améliorations remarquables des prévisions de température exercent une faible influence lorsqu'intégrées aux modèles hydrologiques.

Effectivement, le fait que les prévisions soient à très court terme (horizon maximal de dix jours) ne permet pas de tirer profit des améliorations importantes du prétraitement, notamment pour les prévisions de température. D'un côté, une part des processus hydrologiques où la température est impliquée ont une certaine latence, la fonte des neiges en fait partie. D'un autre côté, l'effet du prétraitement est cumulatif chez une prévision hydrologique. De fait, de meilleurs intrants amélioreront les extrants et variables internes du modèle au premier pas de temps de prévision, qui amélioreront les extrants et variables du second pas de temps, et ainsi de suite. Ainsi, les avantages du prétraitement ne sont visibles qu'à plus long terme, aux pas de temps plus éloignés, comme le montrent les hydrogrammes en Figures 3.7 à 3.10 et boîtes à moustaches en Figures 3.11 à 3.14.

Même si la température joue un rôle important, les précipitations restent néanmoins le facteur ayant le plus d'influence sur une prévision hydrologique, et ce, en tout temps (Sitterson et al., 2017). Bien qu'il soit crucial d'estimer correctement les températures, notamment lors des fontes de neiges au printemps, il s'agit d'abord d'estimer de manière précise l'état du couvert neigeux, conditionné par les chutes de neige. Dans le cas de l'estimation du stock de neige, ce point est majoritairement pris en charge par l'assimilation de données, qui assimile également les états du module de neige. Aux périodes chaudes, les précipitations liquides peuvent cependant avoir un effet notable à court terme, notamment par l'effet du ruissèlement. Toutefois, comme énoncé précédemment, les prévisions de précipitations n'ayant connu, à court terme, que de très faibles améliorations par le prétraitement, de très faibles effets sont observés dans l'étendue d'une prévision, sauf chez les plus petits bassins qui sont bien plus réactifs aux conditions météorologiques. Ces observations confirment d'ailleurs ce que suggèrent Verkade et al. (2013), à savoir que le prétraitement pourrait avoir un effet plus marqué chez les bassins où le débit a une réponse plus « linéaire » à la météorologie (dans ce contexte, une réponse plus rapide et proportionnée du bassin face aux précipitations et températures). C'est effectivement le cas chez les bassins avec moins de stockage, lorsque les horizons prédictifs sont suffisamment longs par rapport à l'inertie du BV étudié.

En ce qui concerne l'effet du prétraitement sur la fiabilité des prévisions hydrologiques, celui-ci est aussi très faible. Effectivement, dans la plupart des diagrammes de Talagrand présentés (Figure 3.18, III-A-1 et III-A-2), les prévisions hydrologiques démontrent seulement de légères détériorations ou améliorations concernant leurs distributions, traduites par de faibles variations des scores ABDU et p-values. Il est à noter que des changements visibles dans les distributions des prévisions ne sont constatés qu'à des horizons prédictifs éloignés (souvent supérieurs à 96 h). Toute prévision en deçà de cet horizon présente toujours une forte sous-dispersion. Cette caractéristique n'est pas surprenante. D'une part, les prévisions tendent naturellement à se disperser davantage à mesure que chaque membre indépendant progresse dans le temps. D'autre part, comme exposé précédemment, l'effet du prétraitement est cumulatif, ainsi son influence la plus forte ne peut qu'être constatée à des horizons prédictifs éloignés.

4.5.2 Variabilité dans la qualité des prévisions hydrologiques à la suite du post-traitement

Selon Kang et al. (2010), si un traitement doit être appliqué aux prévisions hydrologiques, c'est le post-traitement qu'il faut privilégier. En effet, comme le montrent Crochemore et al. (2016) et W. Li et al. (2017), le HM est la plus grande source d'incertitudes dans la chaîne de prévisions hydrologiques. En agissant directement sur les extrants des modèles hydrologiques, celui-ci a effectivement un pouvoir de correction bien plus grand que le prétraitement.

Cependant, comme l'indiquent les Figures 3.11 à 3.14, les conséquences du post-traitement sont très disparates. De fait, les CRPSS des prévisions post-traitées sont très étalés, et ce, quels que soient les bénéfices globaux apportés par post-traitement (prévisions globalement améliorées ou globalement détériorées), mesurés par la médiane des CRPS quotidiens.

Dans le cas où les CRPSS médians sont nuls, leurs distributions présentent souvent une forte asymétrie vers les valeurs négatives (cas du bassin 34 : Batiscan, Figure 3.12). Dans ce contexte, il est bien plus courant d'observer une détérioration importante de la précision des prévisions plutôt qu'une amélioration équivalente. Autrement dit, pour une prévision améliorée, une autre est encore plus fortement détériorée.

Pour certains bassins, les CRPSS médians des prévisions post-traitées sont clairement positifs (cas des bassins 12 : Massawipi, et 26 : Ouareau, Figure 3.13 et 3.14). Leurs distributions s'étendent tout de même régulièrement au-dessous de zéro, indiquant des détériorations. De surcroît, une partie des distributions des CRPSS pour ces bassins (entre la valeur minimale et le premier quartile, 25 % des CRPSS) peuvent régulièrement avoisiner les « -1 ». Ainsi, dans le contexte où les améliorations sont bien plus fréquentes que les détériorations, le post-traitement se montre tout de même instable dans la qualité de ses prévisions. En effet, comme évoqué précédemment, le QM se « contente » d'attribuer une correction aux débits en fonction de leur rang parmi les prévisions effectuées à cette même période de l'année.

Comme le montrent Madadgar et al. (2014), le fait que le QM fasse des correspondances « aveugles », c'est-à-dire que l'information sur le lien direct entre une unique simulation et l'observation n'est pas conservée lors de la calibration de la méthode, lui porte préjudice. Effectivement, la méthode de post-traitement au QM, comme toute méthode statistique simple, se base exclusivement sur les distributions des données historiques. Ainsi, il est impératif que les données disponibles pour la calibration soient les plus exhaustives possibles. Ceci peut être réalisé dans le sens où tous les régimes hydrologiques possibles à une période donnée sont observés, et ce, dans des fréquences réalistes, afin que la méthode de post-traitement soit robuste et préparée à tous les cas de figure. Si le QM est confronté à une situation inédite au regard de la période de calibration, il y a de fortes chances pour que la correction apportée détériore la prévision. Cela souligne l'importance d'avoir une grande quantité de données pour calibrer une méthode de post-traitement statistique, l'idéal étant qu'une certaine proximité entre les régimes hydrologiques observés lors de la période d'entraînement et la période d'application soit assurée, surtout lorsque la période de calibration diffère de la période d'application. C'est d'ailleurs le cas dans la présente étude : d'importantes inondations sont survenues dans la période de calibration en 2017 et 2019, ce qui n'a pas été le cas en 2020. Le Tableau A I-1 montre, entre autres, les écarts relatifs du débit annuel moyen de la période d'application (suffixe « 20 ») et le débit annuel moyen de la période de calibration (suffixe « 15-19 »). Cependant, ces calculs des débits moyens annuels sont à considérer avec prudence, car certaines crues printanières, jouant fortement sur les moyennes annuelles, peuvent ne pas être considérées dépendamment des années.

Il est d'ailleurs possible d'observer que les bassins où le post-traitement a obtenu les meilleures performances sur le critère du plus faible CRPS quotidien médian sont des bassins qui ont connu des régimes hydrologiques similaires lors des périodes de calibration et d'application de la méthode de post-traitement. Pour le cas du bassin n°26 de la rivière Ouareau (Figures 3.10 et 3.14), les débits moyens annuels sont proches ($26 \text{ m}^3/\text{s}$ et $29 \text{ m}^3/\text{s}$ pour les périodes de calibration et d'application respectivement), bien que leurs écarts types soient différents ($26 \text{ m}^3/\text{s}$ et $35 \text{ m}^3/\text{s}$ pour les périodes de calibration et d'application respectivement). Le cas de la rivière Massawipi est particulier (Figures 3.9 et 3.13). D'une part les débits entre les périodes

de calibration et d'application sont proches ($12 \text{ m}^3/\text{s}$ et $10 \text{ m}^3/\text{s}$ pour les périodes de calibration et d'application respectivement), tout comme les écarts types ($11 \text{ m}^3/\text{s}$ et $9 \text{ m}^3/\text{s}$ pour les périodes de calibration et d'application respectivement). D'autre part les débits sont fortement contrôlés dans cette rivière. Cette caractéristique « arbitraire » de la rivière Massawipi ne peut pas être correctement modélisée par les HM. Les débits dans cette rivière soient fixés à des valeurs bien déterminées (en été par exemple, où les débits ont une forme de créneaux entre 1 et $9 \text{ m}^3/\text{s}$), il semble que seul le post-traitement puisse avoir une action sur ceux-ci. Cependant cette action demeure « hasardeuse », puisque seule l'intervention humaine puisse déclencher ces débits, d'où la très mauvaise synchronicité des modèles pour ce bassin.

Tout comme son influence sur la précision des prévisions, l'impact du post-traitement sur la fiabilité est remarquable. De plus, la proximité entre les données de calibration et d'application du post-traitement joue un rôle crucial pour la fiabilité des prévisions post-traitées. Les diagrammes de Talagrand en Figure 3.18 et en Figure A III-1 illustrent que, pour les bassins dont la moyenne des débits observés entre les périodes de calibration et d'application de la méthode sont similaires, le post-traitement entraîne une amélioration notable de la fiabilité des prévisions pour la majorité des modèles. Cependant, les avantages du post-traitement deviennent bien plus imprévisibles lorsque les débits moyens des deux périodes diffèrent considérablement. La Figure A III-2 révèle que dans ce cas (pour le bassin n°10, l'écart relatif entre les débits moyens est égal à 30 %, signifiant que le débit annuel moyen de la période de calibration est 30 % supérieur à celui de l'année 2020), le post-traitement corrige efficacement les modèles biaisés, mais induit également un fort biais positif dans les modèles dont les prévisions brutes sont très fiables. Comme le soulignent Madadgar et al. (2014), le QM pourrait dans ce contexte appliquer des corrections dans le « mauvais sens ». Ce risque est plus élevé lorsque les distributions des prévisions et des observations sont similaires durant la période de calibration. Ce problème est exacerbé lorsque les fonctions de distributions cumulatives se chevauchent. Les auteurs précisent que le QM est particulièrement performant lorsque les prévisions sont « suffisamment » biaisées (fonctions de distribution cumulatives distantes), mais peut engendrer des erreurs lorsque le biais est « insuffisant » (fonctions de distributions cumulatives proches).

4.6 Périodes déficitaires en débits observés

La difficulté majeure rencontrée dans cette étude réside dans les périodes où les observations de débits ne sont pas disponibles. Ceci est dû à la présence d'une couche de glace en surface des rivières. En effet, les débits sont estimés en fonction du niveau d'eau de la rivière, pouvant être déduit à partir de la pression mesurée par des sondes piézométriques immergées dans celle-ci. La présence d'une couche de glace en surface exerce une pression non négligeable sur l'eau de la rivière, et vient ainsi fausser les mesures du niveau d'eau réel. De ce fait, les débits en périodes froides ne sont pas considérés car les mesures ne sont pas fiables. Ce manque de données impacte le processus en trois aspects.

Premièrement, ce déficit d'observations empêche une assimilation de données la plus à jour possible. Lorsque les observations de débits manquent, une simulation hydrologique est réalisée entre la dernière date d'assimilation et la date d'émission des prévisions, en utilisant les observations météorologiques comme intrants. Les états finaux de cette simulation deviennent les états initiaux du modèle pour la prévision. Cette méthode introduit des imprécisions dans les états initiaux du modèle, qui s'accroissent si la période sans observation est longue.

Deuxièmement, l'absence de données affecte négativement l'efficacité du post-traitement. Normalement, 305 observations de débits sont utilisées pour calibrer la méthode de post-traitement. Cependant, les lacunes dans les données d'observations, particulièrement en hiver, peuvent réduire considérablement ce nombre. Les Figures 3.7, 3.8 et 3.10 illustrent cette situation, notamment pour les bassins 34 « Batiscan » et 26 « Ouareau », où aucune donnée d'observation n'a été capturée par la fenêtre glissante entre fin janvier et début mars pour les années 2015 à 2019. Les débits post-traités deviennent alors identiques aux débits bruts, faute de données pour la correction. Lorsque la fenêtre glissante commence à capturer quelques observations, la méthode de post-traitement, en l'absence d'une diversité suffisante de données

observées, produit des facteurs de correction aberrants, entraînant des débits corrigés jusqu'à 5 à 10 fois supérieurs aux débits bruts.

Troisièmement, l'insuffisance d'observations limite toute évaluation fiable des performances des prévisions. Sans données observées, particulièrement lors des crues majeures, il devient impossible de juger de manière objective l'efficacité de chaque méthode.

4.7 Limitations et ouverture

Dans cette section, seront abordées à la fois les limites de la présente étude et les perspectives, mettant en lumière les défis rencontrés au cours de la recherche tout en identifiant les opportunités pour des travaux ultérieurs dans le domaine.

Une première limitation provient des tests statistiques utilisés qui orientent invariablement les interprétations qui sont faites sur les prévisions. En effet, le CRPS, bien qu'il soit, par nature, influencé par la fiabilité d'une prévision, mesure principalement la précision d'une prévision d'ensemble. La présente étude se concentre majoritairement sur cette métrique, et propose un classement des prévisions issues de différents modèles hydrologiques et traitements à partir de leurs CRPS : la médiane des CRPS « quotidiens » sur une année complète de prévisions. Cependant, cette méthode de classement est loin d'être sans biais, elle néglige notamment tout écart particulièrement important des prévisions évaluées, car elle ne considère que la médiane de l'ensemble des prévisions sur toute une année. Aussi, les horizons prédictifs sont tous amalgamés dans le CRPS « quotidien » (moyenne des CRPS des 40 pas de temps de la prévision), écartant ainsi les spécificités de chaque système de prévision propre à l'horizon prédictif (par exemple, le couple {HM ; BV} pourrait être particulièrement efficace à des horizons prédictifs proches, mais très mauvais à des horizons plus éloignés). L'application principale des prévisions hydrologiques à court terme étant la mitigation des risques, notamment liés à d'importantes inondations ou encore de fortes sécheresses, il est naturel de privilégier un système de prévisions particulièrement fiable, quitte à sacrifier quelques précisions. Ainsi, classer les systèmes de prévisions uniquement sur leur CRPS revient souvent

à écarter d'autres systèmes bien plus fiables, tout en possédant une précision tout à fait acceptable. C'est d'ailleurs le cas dans la présente étude, où le modèle qui domine tous les autres en termes de précision génère rarement les prévisions les plus fiables. Rétrospectivement, les diagrammes de Talagrand étant difficiles à interpréter, l'utilisation de la décomposition du CRPS (« CRPS-reliability » et « CRPS-resolution/incertitude », d'après Hersbach (2000)) aurait été un apport intéressant et éclairant pour la vérification de la fiabilité des prévisions.

Une seconde limitation découle des données utilisées pour calibrer les méthodes de post-traitement. Il est important de noter que ces données semblent être en quantité insuffisante, en particulier compte tenu du caractère exceptionnel des années 2017 et 2019 qui les composent. Cette situation soulève la question de la représentativité de ces années dans la calibration du modèle. Pour surmonter cette limitation, une approche pertinente aurait été d'effectuer le processus de calibration et d'application du HM de manière itérative, en choisissant comme année d'application une année entre 2015 et 2020 à chaque itération. D'une part, ce processus aurait permis d'analyser le QM dans plusieurs contextes. D'autre part, un plus grand panel de résultats permet de tirer des conclusions plus solides, écartant un certain facteur chance découlant de la sélection arbitraire d'une unique période test. Aussi, une limite majeure provient des périodes déficitaires en débits observés, qui portent un grand préjudice à cette étude, étant donné le but premier des prévisions à court terme comme discuté en première limite. Il est alors recommandé d'étudier les prévisions à court terme dans des zones ou années disposant d'observations lors des crues printanières notamment.

Une troisième limitation découle de la taille des fenêtres glissantes. Étant donné que dans la présente étude les performances du QM augmentent avec la taille de la fenêtre, augmenter davantage la taille de la fenêtre aurait été pertinent, notamment afin d'identifier une taille idéale de fenêtre ou une valeur seuil. Aussi, comparer la méthode de fenêtre glissante aux méthodes plus classiques de sélection des données (par mois, saisons) peut être une piste pour des projets futurs.

Une autre limite provient de la nature des modèles hydrologiques, qui sont tous des modèles conceptuels globaux. L'utilisation d'autres modèles comme des modèles distribués serait intéressante, notamment dans le contexte des bassins étudiés pouvant atteindre des superficies considérables. De même pour tous les éléments qui composent la chaîne de prévisions hydrologiques, réitérer l'expérience en changeant, ou même en retirant différents éléments (comme l'assimilation de données, changer le module de neige, etc.) et observer les résultats qui en découlent pour quantifier leur apport.

CHAPITRE 5

CONCLUSION

Ce mémoire présente une analyse sur les résultats d'une méthode de traitement statistique sur les prévisions météorologiques et hydrologiques d'ensemble dans le but d'améliorer leurs performances. La capacité de prévoir les régimes hydriques joue un rôle primordial dans la gestion d'un territoire. Des prévisions fiables et éclairées permettent d'une part de gérer au mieux les ressources en eau et d'autre part de se prémunir, et réagir au mieux faces aux risques notamment liés aux crues, pouvant causer des dommages humains et matériels très importants.

Les simulations de 8 modèles hydrologiques conceptuels globaux sont étudiées à travers 42 bassins versants de tailles diverses situés dans la province de Québec, Canada. Ceux-ci, calibrés par l'algorithme CMA-ES (Covariance Matrix Adaptation Evolution Strategy), génèrent des prévisions à partir de prévisions météorologiques d'ensembles à 50 membres au pas de temps 6 h, jusqu'à un horizon prédictif maximal de 10 jours. La chaîne de prévision hydrologique comporte une étape d'assimilation de données, générant 25 états initiaux différents aux modèles, créant ainsi un ensemble total de 1250 membres pour une prévision hydrologique. Le cœur de l'analyse porte sur les effets des traitements statistiques en amont, le prétraitement, et en aval, le post-traitement, des simulations hydrologiques, utilisant la méthode de Quantile Mapping (QM) avec une sélection de données basée sur une fenêtre glissante pour définir les ajustements nécessaires. Les prévisions et observations météorologiques, issues de l'organisme ECMWF (*European Center of Medium Range Forecast*), s'étendent de l'année 2015 à 2020, tandis que les observations hydrologiques sont issues des stations du CEHQ (*Centre d'Expertise Hydrique du Québec*). Les performances des prévisions météorologiques et hydrologiques sont mesurées à l'aide du CRPS (Continuous Ranked Probability Score).

Les résultats indiquent que, parmi les diverses fenêtres de sélection de données analysées, la fenêtre glissante la plus large (± 30 jours) produit généralement les meilleurs résultats en termes

de correction des prévisions, météorologiques comme hydrologiques. Le prétraitement, notamment dans l'ajustement des températures, montre des améliorations remarquables pour la majorité des bassins, mais son impact est limité sur les prévisions de précipitations. Cependant, les améliorations liées au prétraitement sont difficilement visibles lorsque propagées dans les simulations hydrologiques, tandis que les corrections générées par le post-traitement exercent une grande influence sur les débits simulés. De fait, le QM, utilisé pour le post-traitement, semble capable d'améliorer les modèles ayant des performances brutes médiocres, mais ils ne parviennent pas toujours à surpasser les prévisions brutes des modèles les plus performants, ceux-ci connaissent fréquemment de légères détériorations à la suite du post-traitement.

Ainsi les résultats montrent que les prévisions brutes sont les meilleures dans plus d'un tiers des bassins versants étudiés (16 sur 42 bassins), suggérant qu'aucune méthode (pré ou post-traitement) ne domine uniformément en termes de performances. Cependant, certaines limites se posent à la méthode employée.

- 1- La disponibilité et quantité des données de prévision et d'observations
- 2- La nature des prévisions à court terme utilisées
- 3- Le type des modèles hydrologiques étudiés
- 4- Les métriques utilisées pour l'évaluation des prévisions

CHAPITRE 6

RECOMMANDATIONS

Face aux limites relevées dans cette étude et aux perspectives identifiées pour le futur, il apparaît essentiel d'adopter une approche plus holistique dans l'évaluation des modèles hydrologiques.

D'une part, il convient de diversifier les critères d'évaluation des prévisions en intégrant des métriques complémentaires au CRPS. Il convient avant tout de mesurer efficacement la fiabilité des prévisions, par la décomposition du CRPS par exemple. Cette démarche permettrait d'obtenir une évaluation plus nuancée et complète des systèmes de prévision, offrant ainsi une meilleure compréhension de leurs forces et faiblesses.

Par ailleurs, l'extension du jeu de données de calibration par l'intégration d'années supplémentaires ou le recours à des processus de calibration itérative pourrait significativement améliorer la robustesse des observations et conclusions sur les méthodes de traitement utilisées dans la présente étude. Aussi, un panel plus large de taille de fenêtre pourrait être bénéfique, afin d'identifier une taille de fenêtre optimale pour le traitement.

Qui plus est, l'utilisation de davantage de méthodes de traitement, statistiques ou non, apporterait une grande valeur ajoutée à des études ultérieures, en particulier compte-tenu des défis qui se présentent vis-à-vis de la disponibilité des données.

Enfin, prioriser la recherche dans les zones à haut risque, en se concentrant sur les prévisions à court terme lors d'événements extrêmes, aidera à mieux informer la gestion des risques et la prise de décision dans des contextes critiques, à condition que les données soient disponibles.

Ces recommandations visent à surmonter les défis actuels et à exploiter les opportunités de progrès dans les études futures traitant du post-traitement de prévisions hydrologiques.

ANNEXE I

INFORMATIONS SUPPLÉMENTAIRES SUR LES PÉRIODES DE CALIBRATION ET D'APPLICATION DU TRAITEMENT

Tableau A I-1 Précipitations, températures et débits annuels moyens pour les périodes de calibration (suffixe « 15-19 ») et d'application (suffixe « 20 »)

Num	P _{moy, 15-19} (mm)	P _{moy, 20} (mm)	T _{moy, 15-19} (°C)	T _{moy, 20} (°C)	Q _{moy, 15-19} (m ³ /s)	Q _{moy, 20} (m ³ /s)
1	1064,72	1164,14	6,76	7,84	27,30	26,85
2	1105,72	1207,01	6,73	7,83	5,63	6,80
3	1054,22	1170,97	7,19	8,27	3,27	5,34
4	1447,65	1650,95	3,41	4,06	3,26	3,87
5	1153,86	1165,08	6,64	7,83	10,13	6,94
6	1137,73	1176,47	6,29	7,45	71,40	61,32
7	1148,88	1184,29	6,12	7,26	27,55	26,94
8	1266,70	1178,68	5,08	6,24	187,13	135,52
9	1316,52	1223,98	4,72	5,90	15,76	9,92
10	1321,54	1278,68	4,49	5,60	20,77	14,60
11	1281,03	1161,00	4,85	6,06	11,74	7,59
12	1210,84	1093,41	5,50	6,72	11,63	10,15
13	1295,82	1294,89	5,65	6,67	39,00	32,10
14	1370,88	1337,80	5,07	6,08	9,25	7,98
15	1325,36	1346,55	5,04	6,00	57,60	52,30
16	1192,90	1205,06	4,32	5,34	140,68	103,08
17	1290,70	1357,25	5,31	6,16	17,21	15,23
18	1136,06	1198,07	4,15	5,13	18,18	15,49
19	1332,82	1374,56	3,77	4,67	28,86	27,50
20	1213,14	1271,41	4,04	4,88	19,90	19,06
21	1073,90	1330,18	2,88	3,48	82,30	129,03
22	1001,32	1161,59	4,51	5,25	18,62	24,50
23	1079,85	1257,27	3,74	4,45	105,96	130,27
24	1182,76	1373,77	4,17	4,96	25,44	21,64
25	1003,56	1232,17	3,86	4,54	20,42	27,66
26	1112,50	1316,71	3,51	4,23	26,22	28,76
27	1083,13	1268,48	4,80	5,62	13,29	13,51
28	979,57	1202,17	3,46	4,10	3,01	4,09
29	992,48	1245,14	4,89	5,71	2,85	4,42
30	1008,04	1223,65	3,54	4,20	3,41	4,59
31	1036,51	1245,12	3,61	4,30	16,00	23,14

Tableau A I-1 Précipitations, températures et débits annuels moyens pour les périodes de calibration (suffixe « 15-19 ») et d'application (suffixe « 20 ») (suite)

Num	P _{moy, 15-19} (mm)	P _{moy, 20} (mm)	T _{moy, 15-19} (°C)	T _{moy, 20} (°C)	Q _{moy, 15-19} (m ³ /s)	Q _{moy, 20} (m ³ /s)
32	1019,40	1167,20	3,44	4,10	9,33	20,97
33	1040,22	1214,87	3,09	3,70	23,41	30,70
34	1248,29	1430,16	3,13	3,90	108,06	130,65
35	1465,36	1691,25	2,30	2,95	66,43	73,87
36	1454,30	1664,87	2,15	2,80	26,37	28,12
37	1350,04	1559,95	4,33	5,11	9,48	11,36
38	1398,05	1608,00	1,45	2,07	79,06	95,10
39	1375,00	1527,66	4,31	5,01	10,57	13,50
40	1403,10	1566,65	4,20	4,92	1,63	2,03
41	1329,99	1551,61	1,92	2,53	44,78	56,56
42	1429,37	1641,02	3,46	4,10	0,79	0,92

ANNEXE II

BOÎTES À MOUSTACHES EN MATÉRIEL SUPPLÉMENTAIRE

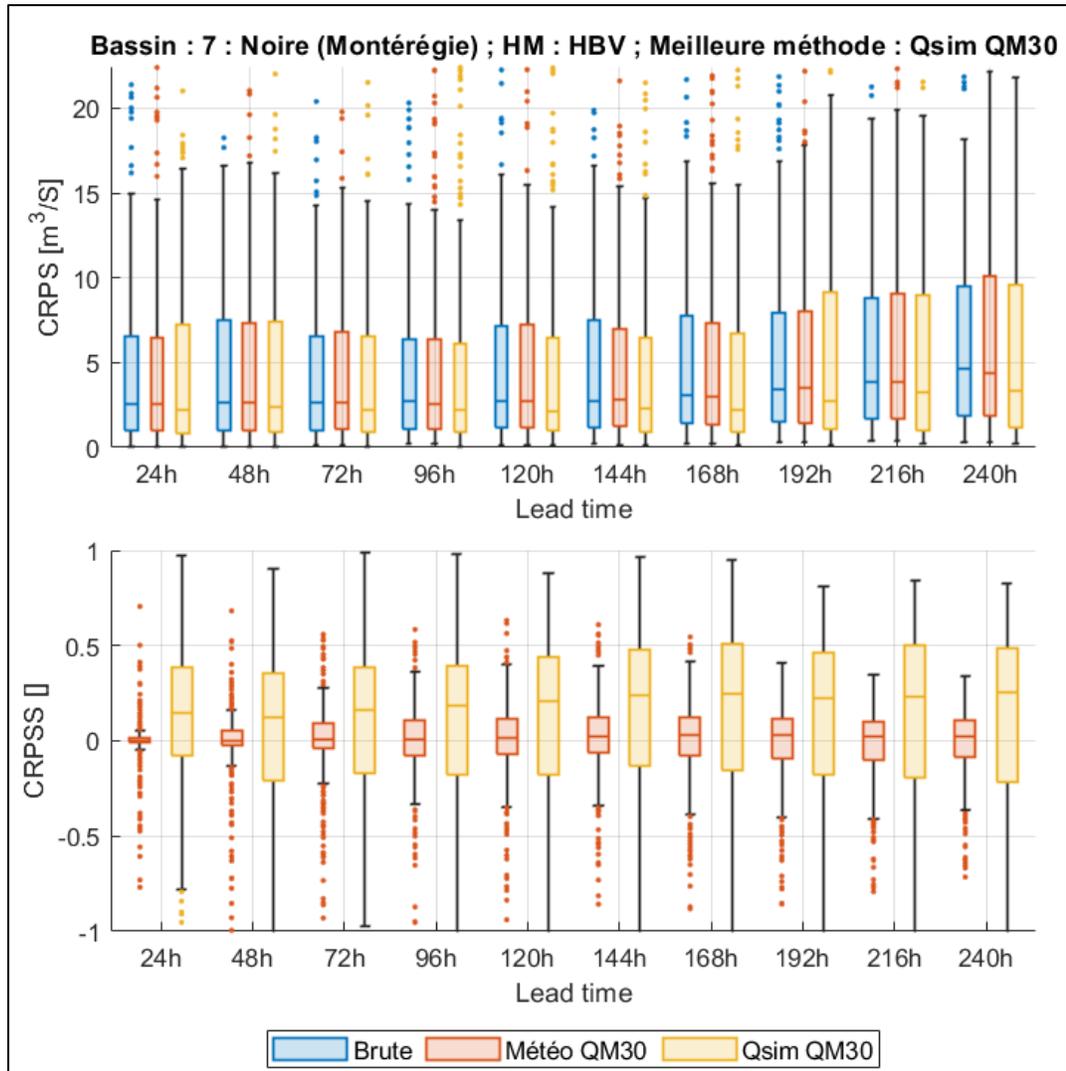


Figure A II-1 Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques du modèle HBV pour le bassin n°7 sur l'année 2020. En haut : CRPS des prévisions brutes (en bleu), prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h. En bas : boîtes à moustaches des CRPSS des prévisions prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h

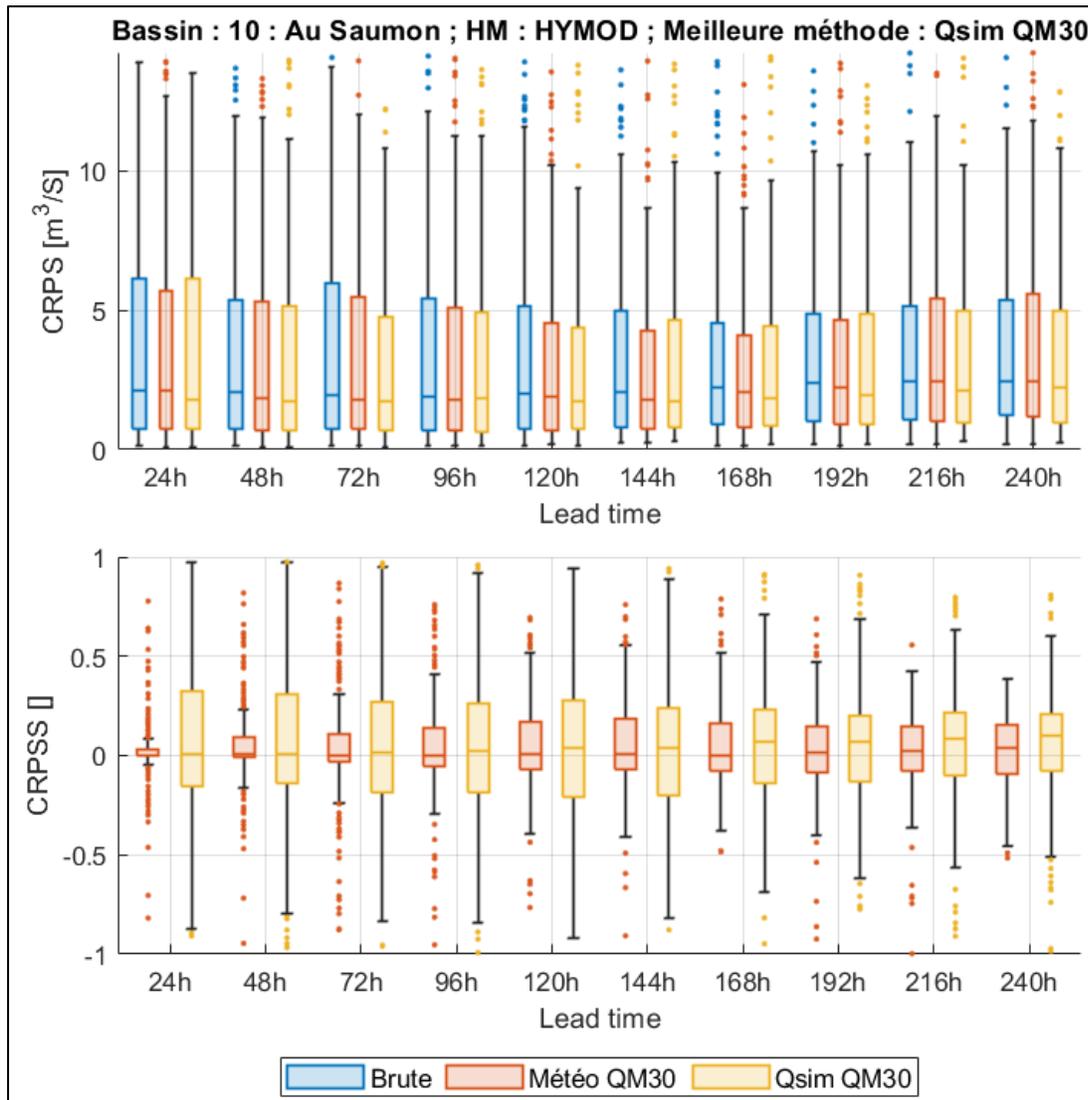


Figure A II-2 Boîtes à moustaches des CRPS et CRPSS, des prévisions hydrologiques du modèle HYMOD pour le bassin n°10 sur l'année 2020. En haut : CRPS des prévisions brutes (en bleu), prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h. En bas : boîtes à moustaches des CRPSS des prévisions prétraitées (Météo QM30, en rouge) et post-traitées (Qsim QM30, en jaune) à différents horizons prédictifs de 24 h à 240 h

ANNEXE III

DIAGRAMMES DE TALAGRAND EN MATÉRIEL SUPPLÉMENTAIRE

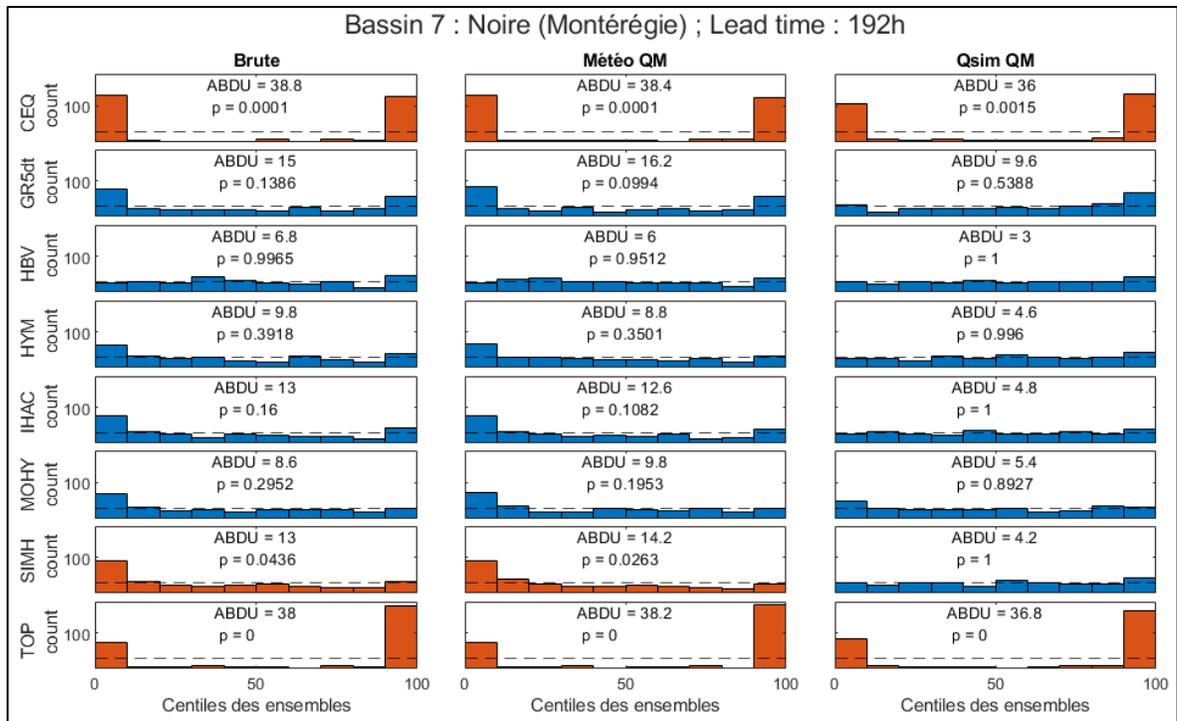


Figure A III-1 Diagrammes de Talagrand pour les prévisions brutes, prétraitées (Météo QM) et post-traitées (Qsim QM) de l'année 2020 par les huit modèles hydrologiques au bassin n°7 à l'horizon prédictif (lead time) 192 h. En rouge, le test de Kolmogorov-Smirnov rejette l'hypothèse d'uniformité, en bleu elle n'est pas rejetée

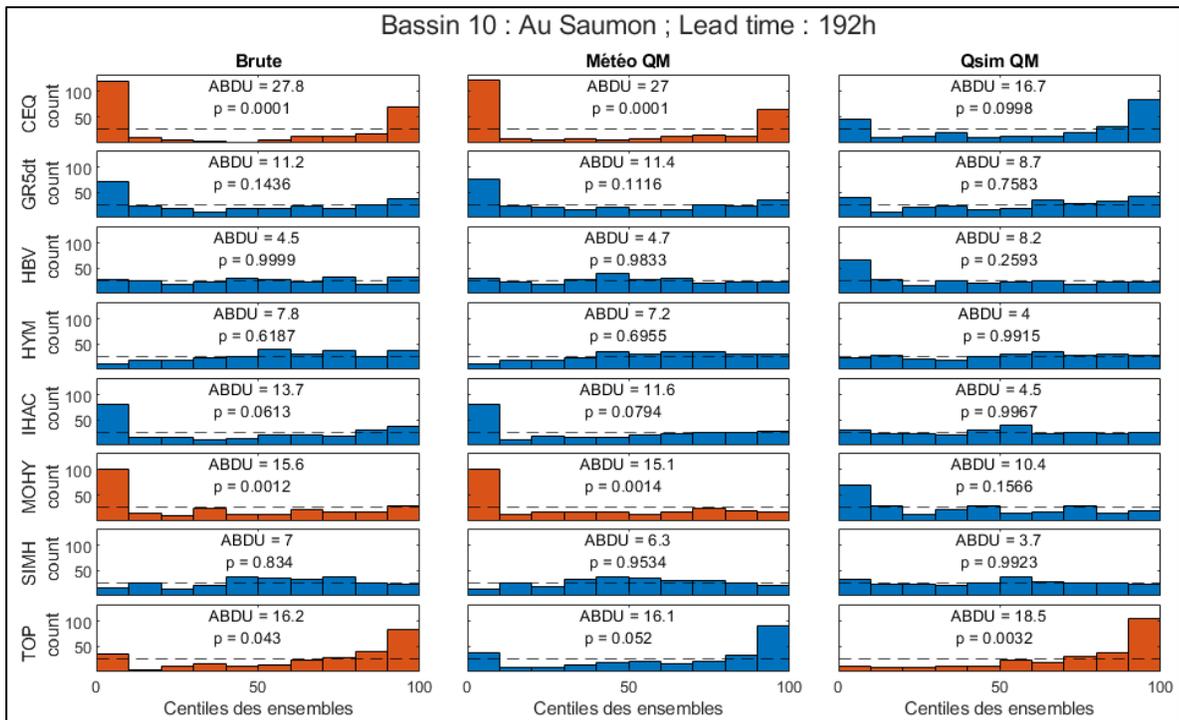


Figure A III-2 Diagrammes de Talagrand pour les prévisions brutes, prétraitées (Météo QM) et post-traitées (Qsim QM) de l'année 2020 par les huit modèles hydrologiques au bassin n°10 à l'horizon prédictif (lead time) 192 h. En rouge, le test de Kolmogorov-Smirnov rejette l'hypothèse d'uniformité, en bleu elle n'est pas rejetée

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- Arsenault, R., Brissette, F., & Martel, J.-L. (2018). The hazards of split-sample validation in hydrological model calibration. *Journal of Hydrology*, 566, 346-362. doi: 10.1016/j.jhydrol.2018.09.027
- Arsenault, R., Latraverse, M., & Duchesne, T. (2016). An Efficient Method to Correct Under-Dispersion in Ensemble Streamflow Prediction of Inflow Volumes for Reservoir Optimization. *Water Resources Management*, 30(12), 4363-4380. doi: 10.1007/s11269-016-1425-4
- Bauer, P., Thorpe, A., & Brunet, G. (2015). The quiet revolution of numerical weather prediction. *Nature*, 525(7567), 47-55. doi: 10.1038/nature14956
- Bergström, S., & Forsman, A. (1973). DEVELOPMENT OF A CONCEPTUAL DETERMINISTIC RAINFALL-RUNOFF MODEL. *Hydrology Research*, 4(3), 147-170. doi: 10.2166/nh.1973.0012
- Beven, K., & Binley, A. (1992). The future of distributed models: Model calibration and uncertainty prediction. *Hydrological Processes*, 6(3), 279-298. doi: 10.1002/hyp.3360060305
- Beven, K. J., & Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology / Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological Sciences Bulletin*, 24(1), 43-69. doi: 10.1080/02626667909491834
- Boyle, D. P., Gupta, H. V., & Sorooshian, S. (2001). Multicriteria calibration of hydrologic models. Dans Q. Duan, H. V. Gupta, S. Sorooshian, A. N. Rousseau, & R. Turcotte (Éds), *Water Science and Application* (Vol. 6, pp. 185-196). Washington, D. C.: American Geophysical Union. doi 10.1029/WS006p0185
- Clark, M., Gangopadhyay, S., Hay, L., Rajagopalan, B., & Wilby, R. (2004). The Schaake Shuffle: A Method for Reconstructing Space-Time Variability in Forecasted Precipitation and Temperature Fields. *Journal of Hydrometeorology*, 5(1), 243-262. doi: 10.1175/1525-7541(2004)005<0243:TSSAMF>2.0.CO;2
- Crochemore, L., Ramos, M.-H., & Pappenberger, F. (2016). Bias correcting precipitation forecasts to improve the skill of seasonal streamflow forecasts. *Hydrology and Earth System Sciences*, 20(9), 3601-3618. doi: 10.5194/hess-20-3601-2016
- Cuo, L., Pagano, T. C., & Wang, Q. J. (2011). A Review of Quantitative Precipitation Forecasts and Their Use in Short- to Medium-Range Streamflow Forecasting. *Journal of Hydrometeorology*, 12(5), 713-728. doi: 10.1175/2011JHM1347.1

- D. N. Moriasi, J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, & T. L. Veith. (2007). Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions of the ASABE*, 50(3), 885-900. doi: 10.13031/2013.23153
- De Olivera Nascimento, N. (1995). *Appréciation à l'Aide d'un Modèle Empirique des Effets d'Actions Anthropique sur la Relation Pluie-Débit à l'Échelle d'un Bassin Versant*. (Thèse de doctorat, École Nationale des Ponts et Chaussées, Paris, France)
- de Lavenne, A., Andréassian, V., Crochemore, L., Lindström, G., & Arheimer, B. (2022). Quantifying multi-year hydrological memory with Catchment Forgetting Curves. *Hydrology and Earth System Sciences*, 26(10), 2715-2732. doi: 10.5194/hess-26-2715-2022
- Devia, G. K., Ganasri, B. P., & Dwarakish, G. S. (2015). A Review on Hydrological Models. *Aquatic Procedia*, 4, 1001-1007. doi: 10.1016/j.aqpro.2015.02.126
- Enayati, M., Bozorg-Haddad, O., Bazrafshan, J., Hejabi, S., & Chu, X. (2021). Bias correction capabilities of quantile mapping methods for rainfall and temperature variables. *Journal of Water and Climate Change*, 12(2), 401-419. doi: 10.2166/wcc.2020.261
- Fortin, V., & Turcotte, R. (2007). Le modèle hydrologique MOHYSE. Note de cours pour SCA7420, Département des Sciences de la Terre et de l'Atmosphère, Université du Québec à Montréal, 23.
- Girard, G., Morin, G., & Charbonneau, R. (1972). Modèle précipitations-débits à discrétisation spatiale. *Cahiers ORSTOM Série Hydrologie*, 9 (4), p. 35-52. Repéré à <https://studylibfr.com/doc/7518171/mod%C3%A8le-pr%C3%A9cipitations-d%C3%A9bits-%C3%A0-discr%C3%A9tisation-spatiale>
- Haiden T., Sandu I., Balsamo G., Arduini Gabriele., & Beljaars A. (2018, octobre). Addressing biases in near-surface forecasts, *ECMWF Newsletter*, 157. Repéré à : <https://www.ecmwf.int/en/newsletter/157/meteorology/addressing-biases-near-surface-forecasts>
- Hansen, N., & Ostermeier, A. (2001). Completely Derandomized Self-Adaptation in Evolution Strategies. *Evolutionary Computation*, 9(2), 159-195. doi: 10.1162/106365601750190398
- Heo, J.-H., Ahn, H., Shin, J.-Y., Kjeldsen, T. R., & Jeong, C. (2019). Probability Distributions for a Quantile Mapping Technique for a Bias Correction of Precipitation Data: A Case Study to Precipitation Data Under Climate Change. *Water*, 11(7), 1475. doi: 10.3390/w11071475

- Hersbach, H. (2000). Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems. *Weather and Forecasting*, 15(5), 559-570. doi: 10.1175/1520-0434(2000)015<0559:DOTCRP>2.0.CO;2
- Jakeman, A. J., Littlewood, I. G., & Whitehead, P. G. (1990). Computation of the instantaneous unit hydrograph and identifiable component flows with application to two small upland catchments. *Journal of Hydrology*, 117(1-4), 275-300. doi: 10.1016/0022-1694(90)90097-H
- Jiang, D., & Wang, K. (2019). The Role of Satellite-Based Remote Sensing in Improving Simulated Streamflow: A Review. *Water*, 11(8), 1615. doi: 10.3390/w11081615
- Kang, T.-H., Kim, Y.-O., & Hong, I.-P. (2010). Comparison of pre- and post-processors for ensemble streamflow prediction. *Atmospheric Science Letters*, 11(2), 153-159. doi: 10.1002/asl.276
- Krzysztofowicz, R. (2004). Bayesian processor of output: A new technique for probabilistic weather forecasting. *Bulletin of the American Meteorological Society*. 3803-3807. Repéré à https://www.researchgate.net/publication/289466201_Bayesian_processor_of_output_A_new_technique_for_probabilistic_weather_forecasting
- Leutbecher, M. (2005). On Ensemble Prediction Using Singular Vectors Started from Forecasts. *Monthly Weather Review*, 133(10), 3038-3046. doi: 10.1175/MWR3018.1
- Li, W., Duan, Q., Miao, C., Ye, A., Gong, W., & Di, Z. (2017). A review on statistical post-processing methods for hydrometeorological ensemble forecasting. *WIREs Water*, 4(6). doi: 10.1002/wat2.1246
- Li, Y., Jiang, Y., Lei, X., Tian, F., Duan, H., & Lu, H. (2018). Comparison of Precipitation and Streamflow Correcting for Ensemble Streamflow Forecasts. *Water*, 10(2), 177. doi: 10.3390/w10020177
- Madadgar, S., Moradkhani, H., & Garen, D. (2014). Towards improved post-processing of hydrologic forecast ensembles: MULTIVARIATE POST-PROCESSING OF HYDROLOGIC ENSEMBLE FORECASTS. *Hydrological Processes*, 28(1), 104-122. doi: 10.1002/hyp.9562
- Mazouz, R., Assani, A. A., Quessy, J.-F., & Légaré, G. (2012). Comparison of the interannual variability of spring heavy floods characteristics of tributaries of the St. Lawrence River in Quebec (Canada). *Advances in Water Resources*, 35, 110-120. doi: 10.1016/j.advwatres.2011.10.006

- Oudin, L., Hervieu, F., Michel, C., Perrin, C., Andréassian, V., Anctil, F., & Loumagne, C. (2005). Which potential evapotranspiration input for a lumped rainfall–runoff model? *Journal of Hydrology*, 303(1-4), 290-306. doi: 10.1016/j.jhydrol.2004.08.026
- Perrin, C. (2002). Vers une amélioration d'un modèle global pluie-débit au travers d'une approche comparative. *La Houille Blanche*, 88(6-7), 84-91. doi : 10.1051/lhb/2002089
- Piani, C., Haerter, J. O., & Coppola, E. (2010). Statistical bias correction for daily precipitation in regional climate models over Europe. *Theoretical and Applied Climatology*, 99(1-2), 187-192. doi: 10.1007/s00704-009-0134-9
- Porter, J. W. (1972). The Synthesis of Continuous Streamflow From Climatic Data by Modelling With a Digital Computer. *Journal of Hydrology*, 24(1-2), 121-134. Repéré à <https://www.sciencedirect.com/science/article/pii/0022169475901468>
- Pu, Z., & Kalnay, E. (2018). Numerical Weather Prediction Basics: Models, Numerical Methods, and Data Assimilation. Dans Q. Duan, F. Pappenberger, J. Thielen, A. Wood, H. L. Cloke, & J. C. Schaake (Éds), *Handbook of Hydrometeorological Ensemble Forecasting* (pp. 1-31). Berlin, Heidelberg: Springer Berlin Heidelberg. doi: 10.1007/978-3-642-40457-3_11-1
- Roundy, K. R., Duan, Q., & Schaake, J. C. (2019). Hydrological Predictability, Scales, and Uncertainty Issues. Dans Q. Duan, F. Pappenberger, A. Wood, H. L. Cloke, & J. C. Schaake (Éds), *Handbook of Hydrometeorological Ensemble Forecasting*. Berlin, Heidelberg: Springer Berlin Heidelberg. doi: 10.1007/978-3-642-39925-1
- Scheuerer, M., & Hamill, T. M. (2015). Statistical Post-processing of Ensemble Precipitation Forecasts by Fitting Censored, Shifted Gamma Distributions*. *Monthly Weather Review*, 143(11), 4578-4596. doi: 10.1175/MWR-D-15-0061.1
- Shukla, J., Palmer, T. N., Hagedorn, R., Hoskins, B., Kinter, J., Marotzke, J., ... Slingo, J. (2010). Toward a New Generation of World Climate Research and Computing Facilities. *Bulletin of the American Meteorological Society*, 91(10), 1407-1412. doi: 10.1175/2010BAMS2900.1
- Simmons, A. J., & Hollingsworth, A. (2002). Some aspects of the improvement in skill of numerical weather prediction. *Quarterly Journal of the Royal Meteorological Society*, 128(580), 647-677. doi: 10.1256/003590002321042135
- Sitterson, J., Knightes, C., Parmar, R., Wolfe, K., Muche, M., & Avant, B. (2017). An Overview of Rainfall-Runoff Model Types. (Rapport de recherche EPA n°152). Athens: United States Environmental Protection Agency. Repéré à https://cfpub.epa.gov/si/si_public_record_report.cfm?dirEntryId=339328&Lab=NERL

- Sloughter, J. M. L., Raftery, A. E., Gneiting, T., & Fraley, C. (2007). Probabilistic Quantitative Precipitation Forecasting Using Bayesian Model Averaging. *Monthly Weather Review*, *135*(9), 3209-3220. doi: 10.1175/MWR3441.1
- Talagrand, O., & Vautard, R. (1997). Evaluation of probabilistic prediction systems. Communication présentée au Workshop on Predictability, Paris. Repéré à : <https://www.ecmwf.int/en/elibrary/76596-evaluation-probabilistic-prediction-systems>
- Troin, M., Arsenault, R., Wood, A. W., Brissette, F., & Martel, J. (2021). Generating Ensemble Streamflow Forecasts: A Review of Methods and Approaches Over the Past 40 Years. *Water Resources Research*, *57*(7). doi: 10.1029/2020WR028392
- US Army Corps of Engineers. (1956). *Snow Hydrology*. (Rapport de recherche n° RN 735-17c). Portland : USACE North Pacific Division. Repéré à <https://usace.contentdm.oclc.org/digital/collection/p266001coll1/id/4172/>
- Valery, A. (2010). *Modélisation précipitations – débit sous influence nivale : Élaboration d'un module neige et évaluation sur 380 bassins versants*. (Thèse de Doctorat, Agro ParisTech, Paris, France). Repéré à <https://hal.inrae.fr/tel-02594605>
- Verkade, J. S., Brown, J. D., Reggiani, P., & Weerts, A. H. (2013). Post-processing ECMWF precipitation and temperature ensemble reforecasts for operational hydrologic forecasting at various spatial scales. *Journal of Hydrology*, *501*, 73-91. doi: 10.1016/j.jhydrol.2013.07.039
- Werner, K., Brandon, D., Clark, M., & Gangopadhyay, S. (2004). Climate Index Weighting Schemes for NWS ESP-Based Seasonal Volume Forecasts. *Journal of Hydrometeorology*, *5*(6), 1076-1090. doi: 10.1175/JHM-381.1
- Whan, K., Zscheischler, J., Jordan, A. I., & Ziegel, J. F. (2021). Novel multivariate quantile mapping methods for ensemble post-processing of medium-range forecasts. *Weather and Climate Extremes*, *32*, 100310. doi: 10.1016/j.wace.2021.100310
- Wilks, D. S. (2009). Extending logistic regression to provide full-probability-distribution MOS forecasts. *Meteorological Applications*, *16*(3), 361-368. doi: 10.1002/met.134
- Wood, A. W., & Schaake, J. C. (2008). Correcting Errors in Streamflow Forecast Ensemble Mean and Spread. *Journal of Hydrometeorology*, *9*(1), 132-148. doi: 10.1175/2007JHM862.1
- Zalachori, I., Ramos, M.-H., Garçon, R., Mathevet, T., & Gailhard, J. (2012). Statistical processing of forecasts for hydrological ensemble prediction: a comparative study of different bias correction strategies. *Advances in Science and Research*, *8*(1), 135-141. doi: 10.5194/asr-8-135-2012

Zhao, T., Bennett, J. C., Wang, Q. J., Schepen, A., Wood, A. W., Robertson, D. E., & Ramos, M.-H. (2017). How Suitable is Quantile Mapping for Post-processing GCM Precipitation Forecasts? *Journal of Climate*, 30(9), 3185-3196. doi: 10.1175/JCLI-D-16-0652.1