

Université du Québec
Institut national de la recherche scientifique
Centre Eau Terre Environnement

**ÉVALUATION DE DIVERSES TECHNIQUES DE MISE
À L'ÉCHELLE STATISTIQUE DES INDICES QUI
CARACTÉRISENT LE DÉBIT D'ÉTIAGE DE
TROIS RIVIÈRES DE L'EST DU CANADA**

Par
Deepti Joshi

Thèse présentée pour l'obtention du grade de
Philosophiae Doctor (Ph.D.) en sciences de l'eau

Jury d'évaluation

Examineur Externe	Madame Marie-Amélie Boucher Université du Québec à Chicoutimi
Examineur Externe	Monsieur Alex J. Cannon Pacific Climate Impacts Consortium
Examineur Interne	Monsieur Fateh Chebana INRS, Centre Eau Terre Environnement
Co-directeur de recherche	Monsieur Taha B.M.J. Ouarda INRS, Centre Eau Terre Environnement
Co-directrice de recherche	Madame Anik Daigle INRS, Centre Eau Terre Environnement Cégep Garneau, Québec
Directeur de recherche	Monsieur André St-Hilaire INRS, Centre Eau Terre Environnement



REMERCIEMENTS

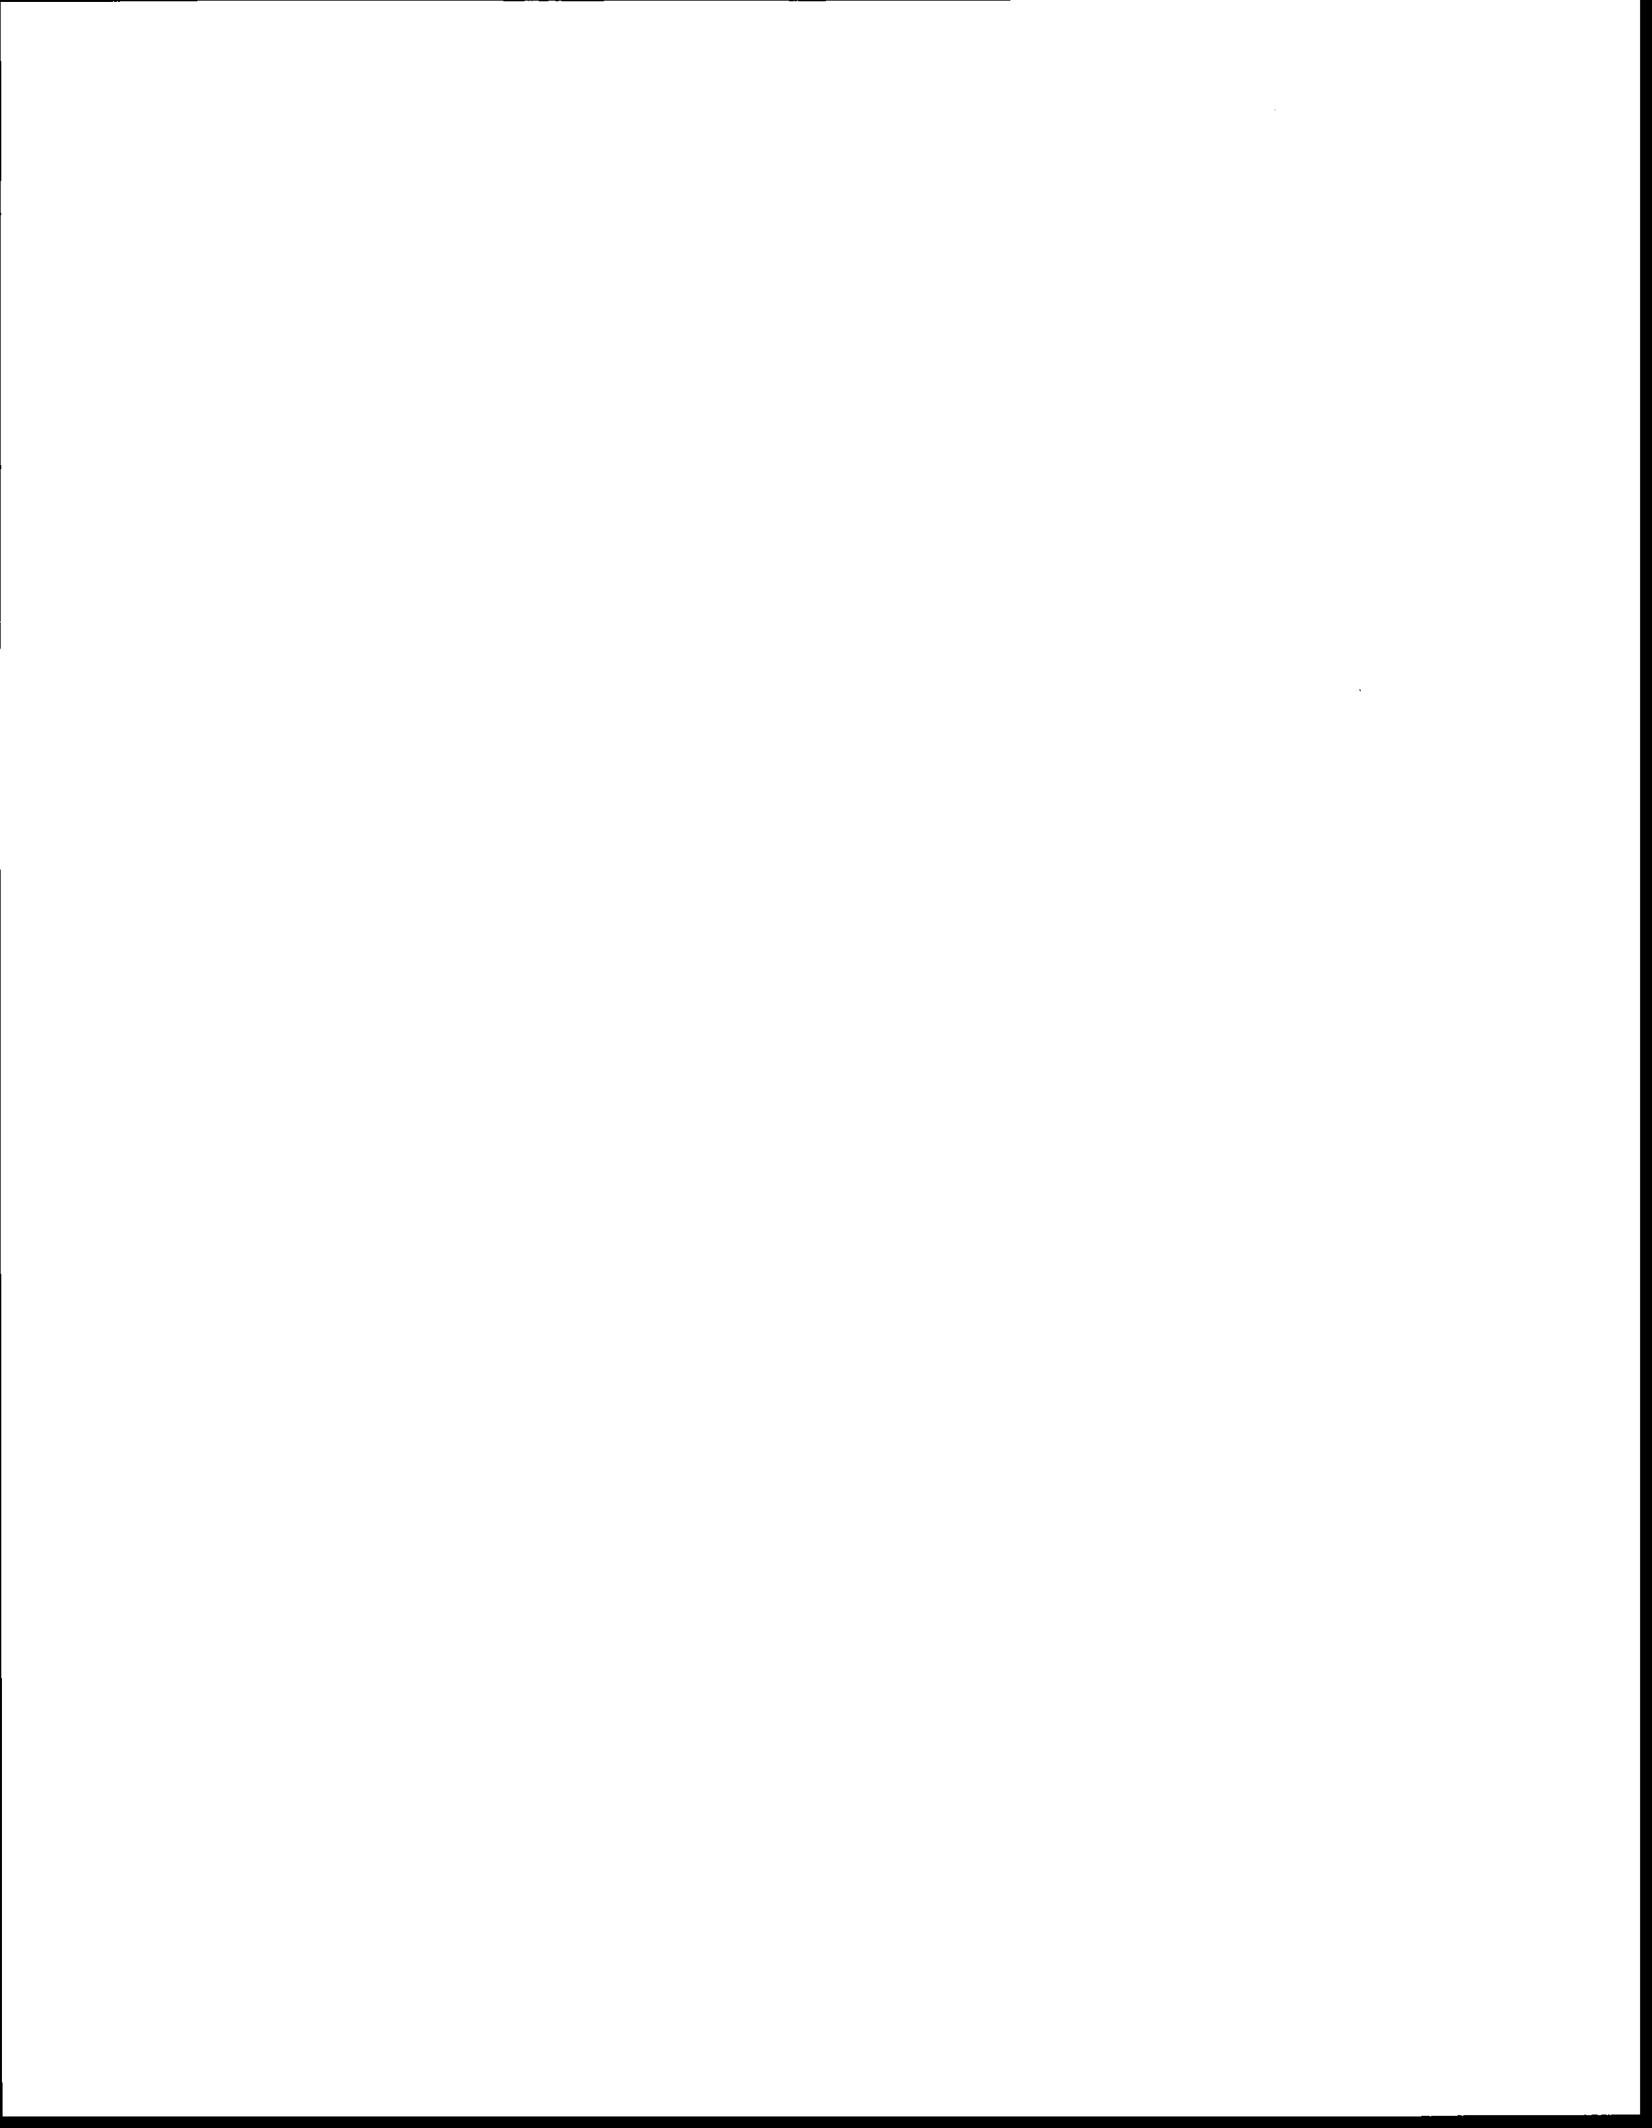
Je tiens à exprimer ma profonde gratitude et ma grande reconnaissance envers mon directeur de recherche le Professeur André St-Hilaire, pour son aide immense, sa coopération et ses conseils qui m'ont guidée dans l'achèvement de cette thèse.

J'exprime également ma profonde et sincère reconnaissance à mes co-directeurs de recherche, le Professeur Taha Ouarda et Anik Daigle dont les suggestions et les conseils m'ont accompagnée tout au long de cette étude.

Je remercie également Mme Suzanne Dussault et Mme Sophie Magos pour leur aide et leurs instructions. Je pense aussi tout particulièrement à mes amis Valérie Ouellet, Hélène Higgins, Sébastien Ouellet-Proulx, Laurence Perron et Christian Saad pour leur coopération et leur aide.

Je suis grandement redevable et exprime un profond sens de l'honneur envers mes parents bien-aimés, mon mari, Anirban Bhattacharjee et mon frère, Vivek Joshi, pour l'amour et les encouragements qu'ils m'ont accordés et pour leur soutien indéfectible tout au long de mes études.

Enfin, je tiens à exprimer mes sincères remerciements à tous ceux qui m'ont aidée, directement ou indirectement, à terminer cette thèse.



PRÉFACE

Cette étude met l'emphase sur la comparaison de deux approches de mise à l'échelle d'indices hydrologiques caractérisant les débits d'étiage dans trois rivières du Québec: la rivière Moisie, la rivière Romaine et la rivière Ouelle. Les résultats de cette étude ont été présentés dans plusieurs publications. La thèse est structurée en quatre chapitres. Le *Chapitre 1* présente le résumé avec une justification de l'utilisation des indices hydrologiques pour la gestion des ressources hydriques, suivi par une description détaillée des différentes approches de mise à l'échelle pour faciliter l'analyse des impacts des changements climatiques. Ce chapitre présente aussi la méthodologie, la formulation mathématique des approches mises en œuvre, les principaux résultats et une discussion à propos des méthodes développées. Le *Chapitre 2* présente les résultats de l'approche directe de mise à l'échelle, qui, comme son nom l'indique, établit une relation directe avec les indices d'étiage (article 1, publié dans le *Journal of Hydrology*). La deuxième approche de mise à l'échelle est appelée 'indirecte' parce qu'elle utilise une approche en deux étapes. D'abord, on procède à la mise à l'échelle statistique des variables météorologiques locales (précipitation et température). Puis, ces variables servent d'intrants à un modèle hydrologique déterministe qui simule les débits. Les indices d'étiage sont calculés à partir des chroniques de débits simulés. Le *Chapitre 3* décrit les résultats de mise à l'échelle de la précipitation et de la température (article 2, soumis à *Stochastic Environmental Research and Risk Assessment*). Finalement, le *Chapitre 4* décrit les résultats des simulations de débit faites à l'aide du modèle SSARR, avec en entrée des données de température et de précipitations mises à l'échelle. Ce chapitre décrit aussi les projections futures des indices de débit d'étiage obtenus à partir des sorties de modèles climatiques régional et global.



RÉSUMÉ

L'étiage est une période de l'année hydrologique pouvant s'avérer critique sur divers plans, notamment en ce qui a trait aux pêcheries, à la capacité d'assimilation des plans d'eau, à la disponibilité de l'eau potable et à la navigation. Toutefois, malgré l'importance évidente que revêt le facteur climatique relativement à la variabilité des débits d'étiage, bien peu d'études portent sur cette question. La plupart des études de mise à l'échelle de données hydroclimatiques qui portent sur les étiages présentent une approche à deux étapes: (1) les sorties issues d'un modèle de circulation générale (MCG) ou d'un modèle climatique régional sont utilisées pour la mise à l'échelle des variables climatiques locales, dont les précipitations et la température; puis (2) les variables ainsi ramenées à l'échelle locale sont insérées dans un modèle hydrologique afin de procéder à une simulation des débits qui peuvent ensuite servir à calculer des indices descripteurs du débit d'étiage. Le cadre de mise à l'échelle utilisant un modèle hydrologique (ou approche indirecte de mise à l'échelle) est entravé par certains écarts entre les sorties du MCG et les entrées requises au modèle hydrologique, les incertitudes relatives à la mise à l'échelle des variables climatiques et à l'estimation des paramètres du modèle, de même que par la propagation d'erreurs à travers les modèles de mise à l'échelle et hydrologique. Pour contourner ces contraintes, certaines études ont tenté d'établir un lien direct entre les variables climatiques à grande échelle et le débit. Toutefois, ces liens directs n'ont pas été explorés de façon aussi exhaustive que les approches indirectes de mise à l'échelle.

La présente étude vise ainsi à comparer les approches directe (AD) et indirecte (AI) de mise à l'échelle en vue de caractériser le régime d'étiage de trois rivières de l'est du Canada, soit les rivières Moisie, Romaine et Ouelle. Le régime d'étiage des rivières est caractérisé par le calcul d'indices hydrologiques (IH). En plus de ces approches, une troisième méthode a été mise en œuvre, laquelle comprend l'introduction de variables météorologiques observées dans le modèle hydrologique choisi en vue de simuler des débits qui serviront ensuite à calculer les IH. Cette approche a été appelée « Approche de validation partielle » (AVP). Les modèles statistiques utilisés pour la mise à l'échelle des IH selon l'AD et des variables climatiques locales selon la AI sont un modèle stochastique d'apprentissage bayésien (MSAB) et la régression linéaire multiple (RLM). D'un côté, le MSAB permet de définir des relations non linéaires entre les variables climatiques à grande échelle (prédicteurs) et la variable mise à

l'échelle (prédicteur) à l'aide d'un cadre probabiliste qui désavantage les modèles complexes en définissant une fonction de probabilité *a priori* associée aux coefficients de pondération.

Ultimement, l'algorithme conduit à un modèle dans lequel la valeur de la plupart des coefficients de pondération est de zéro. Les paramètres correspondants sont alors exclus du modèle prédictif, ce qui assure la parcimonie de la méthode. De l'autre côté, la RLM s'appuie sur les relations linéaires entre les prédicteurs et le prédicteur. Le MSAB a été mis en œuvre sous forme d'une machine à vecteur de pertinence (MVP, ou 'Relevant Vector Machine') alors que la RLM a été mise en œuvre à l'aide de l'outil mise à l'échelle statistique automatique ASD.

Le choix des prédicteurs pour la MVP a été fait à l'aide de l'analyse de corrélation canonique (ACC) alors que l'ASD utilise la régression multiple pas à pas descendante (RMD). En plus de l'ACC et de la régression pas à pas qui sont des constituantes de l'approche indirecte, un algorithme de programmation génétique (PG) a été testé pour la sélection des prédicteurs. Ce type d'algorithme fait évoluer un modèle mathématique à partir de fonctions non-linéaires d'ordre peu élevé qui transforment les variables d'entrée. Les prévisions des IH à partir de deux modèles (ECHAM5 (MCG) et le Modèle régional canadien du climat, MRCC) de 2021 à 2050 et de 2051 à 2070 ont également été analysées.

Les trois rivières sélectionnées sont hôtes de populations de saumon atlantique (*Salmo salar*), espèce qui est sensible aux conditions hydrologiques et thermiques associées aux étiages sévères. Les rivières Moisie et Romaine se situent sur la rive nord du fleuve Saint-Laurent alors que la rivière Ouelle est située sur la rive sud. Les régimes d'étiage de la Moisie et de la Romaine se caractérisent par des débits hivernaux très faibles attribuables à de basses températures prolongées. Ces conditions sont attribuées à l'occurrence de précipitations sous forme de neige et des périodes prolongées de température froide. Quant à la rivière Ouelle, elle se caractérise par des débits estivaux très faibles, probablement en raison des faibles précipitations et de l'évaporation relativement élevée ainsi que du faible afflux d'eaux souterraines. Les trois rivières qui nous intéressent ont été caractérisées par six indices hydrologiques appartenant à quatre catégories principales: l'amplitude, la temporalité, la variabilité et la durée. Les indices choisis sont:

- Les valeurs minimales du débit observées au mois de mars pour chaque année (AMP1); le rapport entre le débit le plus faible observé au cours de l'année et le débit annuel moyen (indice de débit de base, AMP2);
- le jour julien moyen des sept journées au cours desquelles les débits les plus faibles ont

- été observés au cours de l'année (T);
- l'écart type du jour julien de ces sept journées (V);
- le débit le plus faible observé sur une durée de 90 jours divisé par la valeur médiane de toute la période d'enregistrement (D1);
- le débit le plus faible observé sur une durée de 90 jours, de juillet à octobre, divisé par la valeur médiane de toute la période d'enregistrement (D2).

Comparativement à ceux des rivières Moisie et Romaine, les indices observés à la rivière Ouelle présentent de plus fortes variations. Les résultats obtenus ont permis de démontrer que l'approche directe de mise à l'échelle statistique (AD) à l'aide du MVP (AD1) surpasse toutes les autres approches et ce, à de nombreux égards. En effet, les indices de performance obtenus à partir de l'AD1 présentaient des différences marquées par rapport à ceux des autres approches. La parcimonie de la méthode a été assurée en choisissant un faible nombre de paramètres dans le modèle prédictif. La grande capacité de généralisation du modèle, AD1 s'est traduite par une similitude des valeurs des indices de performance lors des étapes d'étalonnage et de validation. Malgré les bons résultats obtenus, il s'avère que les approches d'AD dépendent de la capacité de modélisation de l'approche statistique sélectionnée pour la mise à l'échelle des indices de débit d'étiage. La principale raison qui explique cette conclusion est que pour certains indices (p. ex.: l'indice V pour la rivière Ouelle), de meilleurs résultats ont été obtenus à partir des AI et AVP qu'à partir de l'AD à l'aide de l'ASD. Ainsi, les approches de mise à l'échelle directe s'avèrent grandement influencées par le modèle statistique utilisé.

Les résultats obtenus à partir de la AI sont potentiellement entachés de deux sources d'incertitude: celles associées à la mise à l'échelle des variables climatiques et celles associées au modèle hydrologique. MVP a donné de meilleurs résultats que ASD pour la mise à l'échelle de la température. En contraste, les deux approches ont performé de manière sensiblement égale pour la mise à l'échelle des précipitations. Cependant, les résultats étaient plus probants pour ce qui est de la température (coefficient de corrélation (R) > 0,9) que pour la précipitation (R de l'ordre de 0,3 à 0,7). La combinaison de PG et MVP (MVPPG) améliore les résultats de mise à l'échelle des précipitations tandis que l'utilisation de PG et RLM (RLMPG) ne donne pas de meilleurs résultats que la même méthode sans algorithme génétique. Dans certains cas, ASD performe mieux que RLMPG pour la classification des jours avec et sans pluie, de même que pour l'estimation des quantités de pluie.

Par la suite, les variables climatiques mises à l'échelle locale ont été utilisées comme intrants dans le modèle SSARR en vue de simuler le débit. Cette fois encore, les indices de débit d'étiage (IH) calculés à partir des résultats de la simulation se sont avérés comparables pour les deux approches indirectes de mise à l'échelle. Pour certains indices, l'AVP a été surpassée par les AI (indice V pour la Romaine) et ce, malgré l'utilisation des valeurs observées de précipitation et de température. Les prévisions des IH sur les périodes 2021 à 2050 et 2051 à 2070 ont révélé un changement marqué de leur moyenne et de leur variabilité. Toutefois, aucune tendance croissante ou décroissante n'a été observée chez aucun des indices.

Mots-clés: Indices de débit d'étiage, méthode stochastique d'apprentissage bayésien, régression linéaire multiple, débits d'étiage, analyse de corrélation canonique, mise à l'échelle statistique.

TABLE DES MATIÈRES

REMERCIEMENTS	iii
PRÉFACE	v
RÉSUMÉ	vii
TABLE DES MATIÈRES	xi
LISTE DES TABLEAUX	xvii
LISTE DES FIGURES	xxi
LISTE DES ÉQUATIONS	xxvii
LISTE DES ABRÉVIATIONS	xxxix
PARTIE 1 : SYNTHÈSE	1
CHAPITRE 1: SYNTHÈSE	3
1. INTRODUCTION	3
1.1 Le débit d'étiage et la variabilité du climat	5
1.2 Définition du domaine de l'étiage: Les Indices Hydrologiques	6
1.3 Les conséquences de la variabilité climatique sur le débit d'étiage	8
1.4 Des modèles climatiques globaux au climat régional	9
1.5 LA MISE À L'ÉCHELLE DYNAMIQUE	13
1.6 La mise à l'échelle statistique	14
1.6.1 Le typage météorologique	16
1.6.2 Les générateurs météorologiques stochastiques (WGEN)	16
1.6.3 Les modèles de régression	17
1.7 Le cadre de mise à l'échelle indirecte	21
2 PROBLÉMATIQUE ET OBJECTIFS DE RECHERCHE	23
2.1 Originalité du projet de recherche	24
3 PLAN DE MISE EN APPLICATION	25

3.1	Modèles de mise à l'échelle statistique	25
3.1.1	Apprentissage Bayésien (AB)	25
3.1.1.1	Modèle de régression parcimonieux	26
3.1.1.2	Modèle de classification parcimonieux	30
3.1.2	Régression linéaire multiple (RLM)	31
3.1.3	Algorithme génétique pour la mise à l'échelle des précipitations	32
3.2	Modèle hydrologique	38
3.3	Cadre de mise à l'échelle statistique	44
3.3.1	Préparation des entrées	44
3.3.2	Mise à l'échelle	44
3.3.3	Calcul des IH du débit d'étiage	45
3.3.4	Approches utilisées	45
3.4	Méthodes de validation et mesures du rendement	48
3.5	Projections	50
4	RÉGION ÉTUDIÉE	53
5	CHOIX DES INDICES HYDROLOGIQUES DE DÉBIT D'ÉTIAGE	59
6	RÉSULTATS	63
6.1	Approche directe de mise à l'échelle	63
6.2	Approche indirecte de mise à l'échelle	64
6.2.1	Mise à l'échelle des valeurs de précipitations et de température	64
6.2.2	Simulation des débits à l'aide du modèle SSARR	69
6.2.3	Comparaison des approches indirectes de mise à l'échelle	70
6.3	Comparaison de l'approche directe, de l'approche indirecte et de la validation partielle	72
6.4	Projections	75
7	DISCUSSION	81
8	CONCLUSION	85
9	RECOMMANDATIONS	87
	PARTIE 2: ARTICLES	89

DATABASED COMPARISON OF SPARSE BAYESIAN LEARNING AND MULTIPLE LINEAR REGRESSION FOR STATISTICAL DOWNSCALING OF LOW FLOW INDICES	91
ABSTRACT	93
1 INTRODUCTION	94
2 STATISTICAL DOWNSCALING	98
2.1 Automated Statistical Downscaling Tool	98
2.2 Sparse Bayesian Learning	98
2.2.1 Relevance Vector Machine	99
3 STUDY AREA AND DATA RESOURCE	100
4 METHODOLOGY	104
4.1 Selection of Low flow Indices	104
4.1.1 Selected Low flow Indices	106
4.1.1.1 A1 (Minimum March Flows)	106
4.1.1.2 A2 (Base flow Index)	107
4.1.1.3 T (Average Julian date of seven one day minimum)	107
4.1.1.4 V (standard deviation of the Julian date of seven one day minimum)	108
4.1.1.5 D1 (Annual 90 day minimum divided by Q50)	108
4.1.1.6 D2 (90 day minimum for S2 divided by Q50)	108
4.1.2 Predictor Selection	109
4.1.3 Statistical downscaling Framework	115
4.1.4 Performance Indices	117
5 RESULTS	118
6 DISCUSSION	122
7 CONCLUSION	124
8 APPENDIX-1	126
8.1.1 Theoretical Background of Sparse Bayesian Learning	126
STATISTICAL DOWNSCALING OF PRECIPITATION AND TEMPERATURE USING SPARSE BAYESIAN LEARNING, MULTIPLE LINEAR REGRESSION AND GENETIC PROGRAMMING FRAMEWORKS	131
ABSTRACT	133

1	INTRODUCTION	134
2	STATISTICAL MODELS	137
2.1	Multiple linear regression	137
2.1.1	Automated Statistical Downscaling Tool	137
2.2	Sparse Bayesian Learning	138
2.3	Genetic programming framework for precipitation downscaling	139
3	STUDY AREAS AND DATA	145
4	METHODOLOGY	149
4.1	Statistical Downscaling Framework	149
4.2	Model Accuracy Measures	155
5	RESULTS	156
5.1	Temperature downscaling results	156
5.2	Precipitation Results	159
5.2.1	Classification Results	159
5.2.1.1	Comparison of transition probabilities	161
5.2.2	Precipitation amount downscaling results	162
5.2.2.1	Seasonal results	165
6	DISCUSSION	166
7	CONCLUSION	168
	COMPARISON OF DIRECT STATISTICAL AND INDIRECT STATISTICAL-DETERMINISTIC FRAMEWORKS IN DOWNSCALING RIVER LOW-FLOW INDICES	169
	ABSTRACT	171
1	INTRODUCTION	172
2	STATISTICAL DOWNSCALING FRAMEWORK	175
2.1	Statistical models	178
2.1.1	Relevance vector machine (RVM)	179
2.1.2	Automated statistical downscaling tool	179
2.2	The hydrological model: SSARR	179

2.2.1	SSARR calibration	181
3	STUDY AREA	183
4	SELECTION OF LOW FLOW INDICES	187
5	PREDICTOR SELECTION	189
6	MODEL VALIDATION AND PERFORMANCE	191
7	RESULTS	192
7.1	Intercomparison of DD approaches (DD1 and DD2)	192
7.2	Downscaling of precipitation and temperature	192
7.3	SSARR calibration	192
7.4	Intercomparison of ID approaches (ID1 and ID2)	194
7.5	Comparison of DD and ID approaches	194
7.6	Comparison of PVA and downscaling approaches (DD and ID)	198
7.6.1	PVA and DD approaches	198
7.6.2	PVA and ID approaches	198
7.7	Future projections of low flow HIs	198
7.7.1	Amplitude Indices (AMP1 and AMP2)	199
7.7.2	Timing and Variability Indices (T and V)	199
7.7.3	Duration Indices (D1 and D2)	199
8	DISCUSSION	202
8.1	Comparison between statistical models (SBL and MLR)	202
8.2	Comparison between the two downscaling strategies	202
8.3	Future projections given by GCM and RCM	204
9	CONCLUSION	205
	BIBLIOGRAPHIE	207

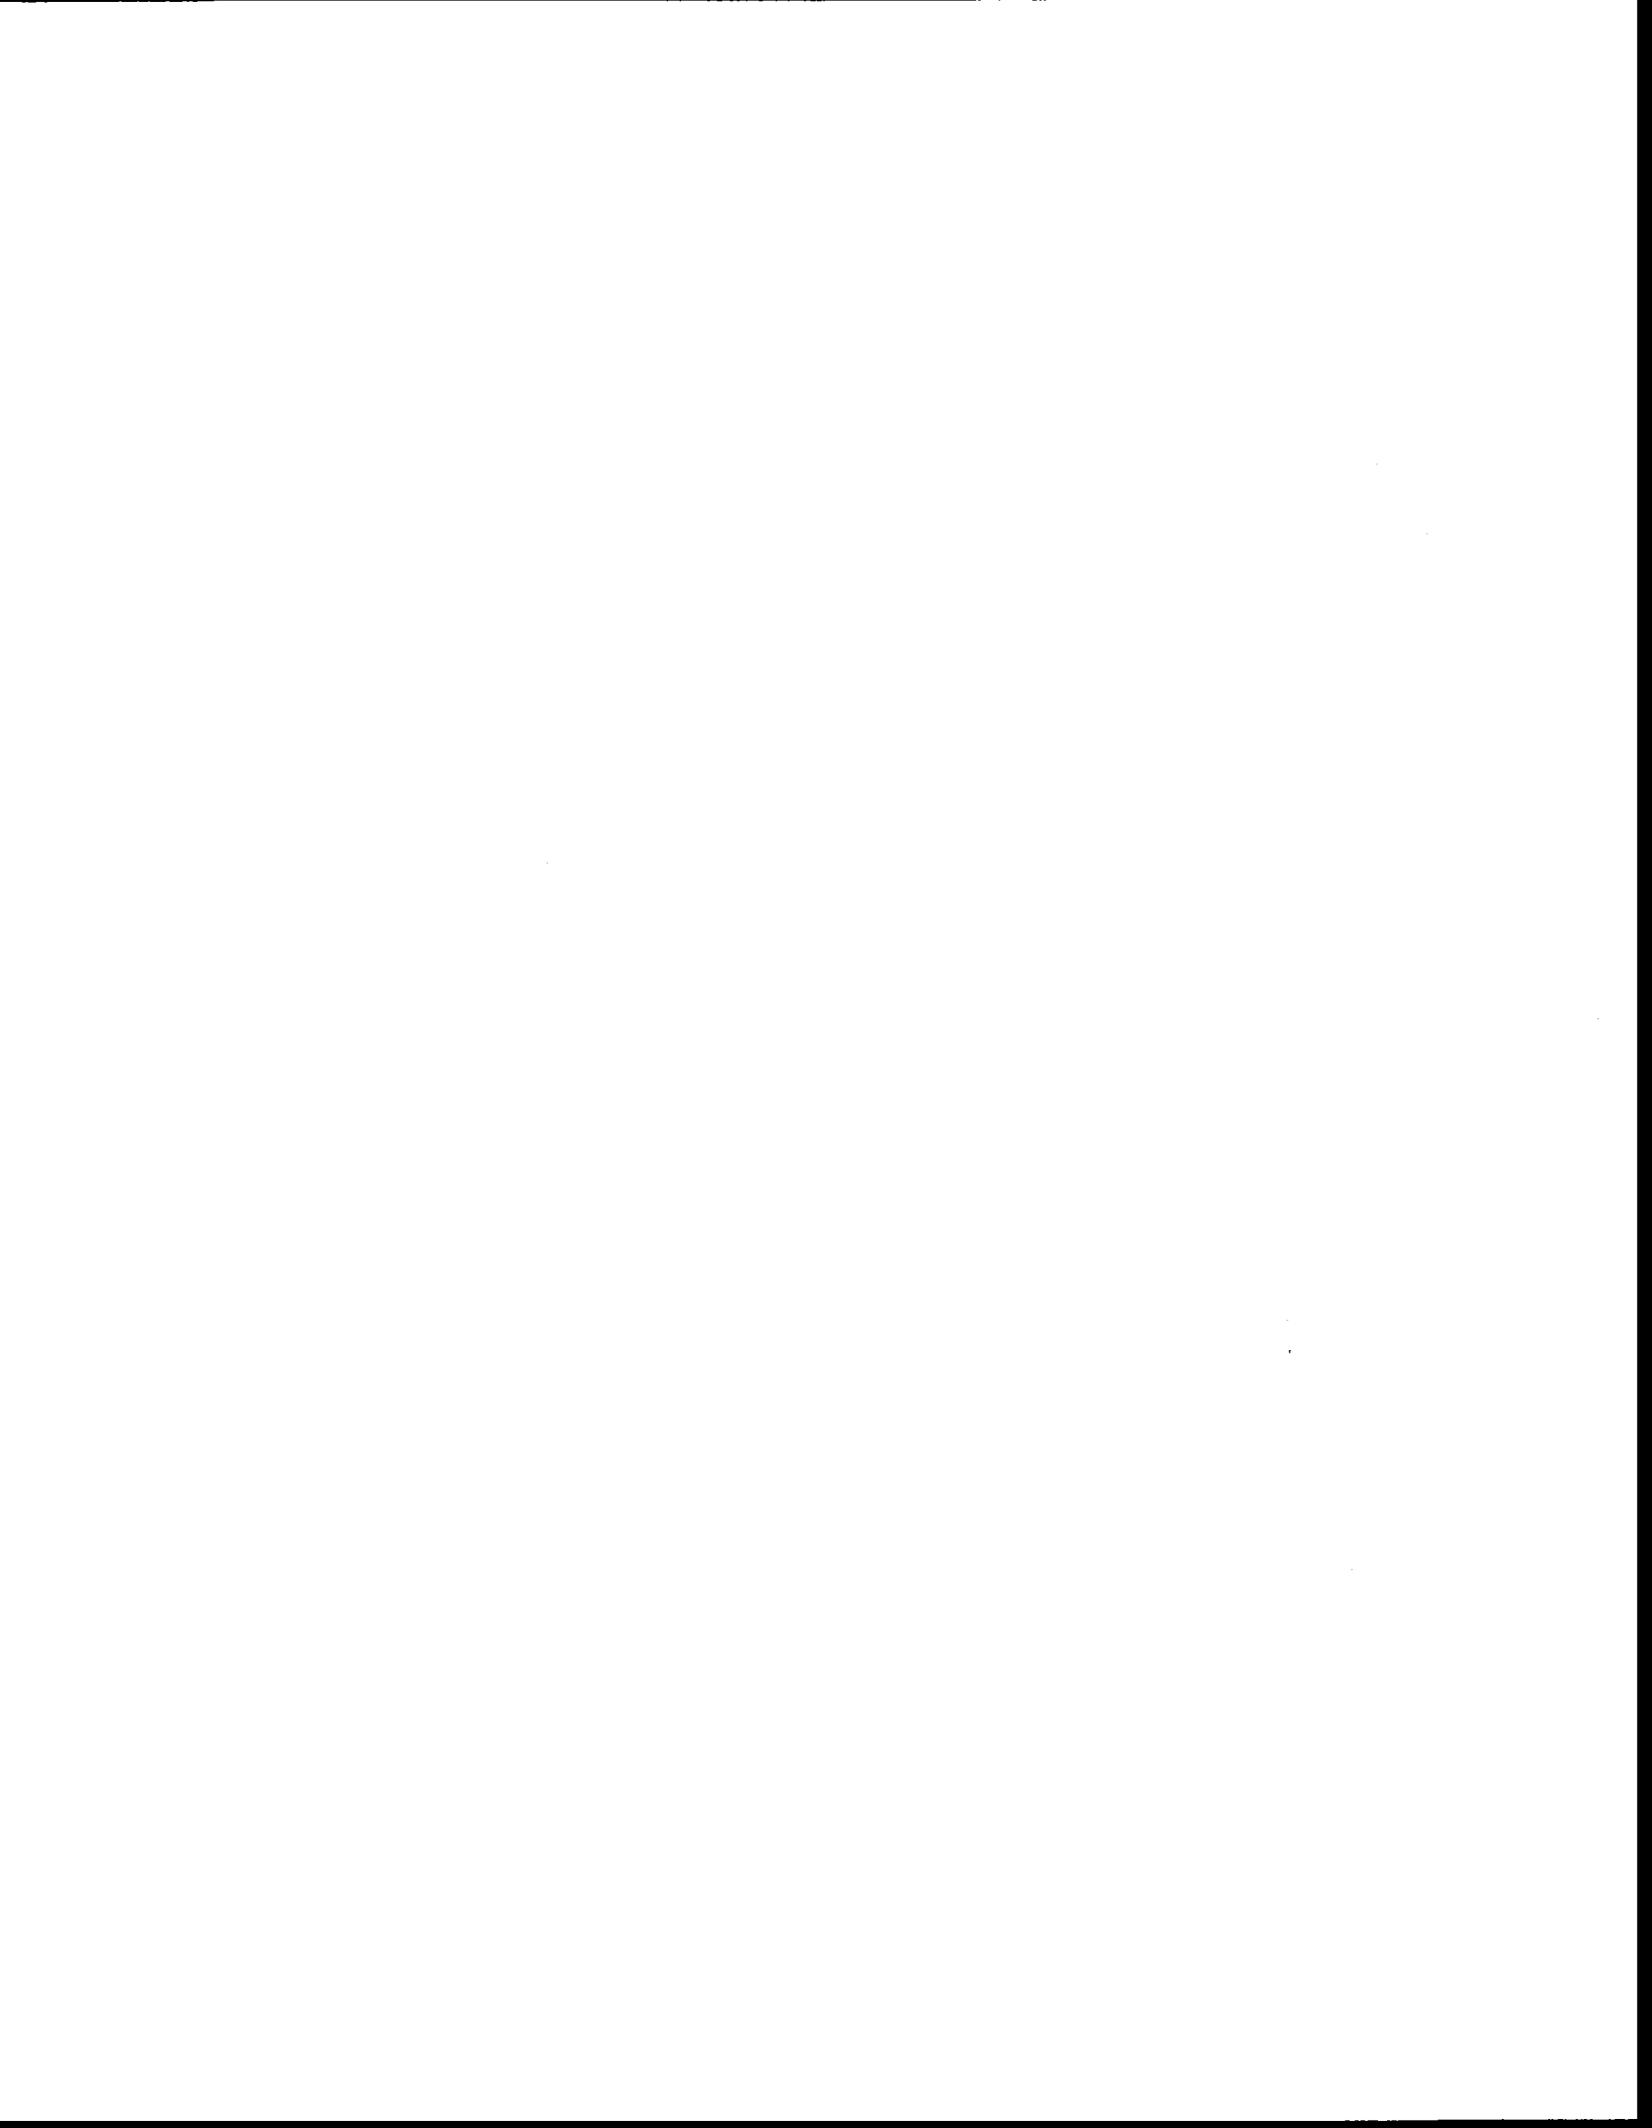


LISTE DES TABLEAUX

Tableau 1.1	Performances de simulation des MCG en fonction de l'échelle spatiale, temporelle, verticale et des variables d'intérêt pour la modélisation hydrologique (Xu, 1999).....	12
Tableau 1.2.	Prédicteurs du NCEP utilisés dans le cadre de la mise à l'échelle	47
Tableau 1.3	Division des données météorologiques disponibles en ensembles d'étalonnage et de validation. Deux combinaisons d'ensembles d'étalonnage et de validation ont été définies ; elles sont désignées par C1 et C2.....	50
Tableau 1.4.	Scénarios d'émissions recommandés par le Groupe d'experts intergouvernemental sur l'évolution du climat (IPCC, 2000) afin d'évaluer les résultats futurs relatifs aux émissions	52
Tableau 1.5	Description des stations et données hydrométriques (tiré de Joshi et al., 2013).....	55
Tableau 1.6.	Prédicteurs sélectionnés pour la mise à l'échelle de la température et de la précipitation. Les numéros des prédicteurs réfèrent au tableau 1.2.....	66
Table 2.1	Description of discharge stations.....	101
Table 2.2	Selected hydrological indices definition with index code.....	105
Table 2.3	NCEP predictors used in the downscaling framework... ..	110
Table 2.4	Predictands significantly correlated with selected low flow indices for river Romaine. Negatively correlated predictors are indicated by bold numbers whereas normal fonts indicate positively correlated predictors. The mentioned numbers refer to NCEP reanalysis variables listed in table 2.3.	112
Table 2.5	Predictands significantly correlated with selected low flow indices for river Moisie. Negatively correlated predictors are indicated by bold numbers whereas normal fonts indicate positively correlated predictors. The mentioned numbers refer to NCEP reanalysis variables listed in table 2.3.	113
Table 2.6	Predictands significantly correlated with selected low flow indices for river Ouelle. Negatively correlated predictors are indicated by bold numbers whereas normal fonts indicate positively correlated predictors. The mentioned numbers refer to NCEP reanalysis variables listed in table 2.3.	114

Table 2.7	Predictors selected using stepwise regression in the ASD tool. The mentioned numbers refer to NCEP reanalysis variables shown in table 2.3.....	116
Table 2.8	Number of Relevant vectors (% of total training points). The width of the kernel functions are indicated in brackets.....	119
Table 3.1	Details of the meteorological stations used in the current work. The alphabet mentioned in brackets in the first column denotes the abbreviation used for the station in subsequent tables and figures.....	147
Table 3.2	List of predictors selected for the downscaling of precipitation and temperature at the selected meteorological stations	150
Table 3.3	Combinations of calibration and validation sets used in downscaling precipitation and temperature downscaling. Data sizes in years are indicated in brackets	151
Table 3.4	Some of the initial system parameters (GPTIPS) used for the GP algorithm.....	153
Table 3.5	Predictors selected for temperature and precipitation downscaling for set 1 and set 2. The numbers refer to the corresponding predictors mentioned in table 3.2. Alphabets refer to the stations mentioned in table 3.1.....	157
Table 3.6	Comparison of wet day transition probabilities obtained for C1. 'Obs' refers to observed values and 'Stn' indicates the stations. The alphabets denoting the station names are shown in table 3.1.....	161
Table 3.7	Comparison of dry day transition probabilities obtained for C1. 'Obs' refers to observed values and 'Stn' indicates the stations. The alphabets denoting the station names are shown in table 3.1.....	162
Table 4.1	Description of meteorological stations used in the current work.....	185
Table 4.2	Description of hydrometric stations (reproduced from Joshi et al., 2013).....	186
Table 4.3	Selected hydrological indices definition with index code (reproduced from Joshi et al., 2013).....	188
Table 4.4	NCEP predictors used in the downscaling framework (reproduced from Joshi et al., 2013).....	190
Table 4.5	Calibration and validation sets used in the analysis. Data sizes in years are indicated in brackets	193

Table 4.6	SSARR simulation results for C1 for the entire year (YEARLY), summer (SMR) and winter (WNTR). The performance indices were calculated for calibration and validation periods combined.....	193
-----------	--	-----



LISTE DES FIGURES

Figure 1.1	Un modèle multigène pseudo-linéaire avec variable dépendante Y et prédicteurs x, y and z. Les coefficients a0, a1 and a2 sont obtenus automatiquement par MVP and ASD.....	34
Figure 1.2	Deux différent types de mutations. L'arbre du haut est l'original. En bas à gauche, on a la représentation d'une mutation d'une seule branche terminale (3) par une autre branche terminale (a). C'est aussi une représentation d'une mutation d'une seule fonction (-) pour une autre fonction (+). L'arbre en bas à droite illustre un remplacement de toute une arborescence par une autre.	36
Figure 1.3	Opération de transfert dans l'algorithme génétique. Les sélections en gras pour les deux parents sont échangées pour créer les enfants.....	37
Figure 1.4	Algorithme du module intégré par bandes de neige homogènes selon le SSARR (guide d'utilisation du SSARR, 1991).	40
Figure 1.5	Cadre de mise à l'échelle statistique décrivant les algorithmes de la mise à l'échelle directe, de la mise à l'échelle indirecte et de la validation partielle. PG a seulement été utilisé pour les précipitations dans AI.....	46
Figure 1.6	Carte de la zone d'étude illustrant l'emplacement des stations hydrométriques (cercles) et météorologiques (carrés) des rivières Romaine, Moisie et Ouelle. (figure tirée de Joshi et al., 2013).....	53
Figure 1.7	Courbes de débits classés estivales et hivernales des rivières Romaine, Moisie et Ouelle	55
Figure 1.8	Températures et précipitations annuelles moyennes enregistrées aux stations météorologiques. Les lettres correspondent aux stations décrites au tableau 1.6.	57
Figure 1.9	Diagrammes en hamac des indices hydrologiques choisis pour les rivières Romaine, Moisie et Ouelle (tirés de Joshi et al., 2013).....	61
Figure 1.10	Résultats de validation des modèles de mise à l'échelle (MVP, ASD et RLMACC) obtenus pour la rivière Ouelle	64
Figure 1.11	Résultats de validation de la mise à l'échelle de la température obtenus par le MVP et l'ASD, pour les combinaisons C1 et C2. Les barres blanches et grises représentent respectivement l'ASD et le MVP. Les noms de stations sont représentés par des lettres sur l'axe horizontal (voir le tableau 1.6).	66

Figure 1.12	Résultats de classification des jours secs et humides pour la mise à l'échelle des précipitations avec PG comme méthode de préparation des intrants. Les résultats sont présentés pour les périodes de validation de C1 et C2 (tableau 1.3). Les noms de stations sont représentés par des lettres sur l'axe horizontal (voir le tableau 1.6).	68
Figure 1.13	Résultats des régressions pour les taux de précipitations mis à l'échelle avec le PG comme méthode de preparation des intrants. Les résultats présentés correspondent aux périodes de validation de C1 et C2 (tableau 1.3). Les noms de stations sont représentés par des lettres sur l'axe horizontal (voir le tableau 1.6).	68
Figure 1.14	Résultats de la simulation à l'aide du modèle SSARR pour les trois rivières, pour les deux combinaisons C1 et C2 des ensembles de calibration et de validation).....	70
Figure 1.15	Indices de performance des IH d'approche indirecte pour la rivière Moisie pour les deux combinaisons des ensembles de calibration et de validation.....	71
Figure 1.16	Indices de performance des IH de l'approche indirecte pour la rivière Romaine pour les deux combinaisons des ensembles de calibration et de validation.....	71
Figure 1.17	Indices de performance des IH de l'approche indirecte pour rivière Ouelle pour les deux combinaisons des ensembles de calibration et de validation.....	72
Figure 1.18	Comparaison des indices de performance des IH pour la combinaison C1 appliquée à la rivière Ouelle. Les approches comparées sont les suivantes : réduction directe à l'aide de la MVP (AD1) et du ASD (AD2); réduction indirecte à l'aide du modèle hydrologique SSARR et des valeurs observées (AVP) et mises à l'échelle des précipitations et de la température à titre d'entrées selon deux méthodes, soit la MVP (AI1) et le ASD (AI2).....	74
Figure 1.19	Comparaison des indices de performance des IH pour la combinaison C2 appliquée à la rivière Ouelle. Les approches comparées sont les suivantes : réduction directe à l'aide de la MVP (AD1) et du ASD (AD2); réduction indirecte à l'aide du modèle hydrologique SSARR et des valeurs observées (AVP) et mises à l'échelle des précipitations et de la température à titre d'entrées selon deux méthodes, soit la MVP (AI1) et le ASD (AI2).....	74
Figure 1.20	Comparaison des IH observés et simulés à partir des sorties du MCG et du MCR, ainsi que des données du NCEP pour la période de référence, soit de 1961 à 2010, à la rivière Romaine.....	75

Figure 1.21	Comparaison des IH observés et simulés à partir des sorties du MCG et du MCR, ainsi que des données du NCEP pour la période de référence, soit de 1961 à 2010, à la rivière Ouelle.	76
Figure 1.22	Comparaison des IH observés et simulés à partir des sorties du MCG et du MCR, ainsi que des données du NCEP pour la période de référence, soit de 1961 à 2010, à la rivière Moisie.	76
Figure 1.23	Diagramme en hamac des IH de débit d'étiage prévus à la rivière Romaine, tels qu'obtenus à partir du modèle ECHAM5 soumis aux scénarios A1B, A2 et B1 pour les années 2020 (2021 à 2050) et 2050 (2051 à 2070). Hist réfère à la période 1960-2010.....	78
Figure 1.24	Diagramme en hamac des IH de débit d'étiage prévus à la rivière Romaine tels qu'obtenus du MRCC soumis aux scénarios A1B, A2 et B1 pour les années 2020 (2021 à 2050) et 2050 (2051 à 2070). Hist réfère à la période 1960-2010.	78
Figure 1.25	Diagramme en hamac des IH de débit d'étiage prévus à la rivière Romaine tels qu'obtenus pour DD2 du ECHAM5 soumis aux scénarios A1B, A2 et B1 pour les années 2020 (2021 à 2050) et 2050 (2051 à 2070). Hist réfère à la période 1960-2010.	79
Figure 2.1	The study area map showing the locations of discharge and meteorological stations on each river. The squares and circles denote meteorological and discharge stations, respectively.	101
Figure 2.2	Precipitation and Temperature normals of the meteorological stations. For Lac Eon and Havre-St Pierre normals are calculated for 1964-1976 and 1964-1984 respectively. For the remaining stations normals correspond to 1971-2000.	103
Figure 2.3	Mean specific hydrograms for (a) Romaine, (b) Moisie and (c) Ouelle. The dotted lines indicate daily mean specific flow plus and minus the daily standard deviation. The drainage area of each river is also indicated.....	103
Figure 2.4	Box plots of low flow indices using the entire available dataset. The gray line represents the median and the '+' sign shows the outliers.	106
Figure 2.5	Statistical downscaling framework.....	117
Figure 2.6	Mean RRMSE, RMABE and R^2 calibration values for (a) Romaine, (b) Moisie and (c) Ouelle. White bars represent ASD results and gray bars represent RVM results.	118
Figure 2.7	RRMSE, RMABE and R^2 validation results for (a) Romaine, (b) Moisie and (c) Ouelle. White bars represent ASD results and gray bars represent RVM results..	119

Figure 2.8	Observed versus predicted plot of the variability index for Ouelle. The dotted line represents 1:1 line.	120
Figure 2.9	RRMSE, RMABE and R ² validation results for river Ouelle using MLR, CCAMLR and SBL frameworks. The description of selected indices is given in table 2.2.	121
Figure 3.1	Example of a function tree formed using grammar functions * and +. The equation representing the tree is $f(x_1, x_2) = x_1 + (x_2 * 10)$	139
Figure 3.2	Crossover operations for genetic programming. The bold selections on both parents are swapped to create the offspring or children.	142
Figure 3.3	Two different types of mutations. The top tree is the original individual. The bottom left tree illustrates a mutation of a single terminal (3) for another single terminal (a). It also illustrates a mutation of a single function (-) for another single function (+). The tree on the extreme right illustrates a replacement of a subtree by another subtree.	143
Figure 3.4	Study area map showing the drainage basins and the location of the meteorological and hydrological stations. Meteorological stations are denoted by squares whereas hydrological stations by circles.	146
Figure 3.5	Precipitation and temperature normals of the meteorological stations described in table 3.1. Normals were calculated for 30 years (1971-2000).	148
Figure 3.6	Statistical downscaling framework for precipitation and temperature.	154
Figure 3.7	SBL (RVM) and MLR (ASD) temperature downscaling results for C1. White bars represent MLR whereas gray bars represent SBL results.	158
Figure 3.8	SBL (RVM) and MLR (ASD) temperature downscaling results for C2. White bars represent MLR whereas gray bars represent SBL results.	158
Figure 3.9	Comparison of classification results given by SBL, MLR, SBLGP and MLRGP for combination C1. White bars represent SBL, light gray bars represent MLR, dark gray bars represent SBLGP and black bars show MLRGP results.	160
Figure 3.10	Comparison of classification results given by SBL, MLR, SBLGP and MLRGP for combination C2. White bars represent SBL, light gray bars represent MLR, dark gray bars represent SBLGP and black bars show MLRGP results.	160
Figure 3.11	Regression results given by SBL, MLR, SBLGP and MLRGP for combination C1. White bars represent SBL, light gray bars represent MLR, dark gray bars represent SBLGP and black bars show MLRGP results.	164

Figure 3.12	Regression results given by SBL, MLR, SBLGP and MLRGP for combination C2. White bars represent SBL, light gray bars represent MLR, dark gray bars represent SBLGP and black bars show MLRGP results.....	164
Figure 3.13	RRMSE, RMAE and R^2 results of winter and summer seasons obtained for C1. White bars and gray bars represent SBL and MLR results.	165
Figure 4.1	Statistical Downscaling Framework.....	178
Figure 4.2	Snow–Elevation band example of rain, snow and melt (SSARR manual, 1991).....	180
Figure 4.3	The study area map showing the locations of discharge and meteorological stations on each river. The squares and circles denote meteorological and discharge stations, respectively.....	184
Figure 4.4	Flow duration curves for Romaine, Moisie and Ouelle for summer (dashed line) and winter flows (smooth line). The drainage areas (DA) are indicated in the figure. Data are plotted on semi-logarithmic axis....	185
Figure 4.5	Comparison of downscaling results for Moisie for C1.The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.....	195
Figure 4.6	Comparison of downscaling results for Moisie for C2.The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.....	195
Figure 4.7	Comparison of downscaling results for Romaine for C1.The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.....	196
Figure 4.8	Comparison of downscaling results for Romaine for C2.The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.....	196
Figure 4.9	Comparison of downscaling results for Ouelle for C1.The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.....	197

Figure 4.10	Comparison of downscaling results for Ouelle for C2. The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.....	197
Figure 4.11	CRCM (RCM) projections for Ouelle for scenario A2. BL refers to baseline period (1961-2010). The naming convention is scenario name followed by 20s (2021-2050) or 50s (2051-2080). A220s and A250s refer to A2 scenario corresponding to 2021-2050 and 2051-2080 respectively.	200
Figure 4.12	ECHAM5 (GCM) projections for Ouelle given by scenarios A1B, A2 and B1. BL refers to baseline period (1961-2010). The naming convention is scenario name followed by 20s (2021-2050) or 50s (2051-2080). A1B20s and A1B50s refer to A1B scenario corresponding to 2021-2050 and 2051-2080 respectively.	200
Figure 4.13	CRCM (RCM) projections for Moisie for scenario A2. BL refers to baseline period (1961-2010). The naming convention is scenario name followed by 20s (2021-2050) or 50s (2051-2080). A220s and A250s refer to A2 scenario corresponding to 2021-2050 and 2051-2080 respectively.....	201
Figure 4.14	ECHAM5 (GCM) projections for Ouelle given by scenarios A1B, A2 and B1. BL refers to baseline period (1961-2010). The naming convention is scenario name followed by 20s (2021-2050) or 50s (2051-2080). A1B20s and A1B50s refer to A1B scenario corresponding to 2021-2050 and 2051-2080 respectively.....	201

LISTE DES ÉQUATIONS

(1-1).....	14
(1 2).....	18
(1 3).....	18
(1 4).....	20
(1-5).....	26
(1-6).....	26
(1-7).....	26
(1-8).....	27
(1-9).....	27
(1-10).....	27
(1-11).....	27
(1-12).....	27
(1-13).....	28
(1-14).....	28
(1-15).....	28
(1-16).....	28
(1-17).....	28
(1-18).....	28
(1-19).....	29
(1-20).....	29
(1-21).....	29
(1-22).....	29
(1-23).....	30
(1-24).....	30
(1-25).....	30

(1-26)	30
(1-27)	30
(1-28)	30
(1-29)	31
(1-30)	31
(1-31)	31
(1-32)	32
(1-33)	35
(1-34)	35
(1-35)	41
(1-36)	43
(1-37)	43
(1-38)	43
(1-39)	43
(1-40)	49
(1-41)	49
(1-42)	49
(1-43)	49
(1-44)	49
(1-45)	51
(2-1)	99
(2-2)	115
(2-3)	117
(2-4)	117
(2-5)	117
(2-6)	126

(2-7)	126
(2-8)	126
(2-9)	127
(2-10)	127
(2-11)	127
(2-12)	127
(2-13)	127
(2-14)	128
(2-15)	128
(2-16)	128
(2-17)	128
(2-18)	128
(2-19)	128
(2-20)	128
(2-21)	129
(2-22)	129
(2-23)	129
(2-24)	129
(2-25)	129
(3 1)	137
(3 2)	138
(3 3)	140
(3 4)	140
(3-5)	151
(3-6)	152
(3-7)	155

(3-8)	155
(3-9)	155
(4-1)	177
(4 2)	179
(4 3)	179
(4 4)	181
(4 5)	181
(4 6)	181
(4 7)	181
(4 8)	191
(4 9)	191
(4 10)	191

LISTE DES ABRÉVIATIONS

ACC	Analyse de corrélation canonique
ACP	Analyse en Composantes Principales
AD	Approche directe de mise à l'échelle
AI	Approche directe de mise à l'échelle
ASD	Automated Statistical Downscaling Model
AVP	Approche de validation partielle
BMA	Biais Moyen Absolu
BMR	Biais moyen relatif
CFDÉ	Courbe de fréquence du débit d'étiage
COSEPAC	Comité sur la situation des espèces en péril au Canada
DAM	Débit annuel moyen
DM	Débit median
DMA	Débit minimal absolu
FDC	Fonctions de distributions cumulées
GIEC	Groupes d'experts intergouvernemental sur l'évolution du climat
IH	Indices de débit d'étiage
IDB	Index de débit de base
ITEÉ	Taux d'efficacité de l'évapotranspiration
MCG	Modèles climatiques globaux
MCR	Modèle climatique régional
MRCC	Modèle régional canadien du climat

MSAB	Méthode stochastique d'apprentissage bayésien
MSABPG	MSAB avec PG
MVP	Machine à vecteur de pertinence
MVS	Machine à vecteur de soutien
NCEP	National Center for Environmental Prediction
PG	Programmation génétique
R^2	Coefficient de détermination
RLM	Régression linéaire multiple
RLMACC	RLM avec ACC
RLMPG	RLM avec PG
RN	Réseaux neuronaux
REQM	Racine de l'erreur quadratique moyenne
RREQM	Racine relative de l'erreur quadratique moyenne
SDSM	Statistical Downscaling Model
SSARR	Synthèse du débit et régulation du reservoir
VCR	Validation croisée par rééchantillonnage

PARTIE 1 : SYNTHÈSE



CHAPITRE 1: SYNTHÈSE

1. INTRODUCTION

Les changements que connaît le climat de la planète risquent de poser une sérieuse menace environnementale au cours du prochain siècle. Les changements climatiques peuvent être attribuables à des processus internes d'origine naturelle, à des influences externes ou à des changements anthropiques persistants dans la composition de l'atmosphère ou dans l'utilisation des sols. À cet effet, le quatrième rapport d'évaluation du Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC) (2007) prévoit une augmentation de la température moyenne à la surface du globe variant de 1,8 à 4,0 °C par rapport à la température actuelle d'ici l'an 2100. De tels changements auront de graves répercussions sur le cycle hydrologique; ils modifieront les taux de précipitation et d'évapotranspiration, lesquels auront à leur tour une influence sur le débit et sur les débits d'étiage (Kite, 1993; Lettenmaier et Gan, 1990; Mortsh et al., 2000; Westmacott et Burn, 1997).

Les débits d'étiage retiennent grandement l'attention de la société scientifique en raison de leur nature diversifiée et complexe, ainsi que de l'intérêt qu'ils représentent dans plusieurs disciplines scientifiques (la géologie, la météorologie, l'hydrologie, etc.). Par ailleurs, un écoulement fluvial réduit peut s'avérer nuisible aux espèces aquatiques en raison d'une diminution de la concentration d'oxygène dissous et d'une variation de la température de l'eau. Il réduit également la capacité d'assimilation de la charge en résidus du plan d'eau, ce qui entraîne des coûts élevés en traitement des eaux. Les débits d'étiage peuvent également avoir de lourdes conséquences socioéconomiques sur l'approvisionnement en eau et sur l'exploitation des réservoirs. C'est pourquoi il est primordial que les responsables de la gestion des ressources en eau prennent conscience des conséquences des changements climatiques sur les débits d'étiage tout en structurant les stratégies de planification et de gestion des systèmes hydriques.

Les modèles de circulation générale (MCG) constituent la principale source de renseignements pour l'évaluation des répercussions des changements climatiques. Lorsqu'il est question de la modification du climat de la planète, l'accent est surtout mis sur la réponse de la société aux conséquences locales et régionales des changements à grande échelle. À l'échelle continentale

et hémisphérique, les MCG intègrent une grande partie de la complexité du système, mais ils ne parviennent pas à représenter les éléments et les dynamiques locales d'échelle inférieure à celle de leur maillage (Wigley et al., 1990). Pour combler l'écart entre la résolution des MCG et les exigences locales et régionales des études d'impact de nature hydrologique, ces modèles sont souvent combinés à des modèles hydrologiques. Les modèles hydrologiques offrent ainsi des façons de conceptualiser et d'évaluer le lien qui unit les variables climatiques au ruissellement et au débit fluvial. Ces modèles ont recours à des descriptions physiques et mathématiques des phénomènes hydrologiques. En outre, les variables d'entrées des modèles hydrologiques peuvent correspondre à des scénarios climatiques hypothétiques ou à des sorties issues des MCG. Voilà pourquoi il s'avère souvent nécessaire de procéder à une mise à l'échelle des sorties du MCG, afin de transférer les sorties de modèle d'une échelle relativement grossière vers un maillage plus fin, à l'échelle du bassin-versant à l'étude.

Les approches de mise à l'échelle (Hewitson et Crane, 1996; Wilby et al., 2004; Wilby et Wigley, 1997; Xu, 1999; Zorita et von Storch, 1999) ont fait leur apparition à titre d'outils servant à établir une correspondance entre des variables atmosphériques à grande échelle et des variables climatiques locales ou par station. Ces méthodes se subdivisent en deux catégories : les approches dynamiques, qui consistent en la résolution explicite des processus physiques à l'œuvre dans le système (Giorgi et Mearns, 1991), et les approches statistiques, qui consistent en l'établissement d'un lien empirique entre les variables atmosphériques à grande échelle (prédicteurs) et les variables climatiques à petite échelle (prédictants) (Landman et al., 2001; Tisseuil et al., 2010). Les sorties issues du MCG subissent souvent d'abord une mise à l'échelle (dynamique ou statistique) locale avant d'être présentées à l'entrée d'un modèle hydrologique en vue de simuler un débit (Evans et Schreider, 2002; Fowler et Kilsby, 2007; Fowler et al., 2007; Graham et al., 2007a; Graham et al., 2007b; Jasper et al., 2004; Muller-Wohlfeil et al., 2000; Prudhomme et al., 2002; Wilby et Wigley, 2000; Wood et al., 2004). Par la suite, les indices caractérisant les débits (IH) peuvent être calculés à partir des simulations.

Ce cadre de mise à l'échelle, basé sur un modèle hydrologique, permet la conceptualisation et l'évaluation des liens qui unissent le climat aux ressources hydrologiques. Certaines études récentes ont tenté d'établir un lien direct entre les variables climatiques à grande échelle et les débits observés (Ghosh et Majumdar, 2008; Philips et al., 2003; Tisseuil et al., 2010). Toutefois, cette approche a été remise en question, car elle ne tient pas compte explicitement de l'influence des processus conceptualisés par les modèles hydrologiques (p. ex.: infiltration, évapotranspiration, etc.). À la lumière de l'importance des débits d'étiage et de l'attention sans

cesse croissante portée à la variabilité du climat, il s'avère primordial pour la gestion des débits d'étiage de favoriser le développement d'outils d'analyse des conséquences possibles des changements climatiques sur ceux-ci, ainsi que l'évaluation des incertitudes inhérentes à ces changements. La présente thèse cherche donc à comparer l'approche de mise à l'échelle basée sur un modèle hydrologique à l'approche directe de mise à l'échelle pour la mise à l'échelle des débits d'étiage. L'approche directe consiste à établir une relation entre les variables de circulation atmosphérique à grande échelle et les indices de débit d'étiage, alors que l'approche de mise à l'échelle basée sur un modèle hydrologique allie les sorties d'un MCG à un modèle hydrologique via une mise à l'échelle des conditions météorologiques locales. Ces deux approches évaluent la mise à l'échelle des indices qui caractérisent le régime d'étiage de trois rivières de l'est du Canada. En outre, les changements observés dans les valeurs de ces IH dans les régimes climatiques à venir sont analysés à partir des projections d'un MCG et d'un MCR.

1.1 Le débit d'étiage et la variabilité du climat

Le débit en rivière résulte des nombreux processus naturels complexes qui interviennent dans l'ensemble d'un bassin versant. Plus particulièrement, le débit d'étiage est influencé par divers facteurs, notamment la distribution et les caractéristiques d'infiltration des types de sols; les caractéristiques hydrauliques et l'étendue des aquifères; la vitesse, la fréquence et le degré de la recharge; les taux d'évapotranspiration dans le bassin; la répartition des types de végétation; la topographie; le climat et les effets anthropiques (Anderson et Burt, 1980; Eheart et Tornil, 1999; FRIEND, 1989; Rogers et Armbruster, 1990; Walker et Thoms, 1993). Burn et al. (2008) ont tenté de comprendre les traits caractéristiques des étiages de six régions du Canada: l'Arctique, la région montagneuse, les Prairies, le sud de l'Ontario, le Bouclier canadien et la région de l'Atlantique. Les résultats obtenus ont révélé une vaste gamme de processus qui ont une incidence sur le débit d'étiage dans les diverses régions. Il s'avère que les faibles réserves d'humidité constituent un facteur dominant commun alors que la fonte de neige et la fonte glaciaire sont des processus de contrôle propres à certaines régions. Tout en se référant à cette étude, la principale région étudiée dans cette thèse est le Bouclier canadien, car elle représente la majeure partie de l'est et du centre du Canada.

Le débit d'étiage des bassins de la partie nord du Bouclier canadien est régi en fonction du taux de rabattement des réservoirs naturels (eau souterraine et lacs). Dans la partie sud, la

disponibilité en eau en période d'étiage est dictée par l'équilibre entre la précipitation et l'évapotranspiration. Dans le nord du Bouclier, le débit d'étiage apparaît généralement vers la fin de l'hiver ou au début du printemps alors que dans le sud, il survient à la fin de l'été en raison d'un apport d'eau périodique (qui maintient un certain débit hivernal) doublé d'une perte par évaporation dans les bassins. Ainsi, la temporalité du débit d'étiage dans le Bouclier canadien représente une transition entre les débits de la fin de l'hiver dans les régions du nord, les valeurs minimales des débits de la fin de l'hiver et de la fin de l'été des régions du centre, et les débits de la fin de l'été dans les régions du sud du Bouclier.

1.2 Définition du domaine de l'étiage: Les Indices Hydrologiques

D'un point de vue historique, la mise en application des renseignements relatifs au débit d'étiage a pratiquement toujours servi à la conception et au bon fonctionnement de projets dans un secteur particulier du domaine de l'eau (p. ex.: service d'eau public, irrigation, énergie, navigation, industrie). Selon les connaissances initiales et les besoins, les séries chronologiques des débits quotidiens peuvent être analysées de nombreuses façons en vue d'en tirer de l'information utile. Par conséquent, il existe toute une gamme de mesures et d'indices qui permettent de quantifier le débit d'étiage. Dans le cadre d'un examen approfondi, Smakhtin (2001) est arrivé à définir et à estimer divers indices de débit d'étiage à partir de séries chronologiques de débit. Selon cette étude, le débit annuel moyen (DAM) ou débit median (DM) représentent la limite supérieure du débit d'étiage. Divers indices descripteurs du débit d'étiage peuvent être exprimés en pourcentage du DAM ou du DM. En outre, le débit quotidien le plus faible, soit le débit minimal absolu (DMA), constitue la limite inférieure du débit d'étiage. Afin de représenter toute l'amplitude d'un débit, de l'étiage aux débits de crue, la courbe des débits classés est utilisée. Il s'agit de la relation entre un débit donné et la probabilité que ce débit soit égalé ou dépassé. Ce type de courbe peut être créé à partir de diverses résolutions temporelles des données de débit, qu'elles soient annuelles, mensuelles ou quotidiennes. Par ailleurs, plusieurs indices de débit d'étiage peuvent être calculés à l'aide d'une courbe des débits classés, par exemple les débits qui, au cours d'une journée ou d'un nombre donné de jours, ont excédé 75% (Q75(n)), 90% (Q90(n)) ou 95 % (Q95(n)) du temps, où n est le nombre de jours sur lequel le débit est moyenné (Vogel et Fennessey, 1994). Des indices couramment utilisés sont: Q95(1), Q95(7) et Q95(10). Q20/Q90 figure parmi les indices moins courants. Cet indice est interprété comme étant une mesure de la variabilité du débit (Arihood et Glatfelter, 1991). En outre, le rapport Q50/Q90 peut représenter la variabilité du

débit d'étiage alors que le rapport inverse (Q_{90}/Q_{50}) peut être interprété comme étant un indice de la proportion du débit provenant des réserves souterraines, à l'exception de ce qui est attribuable au bassin-versant (Smakhtin, 2001).

Le débit d'étiage peut également être représenté à l'aide de la courbe de fréquence du débit d'étiage (CFDÉ), laquelle présente la proportion des années au cours desquelles le débit d'un cours d'eau chute sous un débit donné. Un certain nombre d'indices peut être obtenu à partir de la CFDÉ, l'un des plus couramment utilisés étant le quantile Q_{ja} . Cet indice fait état du débit moyen le plus faible enregistré au cours d'une période de « j » jours consécutifs qui correspond à un intervalle de récurrence (période de retour) de « a » années. Aux États-Unis ainsi qu'au Canada, les indices les plus fréquemment utilisés sont les suivants: $Q_{7,10}$, $Q_{7,2}$ et $Q_{30,5}$ (Ouarda et al., 2008) alors qu'en Russie et en Europe orientale, les indices les plus répandus sont les débits d'étiage hivernaux et estivaux d'une journée et de trente jours (des moyennes ou des probabilités de dépassement de 50, 80, 90 et 95 % (Amusja et al., 1988a; Yevstigneev, 1990; Sakovich, 1990). L'indice de débit de base (IDB) constitue un autre indice important dans l'étude du débit d'étiage. Il s'agit d'un rapport non dimensionnel défini comme étant le volume du débit de base divisé par le volume du débit total. L'IDB peut être estimé pour chacune des années étudiées ou pour toute la période d'observation (p. ex.: FRIEND, 1989; Gustard et al., 1992). Dans les bassins versants où la participation de l'eau souterraine au débit est grande, l'IDB peut s'approcher de 1, mais pour les cours d'eau saisonniers, l'indice s'approche davantage de zéro. L'indice de débit de base s'est révélé un bon indicateur de l'influence de la géologie sur le débit d'étiage. C'est d'ailleurs pourquoi il est utilisé dans autant d'études régionales du débit d'étiage (Beran et Gustard, 1977; FRIEND, 1989; Gustard et al., 1992; Smakhtin et Watkins, 1997).

Ces dernières années, le paradigme du débit naturel est devenu le postulat au cœur de l'élaboration d'indices caractérisant l'amplitude, la durée, la fréquence, la temporalité et la variabilité des événements relatifs aux régimes hydrologiques naturels (Poff et al., 1997). De plus, le paradigme du débit naturel met l'accent sur la nécessité de maintenir ou, dans le cas de rivières aménagées, de retrouver entièrement ou en partie, l'éventail de variation naturelle, au cours d'une même année et d'une année à l'autre, de ces régimes en vue de protéger la biodiversité indigène et le potentiel évolutif des écosystèmes aquatique et riverain ainsi que ceux des milieux humides (Arthington et al., 1991; Poff et al., 1997; Richter et al., 1996; Richter et al., 1997; Sparks, 1992; Stanford et al., 1996). Plusieurs indices hydrologiques (IH) ont été élaborés dans le but de quantifier les caractéristiques du débit qui sont pertinentes sur le plan

biologique, de décrire la variabilité générale des régimes hydrologiques à l'échelle régionale ou mondiale, et de quantifier les caractéristiques du débit qui seraient sensibles à diverses formes de perturbation d'origine humaine (Monk et al., 2006). Olden et Poff (2003) ont passé en revue 171 IH définis en fonction de leur pertinence biologique. Ces indices ont ensuite été examinés afin de déceler des redondances et fournir un certain nombre de recommandations d'ordre statistique et écologique en ce qui a trait au choix d'un plus petit nombre d'indices. Non seulement Olden et Poff (2003) ont-ils expliqué une partie importante de la variation des indices, mais ils sont également parvenus à réduire la multicolinéarité tout en permettant une représentation juste des principales caractéristiques du régime d'écoulement. Dans le cadre d'une autre étude, Monk et al. (2007) ont apporté une mise en garde défendant que les approches de réduction de la dimensionnalité axées sur une analyse de corrélation ne mènent pas forcément à l'identification des IH les plus pertinents. À la lumière de ces résultats, Daigle et al. (2011) ont eu recours à une analyse multivariée en vue de cerner les indices hydrologiques qui caractérisent le mieux les régimes hydrologiques des cours d'eau de l'est du Canada, particulièrement en ce qui a trait au débit d'étiage.

1.3 Les conséquences de la variabilité climatique sur le débit d'étiage

Dans le cadre de son examen approfondi de l'hydrologie des étiages, Smakhtin (2001) affirme que les études qui portent sur les conséquences des changements climatiques sur le débit sont généralement menées à l'aide de deux approches distinctes, soit par l'analyse de l'historique des débits ou par l'utilisation de modèles hydrologiques pour étudier les effets des scénarios de changement climatique possibles sur le débit. Majercakova et al. (1997, 1995) ont eu recours à l'analyse de l'historique des débits et ont remarqué une tendance à la baisse du débit annuel moyen des cours d'eau en Slovaquie. Arnell (1989) ont également utilisé l'historique des débits pour examiner les changements possibles relativement à la fréquence des phénomènes hydrologiques extrêmes en Europe. Selon cette étude, les courtes périodes de cueillette des données ont compliqué encore davantage l'identification de tels changements à partir des données d'observation. Les auteurs concluent que l'approche traditionnelle selon laquelle l'historique des débits constitue un modèle acceptable pour les projections futures s'avère peu réaliste.

Certaines tentatives ont été faites quant à l'étude des répercussions des changements climatiques sur le débit d'étiage (Leith et Whitfield, 1998; Nieto et Wilby, 2005; Whitfield et al., 2002; Yue et Pinon, 2003). Dans le cadre d'une étude portant sur le débit d'étiage des cours d'eau du centre sud de la Colombie-Britannique, Whitfield et Cannon (2001) ont remarqué, en comparant les données de deux décennies récentes, une diminution de la magnitude du débit d'étiage ainsi qu'un changement dans la temporalité des débits les plus faibles, lesquels ont maintenant lieu à l'automne plutôt qu'à l'hiver. Yue et Pinon (2003) ont mis en application une procédure préliminaire de décorrélation indépendante des tendances (*trend-free pre-whitening, TFPW*) en vue d'éliminer l'effet de l'autocorrélation sur le test de Mann-Kendall (MK) dans l'étude des tendances dans les données canadiennes de débits. Au seuil de signification 0,05, l'importance des tendances des maximums annuels, des débits moyens et des minimums quotidiens de 37 stations hydrométriques à travers le pays a été évaluée à l'aide du test de MK et de la procédure de décorrélation indépendante des tendances. L'étude a révélé une tendance à la baisse des valeurs minimales annuelles et des valeurs quotidiennes moyennes dans les séries chronologiques de trente ans des stations situées dans le sud de la Colombie-Britannique (C.-B.), près du centre des Prairies ainsi que dans les provinces de l'Atlantique. L'étude a également révélé une tendance à la hausse de ces valeurs dans le nord de la C.-B. et au Yukon. Étant donné l'attention croissante portée à la variabilité climatique et la pertinence des renseignements portant sur les débits d'étiage dans la gestion des ressources en eau, des recherches plus poussées s'avèrent requises, particulièrement en ce qui a trait à la variation du débit d'étiage dans un contexte de changements climatiques. En outre, la prédiction du débit d'étiage dans des conditions climatiques non permanentes à des fins d'ingénierie et de gestion devrait faire l'objet d'un intérêt plus marqué (Smakhtin, 2001).

1.4 Des modèles climatiques globaux au climat régional

Les modèles climatiques globaux (MCG) constituent des outils mathématiques servant à simuler le climat actuel et à effectuer des projections en imposant des valeurs relatives à l'émission de gaz à effet de serre et d'aérosols. Ces modèles sont adéquats sur des échelles spatiales de quelques centaines de kilomètres et sont en mesure d'intégrer une grande proportion de la complexité qui caractérise le système mondial. Cependant, ils ne peuvent tenir compte des éléments de physiographie d'échelle locale, inférieure à leur maillage qui ont une incidence sur le climat régional (topographie, nuages et utilisation des sols) (Grotch et MacCracken, 1991). Par exemple, le modèle couplé du Hadley Centre, version 3 (HadCM3;

Turner et al., 2006) présente une résolution spatiale de $2,5^\circ$ de latitude et de $3,75^\circ$ de longitude. Or, les simulations hydrologiques du débit mensuel des bassins versants des régions montagneuses nécessitent une résolution spatiale de l'ordre de $0,125^\circ$ (Salathe, 2003). Ainsi, pour combler l'écart entre le rendement du MCG à une échelle régionale et les exigences des études d'impact à cette échelle, des schémas d'intégration des MCG aux modèles hydrologiques ont été créés.

De tels schémas se caractérisent par plusieurs éléments intéressants (Glecik, 1986; Schulze, 1997). Dans un premier temps, les modèles climatiques sont élaborés puis évalués dans diverses conditions climatiques et physiographiques. Ils sont conçus pour supporter diverses échelles spatiales et processus de représentations et sont facilement accessibles. Dans un deuxième temps, toute une gamme de réponses aux scénarios de changements climatiques peut être modélisée, à partir des perturbations climatiques issues du MCG (selon divers niveaux de mise à l'échelle: mensuelle, saisonnière, etc.). Dans un troisième temps, les modèles à l'échelle régionale sont plus faciles d'utilisation comparativement aux MCG. Dans un quatrième temps, ces modèles permettent d'évaluer l'impact sur un bassin-versant de changements climatiques hypothétiques ou projetés. Par ailleurs, le choix du modèle pour une étude de cas donnée dépend de plusieurs facteurs, le principal étant la nature des objectifs et les exigences du modèle en termes de données (Ng et Marsalek, 1992). Par exemple, pour évaluer la gestion des ressources en eau à l'échelle régionale, les modèles de prévision des précipitations et du débit mensuels (bilan hydrique) se sont avérés utiles dans la reconnaissance des conséquences hydrologiques de changements relatifs à la température, aux précipitations et à d'autres variables climatiques (Arnell, 1992; Mimikou et al., 1991; Xu et Halldin, 1997; Xu et Singh, 1998). Pour une évaluation détaillée de l'écoulement de surface, toutefois, les modèles conceptuels à paramètres locaux sont utilisés (Modèle de calcul de l'humidité des sols de Sacramento; Burnash et al., 1973).

L'intégration des schémas locaux présente cependant certaines lacunes en ce qui a trait aux écarts entre la résolution des MCG et celle requise pour les besoins hydrologiques (tableau 1.1; Xu, 1999). Les MCG traitent des processus dont la résolution horizontale se situe entre 200 et 600 km alors que les modèles hydrologiques traitent souvent des processus se produisant à une échelle inférieure à celle du bassin versant, donc bien en-deçà de celle des MCG. Par ailleurs, les échelles temporelles les plus fiables des sorties issues du MCG sont d'ordres saisonnier et annuel alors que les modèles hydrologiques fonctionnent généralement à un pas de temps d'une journée. De plus, il y a une discordance d'échelle verticale entre les MCG et les

besoins hydrologiques, attribuable à la plus grande aptitude du MCG à simuler le climat de la troposphère libre que le climat de surface, alors que les modèles hydrologiques dépendent principalement de variables de surface. Une troisième lacune du schéma d'intégration des données issues du MCG et de modèles hydrologiques a trait aux capacités des MCG à simuler les variables jugées pertinentes à la modélisation hydrologique (p. ex.: précipitations, ruissellement, humidité du sol, etc.) (Loaiciga et al., 1996). Ainsi, il s'avère nécessaire d'obtenir des estimations fiables des sorties du MCG à une échelle, où les modèles hydrologiques sont utilisés. C'est ce que l'on appelle la mise à l'échelle. À cet effet, il existe deux approches fondamentales pour mettre les sorties du MCG à l'échelle: la mise à l'échelle dynamique et la mise à l'échelle statistique.

Tableau 1.1 Performances de simulation des MCG en fonction de l'échelle spatiale, temporelle, verticale et des variables d'intérêt pour la modélisation hydrologique (Xu, 1999).

	Bonne simulation	Simulation acceptable	Simulation laissant à désirer
Non-correspondance des échelles spatiales	Échelle mondiale 500 x 500 km	Échelle régionale 50 x 50 km	Échelle locale 0 à 50 km
Non-correspondance des échelles temporelles	Moyennes annuelle et saisonnière	Moyenne mensuelle	Moyenne quotidienne
Non-correspondance des échelles verticales	500 hPa	800 hPa	Surface terrestre
Non-correspondance des variables utilisées	Température du vent Pression atmosphérique	Nébulosité Précipitations Humidité	Évapotranspiration Humidité du sol Ruissellement
La performance des MCG diminue	→		
Influence des variables sur la modélisation du débit	→		

1.5 LA MISE À L'ÉCHELLE DYNAMIQUE

La mise à l'échelle dynamique fait référence au modèle climatique régional (MCR) ou aux modèles à domaine limité (MDL) qui se servent des conditions à grande échelle et des conditions aux limites latérales en vue de produire des sorties de résolution accrue. Les MCG sont utilisés pour tenir compte de la réponse de la circulation générale à un forçage à grande échelle alors que le MCR permet de représenter les effets d'éléments d'une échelle inférieure à celle du MCG, comme une topographie complexe, une couverture végétale hétérogène, etc. Cela permet d'améliorer la simulation des éléments régionaux comme la précipitation orographique (Frei et al., 2003), les phénomènes climatiques extrêmes (Fowler et al., 2005a) ou les effets non linéaires comme ceux causés par le phénomène El Niño (Leung et al., 2003a). La mise à l'échelle dynamique est un outil important pour l'étude des impacts du changement climatique, car les signes indiquant un changement climatique régional qui en découlent s'avèrent bien différents de ceux obtenus à partir des MCG en raison du forçage orographique et des répercussions de l'ombre pluviométrique (Leung et al., 2004). En outre, la mise à l'échelle dynamique permet d'obtenir une meilleure simulation des processus de précipitation méso-climatiques, qui résultent en de meilleures représentations des statistiques climatiques et, par le fait même, à des scénarios de changements climatiques plus plausibles en ce qui a trait aux phénomènes extrêmes et à la variabilité climatique à l'échelle régionale (Schmidli et al., 2006).

Bien que les MCR constituent une amélioration par rapport à la résolution grossière des MCG pour ce qui est de l'évaluation régionale des répercussions des changements climatiques, il n'en demeure pas moins que ces modèles sont grandement influencés par les biais provenant du MCG qui les pilote et l'importance des forçages à l'échelle régionale, dont l'orographie, la couverture végétale et le contraste entre la terre et la mer (Wang et al., 2004). De plus, la variabilité des paramètres inhérents aux MCR constitue une autre source d'incertitude (Hangemann et al., 2004). En effet, des différences relatives aux schémas numériques, à la résolution de la grille ainsi qu'à d'autres paramètres physiques donnent lieu à des simulations différentes du climat régional (Bachner et al., 2008). Ces incertitudes ont été quantifiées à l'aide d'une comparaison de plusieurs MCR. Les projets européens PRUDENCE (*Prediction of Regional Scenarios and Uncertainties for Defining European Climate Change Risks and Effects*; Christensen et Christensen, 2007) et ENSEMBLES (Hewitt et Griggs, 2004) sont d'excellents exemples de cette comparaison. Les MCR sont coûteux en ressources informatiques (Xu,

1999). De plus, une divergence peut demeurer entre les exigences d'échelles spatiale et temporelle du modèle hydrologique et les sorties du MCR. Le cas échéant, il s'avère nécessaire de procéder à une mise à l'échelle des sorties du MCR afin de pouvoir mener des études d'impact (Chen and Knutson, 2008). Cette mise à l'échelle pratiquée pour chacun des sites est effectuée à l'aide d'une approche statistique de mise à l'échelle.

1.6 La mise à l'échelle statistique

La mise à l'échelle statistique repose sur la prémisse selon laquelle le climat régional découle d'une interaction entre la circulation atmosphérique ou océanique générale, la topographie régionale, la répartition entre la terre et la mer ainsi que l'utilisation des sols. Ainsi, le climat régional est perçu comme étant un processus aléatoire qui dépend d'un régime climatique à grande échelle, lequel est représenté mathématiquement comme suit:

$$R = F(L) \quad (1-1)$$

Où R représente la variable du climat régional ou local (prédicteur), L représente une variable climatique à grande échelle (prédicteur) et F représente une fonction déterministe ou stochastique qui dépend de L et qui est mesurée de manière empirique à partir de séries de données observées (Coulibaly et Dibike, 2004). Selon Von Storch et al. (2000), trois hypothèses implicites sont émises lorsque la mise à l'échelle statistique est utilisée en vue d'évaluer les changements climatiques régionaux:

- Les prédictors associés au prédicteur local doivent être reproduits de façon adéquate par le modèle climatique aux échelles spatiales utilisées pour produire la réponse de la mise à l'échelle. Ainsi, les prédictors doivent être choisis en fonction de leur pertinence par rapport au(x) prédicteur(s) cible(s) et de la justesse de leur représentation par les modèles climatiques (Wilby et Wigley, 2000).
- La relation entre les prédictors et le prédicteur demeure valide en dehors de la période d'ajustement
- Les prédictors choisis doivent être en mesure de représenter l'évolution du climat (Busuioc et al., 1999; Charles et al., 1999b).

Le choix des prédicteurs et de leur domaine constitue un aspect important de la mise à l'échelle empirique. L'exigence de base en ce qui concerne le prédicteur est qu'il soit informatif. Or, cette propriété est déterminée à l'aide d'une analyse statistique, notamment la corrélation entre les prédicteurs et un prédicant. Aussi, un prédicteur pourrait ne pas sembler pertinent dans un modèle de mise à l'échelle qui porte sur le climat actuel, mais les changements à venir du prédicteur peuvent s'avérer d'une importance capitale dans l'évaluation des changements climatiques (Wilby et al., 1998). Dans le cadre d'une évaluation exhaustive de 29 prédicteurs de réanalyses, Cavazos et Hewitson (2005) ont découvert que les prédicteurs relatifs à la circulation (p. ex.: pression au niveau de la mer) se caractérisent par de longues séries d'observations et sont mieux simulés par les MCG. Cependant, dans la mise à l'échelle des valeurs de précipitation, ces prédicteurs ne parviennent pas à représenter les principaux mécanismes de précipitation basés sur la thermodynamique et sur la teneur en vapeur d'eau, rendant nécessaire l'ajout de variables d'humidité (p. ex: humidité relative) (Charles et al., 1999). Dans une autre étude portant sur la mise à l'échelle de la température et des précipitations dans le sud du Québec, Canada, Jeong et al (2012) mettent l'accent sur le choix des prédicteurs. Ils constatent que les meilleurs prédicteurs des températures quotidiennes sont l'humidité spécifique, la hauteur géopotentielle à différents niveaux et la température de l'air à 2 m, tandis que la pression au niveau de la mer et les composantes U et V ont montré un meilleur potentiel en tant que prédicteurs des précipitations quotidiennes. Wilby et Wigley (2000) ont également découvert que la corrélation maximale entre la pression au niveau de la mer et les précipitations ne se trouve pas toujours entre la station la plus proche et les points du modèle, ce qui suggère que le choix du domaine du prédicteur en termes d'emplacement et d'étendue régit la nature des scénarios de précipitation dont l'échelle a été réduite.

Il existe une approche relativement simple et courante qui consiste à mettre en application les projections à l'échelle du MCG en appliquant des facteurs de correction (FC). Cette stratégie est appelée « la méthode des perturbations » ou « l'approche delta » (Prudhomme et al., 2002). Les différences entre la simulation de contrôle et la future simulation du MCG sont appliquées aux observations de base en appliquant les facteurs de correction climatique pour chaque jour. Selon cette méthode, on présume que les MCG simulent de façon plus précise le changement relatif que le changement absolu. Cette méthode ajuste uniquement les valeurs maximales, minimales et moyennes des variables climatiques, sans tenir compte de leur étendue ou de leur variabilité. On présume également que la configuration spatiale du climat actuel restera la même dans le futur. Pour ce qui est des données relatives à la précipitation, l'utilisation de cette

méthode ne permet pas de répondre aux besoins en termes de chronologie des périodes pluvieuses et sèches, laquelle pourrait s'avérer un élément important des changements climatiques (Nieto et Wilby, 2005). Parmi les approches de mise à l'échelle statistique plus sophistiquées, on compte notamment le typage météorologique ('weather typing'), les générateurs météorologiques stochastiques et les modèles de régression.

1.6.1 Le typage météorologique

Le typage météorologique ou les systèmes de classification de la météo associent l'occurrence d'une « catégorie météorologique » donnée au climat local. Les catégories météorologiques peuvent être définies de façon synoptique, généralement à l'aide de fonctions orthogonales empiriques (FOE) obtenues à partir des données de pression (Goodess et Palutikof, 1998), d'indices tirés des données portant sur la pression atmosphérique au niveau de la mer (p. ex.: Conway et al., 1996), d'une classification hiérarchique (Fowler et al., 2000; Fowler et al., 2005b) ou encore de l'établissement d'ensembles et de règles floues (Bardossy et al., 2002; Bardossy et al., 2005) relativement aux champs de pression atmosphérique. Les variables de surface locales, généralement les précipitations, sont conditionnées par les situations météorologiques quotidiennes en dérivant les distributions de probabilité conditionnelle des statistiques observées (p.ex: p (pluie-pluie), probabilité d'une occurrence de précipitation à la suite d'une journée pluvieuse ou nombre moyen de jours pluvieux) associées à une configuration de circulation atmosphérique donnée (p. ex.: Bellone et al., 2000).

1.6.2 Les générateurs météorologiques stochastiques (WGEN)

Les générateurs météorologiques stochastiques présentent de nombreux éléments en commun avec les modèles traditionnels de mise à l'échelle axée sur la circulation. Le générateur Richardson constitue un exemple de WGEN (Richardson, 1981). Il a été conçu en vue de simuler des séries chronologiques quotidiennes de la quantité de précipitations, des températures maximales et minimales ainsi que le rayonnement solaire dans les conditions climatiques actuelles. De plus, au lieu d'être conditionnées par les configurations de circulation, toutes les variables du modèle de Richardson sont simulées de façon conditionnelle à une occurrence de précipitation. Le modèle de génération météorologique quotidienne de la *Climate Research Unit* (CRU) élaboré par Jones et Salmon (1995), puis modifié par Watts et al. (2004) constitue un second exemple de générateur météo. Ce dernier permet de simuler les

précipitations à l'aide d'une chaîne de Markov de premier ordre à partir de laquelle d'autres variables sont générées, dont les températures minimales et maximales, la tension de vapeur, la vitesse du vent et la durée d'ensoleillement. Le principal désavantage des WGEN a trait à leur conditionnement à partir des relations climatiques locales. En effet, cela pourrait faire en sorte que les générateurs ne puissent pas s'appliquer automatiquement à tous les climats. Toutefois, la mesure dans laquelle cette limite restreint leur utilité n'a pas encore été évaluée de façon approfondie.

Le rendement relatif de divers WGEN a été évalué par Semenov et al. (1998), lesquels ont constaté que le générateur LARS-WG (Long Ashton Research Station Weather Generator; Racsko et al., 1991) permet de mieux reproduire les moyennes de température et de précipitation mensuelle aux États-Unis, en Europe et en Asie que le générateur WGEN en raison de son plus grand nombre de paramètres et l'utilisation de distributions plus complexes. Par contre, les deux générateurs ne parviennent pas à modéliser de façon adéquate la variabilité interannuelle des moyennes mensuelles ni à reproduire les périodes de gel et de grande chaleur étant donné leur traitement simpliste du facteur de persistance. Dans le cadre d'une autre étude, Qian et al. (2005) ont évalué les générateurs LARS-WG et AAFC-WG (Agriculture and Agri-Food Canada Weather Generator; Hayhoe, 2000) pour en cerner les différences de rendement. Plus particulièrement, le modèle AAFC-WG serait plus efficace à reproduire la distribution des périodes pluvieuses et sèches que le LARS-WG.

1.6.3 Les modèles de régression

Les modèles de régression constituent l'approche la plus répandue pour associer des prédicteurs à grande échelle à des prédicteurs à l'échelle locale ou régionale. Cette approche comprend l'établissement de rapports linéaires ou non linéaires entre les éléments d'échelle inférieure au maillage des MCG (prédicteurs) et des variables indépendantes disponibles à l'échelle du maillage ou dont la résolution est grossière. Les approches de ce type de mise à l'échelle varient selon le choix des fonctions mathématiques de transfert. Les méthodes les plus couramment employées comprennent la régression multiple (Murphy, 1999), l'analyse de corrélation canonique (Hertig et Jacobeit, 2008; Huth, 2004) et les réseaux neuronaux (Crane et Hewitson, 1998; Von Storch, 1999). La relative simplicité de mise en application et d'utilisation de relations définies entre les variables d'une échelle à l'autre constitue le principal avantage du modèle de régression. Cependant, ses faiblesses ont trait à sa sensibilité quant au choix des

variables indépendantes ainsi qu'à la fonction de transfert et à la présomption de validité des paramètres du modèle dans de futures conditions climatiques. En outre, la mise à l'échelle des futurs phénomènes extrêmes à l'aide du modèle de régression s'avère problématique, car ces événements se situent souvent à la limite ou au-delà de l'ensemble de données d'étalonnage. La principale faiblesse de ces approches est donc qu'elles ne sont en mesure d'expliquer qu'une partie de la variabilité climatique. Or, pour satisfaire à cette exigence, il a été proposé d'augmenter la variance des valeurs prédites ainsi (Karl et al., 1990):

$$y_{aug} = \beta y_{préd} = \sqrt{\frac{var(y_{obs})}{var(y_{préd})}} * y_{préd} \quad (1-2)$$

Où $\beta = \sqrt{\frac{var(y_{obs})}{var(y_{préd})}}$

Dans cette équation y_{aug} , $y_{préd}$ et y_{obs} représentent respectivement les valeurs ajustées, prédites et observées du prédictant. Au lieu d'avoir recours à l'approche par augmentation de la variance, il serait également possible de traiter les valeurs « inexpliquées » comme étant existantes, irrégulières et inexpliquées en intégrant un bruit (Von Storch, 1999) :

$$y_{aug}^{aléa} = y_{pred} + bruit \quad (1-3)$$

Il existe une différence fondamentale entre l'augmentation de la variance et l'ajout d'une composante aléatoire. En effet, les statistiques telles que la corrélation dans l'espace et/ou le temps de y_{aug} sont entièrement régies par la variation de x (prédicteurs) alors que $y_{aug}^{aléa}$ présente une variabilité spatiale et temporelle qui n'est régie qu'en partie par la variable x à grande échelle. Wilby et al. (2002) ont élaboré un outil d'aide à la décision axée sur la régression multiple appelé *le modèle de mise à l'échelle statistique* ('Statistical Downscaling Model' ou SDSM). Le SDSM allie le générateur météorologique stochastique aux modèles de régression. Il a été utilisé dans le cadre de plusieurs études portant sur la mise à l'échelle afin d'évaluer des scénarios climatiques (Dibike et al., 2008; Gachon et al., 2005; Gachon et Dibike., 2007; Nieto et Wilby, 2005). Un second outil, appelé Outil de mise à l'échelle statistique automatique ('Automatic Statistical Downscaling') et basé sur le SDSM a été créé par Hessami et al. (2008). L' ASD permet une mise à l'échelle statistique automatique comprenant le choix des prédicteurs et l'étalonnage du modèle, la génération de scénarios et l'analyse statistique de ces derniers. Pour ce qui est de la régression linéaire multiple, ce modèle permet de réduire les effets de la colinéarité entre prédicteurs grâce à la méthode de régression pseudo-orthogonale (ou

méthode de régression ridge). Hessami et al. (2008) ont opté pour cet outil plutôt que pour le SDSM pour la mise à l'échelle des régimes de température et de précipitation dans l'est du Canada. Ni le SDSM, ni ASD n'ont présenté un bon rendement pour toutes les saisons et tous les mois étudiés. Toutefois, l'utilisation de plusieurs modèles de mise à l'échelle statistique et de données provenant de plusieurs MCG pourrait aider à mieux évaluer et modéliser l'incertitude associée aux indices climatiques.

Les réseaux neuronaux (RN) sont de plus en plus utilisés dans le cadre des études de mise à l'échelle (Hewitson et Crane, 1994; Hewitson et Crane, 1996; Hsu et al., 1997; Karunanithi et al., 1994; Markus et al., 1995; Tisseuil et al., 2010; Zhu et al., 1994), particulièrement lorsque la relation entre les variables de circulation à grande échelle et les variables locales (p. ex.: les précipitations) est non linéaire (French et al., 1992; Navone et Ceccatto, 1994; Tohma et Igata, 1994; Zhang et al., 1997). Les réseaux neuronaux constituent une approche proposée par McCulloch et Pitts (1943) pour mieux comprendre et reproduire le fonctionnement du cerveau humain. En mathématiques, les RN sont souvent perçus comme un outil d'approximation universelle. Comme ils sont capables de percevoir des liens entre des configurations données, les RN peuvent résoudre des problèmes complexes à grande échelle dont ceux qui ont trait à la reconnaissance de formes, à la modélisation non linéaire, à la classification, à l'association et au contrôle. Pour « entraîner » le réseau, une règle d'apprentissage doit d'abord être définie. Les règles d'apprentissage appartiennent à l'une des deux catégories suivantes: l'apprentissage supervisé ou l'apprentissage non supervisé. En apprentissage supervisé, la règle d'apprentissage est accompagnée d'une série d'exemples, soit l'ensemble d'apprentissage, de « comportements » adéquats. À mesure que des données sont présentées au réseau, les sorties de ce dernier sont comparées à des valeurs cibles. Ensuite, la règle d'apprentissage est utilisée en vue d'ajuster les paramètres du réseau pour faire en sorte que les sorties du réseau se rapprochent des valeurs cibles. En apprentissage non supervisé, les poids et les biais varient uniquement en fonction des entrées du réseau, de façon à les regrouper selon leurs similitudes. Il n'y a aucune valeur cible. Plusieurs algorithmes d'apprentissage ont été proposés afin d'améliorer le fonctionnement des RN. Avec l'apparition des algorithmes de rétropropagation de l'erreur, les RN sont maintenant largement utilisés dans les domaines de la neurophysiologie, de la physique, du génie biomédical, du génie électrique, de l'informatique, de l'acoustique, de la cybernétique, de la robotique, du traitement de l'image, des finances, etc. De plus, les RN s'avèrent utiles dans des domaines de l'hydrologie, notamment dans la modélisation pluie-débit, la prévision du débit, la modélisation des eaux souterraines, la qualité de l'eau, l'assistance technique à l'établissement de politiques relatives

à la gestion des eaux, la prévision des précipitations, les séries chronologiques hydrologiques et l'exploitation des réservoirs (ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000b).

Malgré les avantages qu'ils présentent, les réseaux neuronaux traditionnels comportent plusieurs lacunes, dont le risque que le réseau reste bloqué dans des minimums locaux et la subjectivité dans le choix de l'architecture du modèle (Suykens, 2001). Afin de régler ces problèmes, bon nombre de nouveaux algorithmes ont été proposés (Neocleous et Schizas, 2002). L'apparition de RN basés sur un noyau de convolution, appelés « machines à vecteur de soutien » ('Support Vector Machines'; MVS) (Cortes et Vapnik, 1995; Cristianini et Shawe-Taylor, 2000; Haykin, 2003; Sastry, 2003; Tripathi et al., 2006; Vapnik, 1995; Vapnik, 1998) a fourni une solution adéquate à ces problèmes. Pour un vecteur d'apprentissage donné $\{(x_i, y_i)_{i=1}^N\}$, l'équation de la régression à vecteur de soutien correspond à :

$$y(\mathbf{x}, \mathbf{w}) = \sum_{i=1}^N w_i \times K(x_i, x) + b \quad (1-4)$$

Où

$K(x_i, x)$ est la fonction noyau,

$\mathbf{w} = \{w_1, w_2, \dots, w_N\}$ et w_i 's sont les poids utilisés dans la régression à vecteur de soutien

b est une constante (biais)

La principale caractéristique de la MVS, dans un contexte de classification, est qu'elle tente de réduire l'erreur de l'ensemble d'apprentissage tout en augmentant la marge entre deux classes (dans l'espace défini par le noyau de convolution). Cela évite le surapprentissage, entraîne une généralisation adéquate et assure la parcimonie du modèle, lequel dépend uniquement de quelques vecteurs provenant des exemples d'apprentissage connus sous le nom de « vecteurs de soutien ». Malgré la réussite de la MVS, un certain nombre d'inconvénients majeurs sur le plan pratique ont été constatés (Tipping, 2001):

- Le nombre de vecteurs de soutien requis augmente de façon linéaire avec le nombre de vecteurs d'apprentissage.
- Les prédictions ne sont pas probabilistes.
- L'estimation du paramètre erreur-marge implique une étape de validation croisée, ce qui mobilise une partie des données et nécessite des calculs supplémentaires.
- La fonction noyau doit répondre aux exigences de Mercer, c'est-à-dire qu'il doit s'agir

d'un noyau symétrique continu d'un opérateur intégral positif (Smola et al., 1998; Tipping, 2001).

Ces limites sont corrigées par la machine à vecteur de pertinence (MVP). La MVP est simplement un modèle stochastique bayésien spécialisé qui utilise la même fonction de noyau, dépendant des données, que la MVS.

Avec l'apparition des méthodes de mise à l'échelle, une approche à deux étapes a été adoptée dans l'étude d'impact des changements climatiques sur le débit: (1) Les sorties du MCG sont utilisées en vue de générer des conditions climatiques locales, notamment en ce qui a trait aux précipitations et à la température. On parle alors de mise à l'échelle. (2) Les données climatiques mises à l'échelle sont intégrées dans un modèle hydrologique en vue de projeter les changements hydrologiques en fonction du climat futur. Ce cadre appelé « cadre de mise à l'échelle indirecte » fait l'objet de la prochaine section.

1.7 Le cadre de mise à l'échelle indirecte

Dans un espace étudié, l'application du cadre de mise à l'échelle indirecte permet d'intégrer les facteurs physiques (p. ex.: topographie, couverture du sol, etc.), lesquels interagissent avec le climat et influencent le trajet d'écoulement (p. ex.: infiltration, interception, etc.). Ce cadre permet aussi d'évaluer les variations du débit en fonction du climat à venir (Tisseuil et al., 2010). Toutefois, ce cadre est influencé par certaines incertitudes quant à la structure du modèle climatique global ou régional, à l'approche statistique de mise à l'échelle, ainsi qu'à la structure et au paramétrage du modèle hydrologique. Généralement, l'importance que revêt chaque source d'incertitude dépend (i) de l'intervalle de temps; (ii) du prédicteur; (iii) de la saison; et (iv) de la région étudiée (Dobler et al., 2012). Plusieurs études se sont penchées sur ces sources d'incertitude et ont obtenu des résultats mitigés. Par exemple, Quintana-Seguí et al. (2010) ont découvert des différences marquées parmi trois approches de mise à l'échelle et de correction de biais lorsqu'ils ont évalué les impacts des changements climatiques sur l'hydrologie de bassins de la Méditerranée. Des résultats semblables ont été constatés par Stoll et al. (2011), Teutschbein et al. (2011) ainsi que Chen et al. (2011a). À l'opposé, van Roosmalen et al. (2011) n'ont remarqué que des différences mineures lorsqu'ils ont comparé les valeurs projetées des eaux souterraines et du débit à l'aide de deux méthodes de correction de biais. Gosling et al. (2011) ont étudié les conséquences des changements climatiques sur le

débit à l'aide de sept MCG et deux modèles hydrologiques distribute. Or, l'incertitude structurelle du MCG s'est avérée supérieure à celle du modèle hydrologique. Dans le cadre d'une autre étude, Bae et al. (2011) ont analysé les répercussions des changements climatiques à l'aide de trois modèles hydrologiques semi-distribués combinés à un certain nombre de MCG. Ils ont découvert que le choix du modèle hydrologique peut donner lieu à des différences marquées quant à la variation du débit, et ce, avec le même forçage climatique. Bastola et al. (2011) en sont arrivés aux mêmes conclusions lorsqu'ils ont constaté une grande incertitude relativement aux modèles hydrologiques dans le cadre d'une étude portant sur quatre bassins versants en Irlande. Par ailleurs, Poulin et al. (2011) ont démontré que l'effet de la structure du modèle hydrologique s'avère plus important que l'effet de l'incertitude d'un paramètre dans le cadre d'une étude d'impact des changements climatiques dans un bassin-versant où la neige prédomine.

Davison et Kamp (2008) ont étudié la capacité de six modèles utilisés pour modéliser le débit d'étiage. Les processus relatifs à l'eau souterraine, aux milieux riverains et aux canaux et qui ont une incidence sur le débit d'étiage constituaient le cœur de l'étude plutôt que les processus comme le ruissellement de surface et l'écoulement hypodermique, lesquels interviennent principalement dans les débits de crue. L'étude a permis de conclure qu'une révision approfondie de la représentation des processus physiques qui régissent le débit d'étiage s'avère nécessaire. De plus, chacun de ces processus doit être examiné plus attentivement afin de trouver une façon de le paramétrer. En outre, lorsque l'eau souterraine joue un rôle prépondérant dans le débit d'étiage, il est recommandé de combiner les modèles hydrologiques aux modèles d'eaux souterraines.

2 PROBLÉMATIQUE ET OBJECTIFS DE RECHERCHE

L'enjeu que représentent les répercussions possibles des changements climatiques sur le régime hydrologique des rivières a beaucoup été étudié, mais le débit d'étiage fait rarement l'objet de telles études (Smakhtin, 2001). La plupart des études ont trait à la mise à l'échelle des valeurs du débit à l'aide d'un modèle hydrologique et au calcul des valeurs extrêmes de l'étiage à partir des valeurs dont l'échelle a été réduite (p. ex.: les périodes d'étiage de sept jours (Maurer et al., 2010) ou l'indice Q95 (débit excédé 95 % des jours (Nieto et Wilby, 2005))). Ce cadre de mise à l'échelle à deux étapes appelé « approche indirecte de mise à l'échelle » (AI), pourrait être limité par l'incapacité des modèles hydrologiques à saisir les processus qui régissent le débit d'étiage, les incertitudes relatives à l'étalonnage des modèles hydrologiques et la mise à l'échelle des variables du climat local intégrées dans ces modèles (Davison et Kamp, 2008; Fowler et al., 2005). Il est également possible d'aborder le problème que représentent ces sources d'incertitude en établissant un lien direct entre les variables atmosphériques à grande échelle et les indices hydrologiques du débit d'étiage. Cette approche, appelée « approche directe de mise à l'échelle » (AD) fait souvent l'objet de critiques en raison d'une simplification excessive du cycle hydrologique et parce que cette approche ne tient pas suffisamment compte des réserves en eau et des échanges entre le sol et l'eau souterraine des bassins versants (Xu, 1999). Malgré tout, cette approche a déjà été choisie pour procéder à une mise à l'échelle des valeurs du débit obtenues à partir des prédictors atmosphériques à grande échelle (Cannon et Whitfield, 2002; Ghosh et Majumdar, 2008; Phillips et al., 2003). De plus, dans le cadre d'une étude portant sur les répercussions de la variabilité climatique à grande échelle sur le débit d'étiage au Canada, Bonsal et Shabbar (2008) ont constaté que le faible débit des cours d'eau des régions côtières de l'est du Québec présente une corrélation positive avec le mode annulaire nordique ainsi qu'une corrélation négative avec le phénomène El Niño-oscillation australe et la téléconnexion Pacifique-Amérique (PNA) avant les années 1970. Toutefois, après cette période, la corrélation est devenue positive. Ces résultats encouragent l'exploration de l'approche directe de mise à l'échelle du débit d'étiage à partir des prédictors atmosphériques à grande échelle. À la lumière de la pertinence et de la rareté des études portant sur les répercussions des changements climatiques sur le régime à l'étiage, les objectifs suivants ont été choisis pour de cette thèse:

- Comparer les cadres de mise à l'échelle directe et indirecte quant à leur capacité à expliquer la variabilité des indices hydrologiques qui décrivent les caractéristiques d'étiage de trois cours d'eau dans l'est du Canada.
- Comparer le rendement des modèles statistiques utilisés en vue de mettre à l'échelle des indices hydrologiques de débit d'étiage selon l'approche directe de mise à l'échelle et des variables climatiques locales selon l'approche indirecte de mise à l'échelle.
- Prédire les indices hydrologiques du débit d'étiage de périodes futures en tenant compte des forçages imposés par des modèles climatiques mondial et régional.

2.1 Originalité du projet de recherche

Tel que mentionné dans l'introduction, il existe bien peu d'études d'impact des changements climatiques sur le débit d'étiage compte tenu de son importance dans plusieurs domaines d'application liés aux ressources en eau. Le caractère unique du présent projet réside dans la mise en application d'approches de mise à l'échelle directe et indirecte des indices de débit d'étiage possiblement pertinents sur le plan biologique. Une revue de la littérature révèle que jusqu'à présent, l'approche directe n'a pas été explorée de façon aussi exhaustive que les approches indirectes, particulièrement en ce qui a trait au débit d'étiage. En outre, la plupart des approches indirectes de mise à l'échelle qui portent sur le débit d'étiage comprennent un calcul des indices pertinents (obtenus à partir de CDC ou de CFDÉ telles que Q95, Q90, etc.) à partir d'une simulation du ruissellement. L'utilisation de la MSAB et de la RLM dans la mise à l'échelle des indices hydrologiques choisis constitue également une nouveauté. Quant au choix des prédicteurs à l'aide de la programmation génétique (PG) dans l'approche directe de mise à l'échelle des variables climatiques locales, il s'agit également d'une méthode qui n'a jamais été évaluée auparavant.

3 PLAN DE MISE EN APPLICATION

La section qui suit décrit les divers éléments des approches de mise à l'échelle évaluées dans le cadre de la présente étude. La première sous-section décrit les modèles statistiques utilisés pour la mise à l'échelle des IHs dans l'approche directe et pour la mise à l'échelle des variables météorologiques locales dans l'approche indirecte. La seconde sous-section décrit le modèle hydrologique utilisé dans l'approche indirecte. La troisième sous-section décrit le cadre de mise à l'échelle. La quatrième sous-section décrit les indices de performance utilisés pour l'analyse quantitative des résultats des deux approches. La cinquième sous-section décrit les modèles climatiques global et régional utilisées pour prédire les indices hydrologiques du débit d'étiage de périodes futures.

3.1 Modèles de mise à l'échelle statistique

Les modèles statistiques choisis en vue de mettre à l'échelle les indices hydrologiques de débit d'étiage de l'approche directe et les variables climatiques locales de l'approche indirecte sont respectivement la méthode stochastique d'apprentissage bayésien (MSAB) et la régression linéaire multiple (RLM). La MSAB est mise en application sous la forme d'une machine à vecteur de pertinence (MVP; Tipping, 2001) et la RLM sous la forme d'un outil de mise à l'échelle statistique automatique (Automated Statistical Downscaling, ASD; Hessami et al., 2008). Pour la mise à l'échelle des précipitations, la méthode PG sert à la sélection des prédicteurs. Les formulations mathématiques des modèles (MSAB, RLM et PG) sont décrites dans la section qui suit.

3.1.1 Apprentissage Bayésien (AB)

La théorie de probabilité bayésienne vise à concevoir des modèles probabilistes qui tiennent compte des renseignements préalables portant sur le phénomène étudié ainsi que des données en vue d'établir des prédictions optimales à l'aide de ces modèles. Selon la règle bayésienne, la probabilité du modèle H_1 conditionnelle à la donnée D ($p(H_1|D)$) s'exprime ainsi :

$$p(H_1|D) \propto p(H_1)p(D|H_1) \quad (1-5)$$

$p(H_1)$ représente la plausibilité *a priori* de H_1 alors que $p(D|H_1)$ renvoie aux prédictions effectuées par le modèle relativement aux données. Le cadre bayésien présente plusieurs avantages (MacKay, 1994). Tout d'abord, une fois l'espace modèle défini, le théorème de Bayes sur la probabilité permet d'obtenir une réponse unique qui tient systématiquement compte des renseignements préalables portant sur le phénomène étudié ainsi que de ceux tirés des données obtenues. Ensuite, l'inférence bayésienne répond au principe de vraisemblance (Berger, 1985) selon lequel les inférences ne dépendent que des probabilités imputées aux données reçues et non aux propriétés des autres ensembles de données qui auraient pu se réaliser, mais dont ce n'est pas le cas. De plus, la comparaison des modèles bayésiens incarne le principe même du rasoir d'Occam, soit le fait de privilégier les modèles les plus simples.

3.1.1.1 Modèle de régression parcimonieux

Pour obtenir un modèle de régression parcimonieux (Tipping, 2001), nous devons chercher à prévoir \mathbf{y} en fonction de \mathbf{x} selon l'équation suivante:

$$\mathbf{y} = f(\mathbf{x}, \mathbf{w}) + \epsilon = \Phi \mathbf{w} + \epsilon \quad (1-6)$$

Dans cette équation,

$$\epsilon_n \sim N(0, \sigma^2) \text{ et}$$

$\mathbf{w} = (w_0, w_1, \dots, w_M)$ représente un vecteur de poids et la matrice de conception de $M \times (M+1)$ avec

$$\Phi = [\phi(x_1), \phi(x_2), \dots, \phi(x_M)]^T \quad (1-7)$$

où

$$\phi(x_i) = [1, K(x_i, x_1), K(x_i, x_2), \dots, K(x_i, x_M)]^T \text{ et}$$

$K(x_i, x_j)$ constituent des fonctions noyau pour $j=1, 2, \dots, M$.

Ainsi, une fonction de base est définie pour chaque exemple de x_i (où $i=1, 2, \dots, M$) dans l'ensemble de données. La machine à vecteur de pertinence (MVP) est en fait une MSAB spécialisée qui a recours à la même fonction noyau de base, dépendante des données, que la

machine à vecteur de soutien (MVS). Dans le présent projet, la fonction noyau gaussienne suivante est utilisée:

$$K(x, x_i) = \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) \quad (1-8)$$

La vraisemblance de l'ensemble de données est exprimée à l'aide de l'équation suivante:

$$p(\mathbf{y}|\mathbf{w}, \sigma^2) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left\{-\frac{\|\mathbf{y}-\Phi\mathbf{w}\|^2}{2\sigma^2}\right\} \quad (1-9)$$

L'estimation de la vraisemblance maximale de \mathbf{w} et de σ^2 entraîne souvent un sévère surajustement. Pour limiter la complexité de la fonction de vraisemblance, une contrainte est préalablement imposée aux paramètres \mathbf{w} . Il s'agit là d'une information *a priori* qui contrôle le caractère général du système d'apprentissage. Généralement, des hyperparamètres α sont utilisés pour contraindre la distribution de probabilité *a priori* gaussienne des poids \mathbf{w} :

$$p(\mathbf{w}|\alpha) = \prod_{i=1}^M N(w_i|0, \alpha_i^{-1}) \quad (1-10)$$

Une telle représentation impose une préférence pour les fonctions moins complexes. Pour compléter la hiérarchisation des caractéristiques *a priori*, on définit les hyperlois *a priori* de α ainsi que la variance du bruit (σ^2). Ces valeurs constituent des exemples de paramètres d'échelle. Ainsi, les lois *a priori* sont des lois gamma (consulter, par exemple, Berger, 1985):

$$p(\alpha) = \prod_{i=1}^M \text{Gamma}(\alpha_i|a, b) \quad (1-11)$$

et
$$p(\beta) = \text{Gamma}(\beta|c, d) \quad (1-12)$$

où $\beta = \sigma^{-2}$ et

$$\text{Gamma}(\alpha_i|a, b) = \Gamma(a)^{-1} b^a \alpha_i^{a-1} e^{-b\alpha_i}$$

$$\Gamma a = \int_0^{\infty} t^{a-1} e^{-t} dt \text{ (fonction gamma).}$$

Dans le cas de lois *a priori* soient non-informatives, les paramètres se voient accorder une faible valeur (p. ex. $a = b = c = d = 10^{-4}$). En donnant une valeur nulle à ces paramètres, il est possible d'obtenir des hyperlois *a priori* uniformes (sur une échelle logarithmique). Comme toutes les échelles sont equi-vraisemblables, les résultats ne dépendent donc pas de l'unité de mesure des valeurs cibles. Ainsi, selon la règle de Bayes, il est possible de calculer les inconnues *a posteriori* à partir des distributions *a priori* définies sans valeur informative:

$$p(\mathbf{w}, \alpha, \sigma^2 | \mathbf{y}) = p(\mathbf{y} | \mathbf{w}, \alpha, \sigma^2) p(\mathbf{w}, \alpha, \sigma^2) / \int p(\mathbf{y} | \mathbf{w}, \alpha, \sigma^2) p(\mathbf{w}, \alpha, \sigma^2) d\mathbf{w} d\alpha d\sigma^2 \quad (1-13)$$

Il n'est pas possible de calculer directement $p(\mathbf{w}, \alpha, \sigma^2 | \mathbf{y})$ à partir de cette équation, car on ne peut évaluer l'intégrale de droite. On décompose donc la loi *a posteriori* ainsi:

$$p(\mathbf{w}, \alpha, \sigma^2 | \mathbf{y}) = p(\mathbf{w} | \mathbf{y}, \alpha, \sigma^2) p(\alpha, \sigma^2 | \mathbf{y}) \quad (1-14)$$

En outre, la distribution *a posteriori* du coefficient de pondération peut être exprimée ainsi

$$\begin{aligned} p(\mathbf{w} | \mathbf{y}, \alpha, \sigma^2) &= (p(\mathbf{y} | \mathbf{w}, \sigma^2) p(\mathbf{w} | \alpha)) / p(\mathbf{y} | \alpha, \sigma^2) \\ &= (2\pi)^{-(N+1)/2} |\Sigma|^{-1/2} \exp \left\{ -1/2 (\mathbf{w} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{w} - \boldsymbol{\mu}) \right\} \end{aligned} \quad (1-15)$$

Dans cette équation, la covariance *a posteriori* et la moyenne sont:

$$\left. \begin{aligned} \Sigma &= (\sigma^{-2} \Phi^T \Phi + A)^{-1} \\ \boldsymbol{\mu} &= \sigma^{-2} \Sigma \Phi^T \mathbf{y} \end{aligned} \right\} \quad (1-16)$$

Où A est défini comme $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_M)$. Ainsi, si l'on considère les équations (1-14) et (1-15), le problème se résume à trouver l'hyperparamètre *a posteriori* le plus probable, ce qui revient à maximiser $p(\alpha, \sigma^2 | \mathbf{y}) \propto p(\mathbf{y} | \alpha, \sigma^2) p(\alpha) p(\sigma^2)$ en tenant compte de α et de σ^2 . Pour ce qui est des hyperlois *a priori*, il est nécessaire de maximiser le terme $p(\mathbf{y} | \alpha, \sigma^2)$, lequel s'avère calculable grâce à l'équation suivante:

$$\begin{aligned} p(\mathbf{y} | \alpha, \sigma^2) &= \int p(\mathbf{y} | \mathbf{w}, \sigma^2) p(\mathbf{w} | \alpha) d\mathbf{w} \\ &= (2\pi)^{-N/2} |\sigma^2 \mathbf{I} + \Phi \mathbf{A}^{-1} \Phi^T|^{-1/2} \exp \left\{ -1/2 \mathbf{t}^T (\sigma^2 \mathbf{I} + \Phi \mathbf{A}^{-1} \Phi^T)^{-1} \mathbf{y} \right\} \end{aligned} \quad (1-17)$$

Les modèles bayésiens qualifient l'équation (1-17) de fonction de vraisemblance marginale et sa maximisation de maximum de vraisemblance de type II. Par ailleurs, pour maximiser $p(\mathbf{t} | \alpha, \sigma^2)$, une approche par gradient est utilisée. Pour α , on procède à la différentiation de l'équation (1-17) qui doit être égale à zéro et un réarrangement des termes donne lieu à l'équation suivante:

$$\alpha_i^{\text{nouveau}} = \gamma_i / \mu_i^2 \quad (1-18)$$

Dans cette équation, μ_i correspond au i -ième coefficient de pondération moyen *a posteriori* obtenu à partir de l'équation (1-16). De plus, les valeurs de γ_i peuvent être exprimées ainsi:

$$\gamma_i = 1 - \alpha_i N_{ii} \quad (1-19)$$

Dans cette équation, N_{ii} représente le i -ième élément de la diagonale de matrice de covariance du coefficient de pondération *a posteriori* de l'équation (1-16), calculé à partir des valeurs actuelles de α et de σ^2 . Chaque $\gamma_i \in [0,1]$ peut être interprété comme étant la mesure de la détermination par les données du paramètre correspondant w_i . Quant à la variance du bruit, la différentiation entraîne une nouvelle estimation:

$$(\sigma^2)^{\text{nouveau}} = ||t - \Phi\mu||^2 / (M - \sum_i \gamma_i) \quad (1-20)$$

dans laquelle le M du dénominateur indique le nombre de points de données. Le résultat qui découle de cette optimisation, soit la maximisation de $p(\mathbf{y}|\alpha, \sigma^2)$, est que de nombreux éléments de α tendent vers l'infini, et donc que \mathbf{w} ne présente que quelques coefficients de pondération non nuls, considérés comme des facteurs pertinents. Pour un nouveau point de référence x_* , la distribution prédictive est représentée par l'équation suivante:

$$p(y_* | \mathbf{y}, \alpha_{MP}, \sigma_{MP}^2) = \int p(y_* | \mathbf{w}, \sigma_{MP}^2) p(\mathbf{w} | \mathbf{y}, \alpha_{MP}, \sigma_{MP}^2) d\mathbf{w}$$

Comme les deux termes de la fonction à intégrer sont gaussiens, il est facile de calculer l'intégrale de cette équation:

$$p(y_* | \mathbf{y}, \alpha_{MP}, \sigma_{MP}^2) = N(y_* | \mathbf{f}_*, \sigma_*^2) \quad (1-21)$$

avec

$$\left. \begin{aligned} \mathbf{f}_* &= \boldsymbol{\mu}^T \boldsymbol{\phi}(x_*) \\ \sigma_*^2 &= \sigma_{MP}^2 + \boldsymbol{\phi}(x_*)^T \boldsymbol{\Sigma} \boldsymbol{\phi}(x_*) \end{aligned} \right\} \quad (1-22)$$

Ainsi, nous obtenons la moyenne prédictive $f(x_*, \boldsymbol{\mu})$ ainsi que la variance prédictive qui correspond à la somme de deux composantes de variance, soit le bruit prévu relativement aux données ainsi que celui attribuable aux incertitudes dans la prédiction des coefficients de pondération.

3.1.1.2 Modèle de classification parcimonieux

L'algorithme décrit dans cette sous-section (Tipping, 2001) est utilisé pour classifier les précipitations en journées humides et sèches. L'objectif de la classification binaire est de prévoir la probabilité *a posteriori* d'une entrée donnée x de catégorie 0 ou 1. D'ailleurs, il est possible d'utiliser la fonction logistique

$$f(y) = 1/(1 + e^{-y}) \quad (1-23)$$

en vue d'établir un lien avec la probabilité *a posteriori*

$$P(t_m|y_m) = (f(y_m))^{t_m} (1 - f(y_m))^{1-t_m} \quad (1-24)$$

Il s'agit là d'une distribution de Bernoulli à deux classes de $t_m \in \{0,1\}$ pour une valeur cible donnée qui équivaut à $y_m = y(x_m, \mathbf{w})$ et définie par la somme du coefficient de pondération et des fonctions noyaux de base $\{K(x_m, x_i)\}_{i=1}^M$ pour une série d'échantillons d'apprentissage, $\{x_m\}_{m=1}^M$, soit

$$y(x_m, \mathbf{w}) = w_0 + \sum_{i=1}^M w_i K(x_m, x_i) \quad (1-25)$$

où $\mathbf{w} = \{w_1, w_2, \dots, w_M\}^T$ représente les coefficients de pondération. En outre, la vraisemblance d'une série d'indicatrices $\mathbf{t} = \{t_1, t_2, \dots, t_M\}^T$ correspondant à $\{x_m\}_{m=1}^M$ est ensuite définie ainsi:

$$P(\mathbf{t}|\mathbf{w}) = \prod_{m=1}^M f\{y(x_m, \mathbf{w})\}^{t_m} [1 - f\{y(x_m, \mathbf{w})\}]^{1-t_m} \quad (1-26)$$

Cependant, contrairement au modèle de régression, les coefficients de pondération ne peuvent être introduits de façon analytique. C'est pourquoi les expressions fermées du coefficient de pondération *a posteriori* $p(\mathbf{w}|\mathbf{t}, \alpha)$ ou fonction de vraisemblance marginale $p(\mathbf{t}|\alpha)$ ne sont pas acceptées. Ainsi, il convient d'avoir recours à une méthode d'approximation. Pour ce qui est des valeurs actuelles et fixes de α , les coefficients de pondération les plus probables w_{MF} sont trouvés et conséquemment, ils donnent la position du mode de distribution *a posteriori*.

$$p(\mathbf{w}|\mathbf{t}, \alpha) \propto P(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\alpha) \quad (1-27)$$

Cela revient à calculer la valeur maximale, par rapport à w , de :

$$\log\{P(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\alpha)\} = \sum_{m=1}^M [t_m \log y_m + (1 - t_m) \log(1 - y_m)] - \frac{1}{2} \mathbf{w}^T \mathbf{A} \mathbf{w} \quad (1-28)$$

La méthode de Laplace constitue simplement une approximation quadratique du logarithme *a posteriori* autour de son mode. Par ailleurs, l'équation (1-28) est dérivée à deux reprises pour donner l'équation suivante:

$$\nabla_w \nabla_w \log p(\mathbf{w}|\mathbf{t}, \boldsymbol{\alpha})|_{w_{MP}} = -(\boldsymbol{\Phi}^T B \boldsymbol{\Phi} + A) \quad (1-29)$$

Dans cette dernière équation, $B = \text{diag}(\beta_1, \beta_2, \dots, \beta_m)$ représente une matrice diagonale et $\beta_m = f\{y(x_m)\}[1 - f\{y(x_m)\}]$. Cette matrice est ensuite rendue négative, puis inversée, résultant en la covariance Σ pour une approximation gaussienne des poids *a posteriori* centrées sur w_{MP} . À l'aide des statistiques Σ et w_{MP} de l'approximation gaussienne, les hyperparamètres $\boldsymbol{\alpha}$ sont mis à jour à partir de l'équation (1-16), et ce, de la même manière que pour le modèle de régression. Pour ce qui est du mode de $p(\mathbf{w}|\mathbf{t}, \boldsymbol{\alpha})$, en se basant sur l'équation (1-29) et sur le fait que $\nabla_w \log p(\mathbf{w}|\mathbf{t}, \boldsymbol{\alpha})|_{w_{MP}} = 0$, on obtient,

$$\left. \begin{aligned} \Sigma &= (\boldsymbol{\Phi}^T B \boldsymbol{\Phi} + A)^{-1} \\ W_{MP} &= \Sigma \boldsymbol{\Phi}^T B \mathbf{t} \end{aligned} \right\} \quad (1-30)$$

Comparativement à l'équation (1-16), on constate que l'approximation de Laplace fait correspondre ce problème de classification à une régression avec un bruit dépendant des données (hétéroscédastiques, dont la variance pour ϵ_m est de $\beta_n = f\{y(x_m)\}[1 - f\{y(x_m)\}]$).

3.1.2 Régression linéaire multiple (RLM)

La RLM exprime les prédicteurs sous forme d'une combinaison linéaire. Ainsi, le modèle de RLM peut être représenté à l'aide de la fonction linéaire suivante:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_p X_{ip} + \epsilon_i \quad (1-31)$$

pour $i=1, 2, \dots, M$.

Les ϵ_i représentent le bruit aléatoire indépendant par hypothèse $N(0, \sigma^2)$, les X_i sont des prédicteurs et Y_i est un prédicteur. La RLM est implantée dans l'outil de mise à l'échelle statistique automatique (ASD; Hessami et al., 2008) sous la forme de deux méthodes de sélection de prédicteurs, soit la régression multiple descendante et l'analyse de corrélation partielle. Le présent projet a eu recours à la régression multiple descendante, laquelle constitue

une méthode systématique permettant d'éliminer certains termes d'un modèle multilinéaire jusqu'à ce que les termes qui restent soient pertinents sur le plan statistique. La méthode utilise d'abord un modèle initial, puis compare la capacité explicative de modèles de plus en plus petits. À chaque étape, la valeur p d'une statistique F est calculée en vue d'évaluer les modèles avec ou sans un terme donné. En outre, le test F partiel, qui peut être utilisé pour ajouter un prédicteur à une équation qui contient des variables $q-1$ ou à éliminer un prédicteur qui contient des variables q :

$$F = (R_q^2 - R_{q-1}^2)(n - q - 1)/(1 - R_q^2) \quad (1-32)$$

où, n correspond au nombre d'observations,

R_q et R_{q-1} sont des coefficients de corrélation entre la variable critère et l'équation de prévision, lesquels présentent respectivement des variables q et $q - 1$.

Par ailleurs, si un terme n'apparaît pas dans le modèle, l'hypothèse nulle veut que le terme présente un coefficient de zéro s'il est introduit dans le modèle. Or, si les preuves sont suffisantes pour rejeter l'hypothèse nulle, alors le terme est ajouté au modèle. Inversement, si un terme apparaît dans le modèle, selon l'hypothèse nulle, ce terme présente un coefficient de zéro, mais si les preuves ne permettent pas de rejeter l'hypothèse nulle, alors le terme doit être retiré du modèle. La marche à suivre est la suivante:

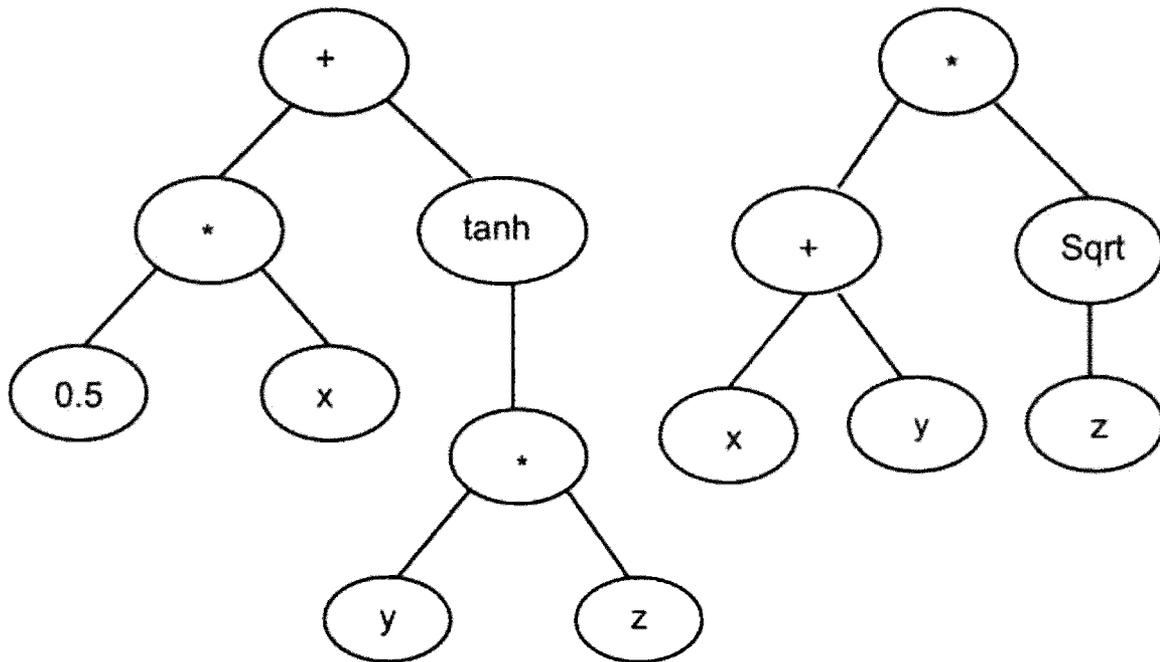
1. Ajuster le modèle initial.
2. Si un terme qui n'apparaît pas dans le modèle présente une valeur p inférieure à la valeur critique, c'est-à-dire s'il est peu probable que son coefficient soit de zéro s'il était introduit dans le modèle, alors le terme dont la valeur p est la plus faible est ajouté au modèle, puis cette étape est répétée. Si cela ne s'applique pas, passer à l'étape 3.
3. Si un terme du modèle présente une valeur p supérieure à la valeur critique, c'est-à-dire s'il est peu probable que l'hypothèse du coefficient nul soit rejetée, alors le terme dont la valeur p est la plus élevée est éliminé du modèle avant de passer à l'étape 2. Si cela ne s'applique pas, cette étape marque la fin de la procédure.

3.1.3 Algorithme génétique pour la mise à l'échelle des précipitations

L'algorithme génétique est une méthode qui permet de résoudre des problèmes d'optimisation avec et sans contrainte. Il est basé sur les principes de la sélection naturelle qui est à la base de l'évolution biologique. Pour ce faire, une première sélection aléatoire d'une population de

programmes (ou fonctions mathématiques représentées par une structure arborescente) est faite, puis les branches les plus performantes de cet arbre sont combinées afin de produire la génération suivante. Ce processus est répété jusqu'à ce qu'une population contienne les fonctions mathématiques qui peuvent accomplir la tâche d'estimation adéquatement. Le programme GPTIPS (<https://sites.google.com/site/gptips4matlab/>) a été utilisé afin d'accomplir cette partie du projet.

GPTIPS utilise une méthode unique de régression symbolique appelée multigène (Hinchliffe et al, 1996). Cette approche fait évoluer des combinaisons linéaires de fonctions non-linéaires qui transforment les intrants. Typiquement, une population 'd'arbres mathématiques' représente des fonctions qui estiment un vecteur de variables dépendantes y de taille $N \times 1$ à partir d'une matrice $(n \times M)$ d'intrants X où N est le nombre d'observations de la variable dépendante qu'on cherche à estimer et M est le nombre de prédicteurs. La $i^{\text{ème}}$ colonne de X inclut N valeurs d'intrants pour le $i^{\text{ème}}$ prédicteur et peut être désignée par x_i . Dans le cas de la régression symbolique multigène, chaque modèle symbolique (et chaque membre de la population) est une combinaison linéaire pondérée des sorties d'un certain nombre d'arbres génétiques et chacun de ces arbres est l'équivalent d'un 'gène'. Par exemple, le modèle multigène de la figure 1.1 estime une valeur à partir des intrants x , y , et z . Cette structure de modèle contient des termes non linéaires (par exemple, une tangente hyperbolique), mais a une structure linéaire en ce qui a trait aux coefficients a_0 , a_1 and a_2 . En pratique, l'utilisateur spécifie le nombre maximum de gènes G_{\max} permis pour un modèle ainsi que la profondeur maximale de l'arbre D_{\max} , de manière à permettre de limiter la complexité du modèle évolué.



$$\text{Modèle Multigène} = a_0 + a_1((0.5*x)+\tanh(y*z)) + a_2((x+y) * \text{sqrt}(z))$$

Figure 1.1 Un modèle multigène pseudo-linéaire avec variable dépendante Y et prédicteurs x, y and z. Les coefficients a_0 , a_1 and a_2 sont obtenus automatiquement par MVP and ASD.

Pour chaque modèle, les coefficients linéaires sont estimés à l'aide des données d'entraînement et les fonctions du ASD et du MVP. Conséquemment, le PG multigène combine la puissance de la régression linéaire classique avec la possibilité de représenter un comportement non-linéaire sans avoir à spécifier la forme de ce dernier au préalable. Les étapes de l'algorithme sont présentées ci-dessous:

1. L'algorithme débute en créant une population initiale tirée aléatoirement. Dans GPTIPS, cette population initiale est construite en créant des individus contenant des arbres de programmes génétiques possédant avec entre 1 et G_{\max} gènes.
2. L'algorithme crée ensuite une séquence de nouvelles populations. À chaque étape, l'algorithme utilise des individus de la génération actuelle afin de créer la prochaine

population. Les étapes suivantes sont nécessaires à la création d'une nouvelle population:

- a. Chaque membre de la population actuelle est un intrant aux algorithmes MSAB et RLM et on leur attribue une valeur d'un indicateur de performance calculé comme suit:

$$fitness_{cfn} = N_{dry} + N_{wet} - (N_{dry} - N_{wet})^2 \quad (1-33)$$

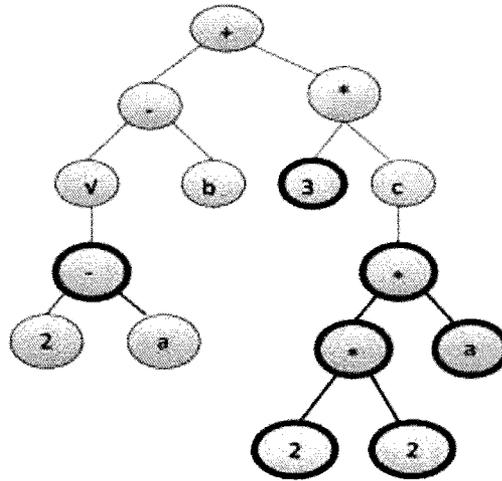
où N_{dry} et N_{wet} sont respectivement les nombres de jours secs et humides correctement classifiés par le modèle. Le terme $(N_{dry} - N_{wet})^2$ pénalise les combinaisons ayant une seule de ces deux proportions bien estimée, alors que l'autre estimation est mauvaise. Pour la quantité de précipitation, l'indicateur de performance est:

$$fitness_{reg} = mean(abs(O - P)) \quad (1-34)$$

Où O et P sont les quantités de précipitations observées et simulées, respectivement.

- b. Sur la base de ces indicateurs de performance, les 'parents' sont sélectionnés.
 - c. Les individus de la population ayant les meilleurs indicateurs de performance sont passés directement à la génération suivante (reproduction directe)
 - d. La progéniture est créée à partir des parents soit en procédant à un changement aléatoire chez un des parents (mutation, figure 1.2), soit par l'échange de gènes entre les deux parents (transfert, ou 'crossover', figure 1.3).
 - e. Les enfants deviennent les parents de la génération suivante
3. Les opérations sont répétées jusqu'à l'atteinte d'un critère d'arrêt. Il s'agit d'une combinaison de bonnes performances avec une valeur maximale de $fitness_{cfn}$ de 2 et un minimale pour $fitness_{reg}$ de 0. Le nombre maximum d'itérations a été fixé à 100.

Individu Original



Individu Muté

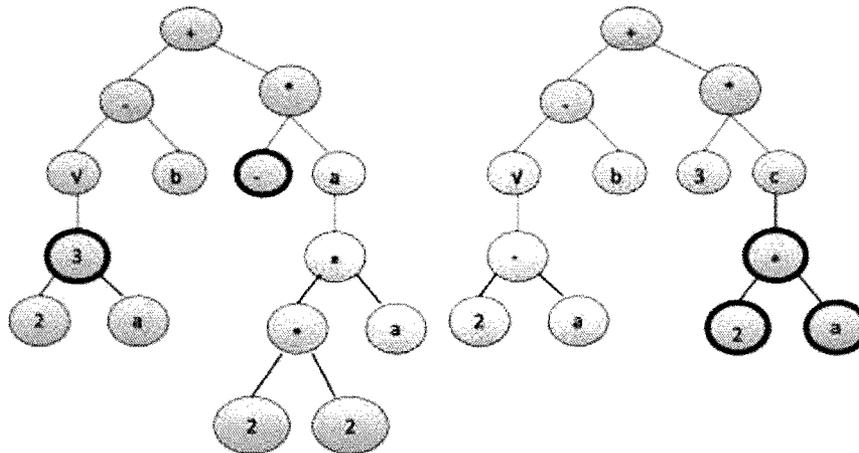
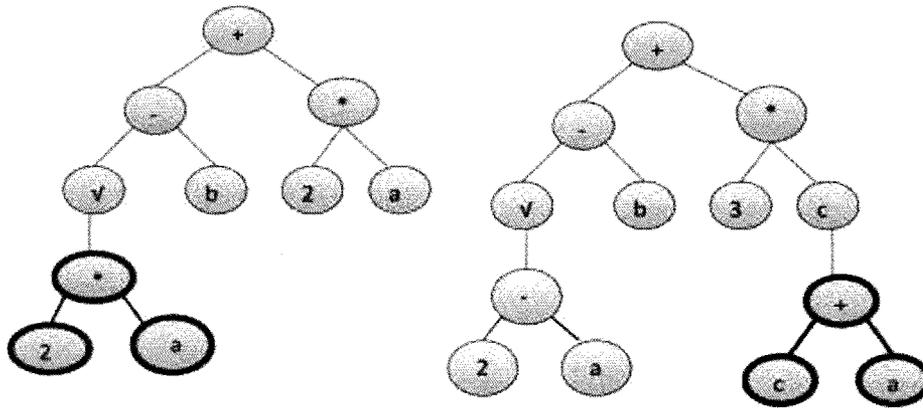


Figure 1.2 Deux différents types de mutations. L'arbre du haut est l'original. En bas à gauche, on a la représentation d'une mutation d'une seule branche terminale (3) par une autre branche terminale (a). C'est aussi une représentation d'une mutation d'une seule fonction (-) pour une autre fonction (+). L'arbre en bas à droite illustre un remplacement de toute une arborescence par une autre.

Parents



Enfants

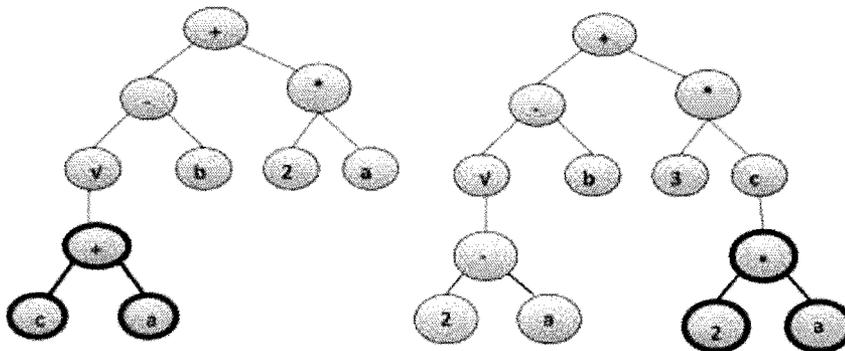


Figure 1.3 Opération de transfert dans l'algorithme génétique. Les sélections en gras pour les deux parents sont échangées pour créer les enfants.

3.2 Modèle hydrologique

Le modèle hydrologique utilisé en vue de simuler un débit porte le nom de modèle SSARR (synthèse du débit et régulation du réservoir; guide d'utilisation du SSARR, 1991). Le SSARR a d'abord été conçu en vue de répondre aux besoins de la division du Pacifique Nord du Corps of Engineers de l'armée américaine, qui cherchait à produire des simulations hydrologiques sur le plan mathématique pour une analyse des systèmes nécessaires à la planification, à la conception et au fonctionnement des aménagements hydrauliques. Le SSARR est un modèle numérique de l'hydrologie d'un bassin-versant. Le débit est simulé à un exutoire en évaluant les précipitations, l'accumulation de neige et la fonte de la neige. Dans l'ensemble du bassin, le débit peut être synthétisé en simulant les répercussions des voies d'écoulement, des dérivations ainsi que de la régulation et de la retenue du réservoir.

Les données d'entrée requises pour le fonctionnement du modèle sont les suivantes:

- Données caractéristiques non variables: ces données portent sur des caractéristiques physiques comme les zones de drainage, la capacité de retenue d'un réservoir ainsi que les caractéristiques du bassin hydrographique qui ont une incidence sur le débit.
- Conditions initiales: ces données précisent les conditions actuelles de tous les indices de ruissellement des bassins hydrographiques, le débit du segment de chaque tronçon du cours d'eau, de même que l'élévation et le débit sortant initiaux du réservoir ou du lac.
- Données variables dans le temps: ces données comprennent des données physiques exprimées sous forme de séries chronologiques (p. ex.: précipitations, température de l'air, données relatives au débit, données relatives à la régulation du réservoir et autres éléments hydrométéorologiques).
- Diverses données relatives à l'exécution du modèle: ces données précisent certains éléments dont la période de calcul totale, les intervalles entre les voies d'écoulement ainsi que des instructions-machine particulières servant à la gestion des sorties papier et des autres possibilités relatives aux entrées et aux sorties.

SSARR comprend deux principaux sous-modèles:

- Le sous-modèle du bassin hydrographique
 - ✓ module intégré par bandes de neige homogènes
 - ✓ module de la courbe de régression
- Le sous-modèle de régulation du réseau hydrographique et des réservoirs conceptuel.

Le sous-modèle du bassin hydrographique a recours aux précipitations, à la température ainsi qu'à d'autres variables hydrométéorologiques pour simuler le ruissellement dans le sous-modèle de régulation du réseau hydrographique.

Le module intégré par bandes de neige homogènes divise le bassin en un certain nombre de bandes ou de zones de même élévation. Chaque bande est ensuite traitée comme si elle constituait un bassin hydrographique distinct qui présente des caractéristiques qui lui sont propres. Le module de la courbe de régression, quant à lui, comporte deux possibilités: le bassin unique et le bassin divisé. Le bassin unique traite le bassin en entier de même que les précipitations et la couverture de neige qui y sont associées, tandis que le bassin divisé sépare le bassin hydrographique en deux régions, soit celle couverte de neige et celle exempte de neige. La principale différence entre le module intégré par bandes de neige homogènes et le module de la courbe de régression réside dans le fait que le premier tient un inventaire des paramètres relatifs à l'équivalent en eau et à l'humidité du sol, et ce, pour chaque bande d'élévation. Ainsi, le module intégré par bandes de neige homogènes tient compte des variations de température, des précipitations et d'autres paramètres météorologiques en fonction de l'élévation. Quant à la courbe de régression, elle traite le bassin-versant comme une entité et réduit les régions couvertes de neige en fonction de l'accumulation saisonnière du ruissellement. Dans le cadre du présent projet, le module intégré par bandes de neige homogènes a été utilisé.

Le modèle de régulation du réseau hydrographique et du réservoir fait circuler l'eau de l'amont à l'aval en considérant le stockage du canal, du lac ou du réservoir, et ce, en mode d'écoulement libre ou contrôlé. Une fois les paramètres hydrologiques des bassins étalonnés, les caractéristiques des voies d'écoulement doivent être établies afin de pouvoir déterminer de façon précise le débit à divers points en aval. Puis, le taux de variation du débit dans un tronçon est calculé en fonction du temps en divisant d'abord ledit tronçon en une série de segments, ou « chaîne de lacs ». Le débit sortant de chacun des segments est ensuite utilisé à titre de débit entrant pour le segment qui suit en aval. Cette procédure par étape est suivie pour chacun des

segments et pour chaque période. La figure 1.4 présente un schéma des processus hydrologiques décrits par le modèle SSARR.

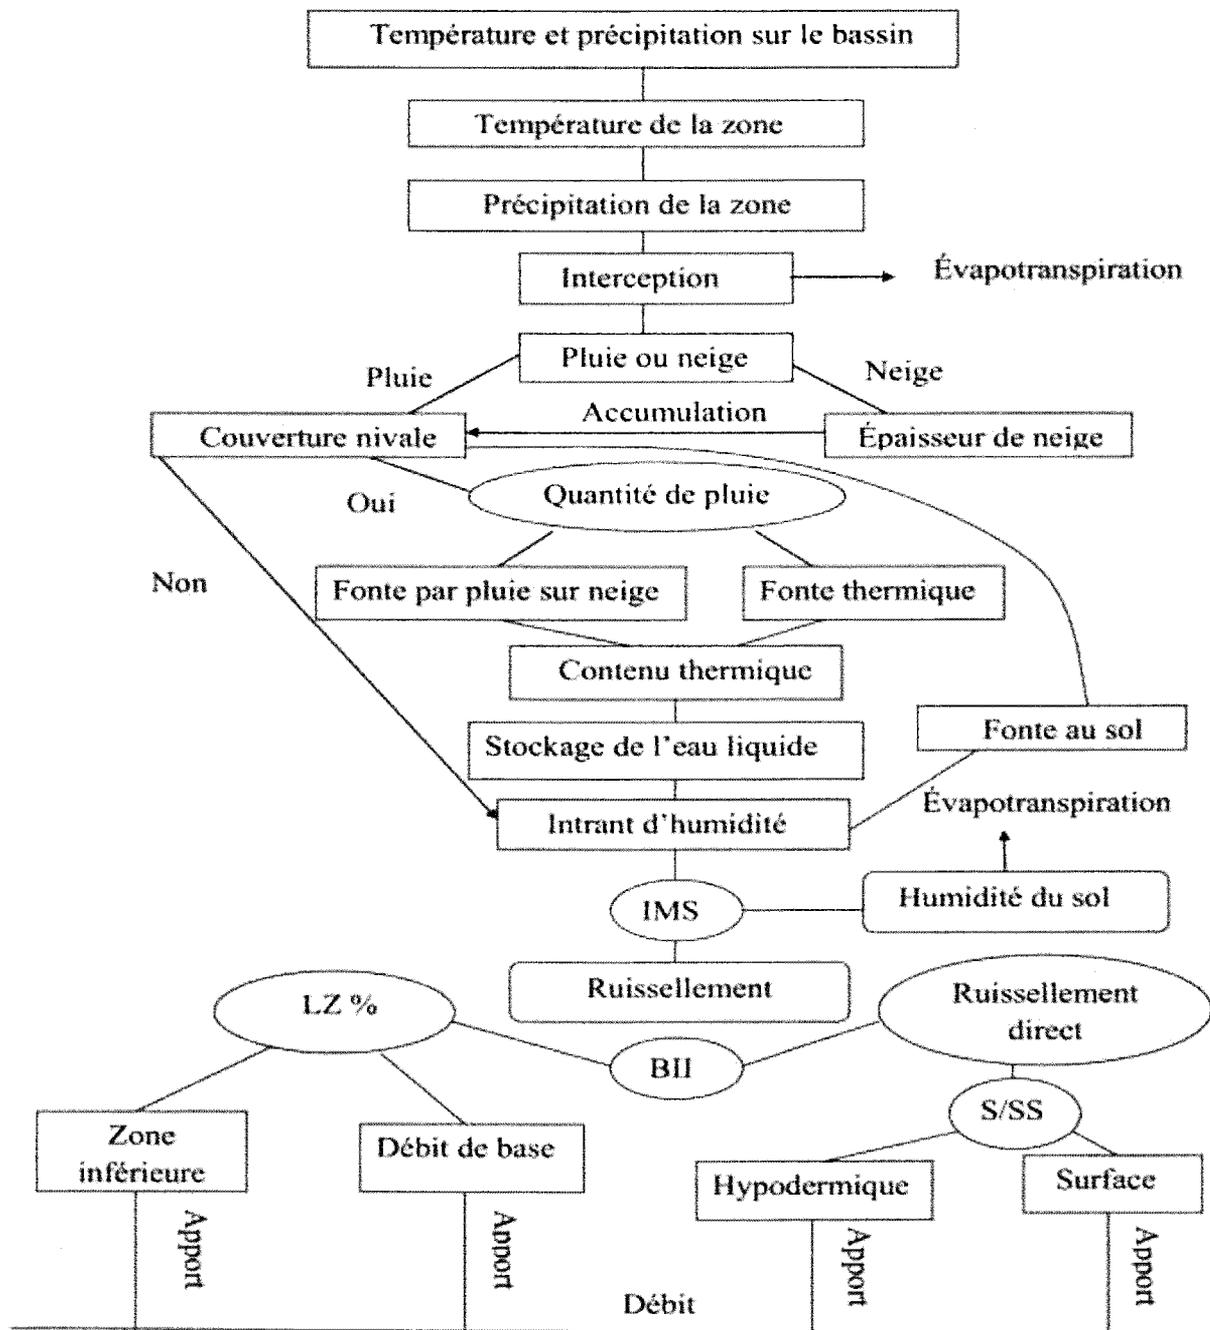


Figure 1.4 Algorithme du module intégré par bandes de neige homogènes selon le SSARR (guide d'utilisation du SSARR, 1991).

L'estimation des paramètres d'un modèle hydrologique représente une tâche ardue en raison de la nature non linéaire des processus hydrologiques et du fait que divers facteurs intervenant dans les modèles qui caractérisent les processus physiques peuvent présenter les mêmes effets sur le débit. Cela signifie que la variation de certains paramètres pourrait être compensée par d'autres. Malheureusement, l'étalonnage manuel des modèles dont les paramètres présentent des valeurs plausibles entraîne souvent de piètres résultats. C'est pourquoi des procédures automatisées axées sur des approches numériques sont de plus en plus utilisées. L'optimisation des paramètres de SSARR a été effectuée à l'aide d'un algorithme qui procède à une recherche itérative de l'espace des paramètres axée sur des mesures du rendement et de fonctions de profondeur (Liu et al., 1999; Rousseeuw et Struyf, 1998; Zuo et Serfling, 2000).

Les fonctions de profondeur ont été définies par Zuo et Serfling (2000): « pour une distribution F_z en R^d , la fonction de profondeur correspondante représente toute fonction $D(.,.)$ qui fournit un classement axé sur F_z du centre vers l'extérieur des points x dans R^d ». Supposons que Δ représente la catégorie des fonctions de distribution cumulée de R^d et F_z la fonction de distribution cumulée d'un vecteur aléatoire donné (Z). Supposons l'application suivante:

$$D(.,.) = R^d \times \Delta \rightarrow R \quad (1-35)$$

Cette équation est bornée, non négative et respecte les conditions suivantes :

1. Invariance affine : $D(Ax + b; F_{Ax+b}) = D(x; F_x)$ s'applique à tout vecteur aléatoire X de R^d , à toute matrice A non singulière de dimension $d \times d$, ainsi qu'à tout vecteur b de longueur d .
2. Maximalité au centre : $D(\theta; F) = \sup_{x \in R^d} D(x; F)$ s'applique à toute $F \in \Delta$ dont le centre est θ .
3. Monotonie relative au point le plus bas : Pour toute $F \in \Delta$ dont le point le plus profond est θ , $D(x; F) \leq D(\theta + \alpha(x - \theta); F)$ s'applique à $\alpha \in [0,1]$.
4. Fonction disparaissant vers l'infini: $D(x; F)$ converge vers 0 alors que la norme de x tend vers l'infini, et ce, pour chaque $F \in \Delta$.

La fonction $D(.,F)$ porte le nom de fonction statistique de profondeur. La sous-routine d'optimisation mise en œuvre dans le présent ouvrage (Thiémonge et Daigle, 2012) suit les étapes ci-dessous:

1. Déterminer les paramètres à ajuster et puis définir leurs limites.
2. Générer M vecteurs aléatoires dans l'espace dimensionnel défini, au point 1, par les limites des paramètres à ajuster. Ces vecteurs constituent l'ensemble X_M .
3. Exécuter le modèle hydrologique pour chacun des vecteurs X_M et calculer le rendement du modèle correspondant à chacun.
4. Déterminer le sous-ensemble X_N des N vecteurs de paramètres dont le rendement est le plus élevé (p. ex. : les 80 % dont le rendement est le meilleur).
5. La fonction de profondeur est calculée en fonction du sous-ensemble X_N pour chacun des N vecteurs de paramètres; les P vecteurs ayant les plus grandes valeurs de profondeur (p. ex., plus grandes que le 50^e percentile) sont identifiés et forment le sous-ensemble X_P .
6. Réduire l'espace des paramètres en le limitant par les valeurs extrêmes des vecteurs de X_P
7. Répéter les étapes 2 à 6 jusqu'à ce que la différence de rendement entre les modèles obtenus par X_M et X_P soit petite, ou jusqu'à ce que la taille de l'espace des paramètres cesse de changer.

Calibrer les paramètres sur la base de la qualité de l'ajustement des hydrogrammes, des débits de pointe de crue et des débits volumétriques peut introduire un biais qui désavantage la représentation des débits d'étiage. Smakhtin et al. (1998) ont d'ailleurs défini certains des problèmes liés aux critères traditionnels de qualité de l'ajustement et ont proposé des solutions qui s'appliquent aux études de modélisation du débit d'étiage. La courbe des débits classés (CDC), la fréquence et la durée des faibles augmentations de débit au cours d'une période sèche, les taux de recul ainsi que les débits volumétriques de base sont autant de variables qui peuvent servir à évaluer le rendement d'un modèle pour ce qui est du débit d'étiage (Davison et Kamp, 2008). Si seul le critère du débit d'étiage est utilisé pour étalonner le modèle, alors ce dernier est aussi susceptible d'arriver à la bonne réponse pour de mauvaises raisons que si l'étalonnage n'est effectué qu'à partir du débit de pointe ou de toute autre fonction d'objectif unique. Afin de résoudre ce problème, il est possible d'avoir recours à un critère multiobjectif qui tient compte tant des périodes d'étiage que de débit de crue (Moore, 1993; Coulibaly et al., 2001). Dans le présent projet, les critères d'évaluation suivants ont servi à l'évaluation des performances obtenus à partir du modèle SSARR:

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (1-36)$$

$$\text{NASH} = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (1-37)$$

$$\text{MODNASH} = 1 - \frac{\sum_{i=1}^n \left(\frac{O_i - P_i}{O_i} \right)^2}{\sum_{i=1}^n \left(\frac{O_i - \bar{O}}{\bar{O}} \right)^2} \quad (1-38)$$

$$\text{LOGNASH} = 1 - \frac{\sum_{i=1}^n (\log(O_i) - \log(P_i))^2}{\sum_{i=1}^n (\log(O_i) - \log(\bar{O}))^2} \quad (1-39)$$

Où

n représente le nombre de jours dans la série chronologique

O_i et P_i représentent respectivement les valeurs quotidiennes observées et simulées.

\bar{O} et \bar{P} ils représentent respectivement les moyennes observées et simulées.

Ces indices ont été quantifiés pour l'année entière ainsi que pour deux saisons (décembre à mars et juillet à octobre). Quatre indices de rendement ont été utilisés afin de couvrir divers aspects de la simulation du débit d'étiage à l'aide du modèle SSARR. Le coefficient de détermination (R^2) permet d'établir dans quelle mesure la dispersion observée peut être expliquée par les valeurs prévues. Ainsi, une surestimation ou une sous-estimation systématique du modèle pourrait exister malgré des valeurs de R^2 élevées. L'amplitude du coefficient de NASH se situe entre 1 (ajustement parfait) et $-\infty$. Une efficacité inférieure à zéro indique que la valeur moyenne des séries chronologiques observées constitue un meilleur prédicteur que les séries chronologiques synthétiques de débits obtenues à partir du modèle. Étant donné que la différence entre les valeurs observées et prévues est élevée au carré, les valeurs de débit les plus élevées ont plus d'influence. Afin de résoudre le problème de la différence élevée au carré et de la sensibilité aux extrêmes, NASH est souvent calculé à l'aide du logarithme des valeurs observées et prévues (LOGNASH). Cela entraîne un lissage des pointes tout en maintenant les débits d'étiage plus ou moins au même niveau. Tous les indices décrits précédemment quantifient la différence entre les valeurs absolues obtenues à partir des observations et des prévisions. Résultat, une surestimation ou une sous-estimation des valeurs les plus élevées ont généralement une plus grande influence que lorsque les valeurs les plus faibles sont surestimées ou sous-estimées. Afin de contrer cela, la différence entre les valeurs observées et simulées est quantifiée comme s'il s'agissait d'un écart relatif, ce qui réduit de manière significative l'incidence des différences absolues des débits de crue. D'un autre côté,

l'incidence des différences absolues les moins marquées lors des périodes d'étiage est accrue, car ces différences sont significatives si elles sont traitées comme des différences relatives.

3.3 Cadre de mise à l'échelle statistique

Les variables de réanalyse du National Center for Environmental Prediction (NCEP; Kalnay et al., 1996) constituent des prédicteurs atmosphériques à grande échelle servant à l'étalonnage des modèles et à la validation des approches utilisées. Ces variables sont disponibles à une résolution spatiale d'environ $2,5^\circ \times 2,5^\circ$ (250 km \times 250 km) et ont été traitées avant d'être introduites dans les modèles statistiques sous forme de prédicteurs. Quant aux prédictants, il s'agit, pour l'approche directe, des indices hydrologiques descripteurs du débit d'étiage, et pour l'approche indirecte, des précipitations ainsi que de la température. Ce cadre est représenté sous forme de diagramme à la figure 1.5. Les étapes du cadre de mise à l'échelle statistique sont les suivantes:

3.3.1 Préparation des entrées

- Les variables de réanalyse du NCEP qui ont été choisies (voir tableau 1.2) sont interpolées à la station hydrométrique ou à la station météorologique par interpolation bilinéaire, ce qui nécessite d'établir une moyenne pondérée des quatre points les plus rapprochés dans la grille.
- Pour ce qui est de l'approche directe, les moyennes annuelles, saisonnières et mensuelles de ces variables sont calculées et leur corrélation avec les IH de débit d'étiage est évaluée.
- Quant à l'approche indirecte, les valeurs quotidiennes des variables de réanalyse du NCEP sont vérifiées afin d'établir une corrélation avec les précipitations et la température observées à la station météorologique.

3.3.2 Mise à l'échelle

- Les variables atmosphériques qui présentent une corrélation significative ($\alpha < 0,05$) avec les IH subissent une analyse de corrélation canonique (ACC; Busuic et al, 2007). Ensuite, les résultats des variables canoniques sont soumis à la MVP à titre de prédicteurs. L'ACC vise à rechercher une combinaison linéaire parmi les prédicteurs qui présentent une corrélation la plus élevée possible avec le prédictant.

- Avec l'ASD, les variables qui présentent une corrélation significative sont soumises à une régression multiple descendante (RMD; McCuen, 2003).
- Pour la mise à l'échelle des précipitations, en plus de l'ACC et de la régression pas à pas, le PG a aussi été testé en générant des populations de programmes représentés par des arborescences et en utilisant différentes méthodes de combinaison (reproduction directe, mutation et transfert) pour les meilleures fonctions afin de créer une nouvelle population. La nouvelle population était alors utilisée en intrant dans les algorithmes MVP et ASD.

3.3.3 Calcul des IH du débit d'étiage

- Dans le cadre de l'AD, les IH du débit d'étiage sont obtenus directement à l'étape de la mise à l'échelle.
- Pour ce qui est de l'AI, les précipitations et la température mises à l'échelle sont introduites dans SSARR en vue de simuler les débits, à partir desquels sont calculés des IH d'étiage.
- Pour évaluer les incertitudes liées à l'étape de la mise à l'échelle, une validation partielle a été effectuée. Celle-ci consiste à utiliser les valeurs observées de température et de précipitations à l'entrée du SSARR. Cette approche sera désignée par la suite par '« Approche de validation partielle » (AVP).

3.3.4 Approches utilisées

Les cinq approches mises en œuvre dans le présent projet combinent les deux modèles statistiques de mise à l'échelle (MVP et ASD) et les deux approches de mise à l'échelle (AD et AI):

AD à l'aide des modèles statistiques

- MVP (AD1)
- ASD (AD2)

AI qui combine le modèle hydrologique (SSARR) aux entrées suivantes:

- les valeurs de précipitations et de température mises à l'échelle à l'aide de la MVP (AI1) et
- les valeurs de précipitations et de température mises à l'échelle à l'aide de l'outil ASD (AI2)

L'Introduction des valeurs observées (précipitations et température) dans SSARR en vue de simuler les débits et, par le fait même, les indices de débit d'étiage. Cette approche donne une base de comparaison en éliminant les biais inhérents aux données de réanalyse et à la mise à l'échelle et porte le nom de « Approche de validation partielle » (AVP).

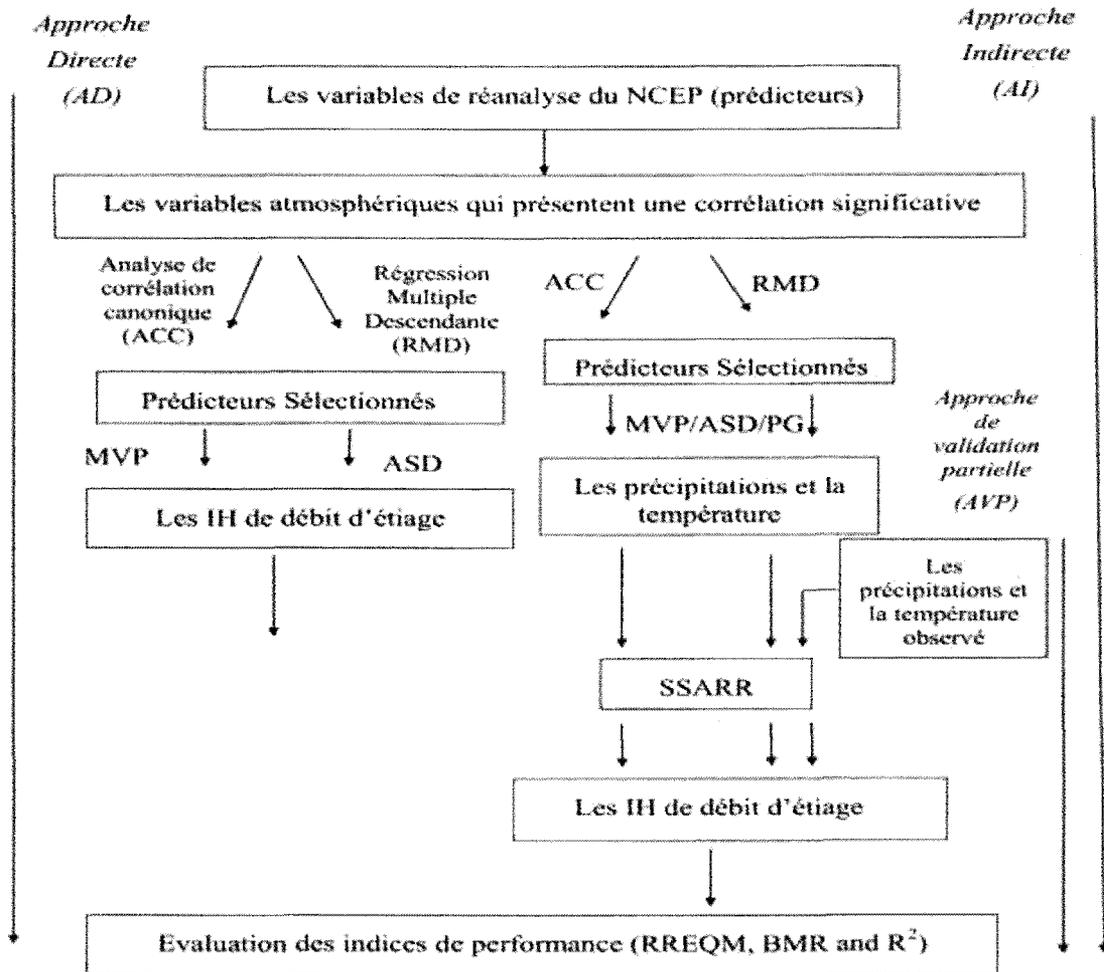


Figure 1.5 Cadre de mise à l'échelle statistique décrivant les algorithmes de la mise à l'échelle directe, de la mise à l'échelle indirecte et de la validation partielle. PG a seulement été utilisé pour les précipitations dans AI.

Tableau 1.2 Prédicteurs du NCEP utilisés dans le cadre de la mise à l'échelle.

Numéro	Nom du prédicteur
1	Température moyenne à 2 m
2	Pression moyenne au niveau de la mer
3	Humidité spécifique à 1000 hPa
4	Humidité spécifique à 850 hPa
5	Humidité spécifique à 500 hPa
6	Humidité relative à 1000 hPa
7	Humidité relative à 850 hPa
8	Humidité relative à 500 hPa
9	Vent zonal à 1000 hPa
10	Vent zonal à 850 hPa
11	Vent zonal à 500 hPa
12	Vent méridien à 1000 hPa
13	Vent méridien à 850 hPa
14	Vent méridien à 500 hPa
15	Vent vertical à 1000 hPa
16	Vent vertical à 850 hPa
17	Vent vertical à 500 hPa
18	Hauteur géopotentielle à 1000 hPa
19	Hauteur géopotentielle à 850 hPa
20	Hauteur géopotentielle à 500 hPa
21	Degrés-jour de chauffage

3.4 Méthodes de validation et mesures du rendement

La validation d'un modèle de prévision, peut être décomposée en fonction des contributions de trois types d'erreur distincts (Geman et al., 1992): (1) les erreurs attribuables au bruit aléatoire; (2) les erreurs attribuables à une différence entre les valeurs observées et les valeurs simulées (biais); et (3) les erreurs attribuables à l'instabilité de l'algorithme d'apprentissage et à l'application de ce dernier à un ensemble de données fini (variance). Les modèles qui présentent le meilleur rendement arrivent à réduire à la fois le biais et la variance en vue de minimiser l'erreur de généralisation.

L'approche de validation classique, appelée « validation croisée » (Stone, 1974), permet de calibrer un modèle à partir d'un ensemble de données d'observation disponibles, puis d'évaluer le rendement du modèle en comparant ses prévisions aux valeurs indépendantes observées. L'échantillonnage fractionné constitue une forme particulière de validation croisée qui consiste à diviser l'ensemble de données en deux sous-ensembles: un pour l'apprentissage, l'autre pour le contrôle. La forme de validation croisée la plus poussée est la validation croisée par rééchantillonnage (VCR) qui consiste à omettre un cas à la fois et à établir le modèle statistique à partir du reste de l'ensemble de données, puis d'estimer la valeur omise à l'aide du modèle. Tous les N cas disponibles sont omis puis estimés à tour de rôle. Finalement, le rendement du modèle est calculé à partir des erreurs d'estimation des cas omis.

Les IH de débit d'étiage choisis pour le présent projet sont annuels et saisonniers. Ainsi, dans le cadre de l'approche directe, le nombre total d'échantillons disponibles pour procéder à l'étalonnage de la MVP et du ASD est égal au nombre total d'années pour lesquelles des données ont été recueillies. C'est pourquoi l'AD est validée à l'aide de la VCR. L'estimation du rendement des approches directes de mise à l'échelle des indices hydrologiques a été réalisée à l'aide des indices de rendement suivant: la racine relative de l'erreur quadratique moyenne (RREQM), le biais moyen relatif (BMR) et le coefficient de détermination (R^2)

$$RREQM = \sqrt{\frac{\sum_{i=1}^n \left(\frac{O_i - P_i}{O_i}\right)^2}{n}} \quad (1-40)$$

$$BMR = \frac{\sum_{i=1}^n \left|\frac{O_i - P_i}{O_i}\right|}{n} \quad (1-41)$$

et

$$R^2 = \left(\frac{\sum_{i=1}^n (O - \bar{O})(P - \bar{P})}{\sqrt{\sum_{i=1}^n (O - \bar{O})^2 \sum_{i=1}^n (P - \bar{P})^2}} \right)^2 \quad (1-42)$$

Où N représente ici le nombre total d'échantillons (d'années),

O_i et P_i indiquent respectivement les i -ièmes valeurs observées et prévues;

\bar{O} et \bar{P} représentent les moyennes observées et prévues.

Dans le cadre de l'approche indirecte, la mise à l'échelle est effectuée pour les valeurs quotidiennes de précipitations et de température, préalablement à leur introduction dans SSARR. Cette mise à l'échelle a été validée à l'aide d'un échantillonnage fractionné. La division des séries d'étalonnage et de validation (C1 et C2) est illustrée au tableau 1.3. Comme les valeurs de précipitations et de température peuvent être nulles, le calcul de la RREQM et du BMR entraîne des erreurs de type « division par zéro ». La mise à l'échelle de ces variables est donc quantifiée à partir du coefficient R^2 et des indices suivants: la racine relative de l'erreur quadratique moyenne corrigée pour l'intervalle des valeurs ($RREQM_C$); et le biais moyen relatif corrigé pour l'intervalle des valeurs (BMR_C).

$$RREQM_C = \frac{\sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{N}}}{\text{intervalle}} \quad (1-43)$$

$$BMR_C = \frac{\frac{\sum_{i=1}^N |O_i - P_i|}{N}}{\text{intervalle}} \quad (1-44)$$

Dans ces équations, « intervalle » correspond aux valeurs maximales observées moins les valeurs minimales observées.

Tableau 1.3 Division des données météorologiques disponibles en ensembles d'étalonnage et de validation. Deux combinaisons d'ensembles d'étalonnage et de validation ont été définies ; elles sont désignées par C1 et C2.

Ensembles	Type	Romaine	Moisie	Ouelle
Combinaison1 (C1)	Étalonnage	Janv. 1964 à déc. 1969	Oct. 1980 à sept. 1990	Oct. 1969 à août 1981
	Validation	Janv. 1970 à déc. 1976	Oct. 1990 à déc. 1996	Oct. 1982 à sept.1991
Combinaison2 (C2)	Étalonnage	Janv. 1970 à déc. 1976	Oct. 1990 à déc. 1996	Oct. 1982 à sept.1991
	Validation	Jan.1964 à déc. 1969	Oct. 1980 à sept. 1990	Oct. 1969 à août 1981

3.5 Projections

Le MCG élaboré par l'Institut de météorologie Max-Planck et le MCR né de la collaboration entre le Réseau canadien en modélisation et diagnostics du climat régional (MDCR), le Centre pour l'étude et la simulation du climat à l'échelle régionale (ESCER) de l'UQAM, Environnement Canada (CCmaC) et le consortium Ouranos ont été utilisés pour prévoir les futurs IH de débit d'étiage. ECHAM5 (Roeckner et al., 2003) représente la cinquième génération du modèle de circulation générale ECHAM. Selon sa configuration, le modèle assure la résolution de l'atmosphère jusqu'à 10 hPa pour les études troposphériques ou jusqu'à 0,01 hPa pour les études mésosphériques (le modèle est alors souvent appelé « MAECHAM5 »). La taille de la grille du modèle ECHAM5 est de 1,875° de latitude × 1,875° de longitude. Les données utilisées font partie du projet ENSEMBLES (<http://www.ensembles-eu.org>), lequel est appuyé par le sixième programme-cadre de la Commission européenne titre de projet intégré de cinq ans (2004 à 2009) dans le cadre de la sous-priorité thématique « Changement planétaire et écosystèmes ». Ce projet vise à élaborer un système de prévision d'ensemble des

changements climatiques axé sur les systèmes terrestres mondial et régional de pointe à haute résolution créés en Europe, lesquels ont été validés à partir de grilles de données européennes à haute résolution qui ont fait l'objet d'un contrôle de la qualité. Le but est de produire pour la première fois une estimation probabiliste objective des incertitudes quant aux projections climatiques futures sur une échelle saisonnière à décennale, ou même sur des échelles plus longues.

Le Modèle régional canadien du climat (MRCC; Jiao et Caya, 2006) utilisé dans le présent projet est axé sur le MCGG3 et suit les concentrations observées des gaz à effet de serre et des aérosols (GES+A). Quatre valeurs horaires des prédicteurs choisis obtenues par le MRCC à une résolution de 0,5° de latitude × 0,5° de longitude ont été tirées du site Données Accès Intégration (http://loki.gc.ec.gc.ca/DAI/rcm_CRCM-f.html). Les futures émissions de gaz à effet de serre (GES) sont le produit de systèmes dynamiques des plus complexes. Elles dépendent des facteurs déterminants tels le développement démographique, le développement socio-économique et le changement technologique. En outre, leur évolution est grandement incertaine. Offrant un choix de représentations d'évolutions possibles, les scénarios sont perçus comme un outil valable permettant d'analyser la façon dont différents éléments peuvent influencer les émissions et d'évaluer les incertitudes liées à ces derniers. Ce projet emploie trois scénarios d'émissions soit: A1B, A2 et B1, lesquels sont décrits brièvement au tableau 1.4 (IPCC, 2000). Les projections sont comparées à l'aide du changement relatif (CR) de médiane et de variabilité des indices des périodes futures suivantes: 2021 à 2050 (années 2020) et 2051-2081 (années 2050), par rapport à la période de base (1961 à 2010). Le CR est calculé ainsi:

$$CR = \frac{\text{valeur future prévue} - \text{valeur de base de la période}}{\text{valeur de base de la période}} \quad (1-45)$$

Tableau 1.4 Scénarios d'émissions recommandés par le Groupe d'experts intergouvernemental sur l'évolution du climat (IPCC, 2000) afin d'évaluer les résultats futurs relatifs aux émissions.

Famille	A1				A2	B1	B2
Groupe de scénarios	A1C	A1G	A1B	A1T	A2	B1	B2
Croissance démographique	faible	faible	faible	faible	élevée	faible	modérée
Croissance du PIB	très élevée	très élevée	très élevée	très élevée	modérée	élevée	modérée
Utilisation d'énergie	très élevée	très élevée	très élevée	élevée	élevée	faible	modérée
Changement d'affectation des terres	faible à modéré	faible à modéré	faible	faible	modéré à élevé	élevé	modéré
Disponibilité des ressources	élevée	élevée	modérée	modérée	faible	faible	modérée
Rythme et direction des progrès technologiques	rapide	rapide	rapide	rapide	lent	modéré	modéré

4 RÉGION ÉTUDIÉE

La zone d'étude est concentrée autour de trois rivières de l'est du Canada, soit les rivières Romaine, Moisie et Ouelle (figure 1.6, tirée de Joshi et al., 2013). Ces trois rivières se déversent toutes dans le fleuve Saint-Laurent. Les rivières Romaine et Moisie se trouvent sur la rive nord du fleuve alors que la rivière Ouelle se situe sur la rive sud. Ces rivières ont été choisies en raison de leur capacité à entretenir des populations de saumon de l'Atlantique (*Salmo salar*), une espèce menacée dans certaines régions (Comité sur la situation des espèces en péril au Canada (COSEPAC), 2011). Les bassins versants des rivières Romaine, Moisie et Ouelle ont des superficies de 13,000, 19,000 et 795 km², respectivement.

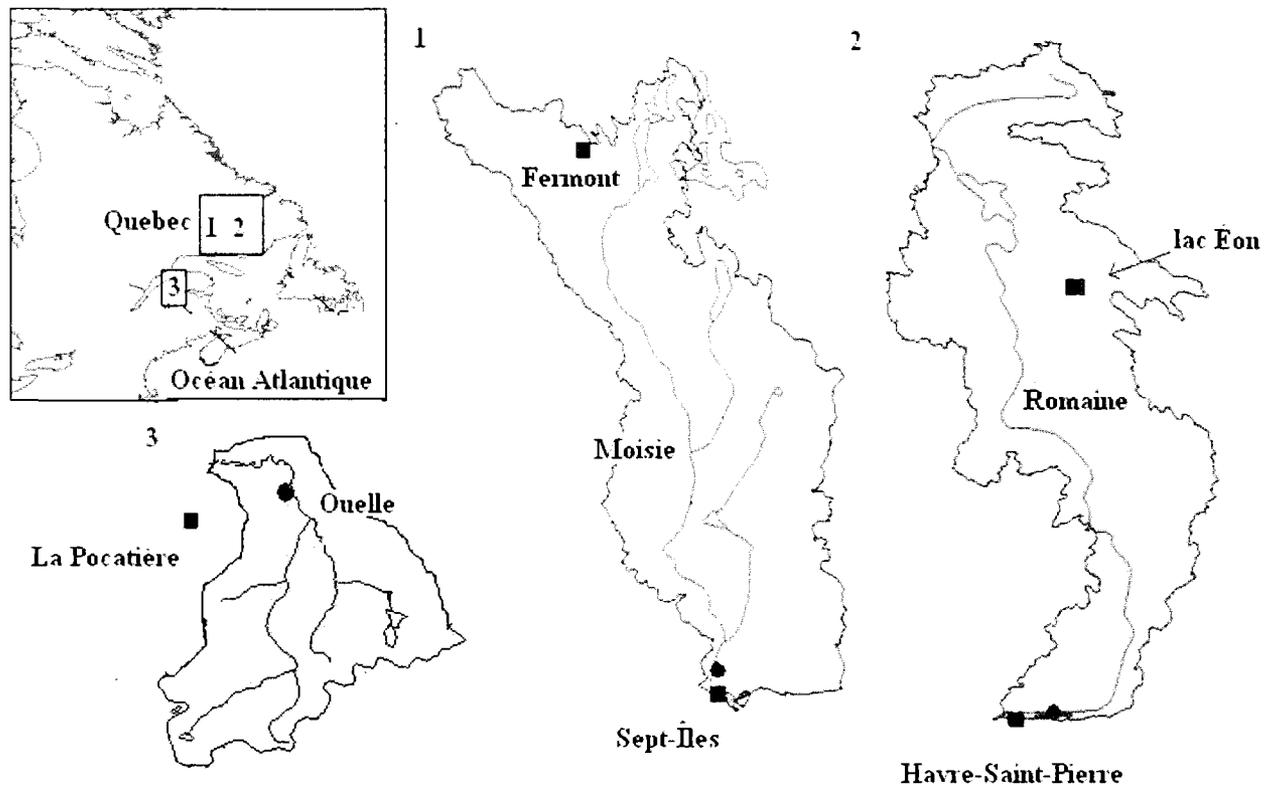


Figure 1.6 Carte de la zone d'étude illustrant l'emplacement des stations hydrométriques (cercles) et météorologiques (carrés) des rivières Romaine, Moisie et Ouelle. (figure tirée de Joshi et al., 2013).

Les localisations des stations hydrométriques et météorologiques choisies pour la mise à l'échelle apparaissent à la figure 1.6. Les données hydrologiques et météorologiques proviennent de la banque de données d'Environnement Canada (<http://climat.meteo.gc.ca>). Les différentes stations sont décrites au tableau 1.5 (tiré de Joshi et al., 2013). Les années présentant un tiers des données de débit manquantes (> 4 mois) ont été exclues. La figure 1.7 présente les courbes des débits classés des débits estivaux et hivernaux des trois rivières. Il apparaît clairement que les rivières Moisie et Romaine présentent des débits d'étiage hivernaux plus marqués que leurs équivalents estivaux alors que la rivière Ouelle présente des débits d'étiage plus importants en été. Ces résultats concordent avec ceux obtenus par Burn et al. (2008), qui ont remarqué que les rivières situées dans la partie nord de l'est du Canada, qui connaissent des périodes prolongées de basses températures, présentent leurs plus faibles débits pendant l'hiver. Les rivières plus au sud, cependant, présentent des débits d'étiage très marqués pendant l'été en raison des faibles précipitations, d'une évapotranspiration élevée et d'une probable sous-affluence plus faible que celle des rivières du nord qui font l'objet de la présente étude. En analysant les courbes des débits classés, il est également évident que la différence entre les débits estivaux et hivernaux des rivières Romaine et Moisie est plus prononcée que celle de la rivière Ouelle. Les valeurs du coefficient Q95 des débits estivaux et hivernaux de la rivière Ouelle s'élèvent respectivement à 0,65 et 0,86 m³/s. Pour les rivières Moisie et Romaine, ces valeurs s'élèvent à 222,5 m³/s et 60,3 m³/s, et à 140 et 42,9 m³/s, respectivement.

Tableau 1.5 Description des stations et données hydrométriques (tiré de Joshi et al., 2013).

Station	Latitude	Longitude	Superficie drainée (km ²)	Années étudiées	Années exclues
Romaine	50°18'28" N	63°37'21" O	13 000	1961 à 2010	2007
Moisie	50°21'1" N	66°11'25" O	19 000	1966 à 2010	1967, 1999, 2000, 2007
Ouelle	47°22'52"N	69°57'29" O	795	1961 à 2010	1967, 1981, 1982, 1996

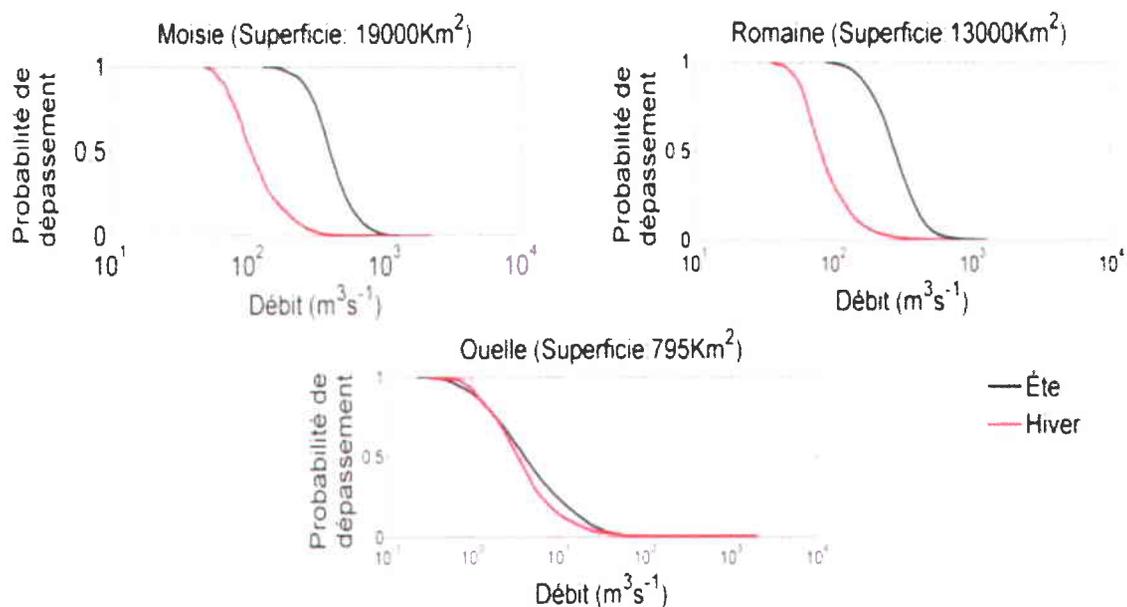


Figure 1.7 Courbes de débits classés estivales et hivernales des rivières Romaine, Moisie et Ouelle.

Les conditions météorologiques observées aux bassins versants des rivières Romaine et Moisie ont été enregistrées à deux stations météorologiques chacune alors que pour la rivière Ouelle, une seule station a été utilisée. Le choix des stations a été établi en fonction du nombre d'années au cours desquelles des données étaient disponibles. Les stations choisies sont décrites au tableau 1.6.

Tableau 1.6 Description des stations météorologiques qui ont servi à l'exercice de mise à l'échelle.

Station	Latitude	Longitude	Élévation (m)	Années disponibles
Fermont (F)	52°48'00,000" N	67°05'00,000" O	594,40	Oct. 1980 à déc. 1996
Sept-Îles (S)	50°13'00,000" N	66°16'00,000" O	54,90	Oct. 1980 à déc. 1996
Lac Éon (L)	51°52'02,000" N	63°17'01,000" O	588,90	Janv. 1964 à déc. 1976
Havre- Saint- Pierre (H)	50°16'55,000" N	63°36'41,000" O	37,80	Janv. 1964 à déc. 1976
La Pocatière (P)	47°21'21,000" N	70°01'55,000" O	31,00	Oct. 1969 à sept. 1991

La figure 1.8 illustre la température annuelle moyenne et les précipitations annuelles moyennes enregistrées aux stations météorologiques. Ces moyennes ont été calculées à partir des données de 1964 à 1976 pour les stations du Havre-Saint-Pierre et du lac Éon (rivière Romaine). Les moyennes ont été calculées à partir de données enregistrées sur 16 ans, soit entre 1981 et 1996, pour les stations Fermont et Sept-Îles (rivière Moisie). Finalement, la station de La Pocatière (rivière Ouelle) a recueilli des données pendant 21 ans, soit de 1970 à 1990. En observant la figure 1.8, on remarque que la température annuelle moyenne diminue entre La Pocatière (4,1 °C), au sud, sur la rivière Ouelle, et Fermont (-3,8 °C), au nord, sur la rivière Moisie. Les précipitations totales annuelles moyennes les plus élevées ont été observées à la station de Sept-Îles (1143,5 mm) tandis que les plus faibles ont été enregistrées à la station de Fermont (789 mm), toutes deux situées sur la rivière Moisie.

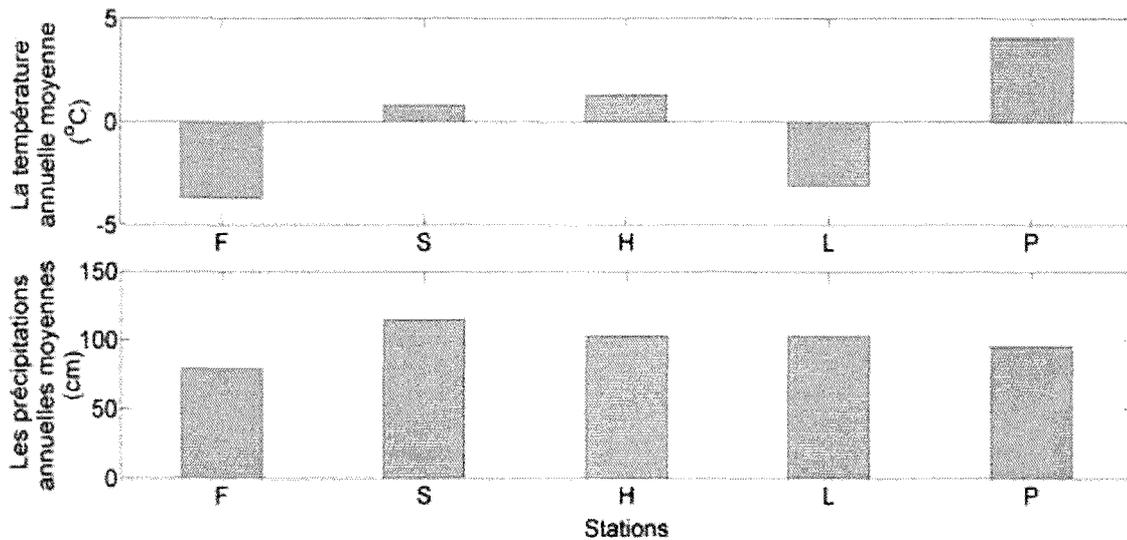
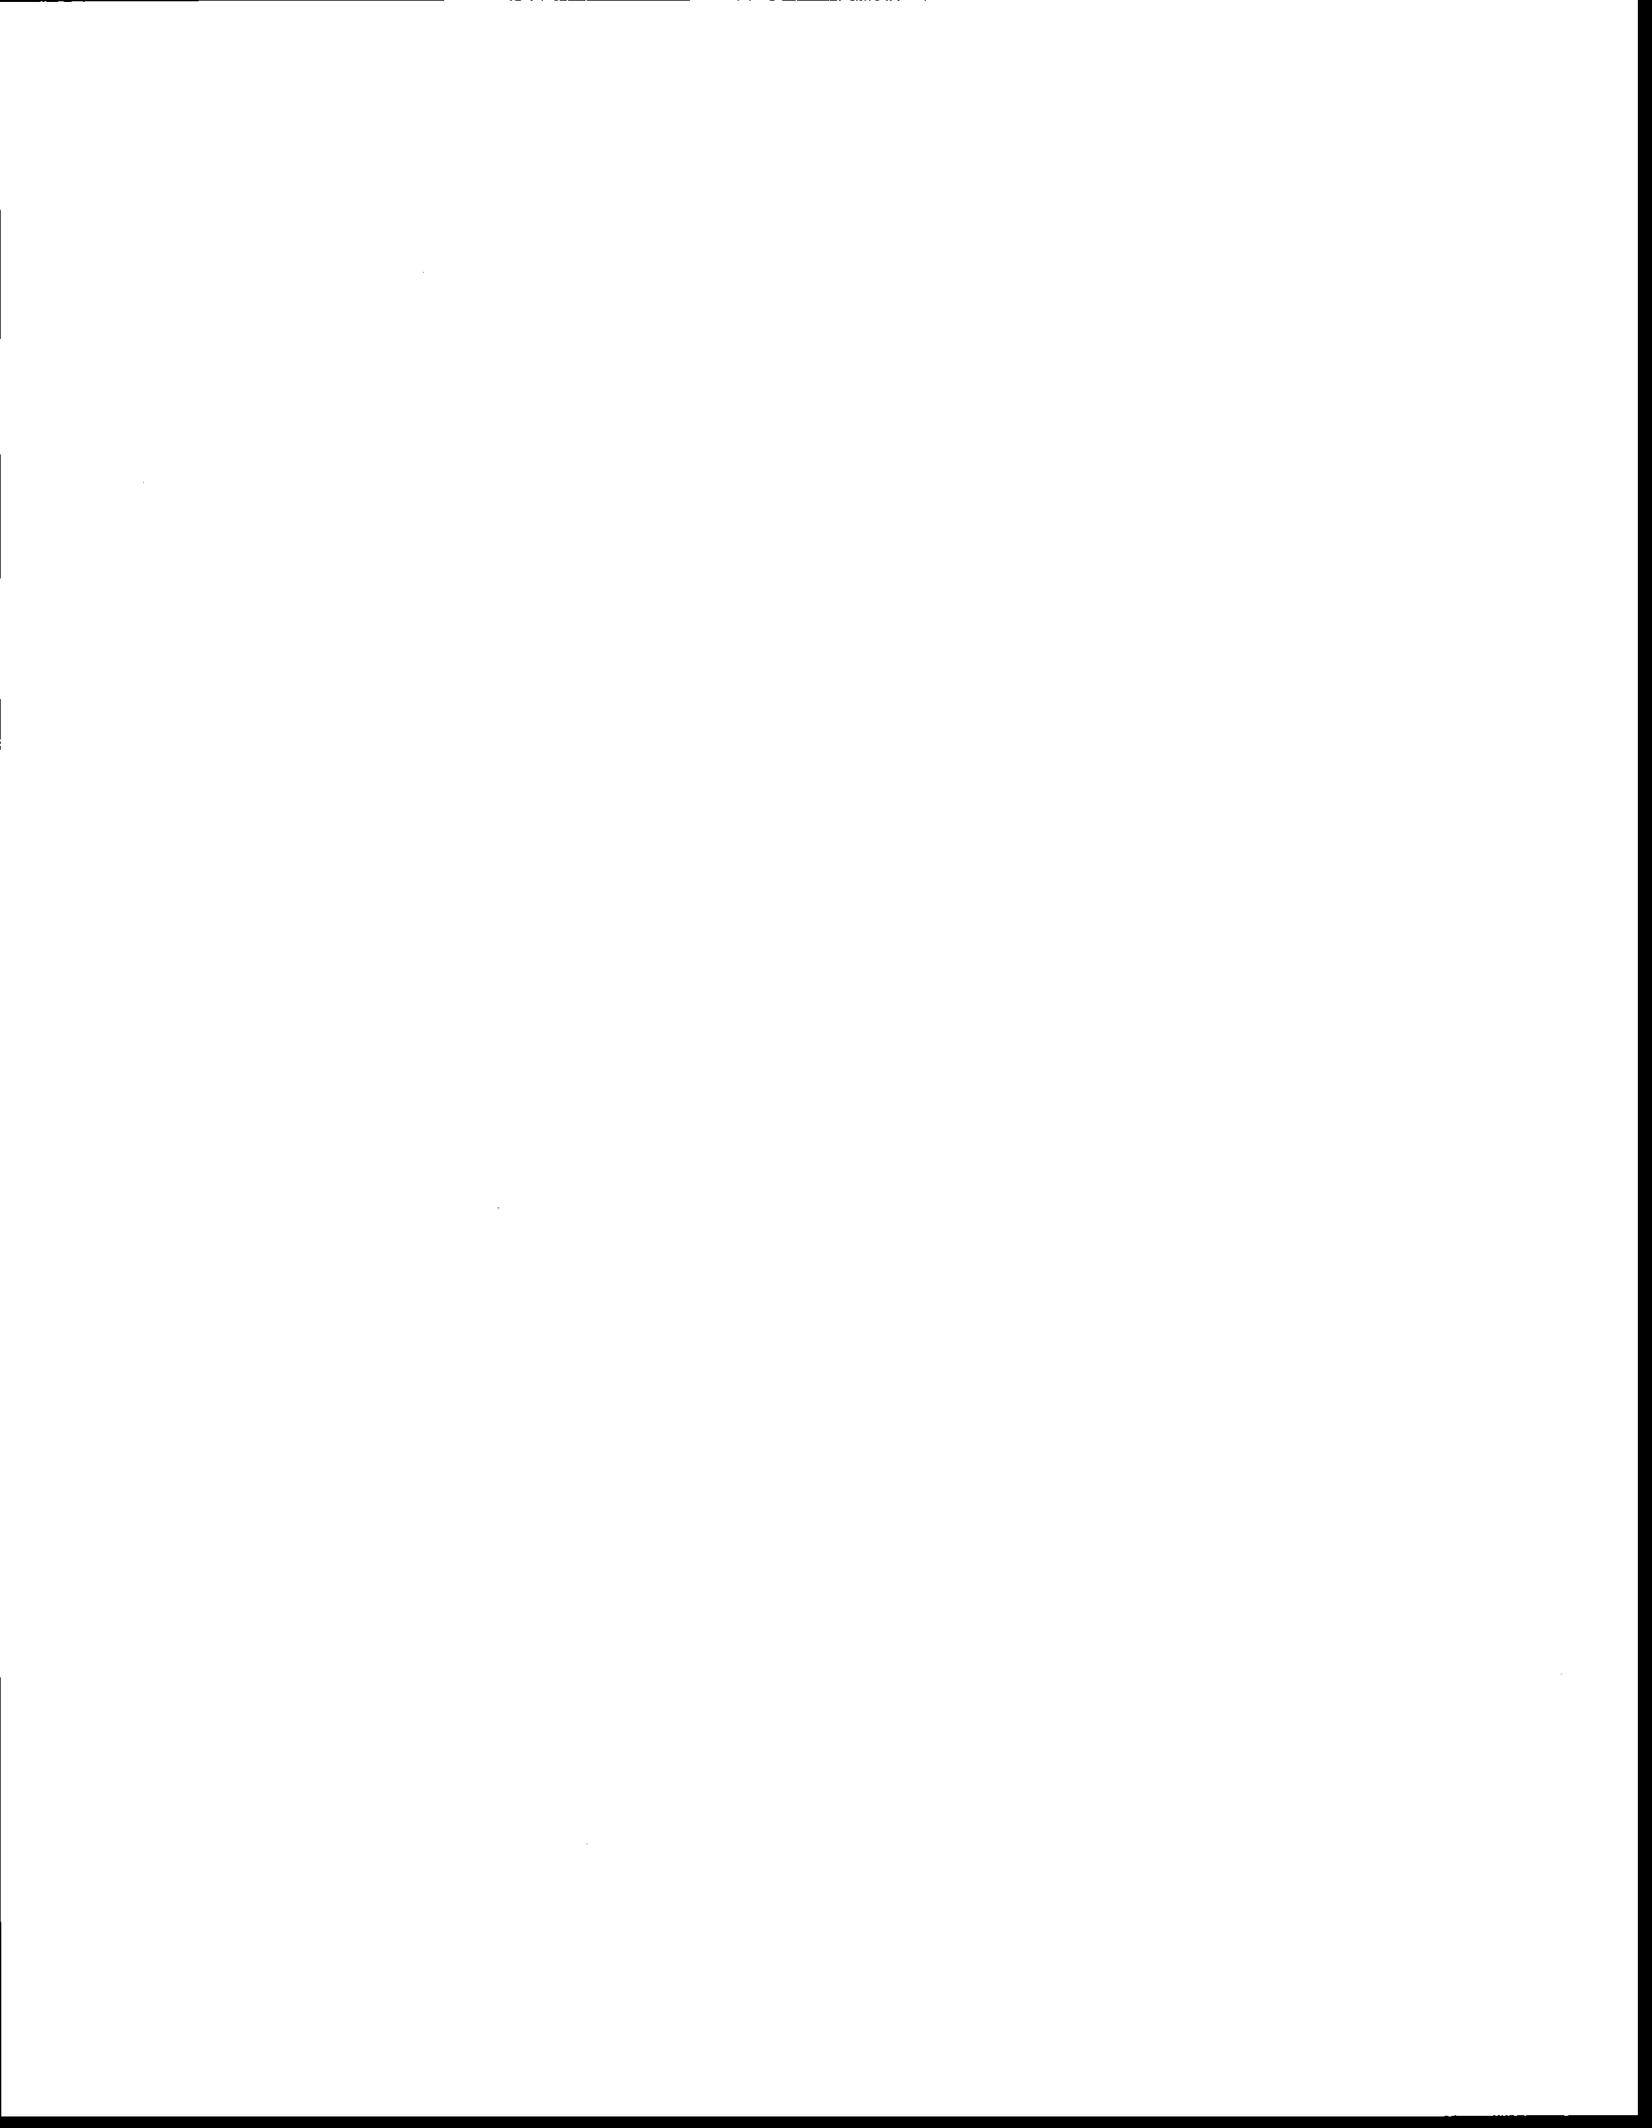


Figure 1.8 Températures et précipitations annuelles moyennes enregistrées aux stations météorologiques. Les lettres correspondent aux stations décrites au tableau 1.6.



5 CHOIX DES INDICES HYDROLOGIQUES DE DÉBIT D'ÉTIAGE

La sélection des indices hydrologiques de débit d'étiage utilisés dans le présent projet a été faite en fonction des travaux de Daigle et al. (2011), lesquels ont procédé à la caractérisation des régimes d'étiage des rivières de l'est du Canada à l'aide d'une analyse en composantes principales (ACP). Un total de 71 IH, liés à la description des débits d'étiage et enregistrés à partir de 175 stations hydrométriques, ont fait l'objet de cette analyse. Les trois premières composantes principales (CP) comptaient pour plus de 75 % de la variance totale des données. Visant une sélection d'un nombre limité d'IH utiles à la description des étiages de l'Est du Canada, les critères suivants ont été suivis:

- Les IH choisis doivent contribuer fortement aux CP₁, CP₂ et CP₃ (*i.e.* expliquer une proportion importante de la variance des IH de débit d'étiage).
- Deux IH séparés par un angle de 0° ou de 180° dans l'espace des CP sont redondants et l'un des deux doit être privilégié.
- Les IH choisis ne doivent présenter aucune autocorrélation (corrélation temporelle). L'autocorrélation interannuelle relevée dans les IHs se situait dans l'intervalle -0,2 à 0,2.

À partir de critères énoncés précédemment, six indices appartenant aux quatre catégories suivantes ont été sélectionnés:

- Amplitude
 - AMP1: Les valeurs minimales du débit observées au mois de mars pour chaque année ($Ls^{-1}Km^{-2}$).
 - AMP2: indice de débit de base, soit le rapport du débit mensuel le plus faible sur le débit annuel moyen (sans unités).
- Temporalité
 - T: le jour julien moyen des sept journées au cours desquelles les débits les plus faibles ont été observés au cours de l'année (jour julien).
- Variabilité
 - V: l'écart type du jour julien de ces sept journées (en jours).

- Durée
 - D1: le débit le plus faible observé sur une période de 90 jours divisé par la valeur médiane de toute la période d'enregistrement (sans unités).
 - D2: le débit le plus faible observé sur une période de 90 jours, de juillet à octobre, divisé par la valeur médiane de toute la période d'enregistrement (sans unités).

Tous les indices, à l'exception de D2, sont des valeurs annuelles. D2, quant à lui, est calculé de juillet à octobre. La figure 1.9 présente d'ailleurs des diagrammes qui illustrent la distribution de ces indices pour chacune des rivières étudiées. En observant ladite figure, il apparaît clairement que les indices de la rivière Ouelle sont ceux dont la variabilité est la plus grande. En outre, de tous les indices appliqués à cette rivière, un nombre maximal de horsains est retrouvé pour l'indice de variabilité, alors que l'indice de temporalité présente la variabilité maximale. De plus, la rivière Ouelle présente une distribution bimodale de la temporalité des débits d'étiage (fin de l'hiver et fin de l'été; figure 2.3, chapitre 2). Par conséquent, lorsque les sept journées de plus faible débit sont réparties au cours de ces deux saisons, l'index de temporalité connaît une augmentation. Par exemple, pour ce qui est de la rivière Ouelle, cinq jours de l'été 1973 et deux jours de l'hiver de cette même année constituaient les sept journées au cours desquelles le débit enregistré était à son plus bas. Si l'on compare les données des rivières Romaine et Moisie, on remarque que les indices correspondants sont semblables en termes de variabilité. Les valeurs médianes des indices AMP1, AMP2, D1 et D2 de la Romaine sont supérieures à celles de la rivière Moisie, mais pour ce qui est des autres indices (T et V), les valeurs médianes des deux rivières sont comparables.

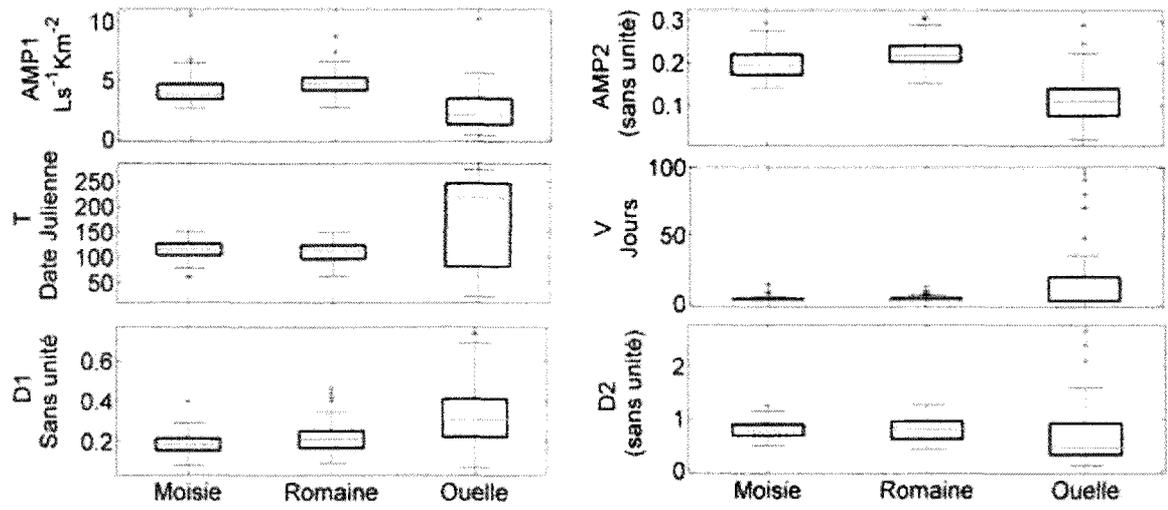
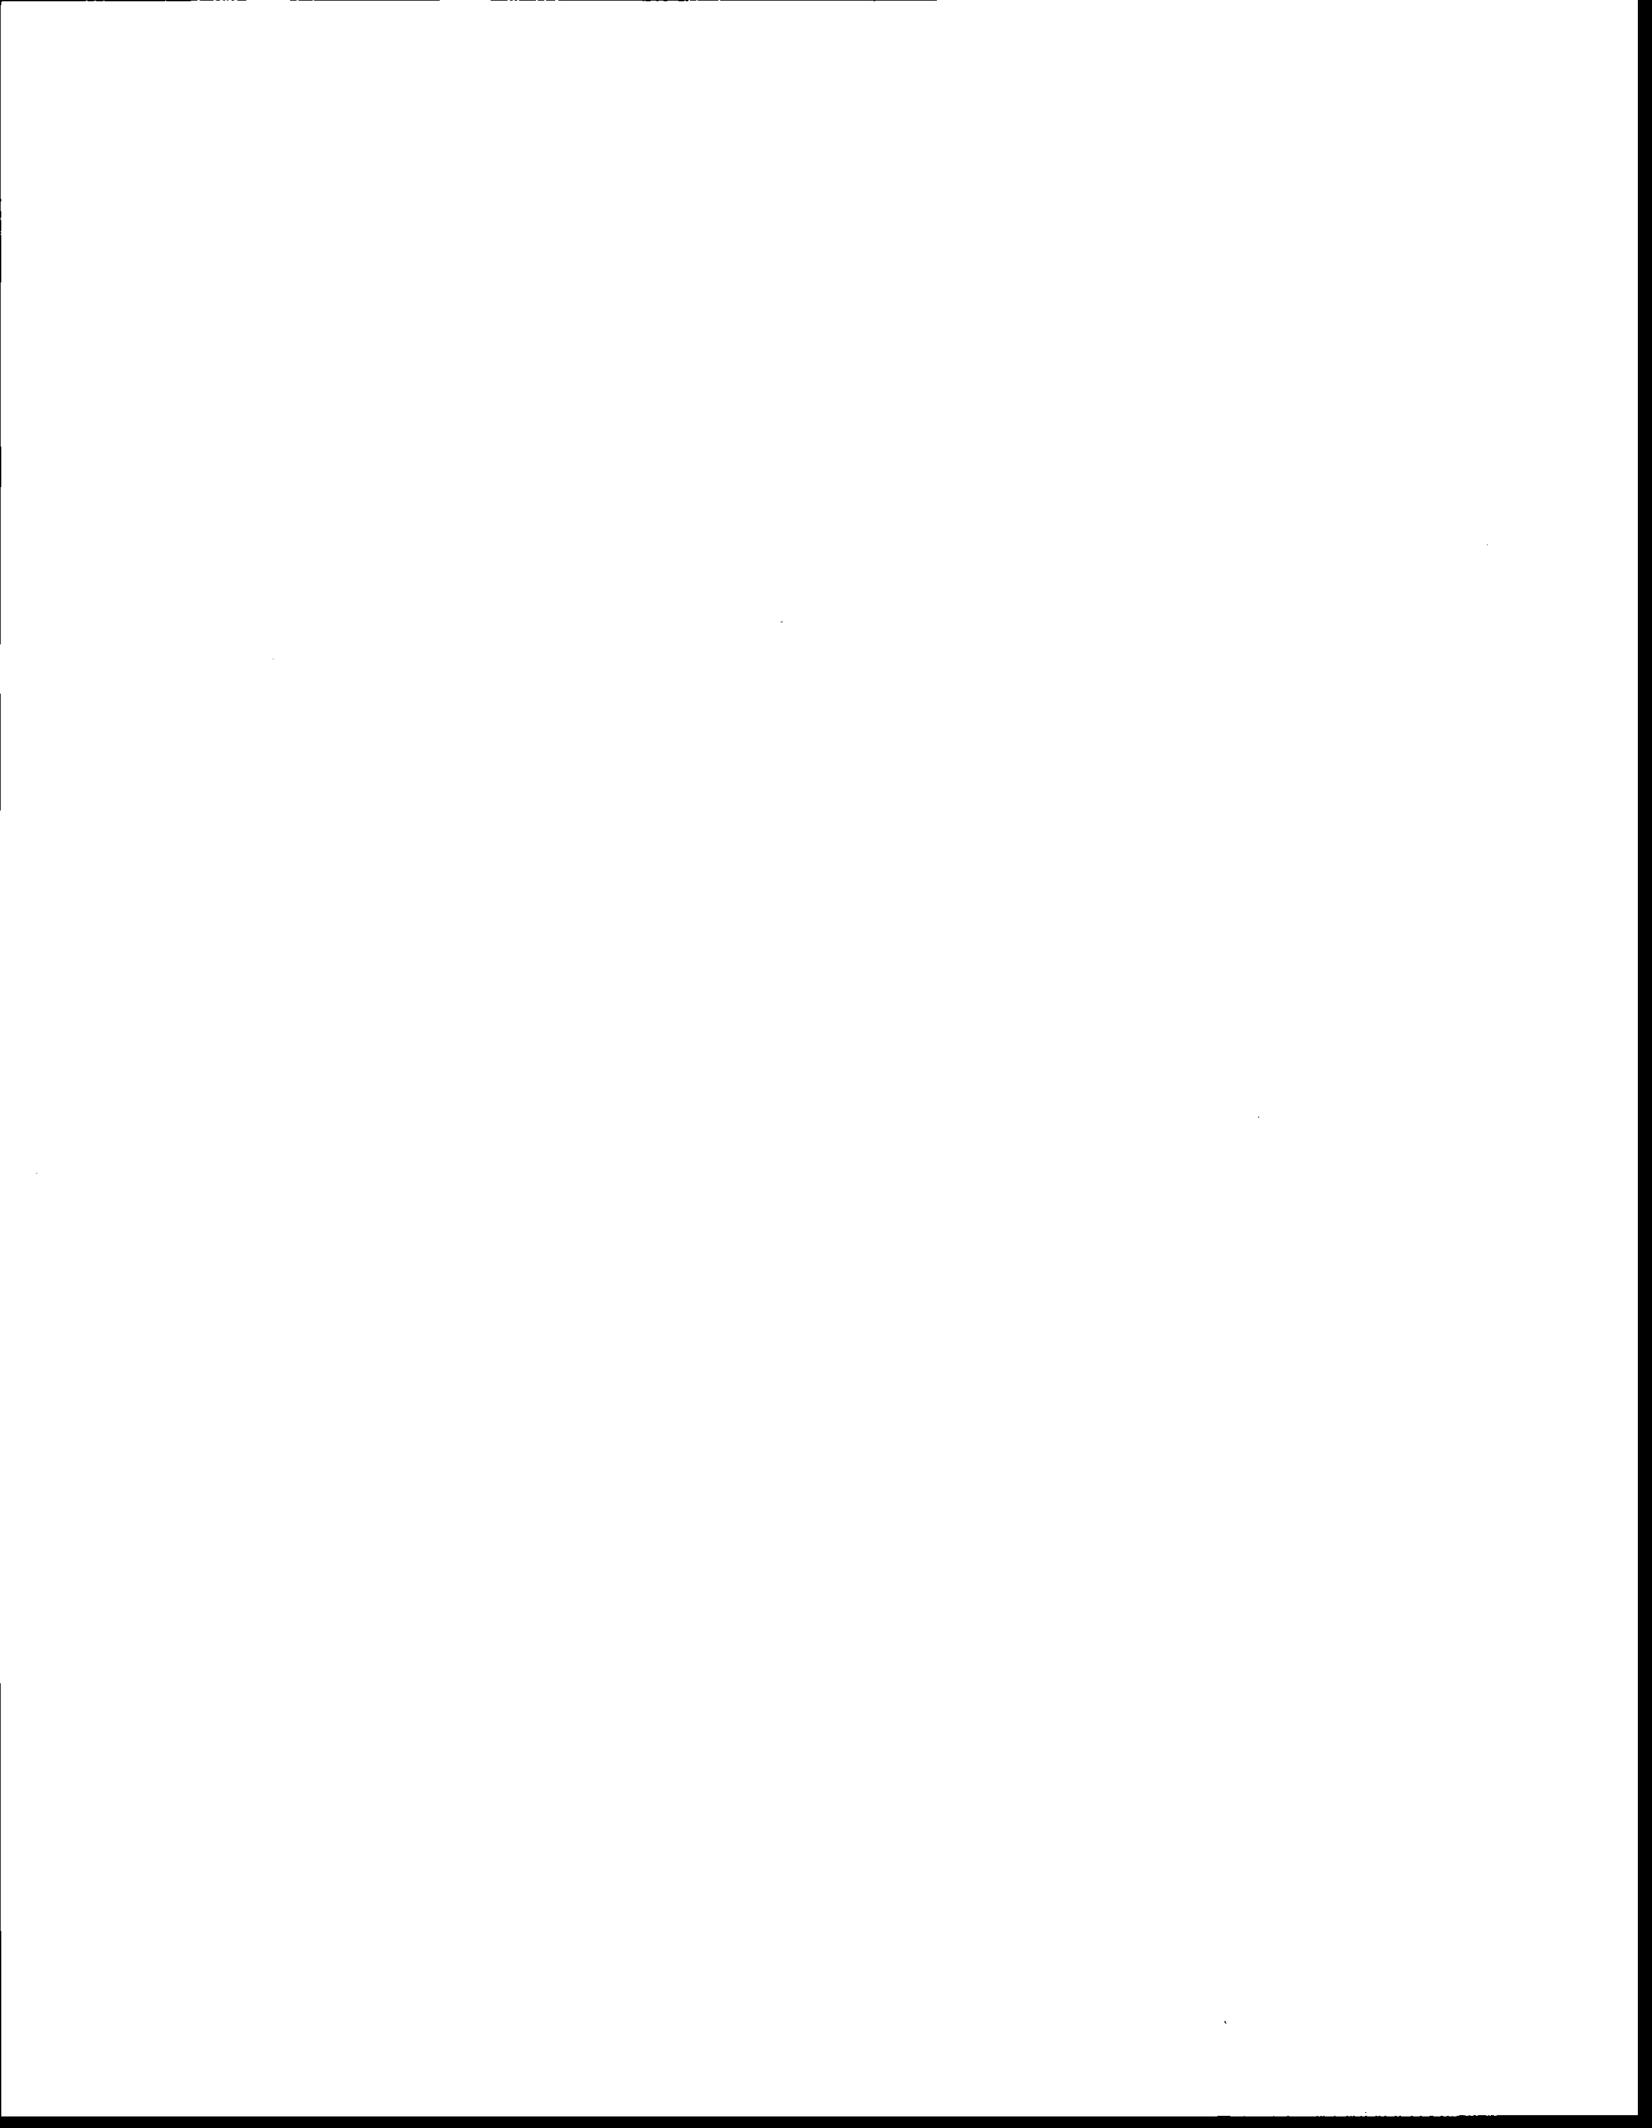


Figure 1.9 Diagrammes en hamac des indices hydrologiques choisis pour les rivières Romaine, Moisie et Ouelle (tirés de Joshi et al., 2013).

Copie originale très pâle



6 RÉSULTATS

6.1 Approche directe de mise à l'échelle

Tel que mentionné dans les sections précédentes, l'approche directe de mise à l'échelle consiste notamment à établir un lien entre les variables climatiques à grande échelle et les indices de débit d'étiage. Les intrants du MVP et du ASD ont été choisis parmi les valeurs annuelles, saisonnières ou mensuelles des variables à grande échelle qui présentaient une corrélation significative ($\alpha = 0.05$) avec les IH. Ces valeurs ont ensuite été soumises à une analyse de corrélation canonique et à une régression multiple descendante respectivement. Les résultats obtenus de l'approche directe de mise à l'échelle sont abordés au chapitre 2. Il s'avère que la plupart des variables présentant une corrélation significative avec les IH d'étiage sont liées à l'humidité et aux vents (vertical, zonal et méridien).

Les résultats de l'approche directe indiquent clairement que pour chaque rivière et chaque indice de débit d'étiage, la MVP s'est montrée plus efficace que l'ASD. Dans chacun des cas, la différence entre les valeurs de RREQM, BMR et R^2 obtenues en mode validation à l'aide de la MVP et du ASD est plus grande (dans la plupart des cas d'un facteur deux) que la différence observée entre ces mêmes valeurs en mode d'étalonnage. La RREQM et le BMR obtenues pour les IH de la Romaine et de la Moisie sont inférieures à celles de la rivière Ouelle et ce, tant en mode d'étalonnage que de validation. Parmi tous les indices, l'indice V obtenu pour la rivière Ouelle présente la RREQM et le BMR les plus élevés. Les valeurs de la RREQM pour cet indice sont respectivement de 1,70 et 1,29 (MVP) et de 7,51 et 4,92 (ASD). Pour ce même indice, l'ASD a donné lieu à des valeurs de V négatives dans les ensembles d'étalonnage et de validation. Une façon d'éviter l'occurrence de valeurs négatives est de transformer l'indice de variabilité en prenant le logarithme. La mise à l'échelle a ainsi été effectuée sur ces valeurs logarithmiques, et les valeurs prédites obtenues retransformées en utilisant la fonction exponentielle. En plus d'éviter les valeurs négatives, la méthode a amélioré les performances des deux modèles, avec de meilleures performances pour la MVP. Pour l'indice de variabilité de la rivière Ouelle, les valeurs de RREQM, RMABE et R^2 sont de 0,71, 0,49 et 0,86, alors que pour l'ASD, on obtient 0,93, 0,70 et 0,64, respectivement. Quant aux autres indices, les plus fortes différences entre la RREQM et le BMR ont été observées dans les données enregistrées à la rivière Ouelle. Les résultats obtenus à l'aide de l'ASD se sont améliorés lorsque le choix des

prédicteurs a été fait grâce à une ACC suivie d'une RLM. Cependant, la RLM améliorée n'est pas parvenue à surpasser la MVP. De plus, parmi tous les indices choisis et dans tous les cas de figure (la figure 1.10 ne porte que sur les résultats de validation de la rivière Ouelle), une différence marquée entre la MVP et la RLM avec ACC (RLMACC) a été observée relativement à l'indice V.

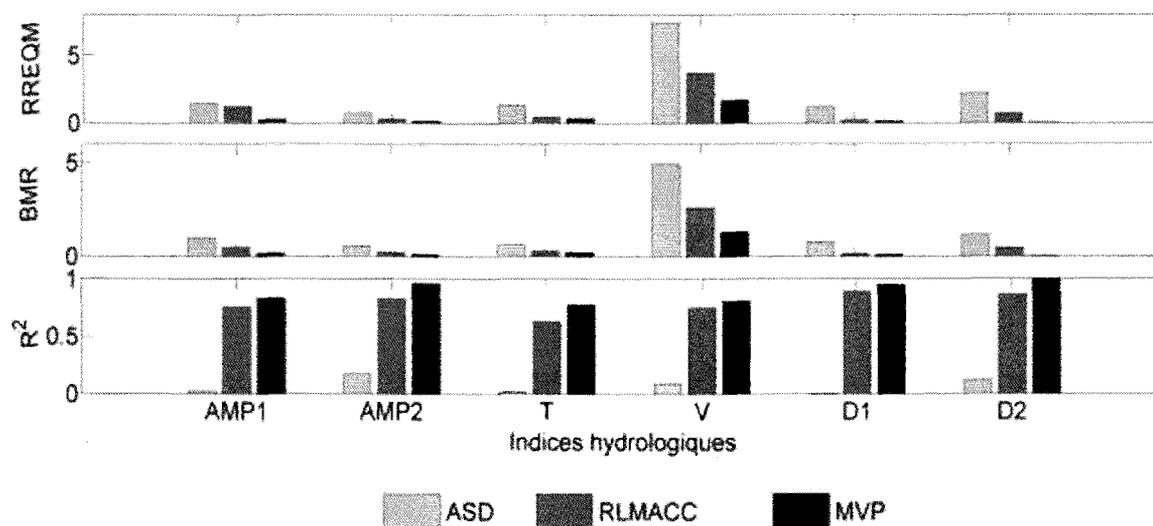


Figure 1.10 Résultats de validation des modèles de mise à l'échelle (MVP, ASD et RLMACC) obtenus pour la rivière Ouelle.

6.2 Approche indirecte de mise à l'échelle

Cette section décrit les résultats de l'AI pour les rivières à l'étude. Les résultats sont discutés dans trois sous-sections. La première résume les résultats de mise à l'échelle de la température et des précipitations. La seconde décrit les simulations faites avec le modèle SSARR aux échelles temporelles saisonnière et annuelle. La dernière sous-section résume les résultats obtenus par l'approche indirecte pour laquelle les précipitations et températures issues du processus de mise à l'échelle sont utilisées en intrants au modèle SSARR afin de générer des débits simulés avec lesquels les indices d'étiage sont calculés.

6.2.1 Mise à l'échelle des valeurs de précipitations et de température

Les résultats de la mise à l'échelle des températures et précipitations sont discutés en détails au chapitre 3. Les prédicteurs sélectionnés pour la température et les précipitations sont listés dans le tableau 1.6. Tel que mentionné dans la section 3, les variables NCEP, significativement corrélées avec la température et les précipitations, ont été sélectionnées pour constituer le

modèle. Afin de tenir compte de la préférence pour des modèles parcimonieux, le modèle contenant tous les prédicteurs corrélés (M_all) a été comparé avec celui contenant seulement les cinq meilleurs prédicteurs (M5). Le critère d'Akaike (AIC) a été utilisé pour faire cette comparaison. M5 a permis d'obtenir une valeur plus faible d'AIC et les résultats des deux modèles (M5 et M_all) sont comparables pour la température et les précipitations. Il n'y a que dans le cas de la station de Sept-Îles, où M5 a produit de meilleures valeurs d'indicateurs de performance que M_all pour les précipitations. Le nombre de prédicteurs a donc été augmenté pas à pas dans le cas des précipitations et c'est le modèle qui utilise les 10 meilleurs prédicteurs qui performe le mieux.

Les résultats de validation de la mise à l'échelle de la température pour les combinaisons C1 et C2 sont présentés dans la figure 1.11. Les résultats montrent que les deux méthodes (MVP et ASD) ont bien performé pour toutes les stations ($R^2 > 0.9$). Pour toutes les stations, MVP a mieux performé qu'ASD. Les valeurs des $RREQM_C$, BMR_C et R^2 obtenus pour le MVP et l'ensemble C1 à Sept-Îles sont de 0,075, 0,055 et 0,91 et pour ASD, de 0,087, 0,066 et 0,89, respectivement. La mise à l'échelle de la température est systématiquement mieux réussie que celle des précipitations. Les corrélations obtenues pour la température sont toujours supérieures à 0,9 alors qu'elles varient entre 0,3 et 0,7 pour les précipitations.

Tableau 1.6 Prédicteurs sélectionnés pour la mise à l'échelle de la température et de la précipitation. Les numéros des prédicteurs réfèrent au tableau 1.2.

Stations/ Variables	Température	Précipitations
Fermont (F)	11,4,12,1,13	13,7,6,5,19
Sept-Îles (S)	11,4,12,1,13	6,7,19,5,15,13,10,20,9,8
Havre-Saint-Pierre (H)	11,4,12,1,13	19,15,5,13,6
Lac-Éon (L)	11,4,12,1,13	7,6,10,13,5
La Pocatière (P)	11,4,12,1,13	15,19,7,13,6

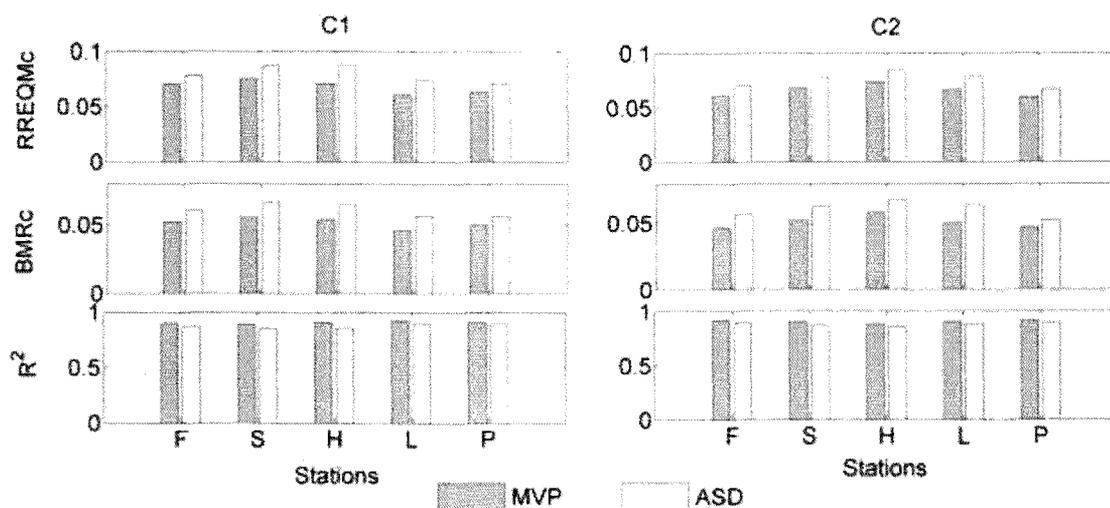


Figure 1.11 Résultats de validation de la mise à l'échelle de la température obtenus par le MVP et l'ASD, pour les combinaisons C1 et C2. Les barres blanches et grises représentent respectivement l'ASD et le MVP. Les noms de stations sont représentés par des lettres sur l'axe horizontal (voir le tableau 1.6).

En incluant l'algorithme génétique, les combinaisons des méthodes décrites sont PG et MVP (MVPPG) et PG et RLM (RLMPG), MVP et ASD. Les résultats de validation pour C1 et C2 sont montrés à la figure 1.12. Des améliorations mineures sont observées pour MVPPG, comparativement à MVP. On peut constater que la prédiction de la proportion de jours secs est meilleure que celle des jours humides. Le pourcentage de jours secs correctement identifiés varie entre 80 et 90%, tandis que celui des jours humides varie de 50 à 70%. La plus grande proportion de jours humides correctement identifiés est observée à la station de Sept-Îles (> 80%), pour toutes les méthodes. Les résultats des classifications de jours secs varient légèrement d'une station l'autre. Ainsi, pour C1 à Havre St-Pierre, la proportion de jours secs correctement identifiés par MVPPG est de 1% supérieure à celle de MVP. Pour C2 cependant, la différence est négligeable. À la station de La Pocatière en C1, le RLMPG a mieux performé que l'ASD tandis que c'est l'inverse en C2. Dans certains cas, comme à Fermont en C1 et Havre St-Pierre en C2, l'ASD a mieux performé que les autres méthodes. Pour les jours humides, le MVPPG a donné de meilleurs résultats à toutes les stations. Pour Sept-Îles, MVPPG a identifié correctement 6% et 3% plus de jours humides que MVP en C1 et C2, respectivement.

RLMPG a permis une meilleure classification des jours humides que ASD dans certains cas (Fermont et Sept-Îles pour C1, Havre St-Pierre, Lac Éon et La Pocatière pour C2), alors que ASD a mieux performé que RLMPG dans certains cas (Lac Éon pour C1 et C2). ASD et MVP ont eu des performances similaires à toutes les stations. Par exemple, pour Fermont, MVP a correctement identifié 71, 82 et 52% des jours totaux, secs et humides, respectivement, tandis que ces proportions pour ASD sont 71, 87 et 45%, respectivement. Les résultats pour la validation en C1 et C2 sont présentés dans la figure 1.13. De toutes les méthodes, MVPPG a donné de meilleurs résultats à toutes les stations. Des améliorations notoires ont été observées à Sept-Îles et Lac Éon pour C1. Les $RREQM_c$, BMR_c et R^2 obtenus pour MVPPG à Sept-Îles sont de 0,06, 0,029 et 0,43, respectivement. Pour C2, des améliorations importantes sont observées dans les résultats obtenus à Sept-Îles, Lac Éon et Havre St-Pierre. Les $RREQM_c$, BMR_c et R^2 obtenus pour MVPPG en C1 sont 0,072, 0,37 et 0,35, respectivement. Les meilleurs résultats ont été obtenus à La Pocatière pour les deux combinaisons. Les valeurs de $RREQM_c$, BMR_c et R^2 du MVPPG en C1 sont de 0,045, 0,025 et 0,29 et pour C2, de 0,049, 0,021 et 0,27, respectivement. ASD a donné de meilleurs résultats que RLMPG, principalement à cause d'une meilleure proportion de jours humides correctement classés. Les résultats obtenus à Lac Éon pour les deux combinaisons en sont un exemple. Les valeurs de $RREQM_c$, BMR_c et R^2 pour C1

avec ASD sont 0,083, 0,044 et 0,33 tandis que pour RLMPG, elles sont 0,085, 0,050 et 0,23, respectivement.

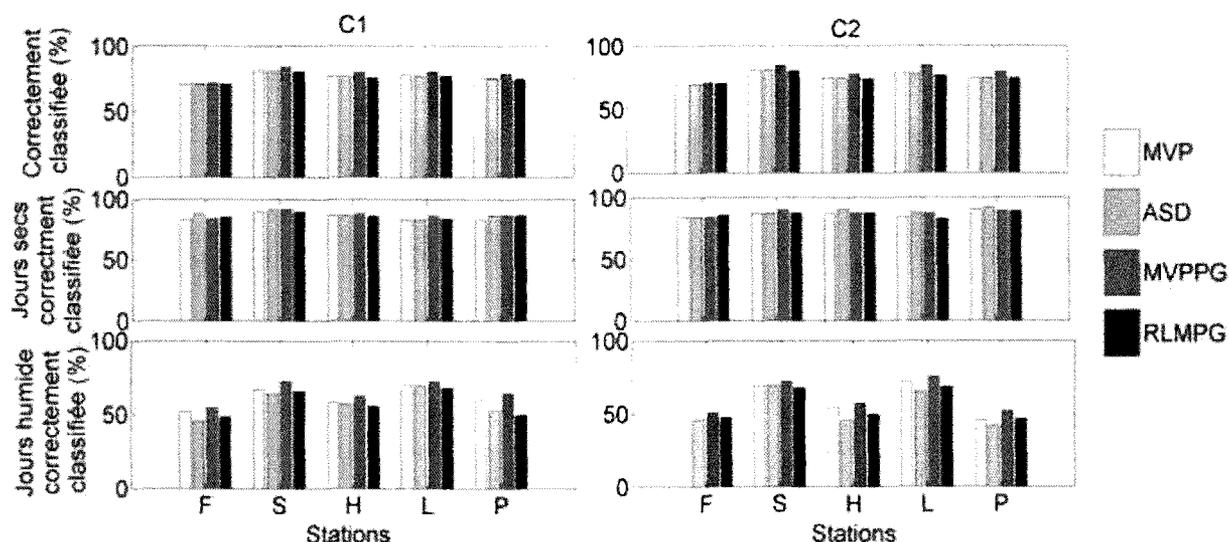


Figure 1.12 Résultats de classification des jours secs et humides pour la mise à l'échelle des précipitations avec PG comme méthode de préparation des intrants. Les résultats sont présentés pour les périodes de validation de C1 et C2 (tableau 1.3). Les noms de stations sont représentés par des lettres sur l'axe horizontal (voir le tableau 1.6).

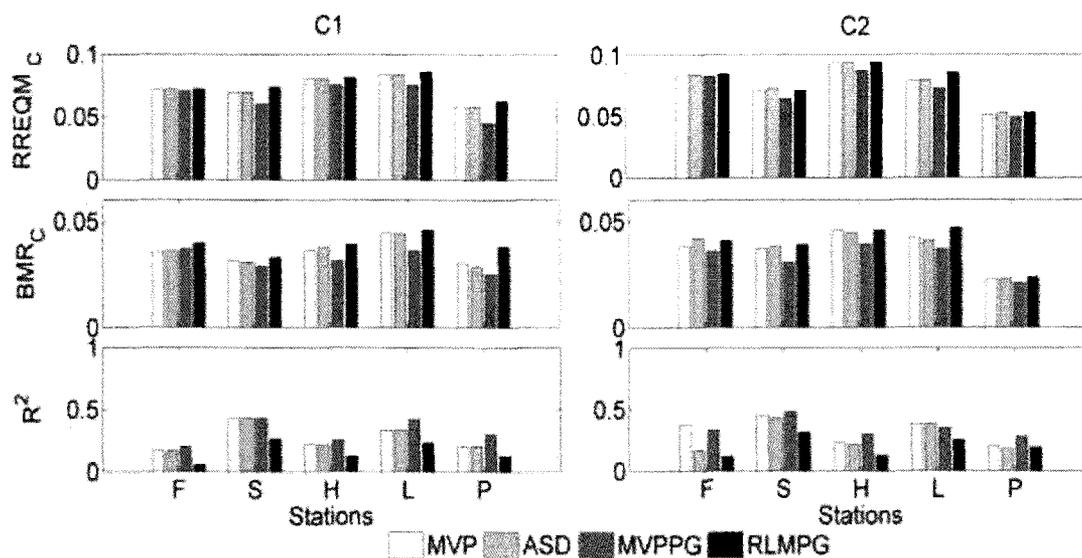


Figure 1.13 Résultats des régressions pour les taux de précipitations mis à l'échelle avec le PG comme méthode de préparation des intrants. Les résultats présentés correspondent aux périodes de validation de C1 et C2 (tableau 1.3). Les noms de stations sont représentés par des lettres sur l'axe horizontal (voir le tableau 1.6).

MVP permet de développer des modèles parcimonieux puisque cette approche utilise moins d'échantillons afin de faire ses estimations. Le pourcentage de vecteurs pertinents utilisés pour la mise à l'échelle de la température et de la précipitation sont de 1 à 5% et de 1 à 7%, respectivement. Cependant, le temps de calcul et la mémoire informatique requise peut rendre son application difficile pour les études de mise à l'échelle. ASD nécessite moins de mémoire et de temps de calcul. L'utilisation de langages tel que C ou C++ pourrait aider à diminuer le temps de calcul, de même que l'accès à des machines plus puissantes et ayant plus de mémoire

6.2.2 Simulation des débits à l'aide du modèle SSARR

Le modèle SSARR a été étalonné à l'aide d'une sous-routine d'optimisation, décrite à la section 3. Des quatre critères choisis en vue de quantifier le rendement du modèle SSARR, il s'avère que MODNASH convient le mieux à la mesure des capacités de modélisation du débit d'étiage (Krause et al., 2005). Par conséquent, les paramètres ont été optimisés en comparant les valeurs de l'indice MODNASH. Les variables météorologiques mises à l'échelle dont il a été question dans la section précédente sont introduites dans SSARR pour simuler un débit (figure 1.14). En observant les valeurs de MODNASH obtenues, on remarque que les simulations hydrologiques des rivières Moisie et Romaine sont mieux réussies que celles de la rivière Ouelle. Pour C1, les valeurs de MODNASH sont respectivement de 0,87, 0,89 et 0,41 aux rivières Moisie, Romaine et Ouelle. Pour C2, ces mêmes valeurs s'élèvent respectivement à 0,8, 0,9 et 0,23. Les débits hivernaux sont mieux simulés que les débits estivaux. Par exemple, à la rivière Moisie, les valeurs hivernale et estivale de MODNASH sont respectivement de 0,73 et 0,16 (C1) et de 0,66 et 0,32 (C2).

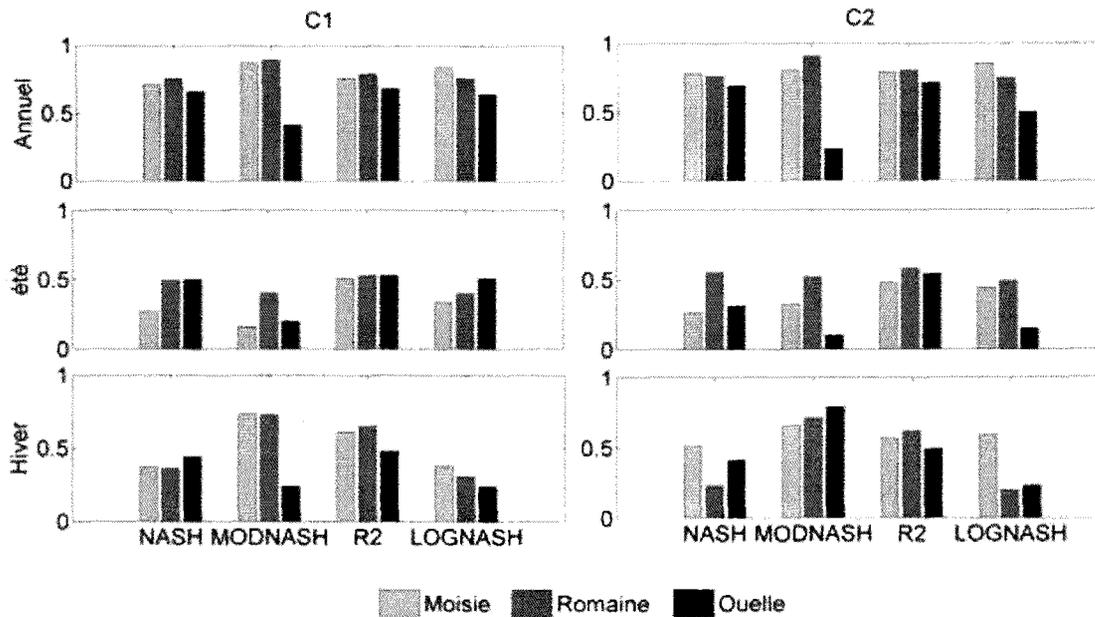


Figure 1.14 Résultats de la simulation à l'aide du modèle SSARR pour les trois rivières, pour les deux combinaisons C1 et C2 des ensembles de calibration et de validation).

6.2.3 Comparaison des approches indirectes de mise à l'échelle

Les figures 1.15 à 1.17 présentent les résultats de la mise à l'échelle indirecte des IH obtenue respectivement aux rivières Moisie, Romaine et Ouelle. Il est difficile de conclure quant à la supériorité de la MVP ou de l'ASD. Par exemple, en ce qui a trait à la RREQM et au BMR pour l'indice D2 de la rivière Romaine, il s'avère que la MVP présente un meilleur rendement que l'ASD pour la combinaison C1, alors que le contraire se produit selon la combinaison C2. Pour ce même indice, à la rivière Moisie, la MVP surpasse l'ASD en termes de rendement. Quant à la rivière Ouelle, pour l'indice D2, les deux méthodes ont donné lieu à une RREQM et à un BMR comparables. Aux rivières Romaine et Moisie, les meilleurs résultats des deux combinaisons ont trait à l'indice AMP1. Cette fois encore, dans les deux cas, les deux méthodes ont donné lieu à une RREQM et à un BMR comparables. Pour ce qui est de l'indice V à la rivière Ouelle, le rendement des méthodes a chuté de façon considérable. Les valeurs de la RREQM et du BMR se sont élevées à plus de cinq et le R^2 s'est abaissé sous les 0,2, et ce, pour les deux combinaisons. Finalement, pour ce qui est de l'indice T à la Romaine (C1), des deux méthodes présentent un rendement semblable quant à la RREQM et au BMR, mais pour le R^2 , il s'avère que l'ASD surpasse la MVP.

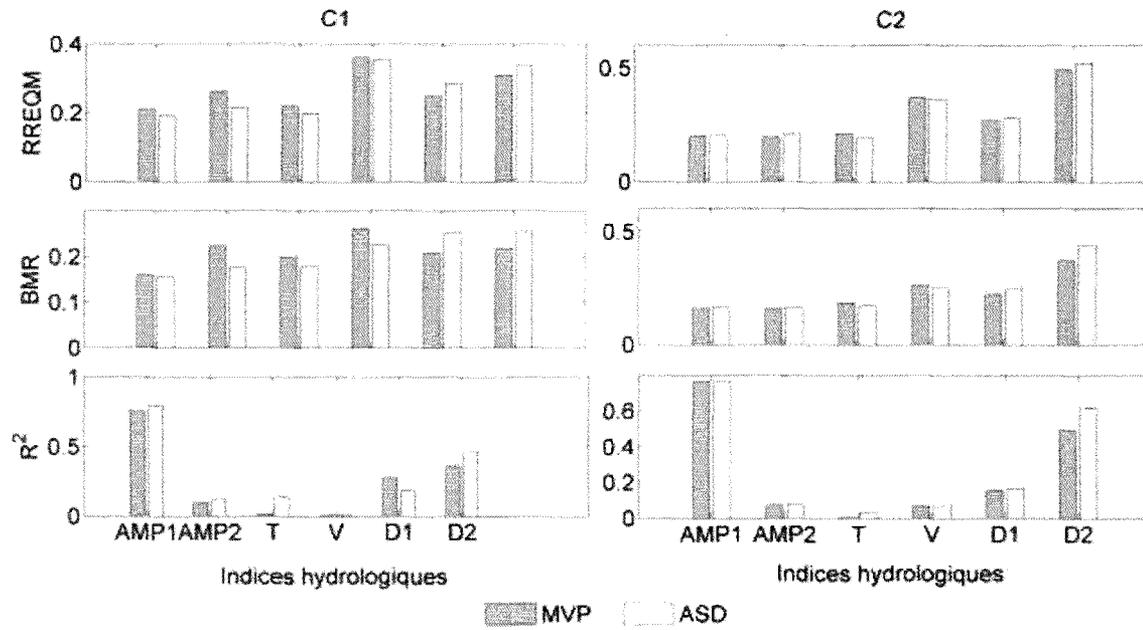


Figure 1.15 Indices de performance des IH d'approche indirecte pour la rivière Moisie pour les deux combinaisons des ensembles de calibration et de validation.

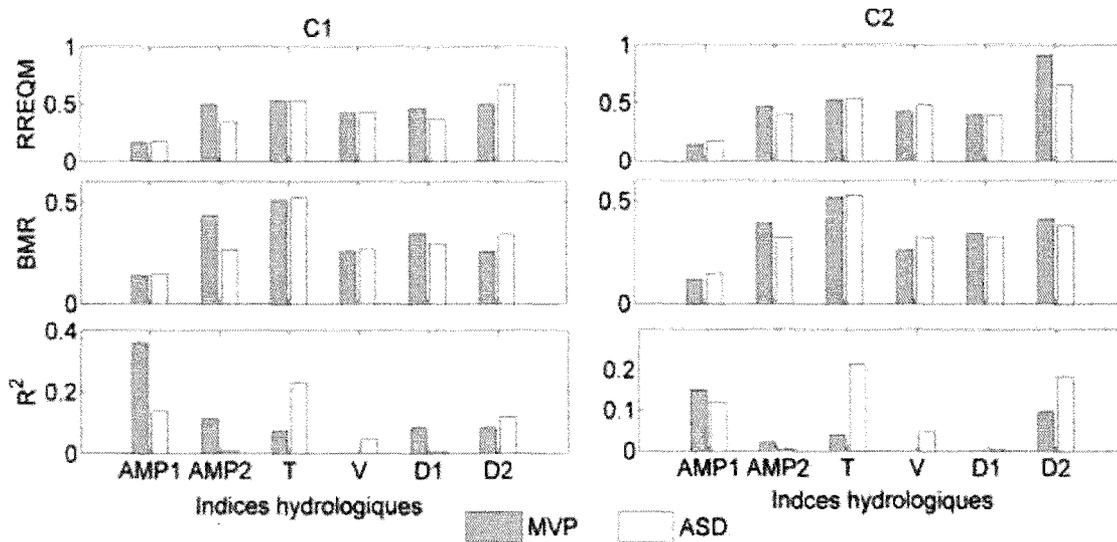


Figure 1.16 Indices de performance des IH de l'approche indirecte pour la rivière Romaine pour les deux combinaisons des ensembles de calibration et de validation.

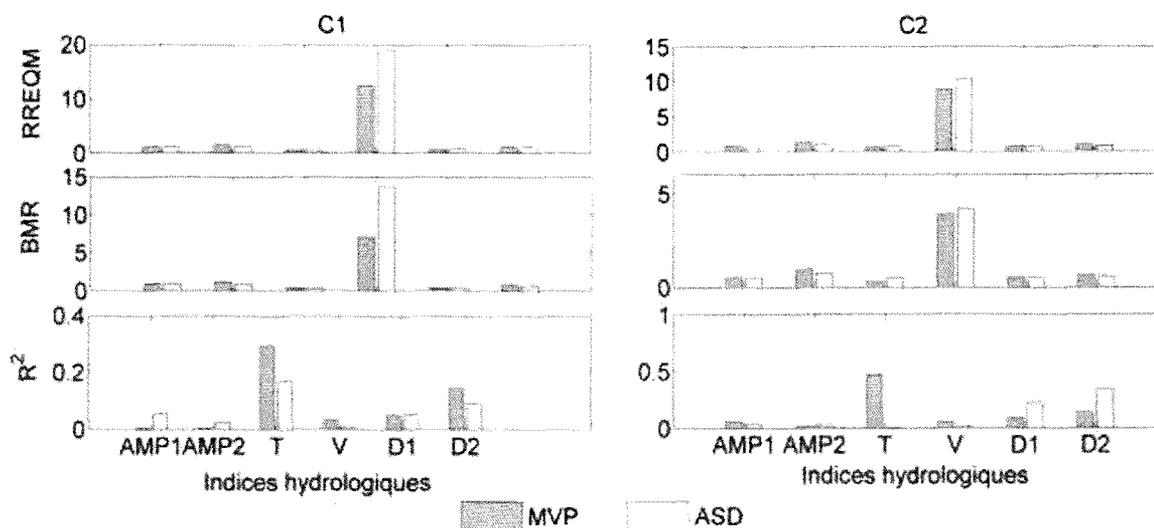


Figure 1.17 Indices de performance des IH de l'approche indirecte pour rivière Ouelle pour les deux combinaisons des ensembles de calibration et de validation.

6.3 Comparaison de l'approche directe, de l'approche indirecte et de la validation partielle

La comparaison de l'approche directe, de l'approche indirecte et de la validation partielle est abordée au chapitre 4. Les résultats en découlant sont illustrés aux figures 1.18 à 1.19. En observant les résultats obtenus, il apparaît clairement que l'AD1 surpasse toutes les autres approches. Par exemple, pour l'indice T à la rivière Romaine (C1), les valeurs de la RREQM obtenues à partir des approches AD1, AD2, AVP, AI1 et AI2 sont respectivement de 0,07, 0,14, 0,47, 0,53 et 0,53. Les valeurs du BMR sont de 0,06, 0,12, 0,45, 0,51 et 0,52 et les valeurs de R^2 respectivement de 0,80, 0,30, 0,23, 0,07 et 0,23. Pour ce même indice, la MVP utilise un nombre données de calibration correspondant à 4 à 6% du nombre de points échantillons de l'ensemble de calibration pour produire ses prévisions.

Tel que mentionné dans les paragraphes précédents, il est difficile de départager clairement les performances des approches AI1 et AI2. Pour l'indice T des rivières Romaine et Ouelle, les deux méthodes ont présenté une performance équivalente pour les deux combinaisons. Pour ce même indice à la rivière Moisie, l'AI2 a surpassé l'AI1 dans les deux combinaisons. De même, il n'est pas possible de conclure que l'AVP est systématiquement supérieure à la AI. Par exemple, pour ce qui est de l'AMP2 de la rivière Ouelle, l'AVP a surpassé les deux approches indirectes avec la combinaison C2 alors que le contraire se produit avec la combinaison C1.

Malgré le fait que l'AVP emploie des valeurs observées de précipitations et de température, cette approche a été surpassée par l'approche indirecte dans bien des cas. Par exemple, à la rivière Romaine, il y a une différence marquée entre le rendement de l'AVP et de l'approche indirecte pour ce qui est de l'indice V.

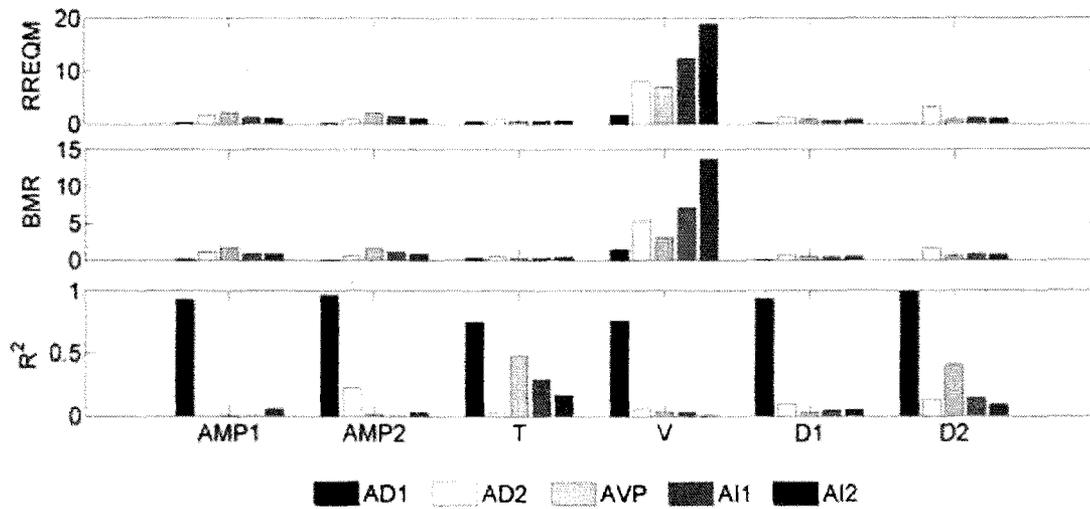


Figure 1.18 Comparaison des indices de performance des IH pour la combinaison C1 appliquée à la rivière Ouelle. Les approches comparées sont les suivantes : réduction directe à l'aide de la MVP (AD1) et du ASD (AD2); réduction indirecte à l'aide du modèle hydrologique SSARR et des valeurs observées (AVP) et mises à l'échelle des précipitations et de la température à titre d'entrées selon deux méthodes, soit la MVP (AI1) et le ASD (AI2).

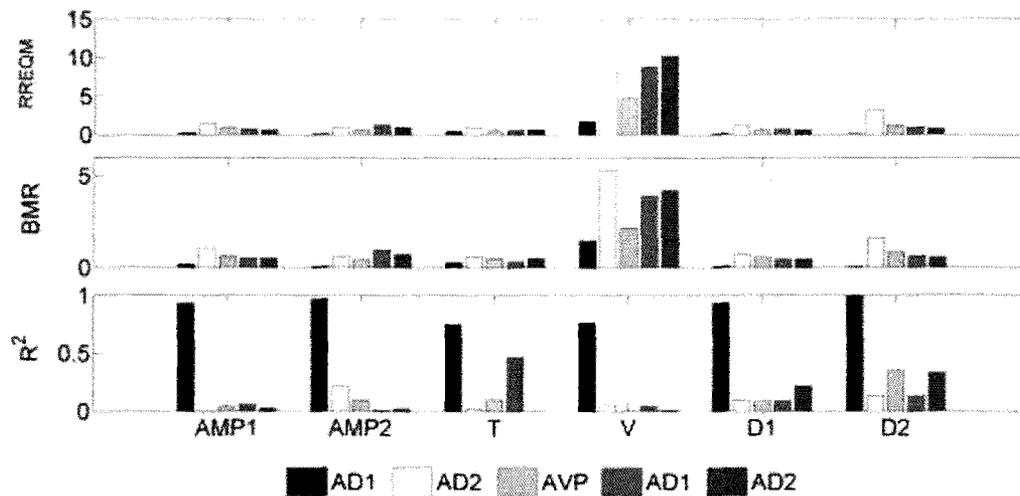


Figure 1.19 Comparaison des indices de performance des IH pour la combinaison C2 appliquée à la rivière Ouelle. Les approches comparées sont les suivantes : réduction directe à l'aide de la MVP (AD1) et du ASD (AD2); réduction indirecte à l'aide du modèle hydrologique SSARR et des valeurs observées (AVP) et mises à l'échelle des précipitations et de la température à titre d'entrées selon deux méthodes, soit la MVP (AI1) et le ASD (AI2).

6.4 Projections

L'approche AD1 étant celle qui a présenté la meilleure performance, c'est cette approche qui a été utilisée pour produire les futures projections des indices de débit d'étiage. Pour des fins de validation, les IH de débit d'étiage ont été calculés pour la période de référence de 1961 à 2010 à partir des sorties du MCG et du MCR. Les fonctions de distributions cumulées (FDC) des IH obtenus à partir des données du NCEP, les sorties du MCG et du MCR ainsi que les données observées sont comparées aux figures 1.20 à 1.22. Bien que la FDC obtenue à partir du MCG semble bien correspondre aux observations, il s'avère que les valeurs les plus faibles et les plus élevées sont considérablement biaisées. Ce biais peut être attribuable au fait que souvent, les modèles de mise à l'échelle statistique ne parviennent pas à reproduire la variance des variables modélisées.

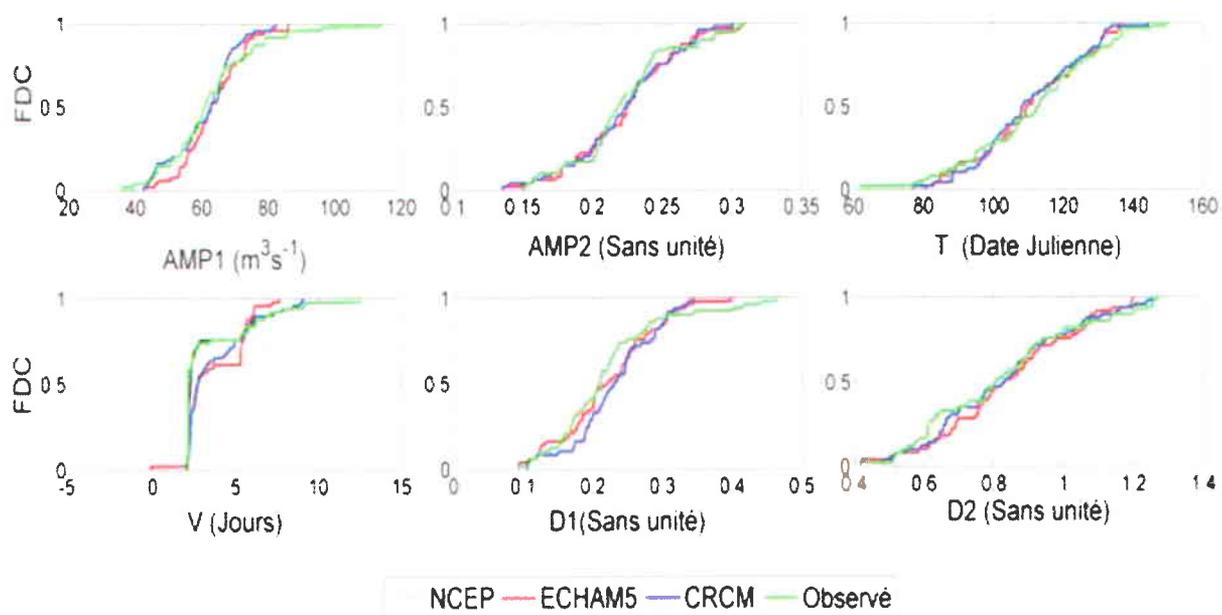


Figure 1.20 Comparaison des IH observés et simulés à partir des sorties du MCG et du MCR, ainsi que des données du NCEP pour la période de référence, soit de 1961 à 2010, à la rivière Romaine.

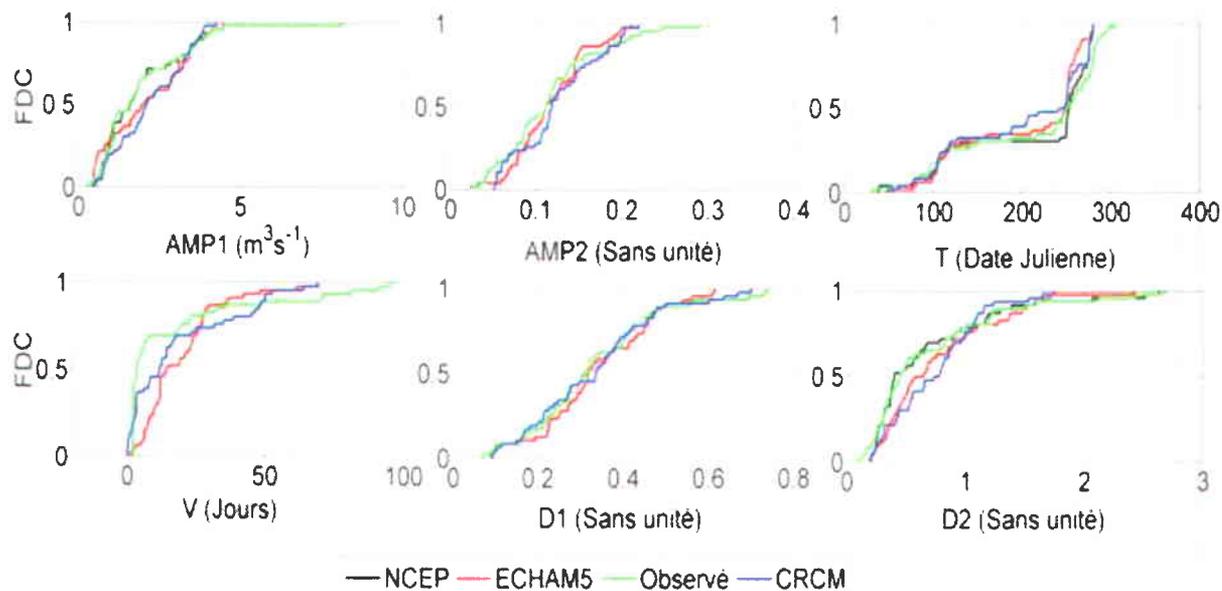


Figure 1.21 Comparaison des IH observés et simulés à partir des sorties du MCG et du MCR, ainsi que des données du NCEP pour la période de référence, soit de 1961 à 2010, à la rivière Ouelle.

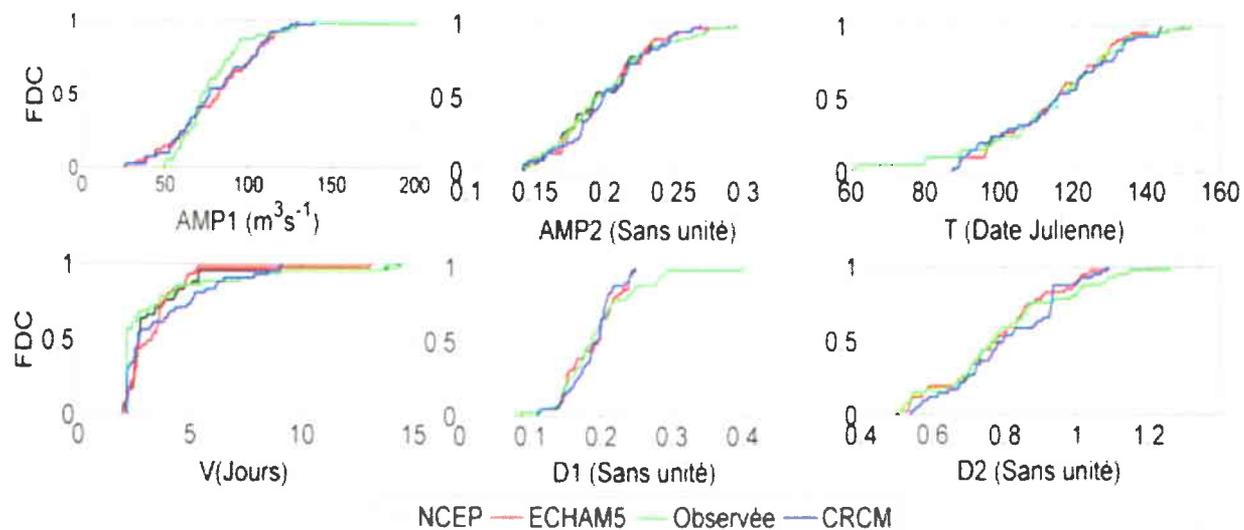


Figure 1.22 Comparaison des IH observés et simulés à partir des sorties du MCG et du MCR, ainsi que des données du NCEP pour la période de référence, soit de 1961 à 2010, à la rivière Moisie.

Les diagrammes de hamac illustrant les projections des IH de débit d'étiage de la rivière Romaine (obtenus à partir du modèle ECHAM5 et du MRCC) sont présentés aux figures 1.23 et 1.24. L'approche AD2 montrant une performance raisonnable dans la mise à l'échelle des indices de la rivière Romaine, elle a été utilisée pour produire des projections à partir des sorties d'ECHAM5 soumis aux scénarios A1B, A2 et B1 (figure 1.25). Les résultats obtenus pour les autres rivières se trouvent au chapitre 4. Aucun changement de position marqué n'est observé dans les diagrammes de hamac. Toutefois, des changements non négligeables dans la médiane et la variabilité des indices peuvent être remarqués. Par exemple, pour la rivière Moisie (voir les graphiques au chapitre 4), tous les scénarios ont prévu une chute de la médiane et de la variabilité de l'indice T et ce, pour toutes les périodes futures. Bien que ces projections soient informatives dans une certaine mesure, elles ne permettent pas de dresser un portrait clair des futurs scénarios liés au débit d'étiage.

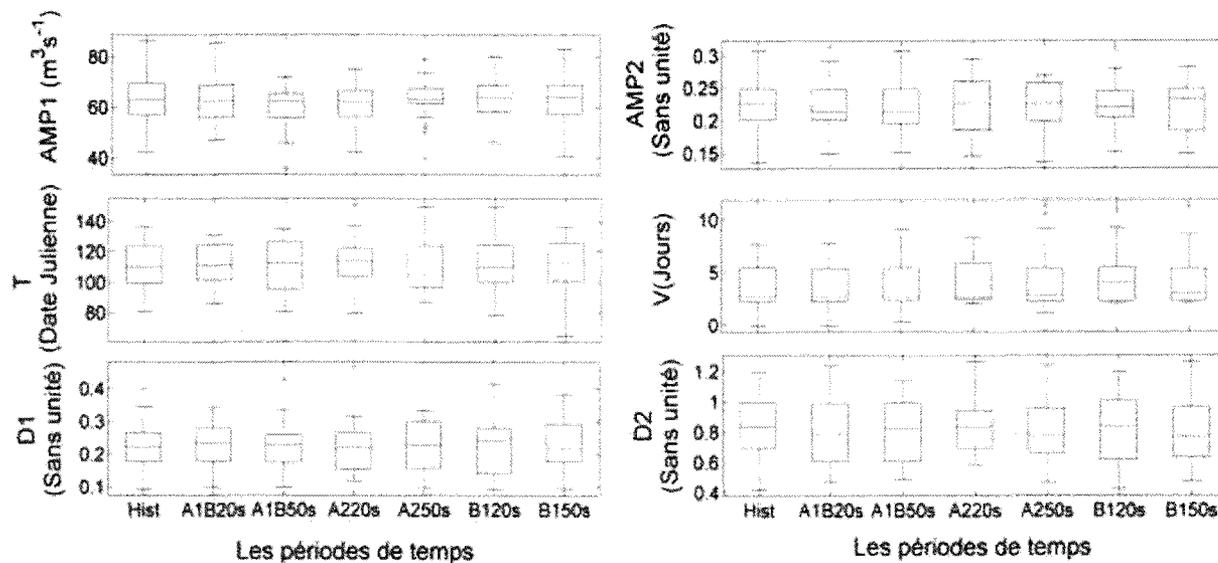


Figure 1.23 Diagramme en hamac des IH de débit d'étiage prévus à la rivière Romaine, tels qu'obtenus à partir du modèle ECHAM5 soumis aux scénarios A1B, A2 et B1 pour les années 2020 (2021 à 2050) et 2050 (2051 à 2070). Hist réfère à la période 1960-2010.

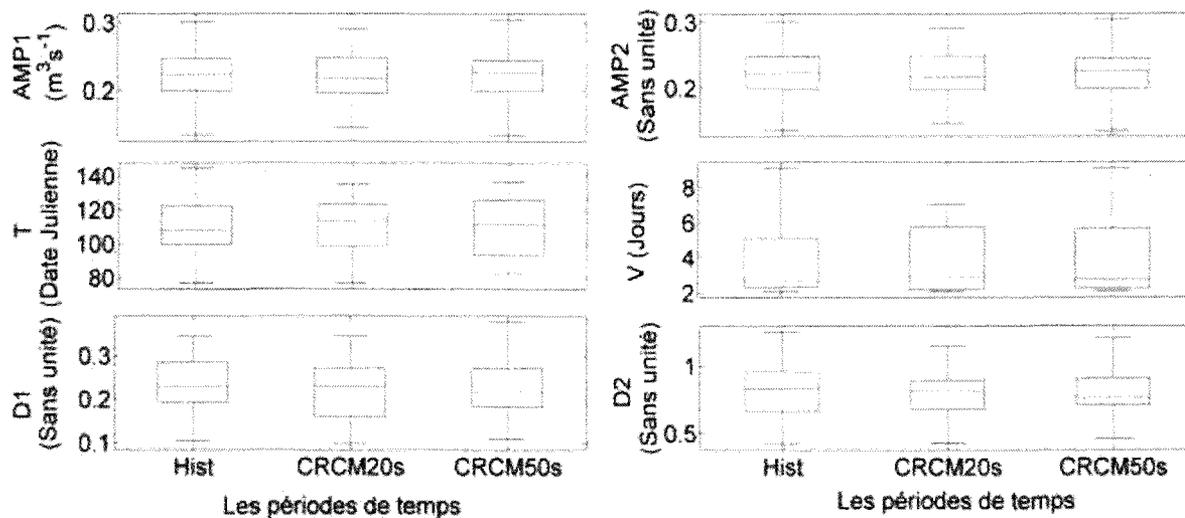


Figure 1.24 Diagramme en hamac des IH de débit d'étiage prévus à la rivière Romaine tels qu'obtenus du MRCC soumis aux scénarios A1B, A2 et B1 pour les années 2020 (2021 à 2050) et 2050 (2051 à 2070). Hist réfère à la période 1960-2010.

Copie originale très pâle

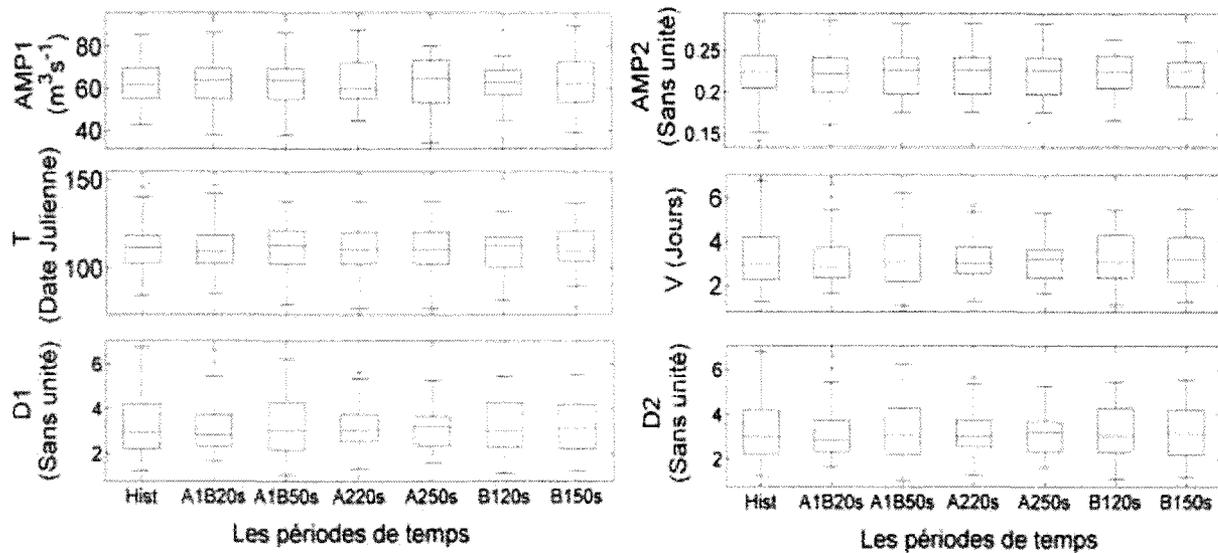
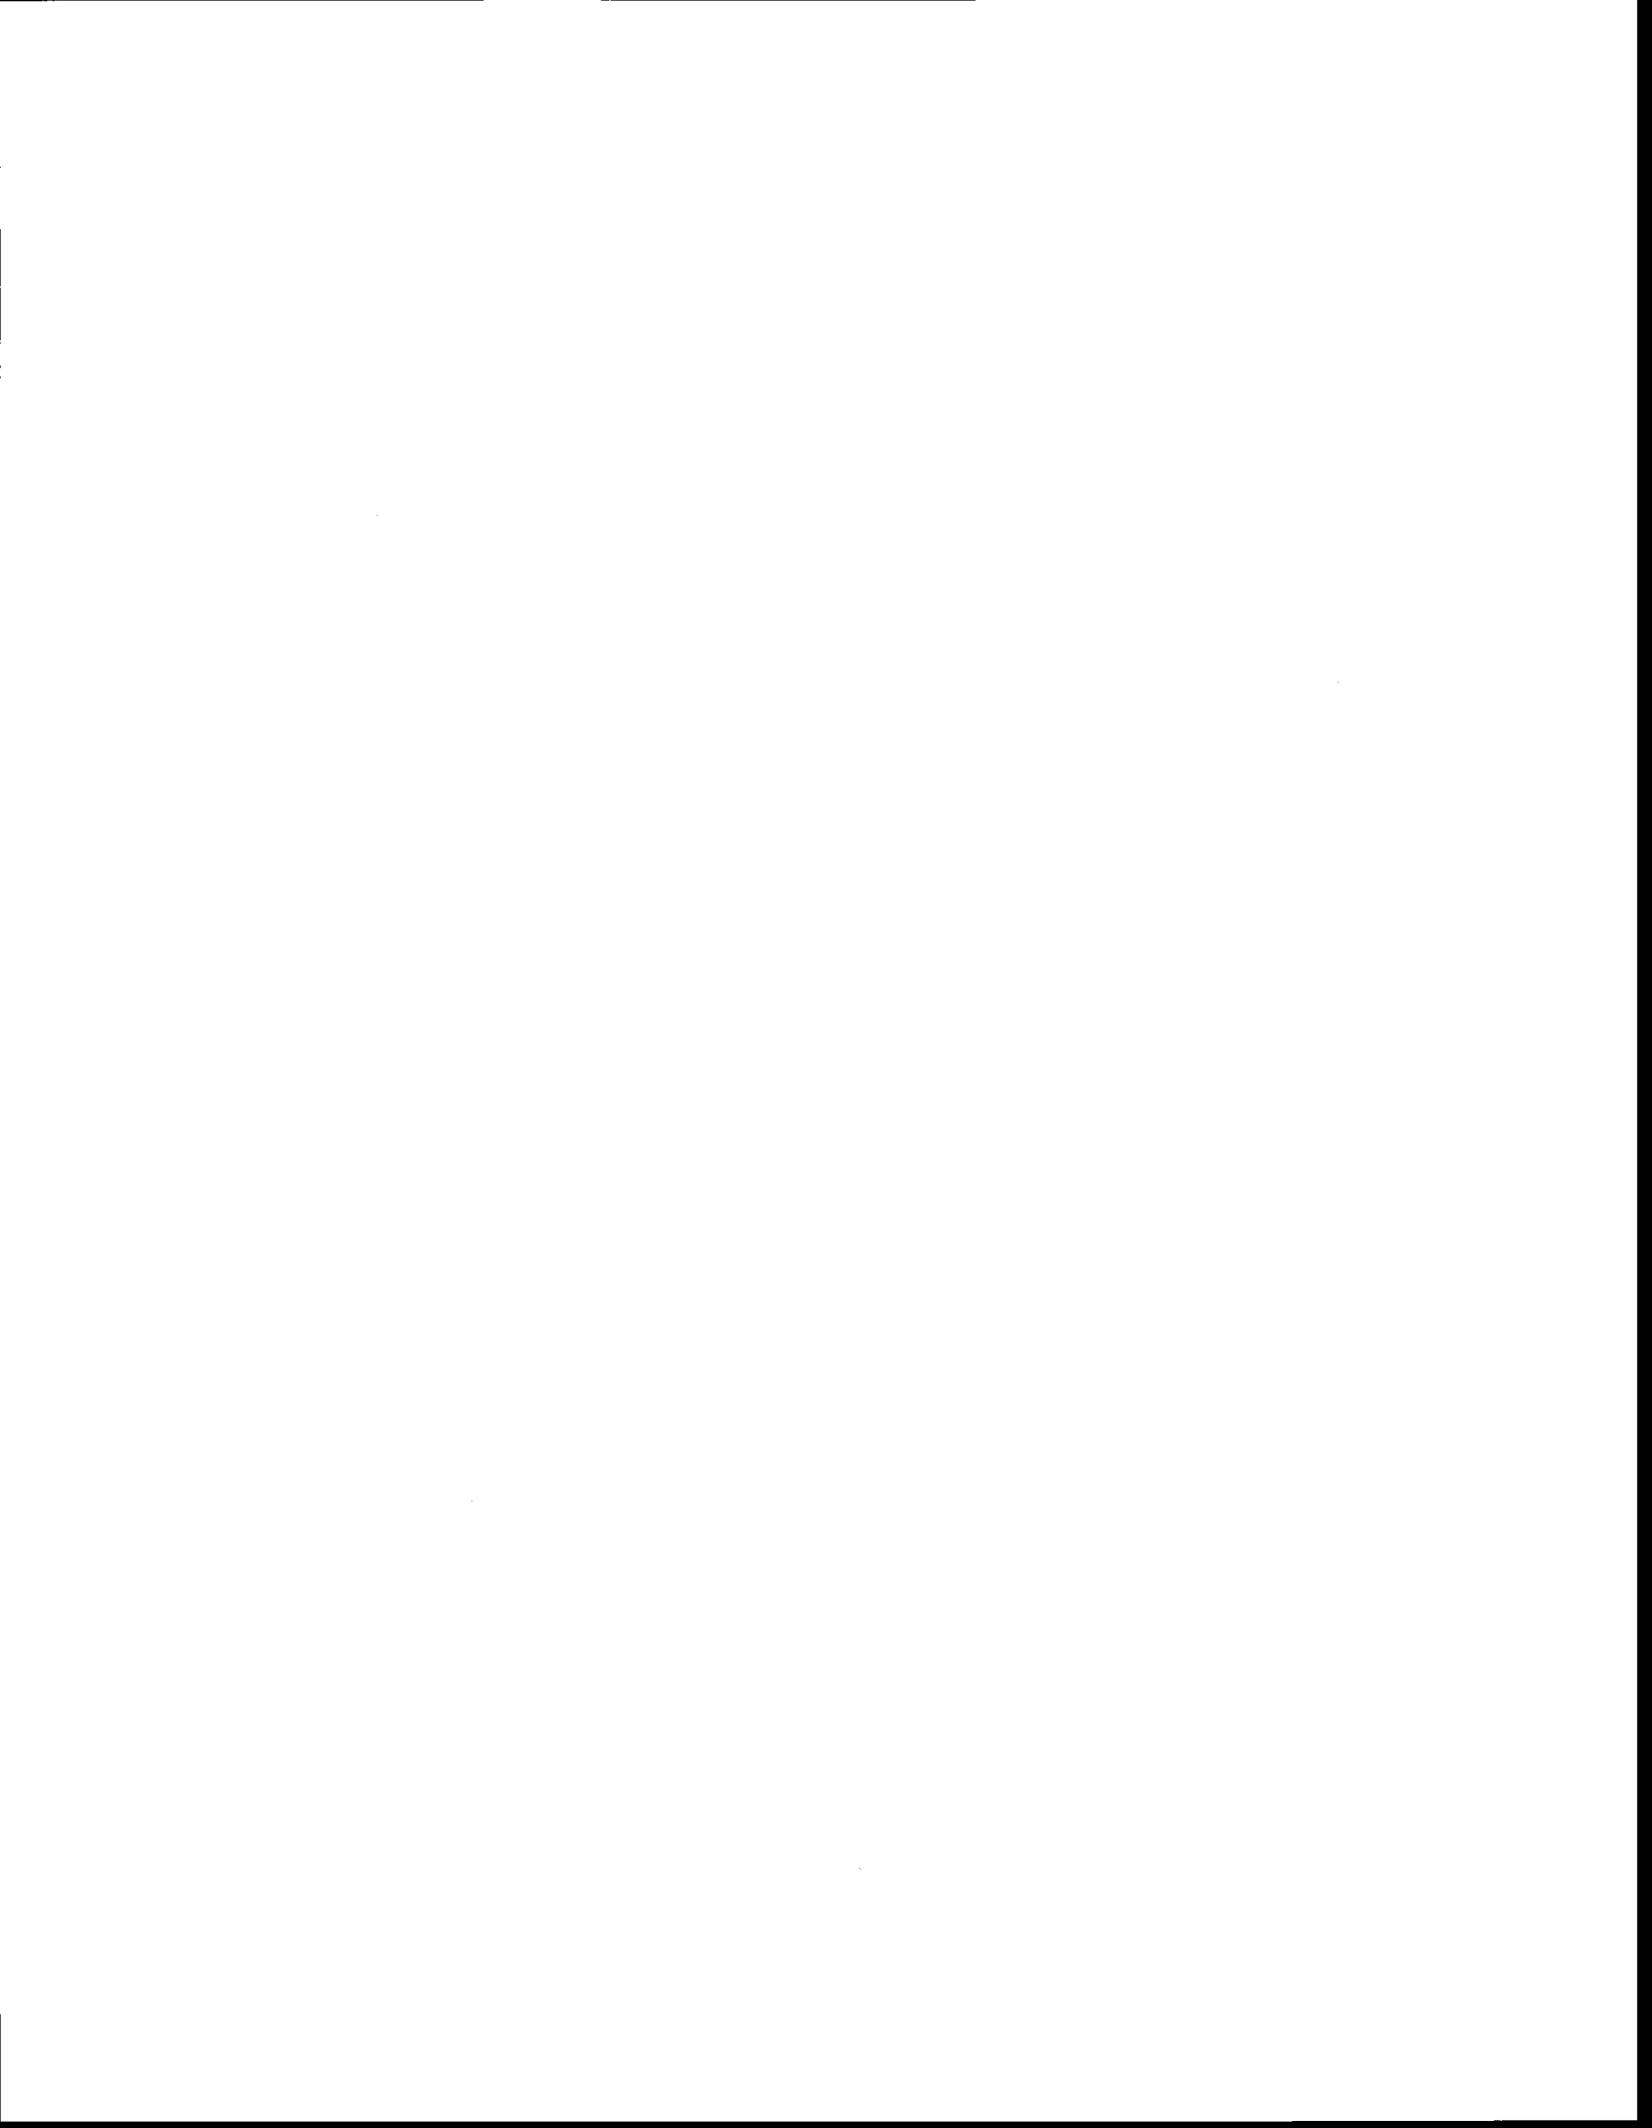


Figure 1.25 Diagramme en hamac des IH de débit d'étiage prévus à la rivière Romaine tels qu'obtenus pour DD2 du ECHAM5 soumis aux scénarios A1B, A2 et B1 pour les années 2020 (2021 à 2050) et 2050 (2051 à 2070). Hist réfère à la période 1960-2010



7 DISCUSSION

La comparaison des résultats des approches directe, indirecte et de validation partielle présentée dans la section précédente indique clairement que parmi toutes les méthodes évaluées, l'AD1 (approche directe avec MVP) se démarque des autres et constitue la meilleure approche de mise à l'échelle. Cependant, cela ne vaut pas pour les approches directes de mise à l'échelle en général. En effet, l'indice V à la rivière Moisie illustre bien cette affirmation, car tant pour les ensembles d'étalonnage que de validation, les résultats obtenus ont révélé que les deux approches indirectes ainsi que l'AVP surpassent l'AD2. L'indice D1 à la rivière Moisie, pour les deux combinaisons d'ensemble d'étalonnage et de validation, et l'indice V à la rivière Ouelle pour la combinaison C2, constituent d'autres exemples.

Quant aux approches indirectes, elles sont affectées par les incertitudes liées à la mise à l'échelle des variables climatiques locales ainsi qu'à la simulation des débits à l'aide du modèle SSARR. Les erreurs engendrées sont propagées à travers chaque étape de la méthode et cela affecte la simulation des indices hydrologiques de débit d'étiage calculés à partir des débits simulés par le SSARR. Les deux approches indirectes présentent un rendement équivalent quant à la mise à l'échelle des variables de précipitations et de températures, avec un rendement supérieur pour ces dernières. Pour les précipitations, les valeurs de coefficient de détermination (R^2) sont comprises entre de 0,3 et 0,7, ce qui est appréciable considérant la difficulté à modéliser cette variable. Pour la même variable, la programmation génétique est apparue comme une meilleure méthode de sélection que la régression pas à pas descendante et l'analyse de corrélation canonique. Pour la classification comme pour la régression, la MVPPG (PG combinée à la MVP) a mieux performé que les autres approches envisagées. Ces améliorations sont probablement dues au fait que la régression pas à pas descendante et l'analyse de corrélation canonique s'appuient toutes deux sur des relations linéaires entre les prédicteurs et les prédicteurs, et donc ne tiennent pas compte de prédicteurs qui pourraient avoir une faible corrélation linéaire mais une forte corrélation non-linéaire avec les prédicteurs.

La modélisation des débits d'étiage à l'aide de modèles hydrologiques déterministes est fortement influencée par la plus ou moins bonne représentation des processus qui régissent les débits d'étiage sont introduits dans la structure du modèle utilisé. Par exemple, la rivière Ouelle connaît des débits d'étiage marqués en été en raison d'une forte évapotranspiration et de

faibles précipitations doublées d'un apport d'eau souterraine moins soutenu en été. Quant aux rivières Moisie et Romaine, les débits d'étiage hivernaux sont attribuables aux périodes de froid prolongées. Ces processus ont lieu sur une vaste gamme d'échelles spatiales et temporelles et la capacité des modèles hydrologiques à cet égard est variable (Davison et Kamp, 2008). Le modèle SSARR représente les processus du débit d'étiage à l'aide de valeurs constantes (p. ex: taux de fonte pendant une période de pluie) ou mensuelles (p. ex. : intensité des chutes de pluie par rapport à l'indice du taux d'efficacité de l'évapotranspiration (ITEÉ), ITEÉ mensuel, taux de fonte effectif mensuel), ce qui pourrait restreindre sa capacité à expliquer la variabilité des débits d'étiage. De plus, les valeurs limites initiales des paramètres du modèle ainsi que leur optimisation grâce à l'algorithme ont également une incidence sur les résultats issus de la modélisation. Le choix des valeurs limites initiales des paramètres du modèle repose sur la connaissance des propriétés des bassins hydrographiques et sur l'expérience du modélisateur. Le rendement de la routine d'optimisation dépend des réglages initiaux des paramètres, du nombre d'itérations dans l'exploration de l'espace des paramètres ainsi que de la mesure de performance (coefficients NASH, LOGNASH, R^2 et MODNASH) qui a été optimisée.

Dans certains cas, comme pour les indices V et AMP2 de la rivière Moisie, il apparaît que les deux approches indirectes de mise à l'échelle ont surpassé l'AVP. Les valeurs observées de température et de précipitations utilisées pour l'AVP sont en fait des moyennes au bassin des mesures acquises aux stations météo. De leur côté, les valeurs mises à l'échelle sont obtenues à partir de la moyenne pondérée des valeurs des quatre points dans la grille du NCEP les plus rapprochés des stations météo. Ainsi, il se pourrait que comparativement aux valeurs observées, les valeurs mises à l'échelle des variables climatiques se rapprochent davantage de la véritable moyenne au bassin, ce qui expliquerait que les approches indirectes présentent un meilleur rendement.

Les indices de rendement employés pour quantifier les résultats de la mise à l'échelle sont la RREQM, le BMR et le R^2 . Dans bien des cas, on remarque que diverses conclusions émergent quant au rendement des différentes approches, selon qu'elles reposent sur le R^2 , sur la RREQM ou le BMR. La racine de l'erreur quadratique moyenne (REQM) est la racine carrée de la somme de la variance et du biais au carré. Statistiquement, les procédures qui cherchent à minimiser le biais peuvent faire augmenter la variance. Conséquemment, deux modèles peuvent avoir le même REQM mais un biais différent. L'utilisation du REQM comme unique mesure de performance peut cacher une partie de l'information. C'est pour cette raison qu'une

mesure de biais tel que la Biais Moyen Absolu (BMA) est utile pour comparer la performance des modèles. Le désavantage lié à l'utilisation du coefficient de détermination (R^2), si l'on ne tient compte que de lui, réside dans le fait qu'il ne permet que de quantifier la dispersion. Par conséquent, un modèle qui surestime ou qui sous-estime systématiquement les prévisions peut tout de même arriver à des valeurs de R^2 intéressantes. La variabilité de l'indice V à la rivière Ouelle constitue un bon exemple. Dans ce cas, il apparaît que l'AD1 a donné lieu à des valeurs supérieures de la RREQM et du BMR (> 1 dans les deux cas), mais à des valeurs raisonnables du coefficient de détermination R^2 , soit 0,77.



8 CONCLUSION

L'objectif du présent projet était de comparer la capacité des approches directes, indirectes et de validation partielle dans la mise à l'échelle des indices hydrologiques du régime d'étiage de rivières de l'est du Canada. Pour les approches directes, la méthode stochastique d'apprentissage bayésien et la régression linéaire multiple ont été utilisées pour modéliser les IH à partir de variables atmosphériques. Ces deux méthodes statistiques ont aussi été utilisées pour la mise à l'échelle des valeurs de précipitations et de température utilisées pour l'approche indirecte. Des projections des IH ont été obtenues à partir de trois scénarios d'émission (A1B, A2 et B1) soumis au modèle ECHAM5 (MCG) et d'un scénario (A2) soumis au MRCC (MCR). Voici les conclusions qu'il a été possible de tirer à la suite du projet:

1. L'AD1 (AD basée sur l'apprentissage bayésien) a surpassé les autres approches. Son meilleur rendement a trait aux valeurs des critères de performance, à la différence entre les résultats d'étalonnage et de validation (capacité de généralisation) ainsi qu'à l'utilisation d'un plus petit nombre de paramètres pour établir ses prévisions (parcimonie).
2. Le rendement de l'approche directe est fortement influencé par les modèles statistiques utilisés. En effet, la régression linéaire directe (AD2) s'est, dans certains cas révélée moins performante que les approches indirectes.
3. Les approches indirectes présentent des résultats mitigés. Ces approches sont affectées par les incertitudes liées aux variables climatiques locales mises à l'échelle ainsi qu'à la simulation des débits par le modèle hydrologique.
4. Pour la mise à l'échelle de la température avec l'approche indirecte, MVP a mieux performé qu'ASD à toutes les stations. La mise à l'échelle de la température a donné de meilleurs résultats que celle de la précipitation. À toutes les stations, des améliorations pour la mise à l'échelle des précipitations (occurrence et quantité) ont été observées quand le PG est utilisé pour la sélection des prédicteurs, conjointement avec MVP (MVPPG). RLMPG n'a pas mieux performé que ASD, dans plusieurs des cas. MVP et ASD ont eu des résultats comparables pour la mise à l'échelle des précipitations. Ceci peut indiquer que des relations non-linéaires telles que celles établies par la programmation génétique sont mieux adaptées à la sélection de prédicteurs que les méthodes linéaires.

5. Pour certains indices, il apparaît que les approches de validation partielle ont été surpassées par les deux approches indirectes. Cela pourrait être attribuable à la nature localisée du modèle hydrologique SSARR. Ce modèle utilise la moyenne au bassin des valeurs de précipitations et de température observées. Ainsi, il pourrait arriver que la moyenne des valeurs observées de ces variables ne représente pas le bassin hydrographique aussi bien que les valeurs mises à l'échelle correspondantes.
6. Les projections des IH de débit d'étiage obtenues à partir du modèle ECHAM5 et du MRCC révèlent des changements quant à la moyenne et la variabilité des indices des tranches de temps futures de 2021 à 2050 et de 2051 à 2080. Toutefois, il est impossible de tirer des conclusions définitives quant à ces projections, car les scénarios ne sont issus que d'un MCG et d'un MCR.

9 RECOMMANDATIONS

Voici quelques recommandations d'avenues à explorer suite au travail présenté dans cette thèse:

1. La sélection et la mise à l'échelle d'autres indices d'étiage, en particulier ceux présentant une autocorrélation temporelle.
2. En plus des méthodes directes et indirectes présentées, une troisième consisterait en la mise à l'échelle directe des débits, suivie par le calcul des indices d'étiage à partir du débit mis à l'échelle.
3. La comparaison des performances de MVP utilisant différentes fonctions de noyau (linéaires, polynomiales, Laplace, etc) et l'analyse des projections futures correspondantes.
4. La validation croisée (Stone, 1974) fournit une méthode simple et efficace à la fois pour la sélection de modèle et de l'évaluation de la performance et est largement utilisée par la communauté. Dans une étude réalisée par Shabbar et Kharin (2007), il a été suggéré que l'utilisation de techniques de validation croisée pour évaluer la performance de l'ACC en prévisions saisonnières opérationnelles peut surestimer la véritable performance. Une façon d'éviter cette surestimation est de laisser une zone tampon autour de l'année de prédiction (Zeng et al., 2012). Cette méthode, appelée « double validation croisée », pourrait être testée dans des études futures.
5. La distribution des valeurs des prédicteurs dans un climat futur à gaz à effet de serre accru est généralement décalée par rapport à la distribution actuelle. L'application d'un modèle de mise à l'échelle statistique calibré en tenant compte du climat actuel pour faire des prédictions implique donc généralement d'extrapoler des relations empiriques. Or, des modèles empiriques non linéaires peuvent se comporter de façons très différentes en mode d'extrapolation (Hsieh, 2009). Dans la présente étude, le choix d'un noyau autre que gaussien conduirait à un comportement d'extrapolation différent. C'est l'une des limites de la présente étude, qui pourrait être explorée en utilisant des fonctions de noyau différentes.
6. L'une des hypothèses fondamentales de la réduction d'échelle statistique est que les relations empiriques développées entre les prédicteurs et les paramètres prévus pour le climat actuel devraient demeurer dans le futur. Comme ces modèles statistiques sont calibrés en fonction des variables de réanalyse du NCEP et que les projections futures

sont obtenues à partir des sorties d'un MCG, il aurait été instructif d'évaluer la fidélité des modèles dans leur simulation des prédicteurs NCEP. Cela n'a pas été fait dans les travaux en cours; en effet, l'objectif ici était d'obtenir un pourcentage de changement dans les indices d'été pour les deux périodes futures considérées et non pas d'en arriver à des valeurs futures absolues. Certaines études se sont penchées sur les écarts systématiques existants entre les sorties GCM / MRC et les variables NCEP. Par exemple, Jeong et al. (2012) ont trouvé des différences importantes entre les caractéristiques statistiques des sorties du modèle MCG3 et des valeurs de réanalyses de NCEP, notamment pour ce qui est des valeurs de la vorticité à 1000 hpa, 850 et 500 hpa, de la composante U de la vitesse à 1000 hPa, de la température de l'air à 2 m et de la direction du vent à 1000 et 500 hPa de niveau. On recommande donc, comme avenue à explorer, de procéder à une correction des sorties du modèle ECHAM5/CRCM pour la projection des indices d'été.

7. Une manière d'estimer l'adéquation des résultats des occurrences de précipitations simulées est le score de *Brier* (Stefanove et al, 2002; Krishnamurti et al 2012). En particulier, l'utilisation de ce critère de performance dans le cas de l'application des méthodes probabilistes telles que les algorithmes génériques et le RVM pourrait indiquer la supériorité de ces méthodes par rapport aux autres testées, en comparant les scores de Brier aux MAE obtenus par les autres méthodes non-probabilistes. Il est donc recommandé pour les travaux futurs.

PARTIE 2: ARTICLES



CHAPITRE 2

DATABSED COMPARISON OF SPARSE BAYESIAN LEARNING AND MULTIPLE LINEAR REGRESSION FOR STATISTICAL DOWNSCALING OF LOW FLOW INDICES

Deepti Joshi¹, André St-Hilaire¹, Anik Daigle^{1,3}, Taha B.M.J. Ouarda^{1,2}

¹ INRS-ETE, University of Quebec, 490 de la Couronne, Quebec G1K 9A9, Canada
(joshi.deepti@ete.inrs.ca, andre.st-hilaire@ete.inrs.ca, anik.daigle@ete.inrs.ca)

² Masdar Institute of Science and Technology, PO Box 54224, Abu Dhabi, United Arab Emirates (touarda@masdar.ac.ae, taha.ouarda@ete.inrs.ca)

³ Cégep Garneau, 1600 boulevard de l'Entente, Québec, G1S 4S3, Canada

Corresponding Author: Deepti Joshi

Article publié dans *Journal of Hydrology* (2012) 488:136-149

The work done in this article is the result of the combined efforts of its authors. The implementation of the mathematical algorithms in MATLAB was performed mostly by Deepti Joshi with significant contribution from Anik Daigle. With the help of all the co-authors, the preparation of relevant databases, evaluation of the results and drafting of the initial version of the manuscript were done by Deepti Joshi. All the co-authors advised in the development of methodology of the work, analysis of the results and in drafting the article



ABSTRACT

This study attempts to compare the performance of two statistical downscaling frameworks in downscaling hydrological indices (descriptive statistics) characterizing the low flow regimes of three rivers in Eastern Canada- Moisie, Romaine and Ouelle. The statistical models selected are Relevance Vector Machine (RVM), an implementation of sparse Bayesian Learning, and the Automated Statistical Downscaling tool (ASD), an implementation of Multiple Linear Regression. Inputs to both frameworks involve climate variables significantly ($\alpha=0.05$) correlated with the indices. These variables were processed using Canonical Correlation Analysis and the resulting canonical variates scores were used as input to RVM to estimate the selected low flow indices. In ASD, the significantly correlated climate variables were subjected to backward stepwise predictor selection and the selected predictors were subsequently used to estimate the selected low flow indices using multiple linear regression. With respect to the correlation between climate variables and the selected low flow indices, it was observed that all indices are influenced, primarily, by wind components (Vertical, Zonal and Meridonal) and humidity variables (Specific and Relative Humidity). The downscaling performance of the framework involving RVM was found to be better than ASD in terms of Relative Root Mean Square Error, Relative Mean Absolute Bias and Coefficient of Determination. In all cases, the former resulted in less variability of the performance indices between calibration and validation sets, implying better generalization ability than for the latter.

Keywords: Downscaling, Low flows, Canonical correlation analysis, Sparse bayesian learning, Multiple linear regression

1 INTRODUCTION

Canada exhibits a considerable diversity in land use and climate which results in differences in processes affecting low flows at different geographic locations. Information on low flows is required for several purposes such as industrial needs, agricultural demands, water pollution control requirements and environmental flows. In addition, low flows play a crucial role in riparian ecosystem and salmon migration due to their impact on the reduction of habitat quality and quantity (Frenette et al., 1984). In a comprehensive review on low flow hydrology Smakhtin (2001), indicated that climate change may have greater effects on low flows than high flows. In a recent study, Burn et al. (2008), found differences in low flow characteristics and their associated impacts between six regions across Canada. In Quebec, the timing of low flows was found to transit from a unimodal distribution of late winter flows in the northern portion of the province, to a bimodal distribution (both late winter and late summer flows) in the central parts of the province, to a unimodal distribution of late summer flows in the southern portion of the province. During winters, low flows occur as a result of storage depletion following freezing temperatures, whereas, occurrence of summer low flows is attributed to low precipitation and increased evaporation due to higher temperatures.

A number of hydrological indices (HIs) characterizing different aspects of the low flow regime of a river, have been proposed. These indices have been extensively used in water resource development and provide a convenient desktop method to assess flow thresholds (Arthington et al., 2006; Monk et al., 2006; Richter et al., 1998). The development of HIs depends on the nature of objectives in hand and applied methodology (Olden and Poff, 2003). The most commonly used hydrological indices include 7Q10, 7Q2, Q_{95} and Q_{90} flows (Riggs et al., 1980; Smakhtin, 2001; Tharme, 2003), where subscripts indicate percentiles and normal fonts indicate return periods. In Canada, the indices 7Q10, 7Q2 and 30Q5 are the most widely used characteristics for determining the waste load assimilative capacity and water supply management during droughts. In recent years, low flow indices have been used in ecological flow studies. The natural flow paradigm (Poff et al., 1997), is a framework to assess ecological flow needs that is based on the notion that in an altered hydrological regime, flows should be managed such that key characteristics of the natural hydrogram are reproduced. In this context, low flow indices are grouped in five categories: Amplitude, Frequency, Duration, Timing and Variability. Using indices from each category in the context of the study of climate change

impacts on low flows offers the advantage of providing key ecologically sensitive information without having to generate daily flow time series.

For a better understanding of potential future changes due to anthropogenic activities, several studies investigated the presence of trends in low flow indices (Adamowski and Bocci, 2001; Burn and Elnur, 2002; Ehsanzaeh and Adamowski, 2007; Yue et al, 2003; Yue and Pilon, 2003; Zhang et al., 2001). Keeping in view the adverse effects of climate change and the relevance of low flow information in water resources management, Smakhtin (2001), gave emphasis to the need to quantify the impacts of climate change on low flows. Typically, future climate change is modelled with several hypothetical scenarios generated by General Circulation Models (GCM). The inability of the GCMs to capture sub-grid scale features (such as topography and land-use), due to its coarse spatial resolution made it unsuitable for climate change impact studies. Therefore, the climate research community focussed on the development of 'downscaling techniques' to shorten the gap between large and local scale climate data. To date, impact studies of climate change on hydrology are investigated through a two step process. The first step involves using GCM outputs to generate local climate conditions such as precipitation and temperature, which is known as 'downscaling'. The downscaled local climate data are then introduced as input to a hydrological model to project the hydrological changes that may be brought about by future climate (Drogue et al., 2004; Flato et al., 2000; Loukas et al., 2002; Nash and Gleick, 1991; Roy et al., 2001; Simonovic and Li, 2003).

Downscaling methods (Wilby et al., 2004) are divided into two categories: dynamical and statistical (also known as empirical) approaches. Dynamical approaches involve running regional climate models (RCMs) with GCM outputs as boundary conditions to simulate processes at much finer scale in comparison to GCMs. However, RCMs are computationally expensive in addition to the possibility of being applied to limited periods and regions. The current work relies on Statistical Downscaling (SD) approaches. These approaches derive the relationships between broad scale variables (predictors), obtained from reanalysis data, and fine scale surface conditions (predictands). The variables that are strongly related with the predictand or response variable must be selected as predictors. Future projections from GCM or RCM are then used in these relationships to estimate the changes in the response variable. SD methods can be classified into three types: weather classification approach, weather generators and regression based methods.

Regression methods were among the earliest downscaling approaches (Kim et al., 1984; Wigley et al., 1990). These approaches generally involve establishing linear or nonlinear relationships between predictors and predictands. Several studies have shown that accounting for non-linearity in the relationships between the predictors and predictands can result in better downscaling ability. Examples of such methods include- Artificial Neural networks (Hewitson and Crane, 1996), kernel based neural networks such as Support Vector Machines (SVM) (Cortes and Vapnik, 1995; Cristianini and Taylor, 2000; Haykin, 2003; Sastry, 2003; Tripathi et al., 2006; Vapnik, 1995,1998).

The two-step modelling framework combining GCM outputs to a hydrological model is usually constrained by the gaps existing between GCMs ability and spatial resolution, and the need of hydrological modellers. According to Xu (1999), there are spatial, temporal and vertical scale mismatches between GCMs hydrological models. In addition to that there are mismatches between GCMs accuracy and the hydrological importance of the variables. For example, runoff, soil moisture and evaporation are not well represented by GCMs but are of extreme importance in hydrologic regimes. Apart from these gaps, the data requirement of these hydrological models, particularly fully distributed models, are large. Davison and Kamp (2008), in a brief review, analyzed six models developed and/or used in Canada, in terms of their ability to model low flow processes. The models varied in their ability to incorporate low flow processes such as drawdown of storage in lakes, stream channels and wetlands, riparian evapotranspiration, freeze-up and bank storage. One way to overcome the drawbacks associated with the two step approach could be to establish a direct link between broad scale climate variables and low flow indices. Such a direct link is criticised because of an over-simplification of the hydrological cycle and ignorance of the factors affecting streamflow variability such as land use . In a review on the impacts of large scale climate variability on low flows over Canada, Bonsal and Shabbar (2008) found that low streamflows for rivers in Eastern coastal regions of Quebec are positively correlated with Northern Annular Node and negatively correlated with El-Nino Southern Oscillation (ENSO) and Pacific North American pattern (PNA) before 1970s but positively correlated with PNA afterwards. Such a study implies a link between the variables characterising atmospheric processes and low flow indices.

To our knowledge, direct downscaling of low flow indices, linking low flow indices to large scale atmospheric predictors, has never been investigated before. Hence the objective of the current work is to test the ability of two downscaling frameworks, to downscale low flow HIs. The first framework involves an implementation of Sparse Bayesian Learning (SBL) which is a probabilistic Bayesian approach whereas the second involves an implementation of Multiple

Linear Regression (MLR). SBL is a recently developed approach and based on literature review, the numbers of applications of SBL for downscaling purposes, particularly in North America were found to be scarce. MLR, on the other hand, has been applied in many downscaling studies involving predictands such as precipitation, temperature (Hessami et al., 2008; Wilby et al., 2002) and runoff (Nieto and Wilby, 2005). The downscaling abilities of the two frameworks will be tested for the low flow HIs corresponding to three rivers in Eastern Canada-Romaine, Moisie and Ouelle. The following section describes the background and mathematical formulations behind the approaches.

2 STATISTICAL DOWNSCALING

A diverse range of statistical downscaling methods have been developed in recent past. Details of the general theory, limitations and practices of these methods have been discussed in detail elsewhere (Giorgi and Mearns, 1991; Wilby and Wigley, 1997; Xu, 1999). These sources group downscaling techniques into four main types: (1) dynamical climate modeling, (b) synoptic weather typing, (c) stochastic weather generation, or (d) regression based approaches. Regression-based downscaling methods are frequently used. These methods rely on empirical relationships between local-scale predictands and regional-scale predictor(s). Driven by the need to provide a decision support tool for the rapid development of single-site, ensemble scenarios of daily weather variables under current and future regional climate forcing, Wilby et al. (2002), developed a Windows based decision support tool known as Statistical Downscaling Model (SDSM).

2.1 Automated Statistical Downscaling Tool

Inspired by the SDSM approach, Hessami et al. (2008) developed an automatic statistical downscaling (ASD) tool. ASD is a regression based approach, capable of performing statistical downscaling automatically from predictor selection to model calibration, scenario generation and statistical analysis of scenarios. The automation is designed to replace SDSM's subjective method of predictor selection, requiring significant input on the part of the user, with a more objective approach. It allows two methods of predictor selection: backward stepwise selection (McCuen, 2003) and partial correlation coefficients (Afifi and Clark, 1996). In addition to MLR, it also allows the use of ridge regression (Hoerl and Kennard, 1970) which accounts for the collinearity of the predictors, which can make the least square estimates of the regression coefficients unstable. Full technical details, including model validation and usage, are described by Hessami et al. (2008).

2.2 Sparse Bayesian Learning

Several studies have shown that accounting for non linear relation between the predictors and predictand can improve the goodness of fit (Huth et al., 2008). For this reason, Artificial Neural Network (ANN) based downscaling techniques gained wide recognition (Crane and Hewitson,

1998; Wilby et al., 1998). The ability to generalize a relationship from given patterns makes it possible for ANNs to solve large-scale complex problems such as non-linear modeling and classification (ASCE Task Committee on Artificial Neural Networks in Hydrology, 2000b; Govindaraju and Rao, 2000). While accuracy in predictions is universally valued, a recent interest in the notion of sparsity diverted the focus of the research community on learning algorithms which use fewer parameters. One of the significant developments in this direction is Support Vector Machines (SVM), a machine learning algorithm. SVM (Cortes and Vapnik, 1995) have found wide application in the fields of pattern recognition and time series analysis. However, despite its success, SVM suffered from several drawbacks which were overcome in Sparse Bayesian Learning (SBL) algorithms. SBL (Faul and Tipping, 2002) enables exploiting a probabilistic Bayesian learning framework to derive accurate prediction models which utilise dramatically fewer basis functions than SVM for a comparable problem. A detailed description of the theoretical background of SBL and the mathematical formulations of the algorithm are shown in appendix 1.

2.2.1 Relevance Vector Machine

RVM (Tipping, 2001) makes predictions based on functions implemented by SVM. SVM makes predictions based on the function

$$t = f(\mathbf{x}; \mathbf{w}) = \sum_{i=1}^N w_i K(x, x_i) + w_0 \quad (2-1)$$

where $K(x, x_i)$ is a kernel function, effectively defining one basis function for each example in the training set. RVM is a Bayesian treatment of (2-1). The most compelling feature of RVM is that, while capable of generalisation performance, it supports sparsity by utilising fewer kernel functions (Chen et al., 2008).

3 STUDY AREA AND DATA RESOURCE

The study area comprises of three rivers in Eastern Canada- Romaine, Moisie and Ouelle. Moisie and Romaine are located on the North shore whereas Ouelle is located on the south shore of the St. Lawrence River. The current study focuses on these three rivers as they sustain Atlantic Salmon (*Salmo salar*) populations, which has been regarded as an endangered species (Committee on the Status of Endangered Wildlife in Canada, 2011).

The locations of discharge and meteorological stations on each of these rivers are shown in figure 2.1. Both Moisie and Romaine have one hydrometric station and have two meteorological stations located within the limits of their drainage basins. River Ouelle has one discharge and one meteorological station, with the former lying within and the latter lying outside the limits of its drainage basin. The details of the hydrometric stations are given in table 2.1. The source of flow and meteorological data for each of the three stations is the Environment Canada database (<http://www.climate.weatheroffice.gc.ca>). For the flow data, years with one-third of the data (>4 months) missing were excluded.

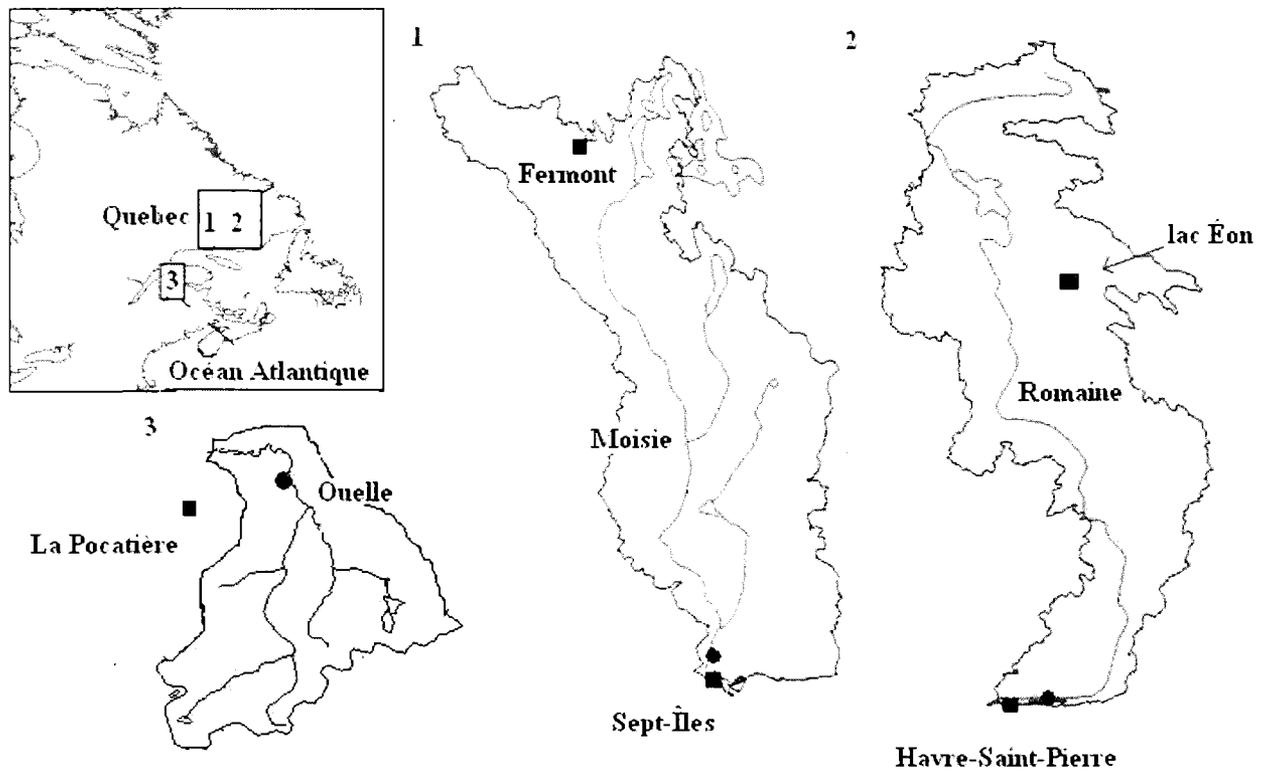


Figure 2.1 The study area map showing the locations of discharge and meteorological stations on each river. The squares and circles denote meteorological and discharge stations, respectively.

Table 2.1 Description of discharge stations.

Station	Latitude	Longitude	Catchment Area(Km ²)	Years	Years Excluded
Romaine	50°18'28" N	63°37'21" W	13000	1961-2010	2007
Moisie	50°21'1" N	66°11'25" W	19000	1966-2010	1967,1999,2000, 2007
Ouelle	47°22'52"N	69°57'29" W	795	1961-2010	1967,1981,1982,1996

The precipitation and temperature (daily average) normals of the meteorological stations are shown in figure 2.2. Due to limited data availability the normals for Lac Eon and Havre St-Pierre meteorological stations were calculated from 1964-1976 (13 years) and 1964-1984 (21 years), respectively. For the rest of the stations normals were calculated for 30 years (1971-2000). The meteorological stations at Sept-Iles and Havre St-Pierre are located near the discharge stations on Moisie and Romaine, respectively. Spatial differences in temperature are evident between stations corresponding to Moisie and Romaine in the North shore and Ouelle in the south shore. The maximum daily average temperature is observed at station La Pocatiere (18.0°C in July) on Ouelle, followed by Sept-Iles (15.5°C in July) on Moisie and Havre St-Pierre (14.1°C in August) on Romaine. The minimum daily average temperature is exhibited by Fermont (-23.0°C in January) on Moisie, Lac Eon (-18.2°C in February) on Romaine and La Pocatiere (-10.3°C) on Ouelle. In addition to that, potential evaporation (plots not shown) shows an increase from north to south (Burn et al., 2008). Highest annual precipitation is observed at station Sept-Iles (1156mm) and lowest at station Fermont (806.5mm).

The flow regime of each river is shown in figure 2.3. The daily mean specific flow is indicated by darker lines and the dotted lines represent daily mean flow plus and minus the daily standard deviation. Winter low flows are prominent for Romaine and Moisie. The minimum specific flow for Moisie ($\sim 4.5 \text{ Ls}^{-1}\text{Km}^{-2}$) is slightly lower than the same for Romaine ($\sim 5.39 \text{ Ls}^{-1}\text{Km}^{-2}$). The hydrogram corresponding to river Ouelle reveals the presence of two low flow seasons (late winter and late summer). In addition to that, daily flow variability is highest in the case of Ouelle.

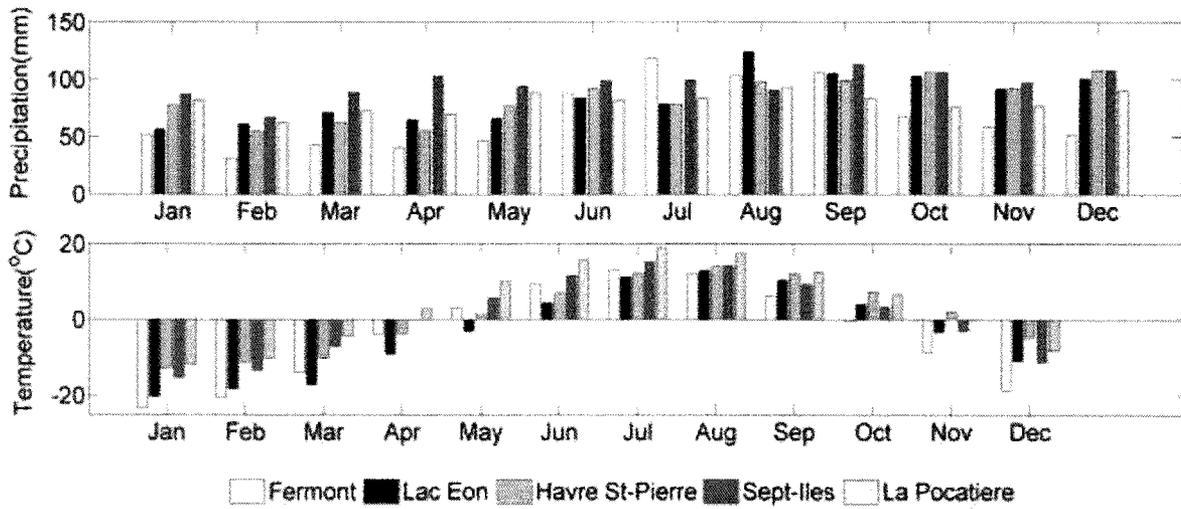


Figure 2.2 Precipitation and Temperature normals of the meteorological stations. For Lac Eon and Havre-St Pierre normals are calculated for 1964-1976 and 1964-1984 respectively. For the remaining stations normals correspond to 1971-2000.

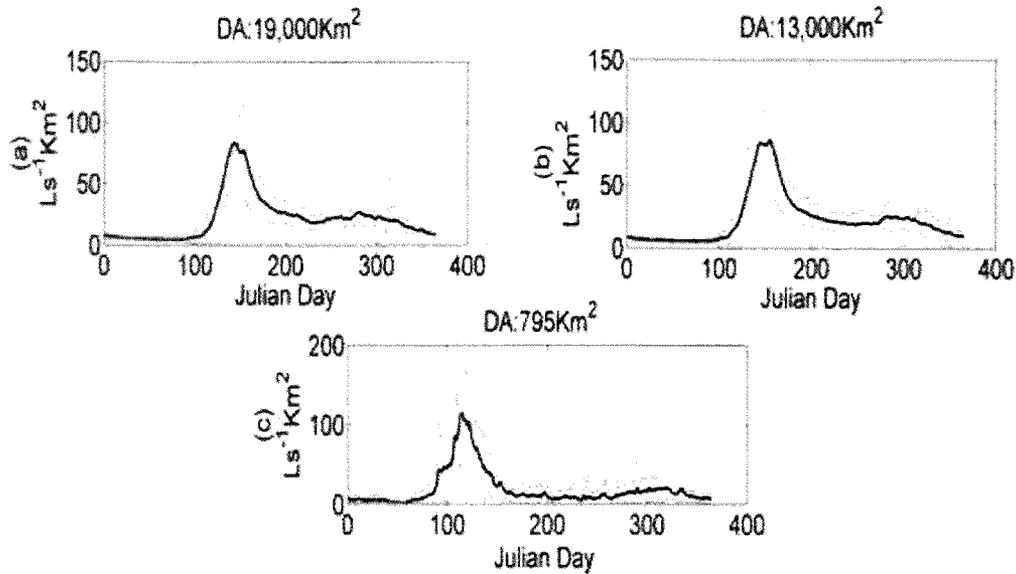


Figure 2.3 Mean specific hydrograms for (a) Romaine, (b) Moisie and (c) Ouelle. The dotted lines indicate daily mean specific flow plus and minus the daily standard deviation. The drainage area of each river is also indicated.

4 METHODOLOGY

4.1 Selection of Low flow Indices

Over 200 HIs have been defined and reported in the literature (Clausen and Biggs, 1997; Extence *et al.*, 1999; Hughes and James, 1989; Poff and Ward, 1989; Puckridge *et al.*, 1998; Richter *et al.*, 1998). In a study, attempting to characterize the low flow regimes of rivers in Eastern Canada using data from 175 discharge stations, Daigle *et al.* (2011) identified 71 HIs as potentially relevant from the low flow perspective. Following Richter *et al.* (1996) these indices were categorized into five groups describing different aspects of low flow regime - magnitude, frequency, duration, variability and timing. The number of indices was reduced from 71 to eight highly informative and low-correlated HIs using Principal Component Analysis (PCA). The selected HIs were then tested for their ability to describe the regional features and differences among the low flow regimes of rivers in Eastern Canada. Based on this work, non redundant HIs, explaining more than 75% of variance of low flow HIs, were selected for the current work. To account for the impacts of temporal dependence on the validity of statistical estimates, indices exhibiting autocorrelation were avoided. In keeping with the principles of the natural flow paradigm, the selected indices were: minimums of March flow values for each year (A1), ratio of the lowest annual monthly discharge to the mean annual discharge (A2), average Julian date of the seven annual one day minimum discharges (T), standard deviation of the Julian date of the seven 1-day minimum discharges (V), 90-day minimum divided by the median of the entire record (D1) and 90-day minimum calculated for July-October, divided by the median of the entire record (D2). These indices are shown in table 2.2. Figure 2.4 shows box plots corresponding to the selected low flow indices for each river. The median and the outliers are represented by a gray line and '+' sign, respectively. The following section briefly describes some of the inferences drawn from these box plots.

Table 2.2 Selected hydrological indices definition with index code.

Index	Description	Timing
A1	Minimums of March flow values for each year ($\text{Ls}^{-1}\text{km}^{-2}$)	Yearly
A2	Ratio of the lowest annual monthly discharge to the mean annual discharge (unitless)	Yearly
T	Average Julian date of the seven annual 1-day minimum discharges (Julian date)	Yearly
V	Standard deviation of the Julian date of the seven 1-day minimum discharges (days)	Yearly
D1	90-day minimum divided by the median of the entire record(unitless)	Yearly
D2	90-day minimum calculated for July-October, divided by the median of the entire record (unitless)	Seasonal

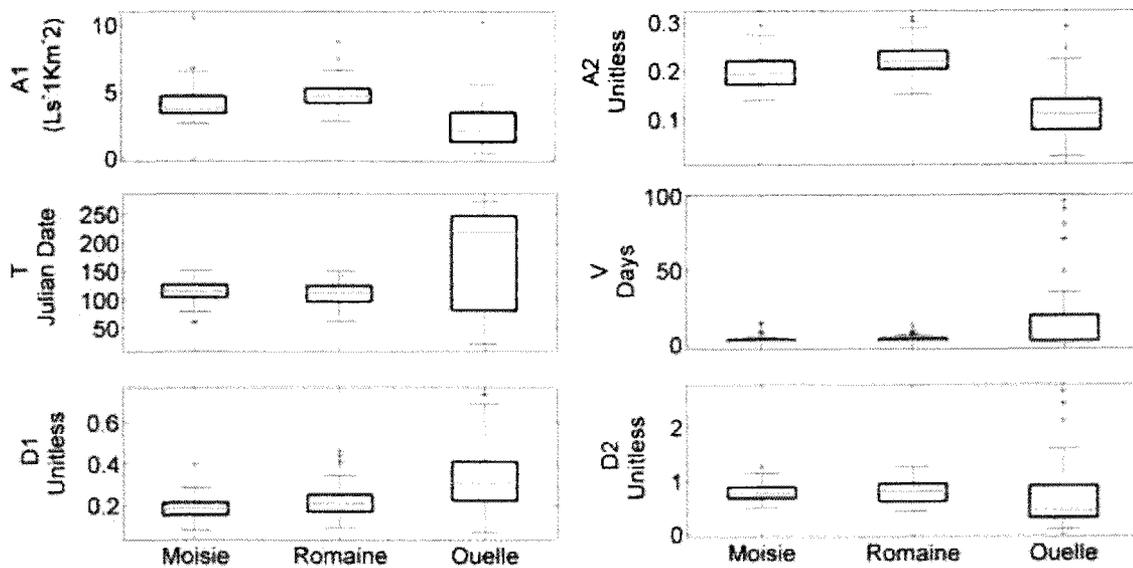


Figure 2.4 Box plots of low flow indices using the entire available dataset. The gray line represents the median and the '+' sign shows the outliers.

4.1.1 Selected Low flow Indices

4.1.1.1 A1 (Minimum March Flows)

For Moisie, the A1 mean and median values of the sample are 4.2 L/s/Km² and 3.8 L/s/Km², respectively. There are two outliers corresponding to the years 1968 (6.8 L/s/Km²) and 1981 (8.9 L/s/Km²) because both the years have experienced rainfall events in the month of February leading to 88.2 and 116 mm of rain, respectively. For the discharge station on river Romaine, the mean and median values of the index are 4.8 and 4.7 L/s/Km², respectively. There are two outliers corresponding to the years 1970 (7.4 L/s/Km²) and 1981 (8.8 L/s/Km²). In the case of river Romaine, the station Havre St-Pierre experienced winter rainfall events in the month of January corresponding to years 1970 and 1981 amounting to 60.6 and 76.10 mm of rainfall, respectively. For Ouelle, the mean and the median values of the index are 2.5 and 2.0 L/s/Km² and there is one outlier corresponding to the year 2000 (10.2 L/s/Km²). Among the three rivers, the index corresponding to Romaine shows the highest median value followed by Moisie and Ouelle. Based on the interquartile range (IQR), it can be said that the index corresponding to Ouelle exhibits largest variability. For Romaine, the position of the median and the length of the

top and the bottom whiskers reflect proximity of the distribution of the sample, to symmetry. For Moisie and Ouelle the same factors indicate positive skewness.

4.1.1.2 A2 (Base flow Index)

For Moisie, Romaine and Ouelle, the respective A2 mean (median) values of the sample are 0.20 (0.194), 0.223 (0.218) and 0.12 (0.111). In case of Moisie there is one outlier corresponding to year 1968. In case of Romaine, there are two outliers corresponding to years 1962 and 1974 and so is for Ouelle, for the years 1986 and 2006. In all the cases, the length of the whiskers and the position of the median indicate reasonably symmetric sample. The median value is highest for Romaine followed by Moisie and Ouelle. In terms of IQR, the largest variability is exhibited by Ouelle followed by Moisie and Romaine.

4.1.1.3 T (Average Julian date of seven one day minimum)

The mean (median) values of the samples of the T index from Moisie, Romaine and Ouelle are 113.6 (116), 111.49 (113.15) and 182.61 (218.28) respectively. The box plots show that the samples corresponding to Romaine and Moisie are comparable to each other in terms of variability and magnitude of the median. On the other hand, the same from Ouelle shows higher median and larger variability in comparison to the rests. The larger variability can be attributed to the bimodal distribution of the timing of low flows (late winter and late summer). In addition, for Ouelle, the position of the box and the length of the lower whisker indicate a negatively skewed sample. For Moisie and Romaine, the samples appear to be reasonably symmetric. For the former, the box plot is characterized by two outliers corresponding to years 1968 and 1981. Daily minima for Moisie are observed in the months of March and April. For these years, rainfall events occurred in February, shifting the daily minima to January thus decreasing the index value.

4.1.1.4 V (standard deviation of the Julian date of seven one day minimum)

For all the rivers, the box plots of the V values are characterized by several outliers. For Ouelle, in the 'outlier' years, daily minima appear in both of the low flow seasons, increasing the variability of the corresponding Julian dates. The mean (median) values of the samples from Moisie, Romaine and Ouelle are 3.55 (2.16), 3.50 (2.16) and 16.36 (3.31), respectively. For all the rivers, the box plots indicate positively skewed samples. The mean, median and the variability of the samples are comparable between Romaine and Moisie. The sample corresponding to river Ouelle exhibits highest median and largest variability in comparison to the rest.

4.1.1.5 D1 (Annual 90 day minimum divided by Q50)

The mean (median) values of the D1 index for Moisie, Romaine and Ouelle are 0.19 (0.185), 0.22 (0.21) and 0.33 (0.31) respectively. The sample from Ouelle exhibits highest median followed by Romaine and Moisie. Apparently from the box plots, Ouelle manifests largest variability followed by Romaine and Moisie. The samples from Romaine and Moisie appear to be reasonably symmetric whereas the same from Ouelle is right-skewed. There are outliers corresponding to years 1970 for Moisie; 1962, 1967, 1970 and 1978 for Romaine and 1973 and 1979 for Ouelle.

4.1.1.6 D2 (90 day minimum for S2 divided by Q50)

The mean (median) D2 values of the samples from Moisie, Romaine and Ouelle are 0.796 (0.820), 0.690(0.763) and 0.808(0.448) respectively. Romaine exhibits highest median followed by Moisie and Ouelle. The largest variability is seen in Ouelle followed by Romaine and Moisie. For Romaine and Moisie, the position of the boxes and the length of the whiskers indicate reasonably symmetric samples whereas for Ouelle, the sample is positively skewed. There are no outliers in case of Romaine while Moisie has one (year 1968) and Ouelle has three (years 1984, 1992 and 2002). For Ouelle, these were the years in which the seasonal 90 day minimum was twice the median flow.

4.1.2 Predictor Selection

One of the most important steps in a downscaling exercise is to select appropriate predictors. Wilby et al. (1999) proposed three main factors constraining the choice of predictors: (1) reliable simulation of the predictors by the GCM; (2) how readily available the GCM outputs are; and (3) the correlation strength with the surface variables of interest. For the current work, 21 variables were tested as potential predictors. The variables at different pressure levels (1000, 850 and 500 hPa) included Relative Humidity (RH), Specific Humidity (SH), Zonal (U), Meridonal (V) and Vertical (ω) components of wind and geopotential height. Sea Level Pressure (SLP) and Heating Degree Days (HDD) were also considered. HDD indicates the number of degrees that a day's average temperature is above a certain threshold (base temperature). For the current work the base temperature has been taken as 1°C. The full list of the tested potential predictors is given in table 2.3. Reanalysis data from the National Center for Environmental Prediction (NCEP; Kalnay et al., 1996) were used as large-scale atmospheric predictors to calibrate the models and validate the approaches. These datasets are typically viewed as 'observed' large-scale data on a regular grid with a spatial resolution of approximately 2.5 X 2.5 (250 km X 250 km). Each NCEP variable was interpolated to each of the three hydrological stations locations using bilinear interpolation. For a given station, the interpolated data are the weighted average of the data of four nearest points located on a regular grid.

Table 2.3 NCEP predictors used in the downscaling framework.

Number	Predictor Names
1	Mean temperature at 2m
2	Mean sea level pressure
3	Specific humidity at 1000 hPa
4	Specific humidity at 850 hPa
5	Specific humidity at 500 hPa
6	Relative humidity at 1000 hPa
7	Relative humidity at 850 hPa
8	Relative humidity at 500 hPa
9	Zonal wind component at 1000 hPa
10	Zonal wind component at 850 hPa
11	Zonal wind component at 500 hPa
12	Meridonal wind component at 1000 hPa
13	Meridonal wind component at 850 hPa
14	Meridonal wind component at 500 hPa
15	Vertical wind component at 1000 hPa
16	Vertical wind component at 850 hPa
17	Vertical wind component at 500 hPa
18	Geopotential height at 1000 hPa
19	Geopotential height at 850 hPa
20	Geopotential height at 500 hPa
21	Heating Degree Days

For each discharge station correlation coefficients were computed for the low flow indices and the yearly, seasonal and monthly series of every climate variable (listed in table 2.3). The variables showing significant correlation ($\alpha < 0.05$) were selected for further processing (described in the next subsection). One should however note that significance does not necessarily imply that the variable is a useful predictor since the amount of explained variance may be low. These significantly correlated variables are mentioned in the tables shown in table 2.6. The numbers in bold represent negatively correlated variables whereas the normal fonts indicate positively correlated variables.

Table 2.4 Predictands significantly correlated with selected low flow indices for river Romaine. Negatively correlated predictors are indicated by bold numbers whereas normal fonts indicate positively correlated predictors. The mentioned numbers refer to NCEP reanalysis variables listed in table 2.3.

	A1	A2	T	V	D1	D2
January	6					4,5,20
February	3,4,5,6, 9,10,12, 15,16,17, 19,20,21	8	11	5		10,12,13, 14
March	2,3,4,6,7, 10,12,13, 14,18	10,14	3,4,7 10,11		5,14,15	
April			3,8,9,10		3,4,16,17, 18	3,4,19
May		18			3	4,14
June		4,5,19,20	5			3,8
July		8			8	6,7,10, 11
August		6,8		7	6	2,18,19
September			12,13,14	3,4,5,19, 20	3	3,4 10,11
October		12,13,15	13,15,21	5,8,13,20	12	5,7
November		20		8		15
December	5,8,7,10, 11	7	5		3,4,5,9, 10,11,12, 16,17	
Winter (DJF)	3,4,5,6,7,8, 9,10,11,12, 14,15	4,5	11		9,10,11,1 6,17	5
Spring (MAM)	2,6,7,10, 11,13,14	13,14	3,4,10,11		3,5,15,16, 17	3,4,20
Summer (JJA)		2,6,7,9 18,19,20,			6,18,19,2 0	14
Autumn (SON)		12	13,15	3,4,5,19, 20		2,3,4,5, 9,10,11 16,18
Annual	9,10,11,12, 13,14,16,17	9,12,20		7,20		3,4,5,10, 11,20

Table 2.5 Predictands significantly correlated with selected low flow indices for river Moisie. Negatively correlated predictors are indicated by bold numbers whereas normal fonts indicate positively correlated predictors. The numbers mentioned refer to NCEP reanalysis variables listed in table 2.3.

	A1	A2	T	V	D1	D2
January	10, 8				20	
February	3,4,6,9,10,11,15,16,17	9,10,11,15,16,17	3,4,5		12,15,16,17	10
March	1,2,6,7,10,11,12,13,14,18		3,4	9		
April			3,4,5,8,9,10,11	17	5	
May			1			14
June						8
July		7,8		11	8,19,20	11
August		6	9,15			
September			8,14			12,13
October			13,17	11	2,12,13,14,18,19,20	6,14
November		12,13,14	13,15,17			11
December	1,11, 17	5,17		5,9,13,14,15,16	11,5	
Winter (DJF)	4,5,6,7,8,9,10,11,16,17	10,11,16,17		9	11,16,17	
Spring (MAM)	2,7,10,11,18,19,		3,4,5,10		3	
Summer (JJA)		8	13,14,15			11
Autumn (SON)		12,13,14			12	9,10,11
Annual	7,10,11,13,16			9	16,17	

Table 2.6 Predictands significantly correlated with selected low flow indices for river Ouelle. Negatively correlated predictors are indicated by bold numbers whereas normal fonts indicate positively correlated predictors. The numbers mentioned refer to NCEP reanalysis variables listed in table 2.3.

	A1	A2	T	V	D1	D2
January	10			8,14		1,21
February	3,4	1		6		
March	9			16,17		3
April		3,21				6,7,8
May		1		6	2,19	
June		1	2,11,14,18, 19		2,7,8,11,1 8,19,20	
July		1,8,9		5, 20	6	6,7
August		9,10			7	5
September		20,3		6		8
October		5	20	16,17		9,10,11, 4,5
November		5	3,4,5, 9,12,20	11	21	
December		1,13,15			2,5,17,18, 19,20	
Winter (DJF)	3,4,5,11, 20,				5,20	1,21
Spring (MAM)	9	1,15		6,16,17		14
Summer (JJA)		1	7,8,11,19	14	7,8,19, 20	6,7,5,12
Autumn (SON)		3,4,5,20	3,4,5,9,12, 19,20,			8,12,13, 14,16
Annual		1,13,15	9,19,20	16,17		10

4.1.3 Statistical downscaling Framework

For the downscaling framework involving RVM, the selected predictors were further processed using Canonical correlation analysis. CCA (Bretherton et al., 1992) gives patterns (linear combinations of the predictors) that share maximum correlation with linear combinations of predictands. Canonical variables or scores were then used as input to RVM. RVM calibration involves only one parameter, which is the width of the kernel function used (σ in Equation (2-11) in appendix 1). For the current work the Gaussian kernel function was used:

$$K(x, x_i) = \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) \quad (2-2)$$

The selection of the width is a crucial component in selecting an appropriate model. Width values ranging from 0.1 to 4 were considered (Ghosh and Majumdar, 2008).

ASD implements two methods of predictor selection: backward stepwise regression and partial correlation. For the current work, the backward stepwise regression method was used. The predictors thus selected in 80% or more of the total number of calibration sets, are mentioned in table 2.7. Leave One Out cross-validation (LOCV) was used to evaluate the prediction performance of the models. LOCV consists of omitting one case at a time and building the statistical model on the remaining dataset, and then estimating the omitted case with the model. The set of all omitted cases forms the validation set. Therefore, for each river there were n calibration sets and 1 validation set combining all n "left-out" cases; where n is the number of training points. The flowchart depicting the statistical downscaling framework is shown in figure 2.5.

Table 2.7 Predictors selected using stepwise regression in the ASD tool. The mentioned numbers refer to NCEP reanalysis variables shown in table 2.3.

Index	Romaine	Moisie	Ouelle
A1	20 (February) 15 (February) 10 (March) 8 (December) 10 (annual)	15 (February)	11 (DJF)
A2	14 (March) 7 (December)	17(February) 17(December) 13(November)	1 (annual) 3(April) 9(August)
T	11 (DJF) 11 (MAM) 5 (December) 15 (October)	3 (February) 5(April) 9(August) 8(September)	19 (Annual) 9(SON)
V	8(October) 7 (August)	3(February) 4 (February)	17 (annual) 8(January) 14 (January) 6 (February) 11(November) 20(July)
D1	18 (JJA) 15(March) 3(September)	11(DJF) 17 (DJF) 13(SON) 15 (February)	5 (DJF) 7(JJA) 2 (December)
D2	20 (April) 3(June) 6(July) 3(September)	10 (February) 6(October)	5 (JJA) 8 (SON) 1 (January) 9(October)

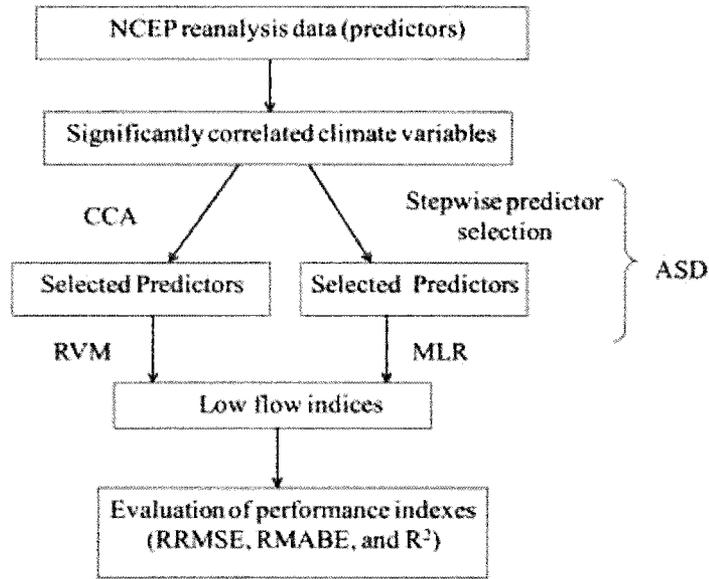


Figure 2.5 Statistical downscaling framework.

4.1.4 Performance Indices

The downscaling efficiency of the two downscaling methods was compared using three performance indices-Relative Root Mean Square Error (RRMSE), Relative Mean Absolute Bias Error (RMABE) and Coefficient of Determination (R^2).

$$RRMSE = \sqrt{\frac{\sum_{i=1}^n \left(\frac{O_i - P_i}{O_i} \right)^2}{n}} \quad (2-3)$$

$$RMABE = \frac{\sum_{i=1}^n \left| \frac{O_i - P_i}{O_i} \right|}{n} \quad (2-4)$$

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (2-5)$$

where n denotes the total number of cases, O_i and P_i denote observed and simulated values, respectively. \bar{O} and \bar{P} denote observed and simulated means, respectively.

5 RESULTS

The mean RRMSE, RMABE and R^2 values for the calibration sets are shown in figure 2.6 and the validation results are shown in figure 2.7. The number of relevant vectors and the selected width of the kernel function (in brackets) are shown in table 2.8. The calibration and validation results clearly indicate that for each river and for each low flow index, RVM is performing better than ASD. In each case, the difference between RRMSE, RMABE and R^2 values given by RVM and ASD for the validation set is greater than (twice, in most cases) the difference obtained for the calibration sets. In comparison to Ouelle, both the methods resulted in lower values of RRMSE and RMABE for Romaine and Moisie for calibration as well as validation sets.

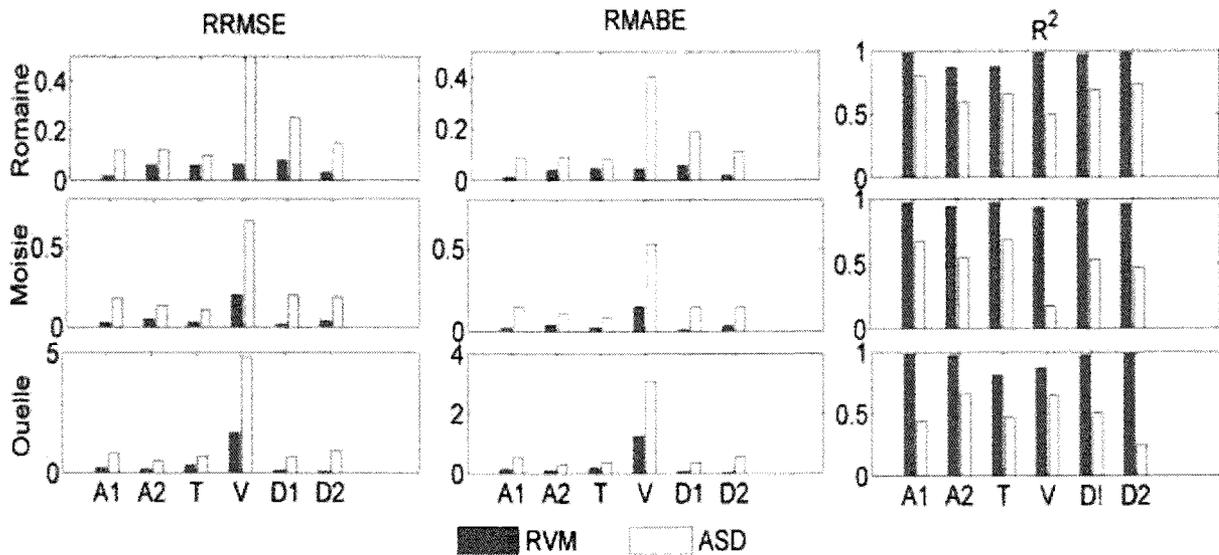


Figure 2.6 Mean RRMSE, RMABE and R^2 calibration values for (a) Romaine, (b) Moisie and (c) Ouelle. White bars represent ASD results and gray bars represent RVM results

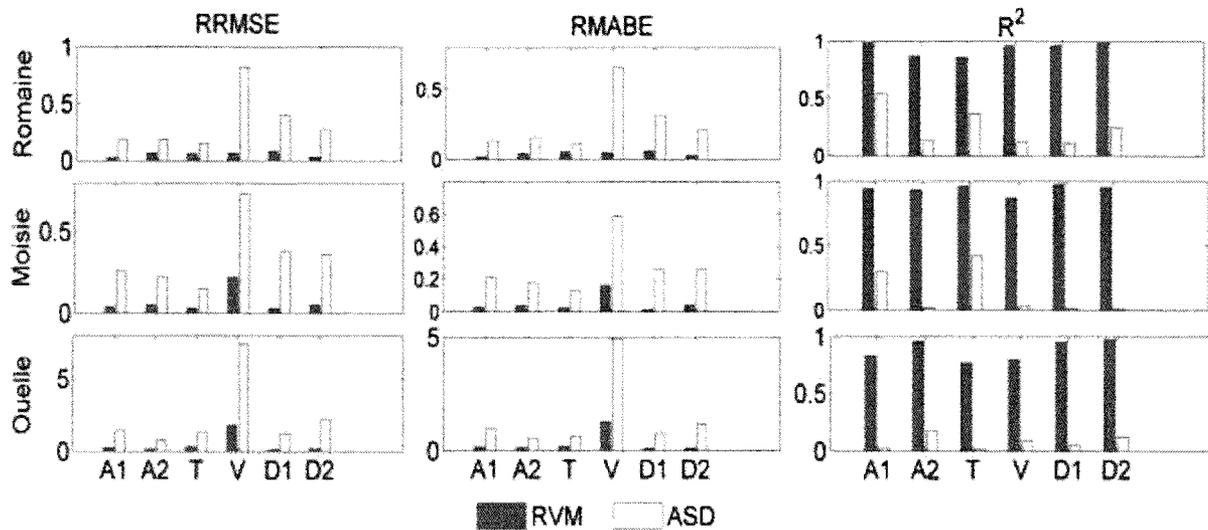


Figure 2.7 RRMSE, RMABE and R^2 validation results for (a) Romaine, (b) Moisie and (c) Ouelle. White bars represent ASD results and gray bars represent RVM results.

Table 2.8 Number of Relevant vectors (% of total training points). The width of the kernel functions are indicated in brackets.

Index	Romaine	Moisie	Ouelle
A1	10-12%(3.5)	10-12% (2.8)	11-13%(3.4)
A2	4-6%(1.3)	5-7%(3.6)	4%(3.6)
T	4-6%(2)	7%(1.8)	4-6%(3.5)
V	8%(2.4)	3%(2.5)	4%(1)
D1	8-12%(2.5)	10-12%(3.2)	13%(0.7)
D2	8-12%(2.8)	5%(2)	8-10%(3.3)

It is clearly evident from figures 2.6-2.7 that for each river, highest values of RRMSE and RMABE are observed for V, for both RVM and ASD. The difference between mean RRMSE, RMABE and R^2 calibration values given by RVM and ASD for index V are 0.437, 0.36 and 0.48 for Moisie, 0.46, 0.38 and 0.76 for Romaine and 3.15, 1.84 and 0.22 for Ouelle, respectively. For the validation set, the same are 0.75, 0.61 and 0.84 for Moisie, 0.51, 0.43 and 0.84 for Romaine and 5.65, 3.64 and 0.71 for Ouelle, respectively. For both, calibration and validation

sets, highest differences between RVM and ASD are observed for index V from Ouelle. In addition to that, for the remaining indices, highest differences between RRMSE and RMABE values obtained for RVM and ASD are seen in the case of Ouelle. For the variability index V from Ouelle, it is observed that RVM results in higher values of RRMSE and RMABE (>1 in both the cases) but gives reasonable values of R^2 for both, calibration (0.87) and validation (0.80) sets. In the case of ASD, it is seen that negative values of V are obtained for calibration and validation sets. The validation plots for V are shown in figure 2.8. Compared to ASD, RVM results in small differences between calibration and validation values of performance indices. These differences are highest for the indices from Ouelle for both RVM and ASD. Additionally, among the indices from Ouelle, highest difference is observed for index V. For the same, the differences between RRMSE, RMABE and R^2 calibration and validation values given by ASD are 2.63, 1.84 and 0.56 and those given by RVM are 0.13, 0.04 and 0.07, respectively.

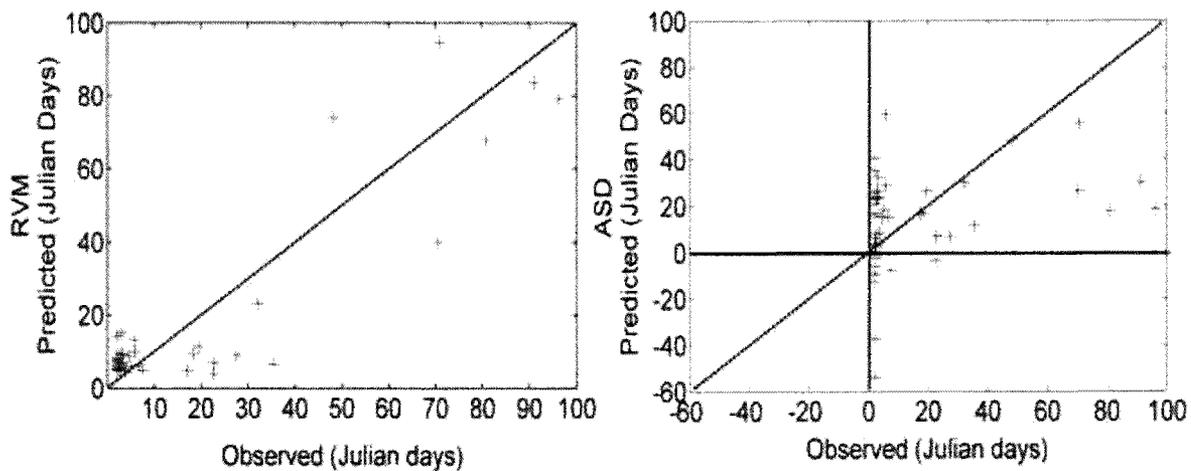


Figure 2.8 Observed versus predicted plot of the variability index for Ouelle. The dotted line represents 1:1 line.

The selection of predictors in the two frameworks is done differently. To analyse the effects of predictor selection on the performance of MLR framework, stepwise regression was replaced with CCA. The comparison results for the indices corresponding to river Ouelle are shown in figure 2.9. Combining CCA with MLR (CCAMLR) shows marked improvements in the prediction and generalisation abilities of MLR framework. Despite improvements, SBL framework is still superior than CCAMLR in terms of goodness of fit and generalisation. Pronounced differences are visible in RRMSE and RMABE values of index V. The corresponding RRMSE, RMABE and

R^2 values for using SBL framework are 1.70, 1.29 and 0.81 and for CCAMLR framework, they are 3.72, 2.63 and 0.75, respectively.

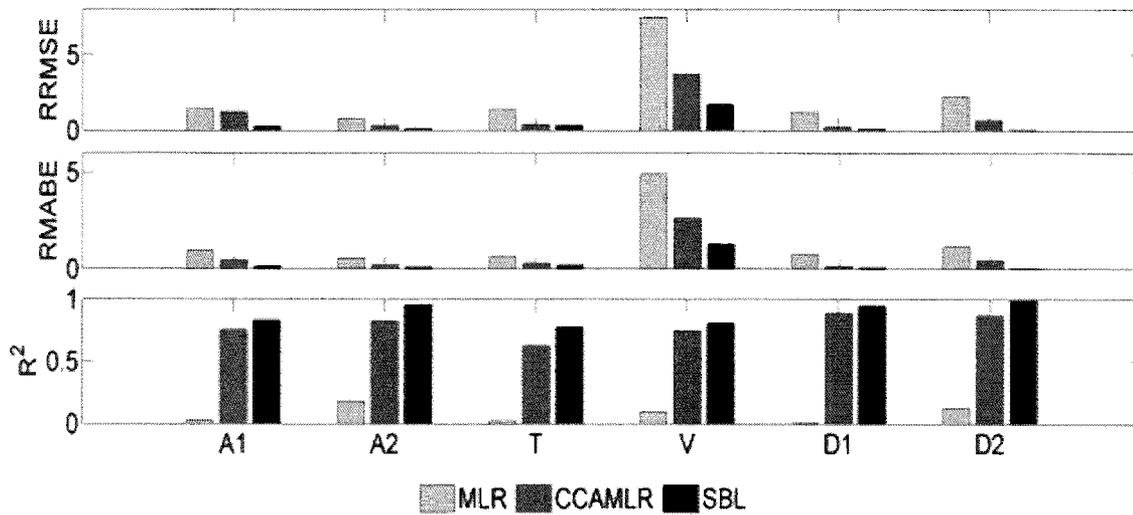


Figure 2.9 RRMSE, RMABE and R^2 validation results for river Ouelle using MLR, CCAMLR and SBL frameworks. The description of selected indices is given in table 2.2.

6 DISCUSSION

The current work is one of the first to compare two downscaling frameworks in capturing the variability in low flow indices using atmospheric variables. As explained earlier, the selected indices abide by the principles of the natural flow paradigm, as they characterize four aspects of the low flow regime of the considered rivers: amplitude, timing, duration and variability. The indices describing the Ouelle low flow regime exhibit more variability in comparison to Moisie and Romaine. Such behaviour is attributed to the occurrence of two low flow seasons (late summer and late winter) for Ouelle. Based on the correlation values between the low flow indices and large scale climate variables at different temporal scales (yearly, seasonal and temporal), it was observed that the variables appearing most commonly as significant correlated with the selected low flow indices are humidity and wind components (Vertical, Zonal and Meridonal). Wind movement regulates the humidity levels of the atmosphere. For example, a west to east wind brings cold dry air (very low moisture) along with it, thereby reducing precipitation. Humidity variables (SH and RH) are expected to influence low flow indices as their variation affects temperature and precipitation and hence river flows. This has been highlighted with the use of humidity variables as predictors in flow downscaling studies (Cannon and Whitfield, 2002; Ghosh and Majumdar, 2008; Tisseuil et al., 2010).

Comparing the values of performance indices clearly indicated that SBL performed better than MLR to downscale the selected low flow indices of the considered rivers. For all three rivers, the relatively small difference between performance indices values corresponding to calibration and validation sets (figures 2.6 and 2.7) reflected better generalisation ability (less overfitting) of RVM as compared to ASD. The higher RRMSE and RMABE values corresponding to Ouelle can be explained by the higher variability present in the indices (particularly V) from the same in comparison to those from Romaine and Moisie. Regression based statistical downscaling models often cannot explain all of the variance of the downscaled variable (Ghosh et al., 2008; Wilby et al., 2004). Improvements in the performance of MLR framework were observed by rerunning ASD with CCA as the predictor selection method. But the improved MLR framework did not surpass RVM in terms of the evaluation criteria. For all the rivers (validation plots shown only for Ouelle in figure 2.9), noticeable differences between SBL and CCAMLR were observed for index V, which exhibits the highest variability. The ability of SBL to better capture the

variability than MLR is reflected by the values of performance indices for the low flow HIs from Ouelle as well as the variability index for all the rivers. In addition to that, in all cases, SBL supported sparsity by using fewer relevant vectors (shown in table 2.8) in comparison to MLR and CCAMLR, thereby leading to lesser computation time.

It is observed that SBL resulted in higher values of RRMSE and RMABE (> 1) but reasonable values of R^2 (> 0.80 for both calibration and validation sets), for the variability index computed for Ouelle. In the observed versus predicted plots of the variability index from Ouelle (shown in figure 2.8), it can be seen that the clustering of points around the 1-1 line gave a reasonable value to R^2 . The high values of RRMSE (1.79) and RMABE (1.28) were an outcome of under prediction of lower values of the index. In the case of MLR, predicted values corresponding to certain lower values of the index were found to be negative, leading to higher values of RRMSE (7.44) and RMABE (4.94).

7 CONCLUSION

This study proposes a direct downscaling approach from atmospheric variables to low flow indices, which is less commonly implemented than the approach involving the use of an intermediate hydrological model between GCMs and streamflow. This paper presents the downscaling of low flow indices using SBL and MLR, with NCEP climate variables as predictors. This approach relies on the assumption that the low flow indices are influenced by atmospheric factors only. Such an assumption disregards the influence of some physical factors such as soil and land use which affect the movement of water through the soil and which are at least partially taken into account in a framework involving the use of a hydrological model. However, the results revealed by the current work are encouraging and further developments in the use of direct downscaling approaches are promising.

Six indices characterising the low flow regime of Moisie, Romaine (both located on the Quebec North shore) and Ouelle (located on the south shore of Quebec) rivers, which all sustain salmon populations, were selected. Low flow indices are of the utmost importance to characterize and assess potential impacts of changing hydrological regimes on fish and associated fisheries. The indices corresponding to Ouelle were found to show higher variability in comparison to the ones from Romaine and Moisie. The predictors corresponding to the selected indices were identified on the basis of their correlation with the climate variables. For SBL and CCAMLR frameworks, input was prepared using CCA, whereas for MLR, stepwise predictor selection method was used. In contrast to MLR, SBL is characterised by a complex algorithm based on probabilistic Bayesian learning. This complexity becomes a drawback in terms of computation time in cases where the sample size is large. Despite its complexity, the probabilistic nature of the algorithm accounts for the uncertainties present in the predictions. In addition to that, the algorithm automatically sets majority of parameters to zero, leading to a procedure which is effective at discerning those basis functions which are 'relevant' for making good predictions.

It was observed that the climate variables showing significant correlation with the indices were wind components and humidity variables. SBL not only outperformed MLR in terms of the values of the performance indices but also involved fewer parameters. The proximity of the values of the performance indices for calibration and validation sets indicated a good generalization capability of SBL. Rerunning ASD with CCA predictor selection method improved

the results of MLR framework but SBL still showed better performance. This suggests that the performance of MLR framework was impacted by the considered predictor selection method, but not to the extent of outperforming SBL. Marked differences between the performances of CCAMLR and SBL were observed for the variability index for all rivers. The inability of SBL and MLR to capture variability was reflected in the values of performance indices, obtained for the low flow HIs corresponding to Ouelle and the variability index for all rivers. The proposed methodology can be used to project low flow indices for future years using GCM and RCM outputs. In addition to that different ways of preparing the input for the regression model (e.g. Classification and regression trees, combination of PCA and fuzzy logic) could be explored.

8 APPENDIX-1

8.1.1 Theoretical Background of Sparse Bayesian Learning

In an archetypical regression situation, given a set of data $\{x_n, t_n\}_{n=1}^N$, the target samples are considered to be realisations of a deterministic function y , potentially corrupted by some noise process:

$$t_i = y(x_i, \mathbf{w}) + \varepsilon_i \quad (2-6)$$

Where $\varepsilon_i, i=1,2,\dots,n$ are random errors which are independent normally distributed random variables with mean zero and constant variance σ^2 . The function y is modelled as a linearly-weighted sum of M fixed basis functions $\{\phi_m(\mathbf{x})\}_{m=0}^M$:

$$y(\mathbf{x}; \mathbf{w}) = \sum_{m=0}^M w_m \phi_m(\mathbf{x}) = \Phi \mathbf{w} \quad (2-7)$$

where Φ is the design matrix and $\mathbf{w} = (w_0, w_1, \dots, w_M)$ is the weight vector. The objective is to infer values of the parameters/weights $\{w_m\}_{m=0}^M$ such that the function y models the underlying generative function. A classic approach to estimate $y(\mathbf{x}, \mathbf{w})$ is to minimise the cost function:

$$E_D(\mathbf{w}) = 1/2 \sum_{n=1}^N [t_n - \sum_{m=0}^M w_m \phi_m(x_n)]^2 \quad (2-8)$$

Minimisation of squared error leads to a model which exactly interpolates the data. One way to meaningfully learn from data is to impose a 'priors' prejudice on the nature of the complexity of functions we wish to elucidate. A common way of doing this is via 'regularisation'. In linear model framework, smoother functions have smaller weight magnitude and therefore, complex functions are penalised by including a penalty term to the cost function defined in (2-8). Hence, we now minimise

$$\widehat{E}(\mathbf{w}) = E_D(\mathbf{w}) + \lambda E_w(\mathbf{w}) \quad (2-9)$$

where

$$E_w(\mathbf{w}) = 1/2 \sum_{m=1}^M w_m^2 \quad (2-10)$$

and the hyperparameter λ balances the trade off between how smooth the function is and how well the function fits the data. In the probabilistic Bayesian framework, an explicit probabilistic model is defined over ϵ_i , chosen to be a Gaussian distribution with mean zero and variance σ^2 . Therefore,

$$p(\epsilon_i | \sigma^2) = N(0, \sigma^2) \quad (2-11)$$

Consequently, using (2-6), $p(t_i | w_i, \sigma^2) = N(y, \sigma^2)$ and therefore, the likelihood function is given by:

$$\begin{aligned} p(\mathbf{t} | \mathbf{w}, \sigma^2) &= (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left\{-\frac{\|\mathbf{t}-\mathbf{y}\|^2}{2\sigma^2}\right\} \\ &= (2\pi\sigma^2)^{-N/2} \exp\left\{-\frac{\|\mathbf{t}-\Phi\mathbf{w}\|^2}{2\sigma^2}\right\} \end{aligned} \quad (2-12)$$

where $\mathbf{t}=(t_1, \dots, t_N)^T, \mathbf{w}=(w_0 \dots w_N)^T$ and Φ is the $N \times (N+1)$ 'design matrix' with $\Phi = [\phi(x_1), \phi(x_2), \dots, \phi(x_N)]^T$, wherein $\phi(x_i) = [1, K(x_i, x_1), K(x_i, x_2), \dots, K(x_i, x_N)]^T$ where $K(x_i, x_j)$ for $j=1, 2, \dots, N$ is a kernel function, effectively defining one basis function for each example x_i (where $i=1, 2, \dots, N$) in the training set. Since the numbers of parameters in the model are equal to the number of equations ($M=N$), maximum likelihood estimation of \mathbf{w} and σ^2 would lead to severe over fitting. To control model complexity, instead of the regularisation weight penalty, defined in (2-9), a 'prior' probability distribution, expressing our degree of belief over the values \mathbf{w} might take, is defined as:

$$p(\mathbf{w} | \alpha) = \prod_{i=0}^N N(w_i | 0, \alpha_i^{-1}) \quad (2-13)$$

with α a vector of $N+1$ hyperparameters. Such a representation, encodes a preference for smoother (less complex) functions. Importantly, there is an individual hyperparameter

associated with every weight, moderating the strength of the prior. The prior given by equation (2-13) is conditioned on α , so for full Bayesian consistency, hyperpriors are defined over α as well as the remaining parameters of the model, the noise variance σ^2 . Once the prior has been defined, the posterior distribution over all unknowns can be defined as:

$$p(\mathbf{w}, \alpha, \sigma^2 | \mathbf{t}) = p(\mathbf{t} | \mathbf{w}, \alpha, \sigma^2) p(\mathbf{w}, \alpha, \sigma^2) / p(\mathbf{t}) \quad (2-14)$$

which cannot be computed analytically. Therefore, the posterior is decomposed as

$$p(\mathbf{w}, \alpha, \sigma^2 | \mathbf{t}) = p(\mathbf{w} | \mathbf{t}, \alpha, \sigma^2) p(\alpha, \sigma^2 | \mathbf{t}) \quad (2-15)$$

The first term on the RHS of (2-15), denoting the posterior distribution over the weights is given by

$$\begin{aligned} p(\mathbf{w} | \mathbf{t}, \alpha, \sigma^2) &= (p(\mathbf{t} | \mathbf{w}, \sigma^2) p(\mathbf{w} | \alpha)) / p(\mathbf{t} | \alpha, \sigma^2) \\ &= (2\pi)^{-(N+1)/2} |\Sigma|^{-1/2} \exp \left\{ -1/2 (\mathbf{w} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{w} - \boldsymbol{\mu}) \right\} \end{aligned} \quad (2-16)$$

where the posterior covariance and mean are respectively:

$$\Sigma = (\sigma^{-2} \Phi^T \Phi + A)^{-1} \quad (2-17)$$

$$\boldsymbol{\mu} = \sigma^{-2} \Sigma \Phi^T \mathbf{t} \quad (2-18)$$

where A is a diagonal matrix defined as $\text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$.

The hyperparameter posterior, which is the second term on the RHS of (2-15) is represented by a delta function at its mode, *i.e.* at its most-probable values $\alpha_{MP}, \sigma_{MP}^2$. We have

$$p(\alpha, \sigma^2 | \mathbf{t}) \propto p(\mathbf{t} | \alpha, \sigma^2) p(\alpha) p(\sigma^2) \quad (2-19)$$

For the case of uniform hyperpriors, it is needed to maximize the term $p(\mathbf{t} | \alpha, \sigma^2)$ only, which is computable and is given by:

$$\begin{aligned} p(\mathbf{t} | \alpha, \sigma^2) &= \int p(\mathbf{t} | \mathbf{w}, \sigma^2) p(\mathbf{w} | \alpha) d\mathbf{w} \\ &= (2\pi)^{-N/2} |\sigma^2 \mathbf{I} + \Phi A^{-1} \Phi^T|^{-1/2} \exp \left\{ -1/2 \mathbf{t}^T (\sigma^2 \mathbf{I} + \Phi A^{-1} \Phi^T)^{-1} \mathbf{t} \right\} \end{aligned} \quad (2-20)$$

This quantity is known as the marginalized likelihood and its maximization is known as the *type II maximum likelihood* method. For maximizing $p(\mathbf{t} | \alpha, \sigma^2)$, a gradient based approach is used.

For α differentiating (2-20), equating to zero and rearranging gives:

$$\alpha_i^{new} = \gamma_i / \mu_i^2 \quad (2-21)$$

where μ_i is the i -th posterior mean weight from (2-18) and the quantities γ_i can be defined by:

$$\gamma_i = 1 - \alpha_i N_{ii} \quad (2-22)$$

With N_{ii} the i -th diagonal element of the posterior weight covariance from (2-17) computed with the current α and σ^2 . Each $\gamma_i \in [0,1]$ can be interpreted as a measure of how 'well-determined' its corresponding parameter w_i is by the data.

For the noise variance σ^2 , differentiation leads to the re-estimate:

$$(\sigma^2)^{new} = \|\mathbf{t} - \Phi\boldsymbol{\mu}\|^2 / (N - \sum_i \gamma_i) \quad (2-23)$$

where N in the denominator denotes the number of data examples.

Hyperparameter estimation is typically carried out with an iterative formula such as a gradient ascent on the objective function given by (2-20). In practice, many of the α_i 's tend to infinity and from (2-13) it implies that $p(w_i | \mathbf{t}, \alpha, \sigma^2)$ becomes highly peaked at zero. Therefore, the corresponding w_i become close to zero and can thus be pruned and consequently sparsity is realized. At convergence of the hyperparameter estimation procedure, predictions are made based on the posterior distribution over the weights conditioned on the maximizing values α_{MP} and σ_{MP}^2 . For a new datum x_* , the predictive distribution is given by:

$$p(\mathbf{t}_* | \mathbf{t}, \alpha_{MP}, \sigma_{MP}^2) = \int p(\mathbf{t}_* | \mathbf{w}, \sigma_{MP}^2) p(\mathbf{w} | \mathbf{t}, \alpha_{MP}, \sigma_{MP}^2) d\mathbf{w} \quad (2-24)$$

Since both terms in the integrand are Gaussian, (2-24) can be readily computed, giving:

$$p(\mathbf{t}_* | \mathbf{t}, \alpha_{MP}, \sigma_{MP}^2) = N(\mathbf{t}_* | \mathbf{y}_*, \boldsymbol{\sigma}_*^2)$$

with

$$\mathbf{y}_* = \boldsymbol{\mu}^T \boldsymbol{\phi}(x_*)$$

$$\boldsymbol{\sigma}_*^2 = \sigma_{MP}^2 + \boldsymbol{\phi}(x_*)^T \boldsymbol{\Sigma} \boldsymbol{\phi}(x_*) \quad (2-25)$$

This gives the predictive mean as $y(x, \mu)$ and the predictive variance as the sum of two variance components: the estimated noise on the data and that due to uncertainty in the prediction of the weights.

CHAPITRE 3

STATISTICAL DOWNSCALING OF PRECIPITATION AND TEMPERATURE USING SPARSE BAYESIAN LEARNING, MULTIPLE LINEAR REGRESSION AND GENETIC PROGRAMMING FRAMEWORKS

Deepti Joshi¹, Andre St-Hilaire¹, Taha Ouarda^{1,2}, Anik Daigle^{1,3}

¹ INRS-ETE, University of Québec, 490 de la Couronne, Québec G1K 9A9, Canada
(joshi.deepti@ete.inrs.ca, andre.st-hilaire@ete.inrs.ca)

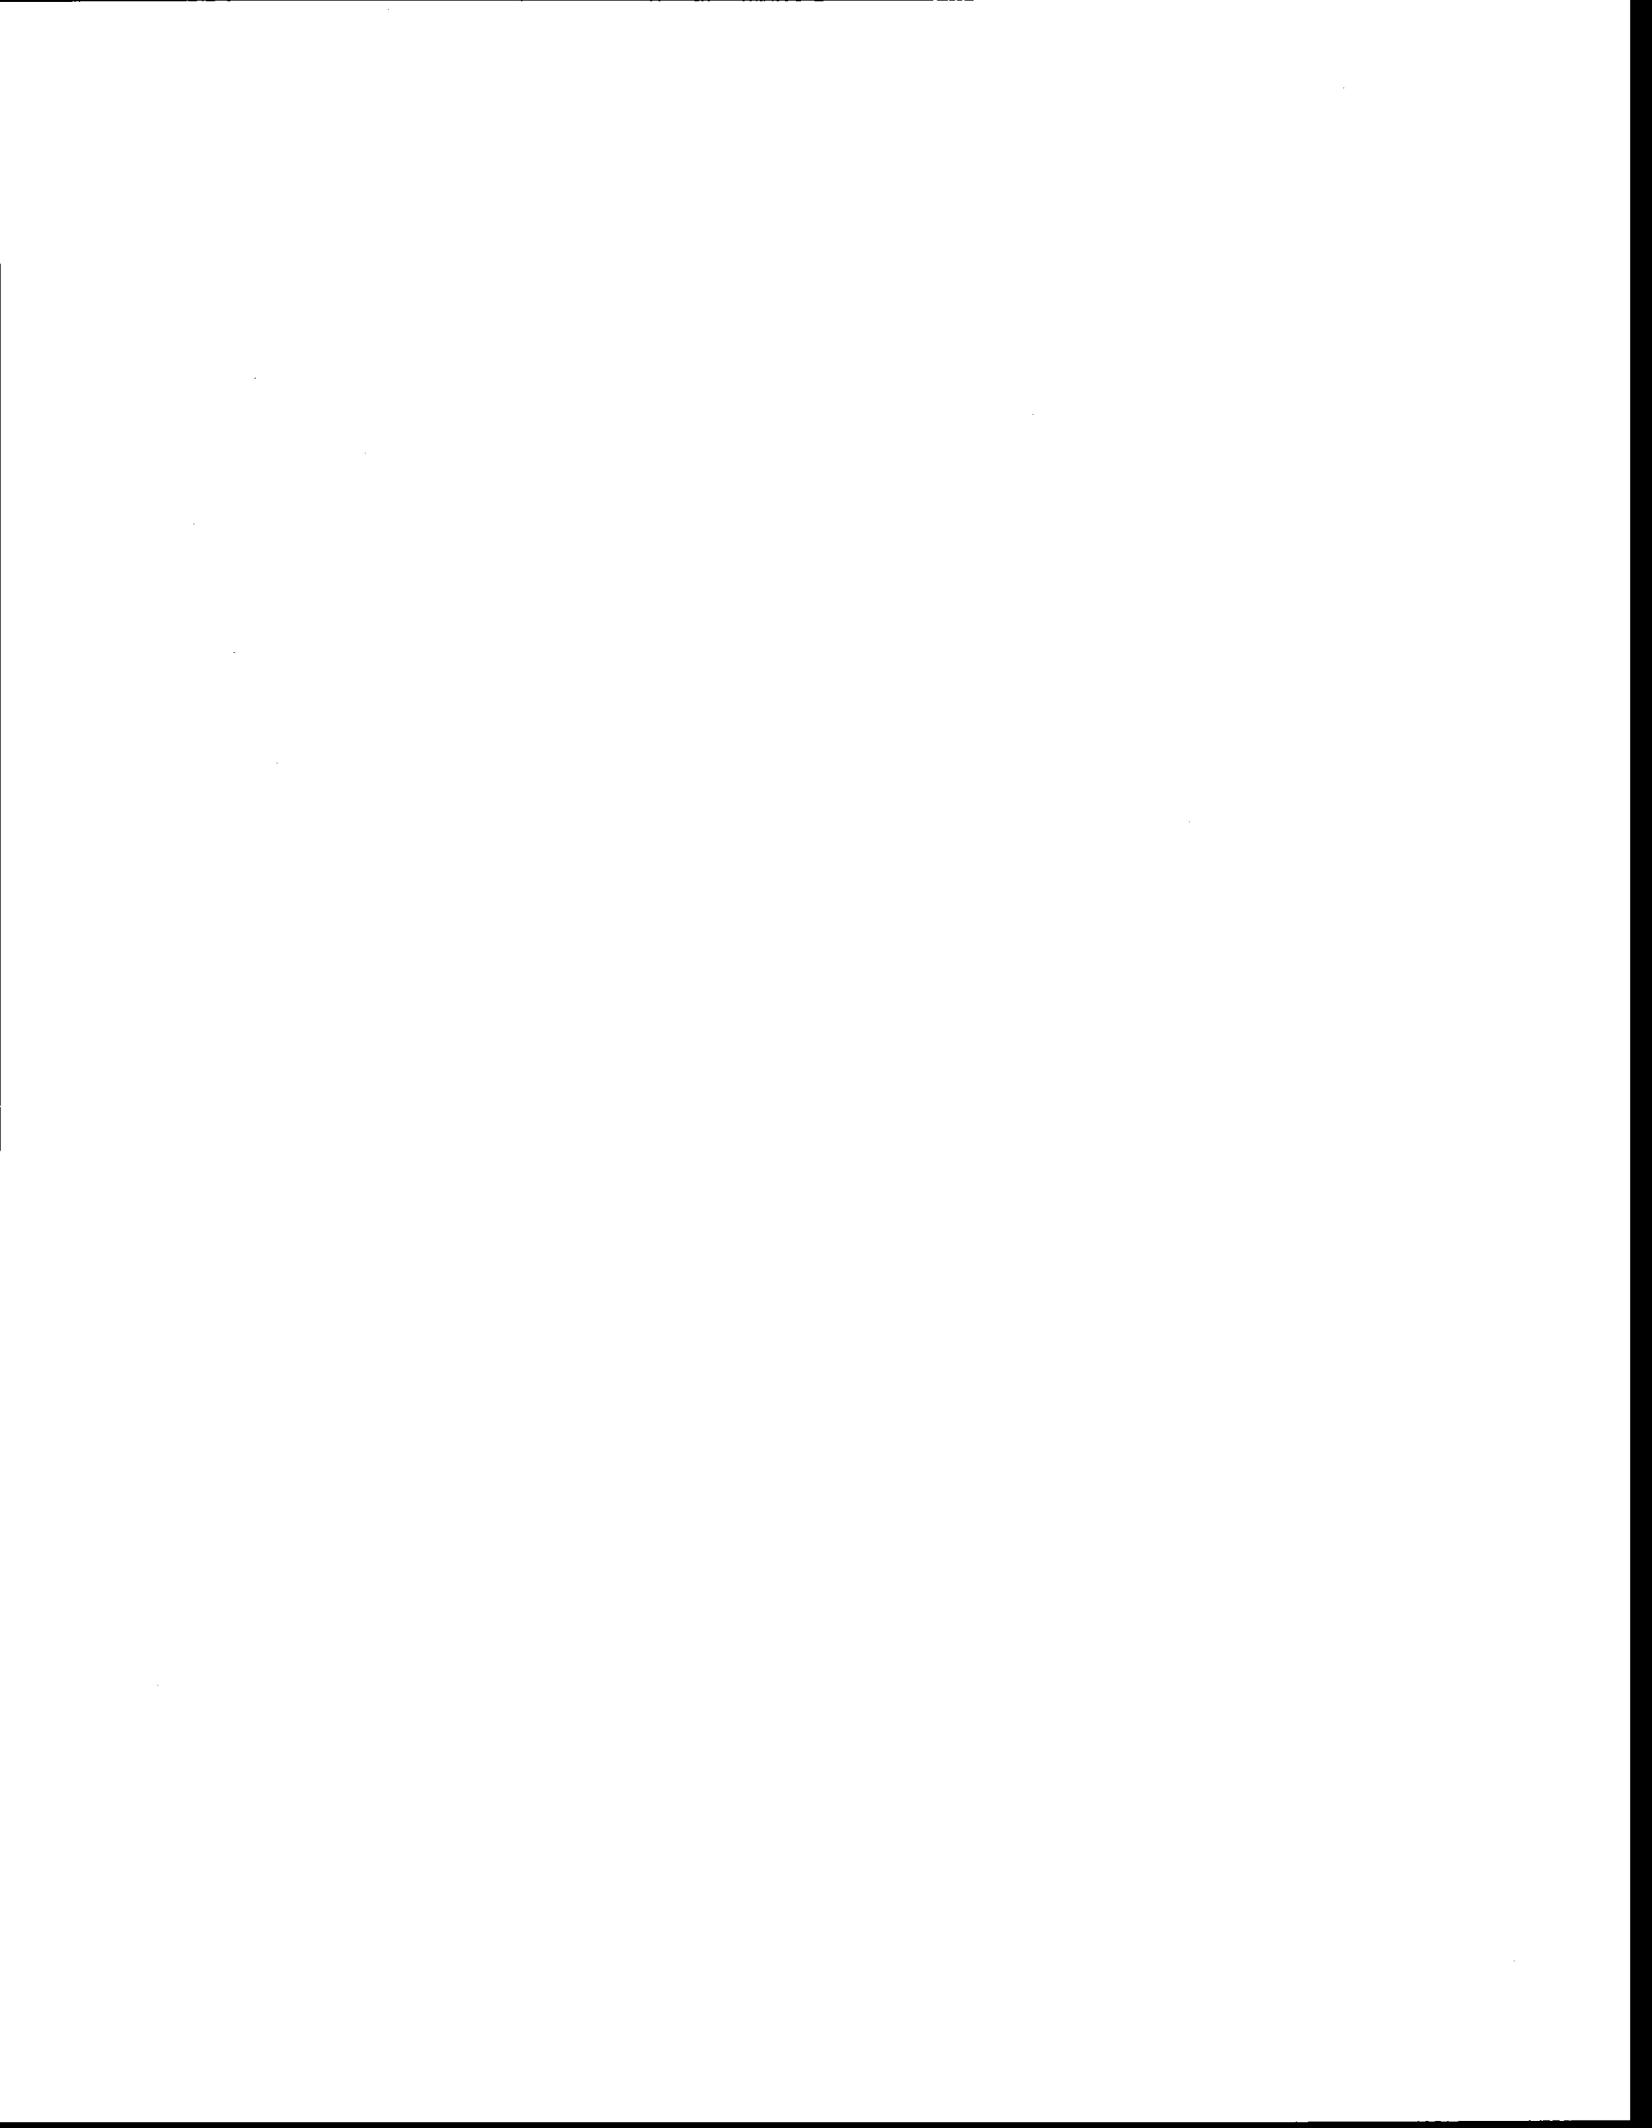
² Masdar Institute, Professor & Head - Water & Environmental Engineering, PO Box 54224, Abu Dhabi, United Arab Emirates (touarda@masdar.ac.ae, taha.ouarda@ete.inrs.ca)

³ Cégep Garneau, 1600 boulevard de l'Entente, Québec, G1S 4S3, Canada
(anik.daigle@ete.inrs.ca)

Corresponding author: Deepti Joshi

Article soumis à Stochastic Environmental Research and Risk Assessment le 8 octobre 2013

The work presented in the following article consists of the combined endeavours of all its authors. The implementation of the mathematical algorithms in MATLAB was done by Deepti Joshi and Anik Daigle. The co-authors advised in the development of the methodology of the work and analysis of the results. The data extraction and processing, evaluation of results and the preparation of the initial version of the manuscript were done by Deepti Joshi, under the guidance of all co-authors.



ABSTRACT

This study attempted to investigate two downscaling frameworks to downscale temperature and four to downscale precipitation. Input to all frameworks were climate variables (NCEP reanalysis variables) significantly ($\alpha < 0.05$) correlated with the predictands (temperature and precipitation). The first framework was an implementation of Multiple Linear Regression (MLR) called Automated Statistical Downscaling (ASD) tool. ASD selects predictors using backward stepwise regression and subjects the selected predictors to MLR. The second framework implemented Relevance Vector machine (RVM) which is a Sparse Bayesian Learning (SBL) approach. The SBL framework involves selecting predictors using canonical correlation analysis followed by their input into the RVM algorithm. For precipitation downscaling, two additional frameworks that combine genetic programming (as the predictor selection method) with SBL and MLR were presented. The results showed that SBL outperformed MLR in downscaling temperature. For all stations, temperature was better downscaled than precipitation. For precipitation downscaling, SBLGP framework outperformed all other frameworks in classification as well as regression. MLRGP, on the other hand, did not bring about much improvement in the results and was in many cases outperformed by MLR.

Keywords: Downscaling, Sparse Bayesian Learning, Multiple Linear Regression, Low flows, Canonical Correlation Analysis, Genetic Programming.

1 INTRODUCTION

The fourth assessment report of Intergovernmental Panel on climate change (IPCC, 2007d) stated that continued greenhouse gas emissions at or above current rates would induce many changes in the global climate during the 21st century. These changes are likely to be larger than those observed during the 20th century. Under these circumstances, there is a need to improve our knowledge of the global climate system and its possible impacts on the meteorological and consequently hydrological patterns and processes. Global Climate Models (GCMs) are mathematical tools that simulate present climate and generate future climate scenarios upto a resolution of tens to hundreds of kilometers with forcings including greenhouse gases and aerosol emissions. However, due to their coarse sparse resolution they are not considered a reliable source of information in impact studies that require information at a fine scale to characterize spatial variations and establish parameterizations (Wilby et al., 2004). For example, in studying the hydrological impacts of climate change, hydrological models are required to simulate sub-grid scale phenomena and therefore need input data such as daily precipitation and temperature at a similar scale. Hence, there is a need to convert GCM outputs into precipitation and temperature time series at a scale at which the hydrological impact is to be investigated. The methods used to covert GCM outputs into local meteorological variables are referred to as 'downscaling'.

Downscaling techniques are broadly classified into two categories-dynamical downscaling and statistical downscaling (SD). Dynamical downscaling techniques involve the use of Regional Climate Models (RCMs) which use initial and time dependent lateral boundary conditions from GCMs to achieve a higher spatial resolution at the cost of limited area modeling. SD techniques derive relationships between large scale variables (predictors), obtained from reanalysis data, and local scale surface conditions (predictands). Climate variables that are closely related to the predictand are selected as predictors. Future projections from GCM or RCM are then used in these relationships to estimate the changes in the response variable. SD methods are further classified into three types: Weather classification (Huth, 2000; Jones et al., 1993), weather generator (Katz, 1996; Wilks & Wilby, 1999) and regression (transfer functions) models (Wilby et al., 2002). Out of the three, regression based methods are the most widely used. The relative ease of application and use of observable trans-scale relationships forms the strength of regression downscaling. The major weakness of this approach is that it explains only a part of the climate variability. Apart from assuming the validity of model parameters under future

climate conditions, these approaches are also sensitive to the choice of predictor variables and of the transfer function. The most commonly used SD methods implement linear methods such as Multiple linear regression (Hessami et al., 2008, Wilby et al., 2002), canonical correlation analysis (Huth, 2004) and artificial neural networks (Hewitson & Crane, 1996).

Dibike and Coulibaly (2006) compared two downscaling models- a temporal neural network (TNN) model and a regression-based statistical model, to predict daily precipitation, daily minimum temperature and daily maximum temperature in northern Quebec, Canada. They found that the TNN model was more efficient in downscaling both daily precipitation and daily maximum and minimum temperatures. In another study, Tripathi et al. (2006) proposed a support vector machine (SVM) approach to obtain average monthly rainfall at meteorological sub-divisions (MSDs) for India and concluded that a SVM based model was a suitable statistical downscaling method for precipitation. Chen et al. (2008) compared three downscaling models— one based on a Relevance Vector Machine (RVM), a least square support vector machine (LSSVM) and a back propagation neural network (BPNN) to downscale runoff and found RVM to be an effective way to assess climate change impact on hydrology.

The selection of suitable predictors is crucial in developing a statistical downscaling model. The most basic requirement for a predictor is that it is informative, i.e. it has a high predictive power. Informative predictors can be identified by statistical analyses, typically by correlating possible predictors with the predictands. A list of predictors used for precipitation downscaling is given by Wilby and Wigley (2000), along with a comparison of observed and simulated predictors and a stationarity assessment. In another study, 29 individual atmospheric predictors of daily precipitation are examined for their downscaling skill in 15 locations that encompass diverse climate regimes (Cavazos and Hewitson, 2005). Mid-tropospheric geopotential heights and mid-tropospheric humidity were found to be the two most relevant controls of daily precipitation in all the locations and seasons analyzed. In a study implementing genetic programming (GP) method, Coulibaly (2004), presented a method to simulate local scale daily extreme (maximum and minimum) temperatures based on large scale atmospheric variables. GP outperformed MLR in downscaling daily minimum temperature, while the two models were almost equivalent in downscaling daily maximum temperature. Hashmi et al. (2011) presented the results of statistical downscaling of precipitation data from the Clutha Watershed in New Zealand using a non-linear regression model developed using Gene Expression Programming (GEP, a variant of GP). The results showed that GEP-based downscaling models can offer very simple and efficient solutions in downscaling precipitation.

The work presented in this paper is motivated by the desire to explore the potential of two and four downscaling frameworks for temperature and daily precipitation series, respectively. Temperature is modeled as an unconditional event whereas precipitation is modeled as a two step approach: precipitation occurrence and precipitation amounts. The first framework (F1) is an implementation of MLR, known as Automated Statistical Downscaling tool (ASD). ASD applies backward stepwise regression to draw a relationship between predictors and predictand. The second downscaling framework (F2) involves the combination of canonical correlation analysis and Relevance Vector Machine (RVM). RVM is an implementation of probabilistic Sparse Bayesian Learning (SBL) which uses distance based kernel functions to define the transfer function. Several studies have implemented machine learning methods in precipitation and temperature downscaling studies (Ghosh et al., 2008; Chen et al., 2008; Chen et al 2010; Najafi et al., 2011; Samui and Dixon, 2012; Joshi et al., 2013). MLR has also found several applications in downscaling studies (Aksornsingchai and Chutimet, 2011; Burgor et al, 2012 and Nieto & Wilby, 2005). In addition to the above mentioned frameworks, two more frameworks were tested for precipitation downscaling. These consisted of replacing canonical correlation analysis and backward stepwise regression with Genetic programming GP as the predictor selection method. Therefore, the remaining two frameworks involve combining GP (as predictor selection method) with SBL and MLR (as statistical downscaling models). GP has been used in other downscaling studies (Hashmi, 2009; Hashmi, 2011; Hassanzadeh et al, 2013), but the combination of GP with RVM is one novel aspect of this project.

The paper is organized as follows. Section 3.3 describes the statistical models (SBL and MLR) used for downscaling as well as a brief explanation of GP. Section 3.4 describes the study area followed by section 3.5 that describes the Methodology. Section 3.6 presents the results followed by discussion and conclusion in section 3.7 and 3.8 respectively.

2 STATISTICAL MODELS

This section describes the methods/models used in the applied downscaling frameworks. The first subsection describes the MLR as is followed by a brief description of SBL. Finally, the third subsection describes the GP framework implemented for precipitation downscaling

2.1 Multiple linear regression

MLR is a statistic method that is used to model linear relationship between a dependent variable (predictand) and one or more independent variables (predictors). Therefore, the MLR model can be expressed as a linear function:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_p X_{ip} + \varepsilon_i \quad (3-1)$$

for $i=1, 2, \dots, N$

Where the ε_i 's are random noise assumed to be independent $N(0, \sigma^2)$, X_i 's are the predictors and Y_i is the predictand. Wilby et al. (2002), developed a Windows based decision support tool known as Statistical Downscaling Model (SDSM) that facilitates the rapid development of multiple, low-cost, single-site scenarios of daily surface weather variables under current and future regional climate forcing. Additionally, the software performs ancillary tasks of predictor variable pre-screening, model calibration, basic diagnostic testing, statistical analyses and graphing of climate data. Inspired by the SDSM approach, Hessami et al. (2008) developed the automatic statistical downscaling (ASD) tool.

2.1.1 Automated Statistical Downscaling Tool

ASD is a regression based downscaling tool, capable of performing statistical downscaling automatically from predictor selection to model calibration, scenario generation and statistical analysis of scenarios. The automation is designed to replace SDSM's subjective method of predictor selection, requiring significant input on the part of the user, with a more objective approach. It allows two methods of predictor selection: backward stepwise selection and partial correlation coefficients (Afifi & Clark, 1996). In addition to MLR, it also allows the use of the ridge regression (Hoerl & Kennard, 1970). Ridge regression accounts for the collinearity of predictors, resulting in more stable least square estimates of the regression coefficients. Full

technical details about ASD, including model validation and usage, are described by Hessami et al. (2008).

2.2 Sparse Bayesian Learning

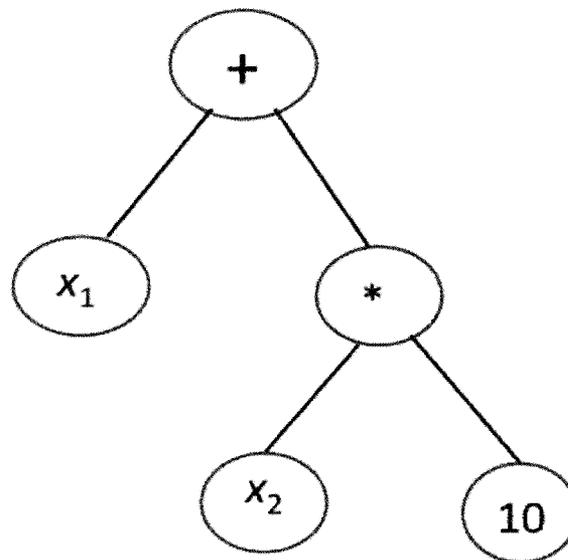
Several studies have shown that accounting for non-linear relation between the predictors and predictand can improve the goodness of fit (Huth et al., 2008). For this reason, Artificial Neural Network (ANN) based downscaling techniques have gained wide recognition (Crane & Hewitson, 1998, Wilby et al., 1998). The ability to generalize a relationship from given patterns makes it possible for ANNs to solve large-scale complex problems such as non-linear modeling and classification (ASCE Task Committee on Artificial Neural Networks in Hydrology, 2000b; Govindaraju & Rao 2000). While accuracy in predictions is universally valued, a recent interest in the notion of sparsity diverted the focus of the research community on learning algorithms which use fewer parameters. One of the significant developments in this direction is Support Vector Machines (SVM), a machine learning algorithm. SVM (Cortes & Vapnik, 1995) has found wide application in the field of pattern recognition and time series analysis. However, despite its success, SVM suffers from several drawbacks (Tipping, 2001) which were overcome in Sparse Bayesian Learning (SBL) algorithms. SBL (Faul & Tipping, 2002) enables exploiting probabilistic Bayesian learning framework to derive accurate prediction models which utilize fewer basis functions than SVM for a comparable problem. A detailed explanation of the mathematical formulations behind SBL regression and classification algorithms is provided in the appendix. For the current work, Relevance Vector Machine (RVM), which is an implementation of SBL, is used. RVM makes predictions based on functions implemented by SVM. SVM uses the function

$$t = f(\mathbf{x}, \mathbf{w}) = \sum_{i=1}^N w_i K(x, x_i) + w_0 \quad (3-2)$$

where $K(x, x_i)$ is a kernel function, effectively defining one basis function for each example in the training set. RVM is a Bayesian treatment of (3-2). The algorithm adopts a fully probabilistic framework and introduces a prior over the model weights governed by a set of hyperparameters, one associated with each weight, whose most probable values are iteratively estimated from the data. Sparsity is achieved because in practice the posterior distributions of many of the weights are sharply (indeed infinitely) peaked around zero. These training vectors, associated with the remaining non-zero weights are termed as 'relevance' vectors'. The mathematical formulations behind RVM can be found in Tipping (2001).

2.3 Genetic programming framework for precipitation downscaling

GP is a biologically inspired machine learning method that allows computer programs to evolve in order to perform a task. The objective of the evolutionary process is to discover an optimal equation (or model) for relating a dependent variable (or predictand) and independent variables (or predictors). However, as the search space of all possible equations is extremely large, particularly in problems involving multivariate time series, the heuristic search has to be restricted to only those equations that follow a specified 'grammar' (or set of rules used to build equations). Figure 3.1, shows a tree represented by the equation $f(x_1, x_2) = x_1 + (x_2 * 10)$. In the tree, the inner connection points (or inner nodes) are called binary arity functions (e.g., '+', '/', '**' in figure 3.1) or non-terminals that require two arguments or sub-trees, whereas the leaf nodes are called terminals, which represent external input variables and constants.



Equation representing the tree: $f(x_1, x_2) = x_1 + (x_2 * 10)$

Figure 3.1 Example of a function tree formed using grammar functions * and +. The equation representing the tree is $f(x_1, x_2) = x_1 + (x_2 * 10)$.

Whatever the type of grammar used, it is essential to specify the list of functions and terminals that will be used to create the derivation trees. A maximum depth of derivation tree (or maximum expression depth) must also be set to halt the generation process and prevent the evolution of too complex (or larger) models. A higher maximum expression depth means more complex equations will likely be produced. Once the grammar is set, the next step is to generate the initial population. In this case, the grow method (Koza, 1999) is used to create the initial population of random individuals (or trees). In the grow method, a tree of arbitrary size is generated by selecting terminals or primitive functions with equal probability. The shape of the optimal tree is found using an evolutionary process as follows:

1. Each individual of the initial generation is evaluated and a score (or fitness) is determined for each population member. Here the score of each individual is based upon the optimization method, the error function and the parsimony. The latter is a weighting added to an individual depending on its tree-size. This term is used to guide the selection towards shorter equations that have the same prediction accuracy as longer equations. For the current work on precipitation, the fitness function used for classification problem is

$$fitness_{cfn} = N_{dry} + N_{wet} - (N_{dry} - N_{wet})^2 \quad (3-3)$$

Where N_{dry} and N_{wet} indicates the number of rightly classified dry and wet days, respectively. The term $(N_{dry} - N_{wet})^2$ penalises those combinations for which one of the N_{dry} and N_{wet} is well determined and the other poorly predicted. For the regression problem (precipitation amount downscaling), the fitness function is given by

$$fitness_{reg} = mean(abs(O - P)) \quad (3-4)$$

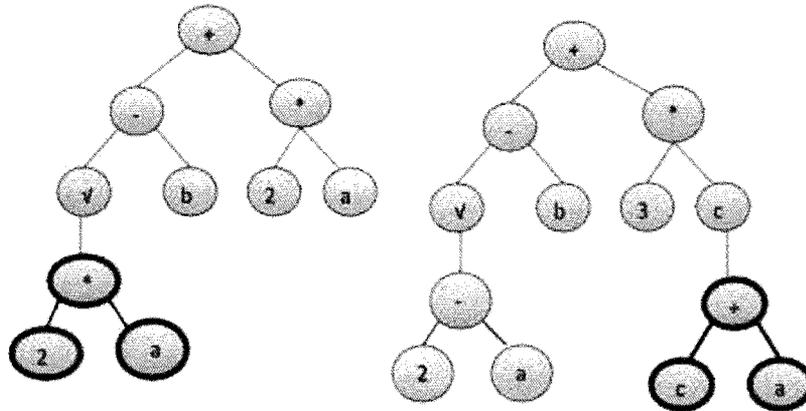
where O and P indicate observed and predicted precipitation amounts, respectively. The best scoring members are selected as “parents” for “reproduction”.

2. Once individuals have been selected as parents for reproduction, three genetic operators (crossover, mutation, and direct reproduction) may be applied to generate a new population. Crossover (figure 3.2) is the process of taking more than one parent and producing a child solution from them. Crossover produces a new population, but it does not introduce any new information into the population. Thus the population can become

more and more homogeneous leading to a premature convergence to a non-optimal solution. To guard against such premature convergence, a mutation of feature is often introduced in the population. Mutation (figure 3.3) alters one or more gene from its initial state. Various types of computational mutations (e.g., branch mutation, node-mutation, etc) may be used to introduce new information into the population. In direct reproduction, the entire individual is simply copied to the next generation without modification.

3. The process goes back to scoring the new population members. The iterative process stops when the specified maximum number of generation (100) is reached or the fitness function reaches its threshold value. For precipitation classification, the threshold value of the fitness function is 2 and for precipitation amount (regression), the same is 0.

PARENTS



CHILDREN

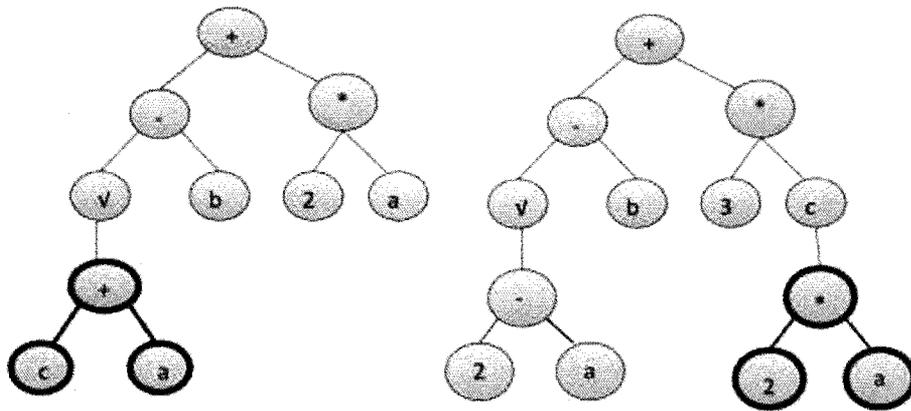
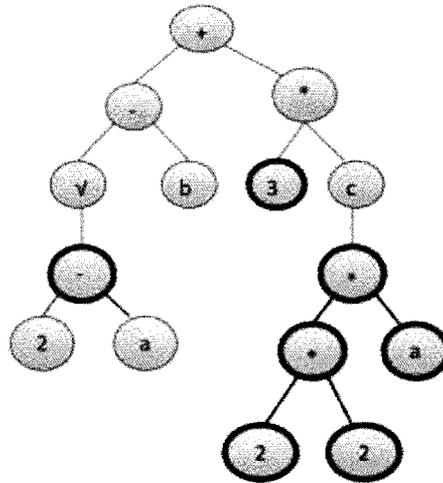


Figure 3.2 Crossover operations for genetic programming. The bold selections on both parents are swapped to create the offspring or children.

ORIGINAL INDIVIDUAL



MUTATED INDIVIDUALS

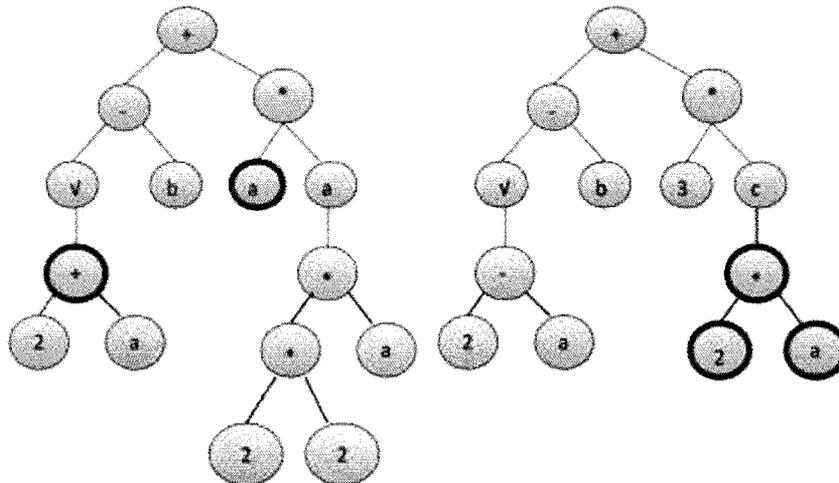


Figure 3.3 Two different types of mutations. The top tree is the original individual. The bottom left tree illustrates a mutation of a single terminal (3) for another single terminal (a). It also illustrates a mutation of a single function (-) for another single function (+). The tree on the extreme right illustrates a replacement of a subtree by another subtree.

A major advantage of this GP method as compared to classic multiple regression, is that the specific model structure is not chosen in advance, but is rather part of the optimization and search process. Another advantage of the GP approach over nonlinear methods such as artificial neural networks is that it provides explicit an model structure (i.e. mathematical equations) that can improve our knowledge of the predictand - predictor relationship.

For this work, the GP algorithm is applied using GPTIPS, a genetic programming toolbox for use with MATLAB. Information about the toolbox can be obtained from <https://sites.google.com/site/GAtips4matlab/>. It provides a number of convenient functions for exploring the population of evolved models, investigating model behaviour, post-run model simplification and export to different formats, e.g. graphics file, symbolic math object or standalone m-file. One of the main features of GPTIPS is that it can be configured to evolve multigene individuals. A multigene individual consists of one or more genes, each of which is a "traditional" GP tree. Genes are acquired incrementally by individuals in order to improve fitness. The overall model is a weighted linear combination of each gene. In GPTIPS, the optimal weights for the genes are automatically obtained, using MLR and SBL by regressing the genes against the output data. The resulting pseudo-linear model can capture non-linear behaviour.

3 STUDY AREAS AND DATA

The two study areas are drainage basins of two rivers located in Eastern Canada. The Moisie river is located on the North shore of the St. Lawrence river, whereas the Ouelle river is located on the south shore of the St. Lawrence. The current study focuses on these two rivers as they sustain Atlantic Salmon (*Salmo salar*) populations. Atlantic Salmon has been regarded as an endangered species (Committee on the Status of Endangered Wildlife in Canada 2011). This has prompted a number of studies related to possible climate change impacts on flow and water temperature on these rivers (Jeong et al. 2012, Morin & Slivitzky 1992), impacts that could lead to important salmon habitat loss.

The locations of discharge and meteorological stations on each of these river basins are shown in figure 3.4. Moisie has one hydrometric station and two meteorological stations located within the limits of its drainage basin. Ouelle has one discharge and one meteorological station, with the former lying within and the latter lying outside the limits of its drainage basin. The details of the meteorological stations are given in table 3.1. The selection of meteorological stations was based on data availability. The alphabets mentioned in brackets in the first column of table 3.1 denote the abbreviation used for the station in subsequent tables and figures. The source of meteorological data for each of the two study areas is the Environment Canada database (<http://www.climate.weatheroffice.gc.ca>).

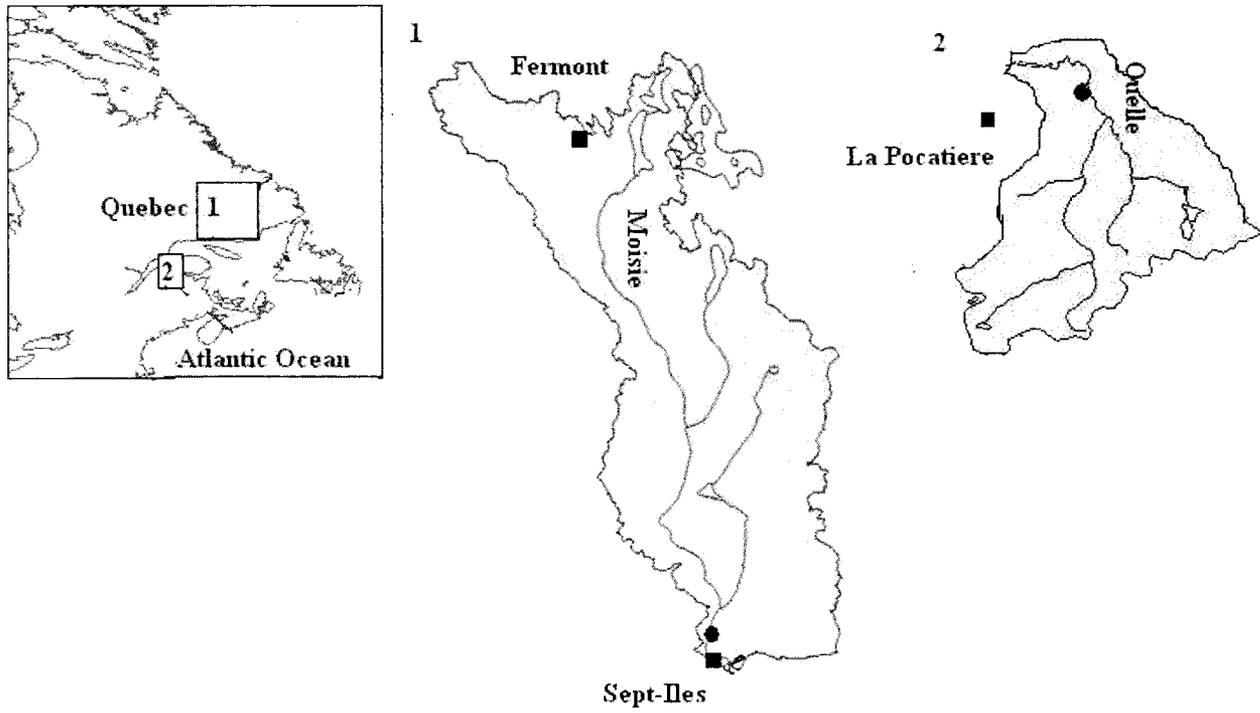


Figure 3.4 Study area map showing the drainage basins and the location of the meteorological and hydrological stations. Meteorological stations are denoted by squares whereas hydrological stations by circles.

Table 3.1 Details of the meteorological stations used in the current work. The alphabet mentioned in brackets in the first column denotes the abbreviation used for the station in subsequent tables and figures.

Station	Latitude	Longitude	Elevation (m)	Available years
Fermont (F)	52°48'0 000" N	67°05'0 000" W	594.40	Oct 1980-Dec 1996
Sept-Iles (S)	50°13'0 000" N	66°16'0 000" W	54.90	Oct 1980-Dec 1996
La Pocatiere (P)	47°21'21.000" N	70°01'55.000" W	31.00	Oct 1969-Sept 1991

Figure 3.5 shows precipitation and temperature (daily average) normals at the selected meteorological stations. The station normals were calculated for a 30 year period (1971-2000). Spatial differences in temperature are evident between stations corresponding to the North shore and south shore locations. The maximum daily average temperature is observed at station La Pocatiere (18.0°C in July) on the South shore, followed by Sept-Iles (15.5°C in July) on the North shore. The minimum daily average temperature is exhibited by Fermont (-23.0°C in January) on the North shore and La Pocatiere (-10.3°C). In addition, potential evaporation (plots not shown) shows an increase from north to south (Burn et al., 2008). Highest annual precipitation is observed at Sept-Iles (1156mm) and lowest at Fermont (806.5mm).

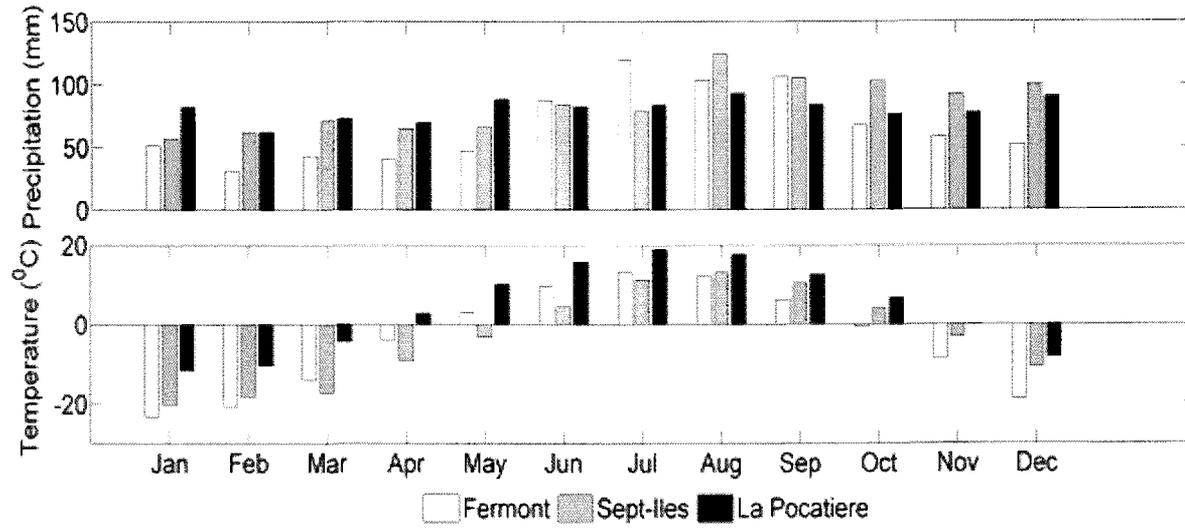


Figure 3.5 Precipitation and temperature normals of the meteorological stations described in table 3.1. Normals were calculated for 30 years (1971-2000).

4 METHODOLOGY

4.1 Statistical Downscaling Framework

The present work compares linear and non-linear downscaling frameworks to downscale predictands (mean temperature and precipitation) at the selected meteorological stations. Twenty NCEP re-analysis variables listed in table 3.2 were considered as predictors. These variables include Relative Humidity (RH), Specific Humidity (SH), Zonal (U), Meridonal (V) and Vertical (ω) components of wind and geopotential height at different pressure levels (1000, 850 and 500 hPa) and Sea Level Pressure (SLP). Reanalysis data from the National Center for Environmental Prediction (NCEP, Kalnay et al., 1996) were used as large-scale atmospheric predictors to calibrate the models and validate the approaches. These datasets are typically viewed as 'observed' large-scale data on a regular grid with a spatial resolution of approximately $2.5^\circ \times 2.5^\circ$ (250 km X 250 km). Each NCEP variable was interpolated at each of the three meteorological stations locations using bilinear interpolation. For a given station, the interpolated data are the weighted average of the data of the four nearest points located on the NCEP grid. To evaluate the prediction performance of the considered frameworks, split sampling was used. The dataset was divided into two subsets. For combination 1 (C1), the first sample was used to calibrate the model and the second was used for validation. For combination 2 (C2), the calibration and validation sets were reversed. The data division into calibration and validation sets and the lengths of the corresponding time series are shown in table 3.3.

Table 3.2 List of predictors selected for the downscaling of precipitation and temperature at the selected meteorological stations.

Number	Predictor Name
1	Air temperature at 2m
2	Geopotential height at 1000hPa
3	Geopotential height at 850hPa
4	Geopotential height at 500 hPa
5	Vertical component of wind at 1000hPa
6	Vertical component of wind at 850hPa
7	Vertical component of wind at 500hPa
8	Relative humidity at 1000hPa
9	Relative humidity at 850 hPa
10	Relative humidity at 500hPa
11	Specific humidity at 1000hPa
12	Specific humidity at 850hPa
13	Specific humidity at 500hPa
14	Sea level pressure
15	U component of wind at 1000hPa
16	U component of wind at 850 hPa
17	U component of wind at 500 hPa
18	V component of wind at 1000hPa
19	V component of wind at 850 hPa
20	V component of wind at 500 hPa

Table 3.3 Combinations of calibration and validation sets used in downscaling precipitation and temperature downscaling. Data sizes in years are indicated in brackets.

Combinations	Moisie	Ouelle
C1	Oct 1980-Sep 1990 (10)	Oct 1969-Aug 1981(~12)
	Oct 1990-Dec 1996 (6)	Oct 1982-Sep1991 (9)
C2	Oct 1990-Dec 1996 (6)	Oct 1982-Sep1991(9)
	Oct 1980-Sep 1990 (10)	Oct 1969-Aug 1981(~12)

For each meteorological station, correlation coefficients were computed between the predictand (local temperature or precipitations) and predictors (large-scale variables). The variables showing significant correlation ($\alpha < 0.05$) were selected for further processing. In an attempt to select parsimonious models, for each station, models formed using top five significantly correlated variables (M5) were compared to the one using all significantly correlated variables (M_all). The comparison was done using RRMSE, RMABE, R^2 and the Akaike Information criteris (AIC, Akaike, 1974) criterion which is given by:

$$AIC = 2k - 2\ln(L) \quad (3-5)$$

where k is the number of parameters in the statistical model, and L is the maximized value of the likelihood function for the estimated model. If the M5 model performed poorly, in comparison to M_all, then the number of input variables was gradually increased until we obtained a model that performed better or equivalently to the M_all model. The selected predictors were further processed using backward stepwise selection in the MLR framework and canonical correlation analysis in the SBL framework. Backward stepwise regression begins with an examination of the combined effect of all of the independent variables on the dependent variable. One by one, independent variables (usually starting with the weakest predictor) are removed, and a new analysis is performed. The results provide coefficients for each independent variable, signifying the degree to which each one, when combined with the others, contributes to predicting the

dependent variable. CCA (Bretherton et al. 1992) constructs variates (linear combinations of the predictors) that share maximum correlation with linear combinations of predictands, while ensuring orthogonality between the newly created variates. Canonical variables or scores were then used as input to RVM. RVM calibration involves only one parameter, which is the width σ of the kernel function used. For the current work, the Gaussian kernel function was used:

$$K(x, x_i) = \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) \quad (3-6)$$

Width values ranging from 0.1 to 4 were used (Ghosh & Majumdar, 2008). For both GP frameworks, all significantly correlated NCEP variables were input into the GP algorithm. The algorithm then formed genes, each of which is a combination of NCEP variables formed using the specified grammar functions ('+', '/', '*'). For the current work, a maximum of four genes (Searson et al., 2010) was selected to form the input to the SBL and MLR algorithms. Table 3.4 summarizes some of the initial system parameters used in this study. The values of the system parameters (e.g., the mutation and crossover rate, the population size) are problem dependent, and were selected by trial-and-error during the model calibration stage.

Table 3.4 Some of the initial system parameters (GPTIPS) used for the GP algorithm.

Description	Value
Size of the population	100
Number of generations to run for (including generation zero)	20
Termination threshold value	0 (precipitation amount) 2 (precipitation classification)
Probability of GP tree crossover.	0.85
Probability of GP tree mutation.	0.1
Probability of GP tree direct copy.	0.05
Maximum number of genes per individual.	4

Precipitation downscaling is performed in two steps: precipitation occurrence (classification) and amount (regression). Precipitation occurrence involves classifying the days as dry and wet where dry days are assigned precipitation amount equal to 0. Regression is then used to predict precipitation amounts for wet days only. Unlike precipitation, temperature is modeled as an unconditional event. The algorithm describing the statistical downscaling frameworks experimented for precipitation and temperature is shown in figure 3.6.

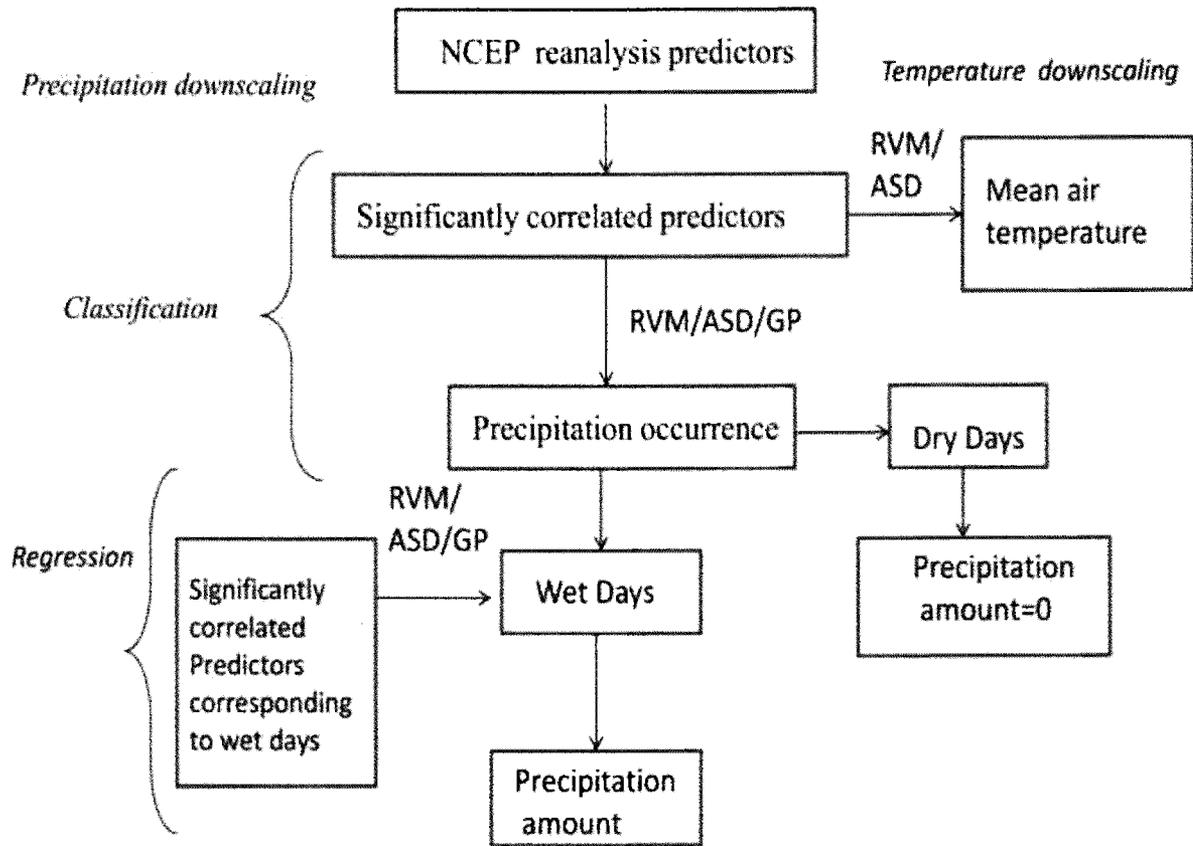


Figure 3.6 Statistical downscaling framework for precipitation and temperature.

4.2 Model Accuracy Measures

The accuracy measures used to evaluate the temperature and precipitation amount downscaling performance of the considered frameworks are the Relative root mean square error (RRMSE), the relative mean absolute bias (RMABE) and the coefficient of determination (R^2).

$$RRMSE = \frac{\sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{N}}}{\text{range}} \quad (3-7)$$

$$RMABE = \frac{\frac{\sum_{i=1}^N |O_i - P_i|}{N}}{\text{range}} \quad (3-8)$$

$$R^2 = \left(\frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \right)^2 \quad (3-9)$$

where N is the total number of points, O_i and P_i indicate the i^{th} observed value and predicted value, respectively. \bar{O} and \bar{P} denote observed and predicted means, respectively, and 'range' denotes $\max(\text{observed}) - \min(\text{observed})$.

Precipitation classification results were evaluated in the form of percentage of rightly classified total, dry and wet days. The occurrence of wet or dry days is assumed to be a stochastic process, represented by a first-order Markov chain (Nicks et al., 1990). To generate wet and dry days, the probabilities $p(w|w)$ and $p(w|d)$ are used. $p(w|w)$ is defined as the probability of having a wet day preceded by a wet day (wet-wet) = $N(w|w)/N(w)$ and $p(w|d)$ is defined as the probability of having a wet day preceded by a dry day (dry-wet) = $N(w|d)/N(w)$ where, $N(w|w)$: number of wet days preceded by a wet day, $N(w|d)$: number of wet days preceded by a dry day and $N(w)$: total number of wet days. The complementary dry-dry ($p(d|d)$) and wet-dry ($p(d|w)$) probabilities are computed as: $p(d|d) = 1 - p(w|d)$ and $p(d|w) = 1 - p(w|w)$.

5 RESULTS

This section states the result of temperature and precipitation downscaling. Split sampling was used to validate the models and the model resulting in the best RRMSE, RMABE and R^2 values for validation set is considered as the best model with a minimum chance of overfitting. The selected NCEP reanalysis variables were first checked for their correlations with precipitation and temperature. From the perspective of parsimony, it was observed that the M5 model lead to lower AIC values and comparable values of the performance indices, for both temperature and precipitation, for all stations, except Sept-Iles. For this station, the M5 model for precipitation performed poorly in comparison to M_all. Therefore, the numbers of input variables were gradually increased from five until a model performing comparably/superior to M_all was obtained. The model using top 10 significantly correlated variables (M10) was found to perform comparably to M_all and also resulted in lower AIC value than the latter. Therefore, for Sept-Iles, precipitation downscaling was performed using top 10 significantly correlated variables as input.

5.1 Temperature downscaling results

The predictors selected by for temperature and precipitation downscaling are shown in table 3.5. Figures 3.7 and 3.8 show temperature downscaling results for both calibration and validation combinations. It is evident from both figures that SBL performs better than MLR in downscaling temperature. As an example, the RRMSE, RMABE and R^2 validation values for Sept-Iles given by SBL for C1 are 0.075, 0.055 and 0.91 and by MLR are 0.086, 0.066 and 0.90, respectively. For C2, the same given by SBL are 0.06, 0.052 and 0.90 and by MLR are 0.078, 0.062 and 0.89, respectively. It can be seen that for all stations the percentage of total number of sample points used for making prediction is less than equal to 5%. The highest number of sample points are used for La Pocatiere for C2 (5%) and lowest for Fermont for both C1 and C2 (1%).

Table 3.5 Predictors selected for temperature and precipitation downscaling for set 1 and set 2. The numbers refer to the corresponding predictors mentioned in table 3.2. Alphabets refer to the stations mentioned in table 3.1.

Stations/ Variables	Temperature	Precipitation
Fermont (F)	11,4,12,1,13	13,7,6,5,19
Sept-Iles (S)	11,4,12,1,13	6,7,19,5,15,13,10,20,9,8
La Pocatiere (P)	11,4,12,1,3	15,19,7,13,6

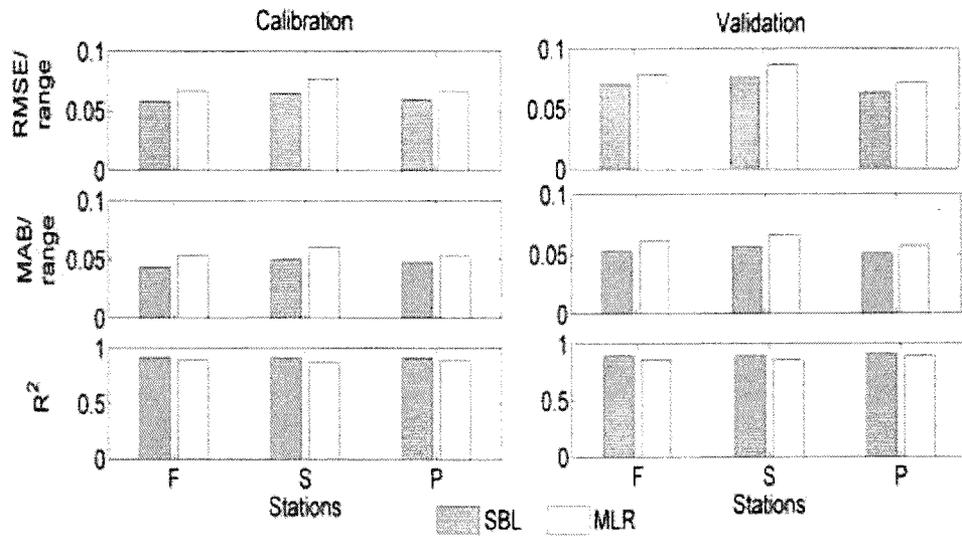


Figure 3.7 SBL (RVM) and MLR (ASD) temperature downscaling results for C1. White bars represent MLR whereas gray bars represent SBL results.

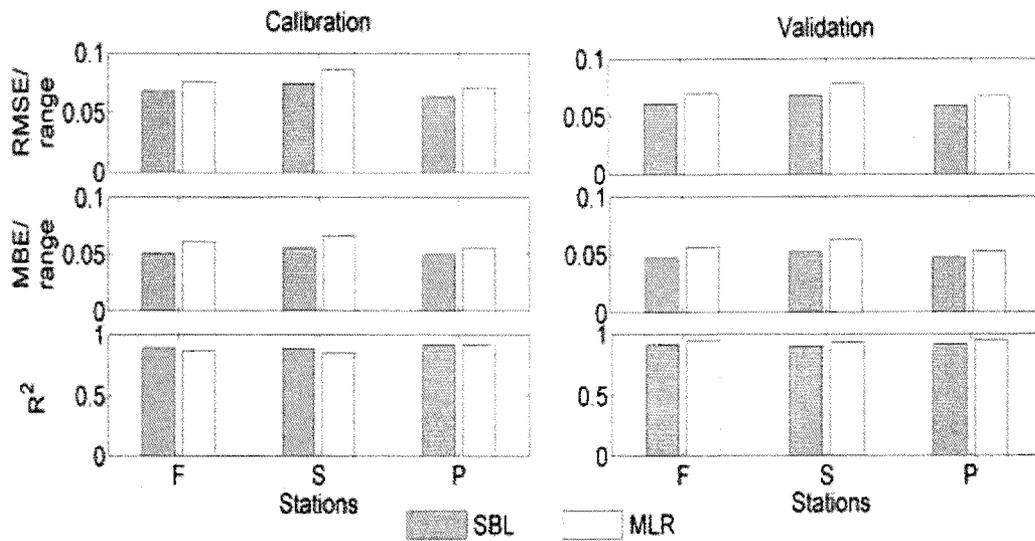


Figure 3.8 SBL (RVM) and MLR (ASD) temperature downscaling results for C2. White bars represent MLR whereas gray bars represent SBL results.

5.2 Precipitation Results

This subsection is subdivided into four parts. The first two parts describes the comparison of classification results given by SBL, MLR, SBLGP and MLRGP frameworks in terms of the selected performance indices (RRMSE, RMABE and R^2) and transition probabilities (described in the previous section). The third and fourth subsections compare the regression results given by these methods for the entire dataset and two seasons: Winter (December-March) and Summer (July-October).

5.2.1 Classification Results

The results of precipitation classification are shown in figures 3.9 and 3.10. The percentage of relevant vectors used for prediction by SBL and SBLGP algorithms lie in the range 1-5% for all stations. All methods give better classification for dry days, in comparison to wet days. The correctly identified dry days lie in the range 80-90% whereas the correctly identified wet days are in the range 45-75%. For wet day classification, SBLGP outperforms all methods, in all cases. For dry day classification, in the case of stations La Pocatiere and Fermont, MLRGP and MLR outperform SBLGP. For example, for La Pocatiere, the percentage of corresponding correctly identified dry days in the validation set of combination C1 are 87, 84 and 86% for MLR, SBLGP and MLRGP, respectively. MLR is seen to outperform MLRGP in some cases. For example, for the validation set corresponding to C1 for station Fermont, the percentage of rightly classified dry days given by MLR and MLRGP are 87% and 85%, respectively. Another example is of station Sept-Iles for which MLR and MLRGP give 70 and 68% of rightly classified wet days for the validation set of C2. In some cases, MLR and MLRGP perform comparably in identifying wet and dry days. Station Sept-Iles for the validation sets of C1 and C2 exemplifies this observation, where the percentage of appropriately classified dry days given by MLR and MLRGP are 87% for C1 and 90% for C2. Comparison of SBL and MLR shows that both methods give equivalent performance in classifying wet and dry days. For C1, for all stations, wet days are better classified by SBL and dry days by MLR. For C2, both methods give comparable results for dry days. For wet days corresponding to C2, SBL performs better than MLR for Fermont and La Pocatiere. Equivalent results are observed for Sept-Iles.

Of all stations, the highest number of rightly classified days is obtained for Sept-Iles for both combinations. For this station, the percentage of rightly classified total (both wet and dry) days given for the validation set of C1 by SBL, MLR, SBLGP and MLRGP are 80, 80, 82 and 80%

respectively. The lowest number of correctly identified days is seen for Fermont. For this station, the percentage of rightly classified total days given for the validation set of C1 by SBL, MLR, SBLGP and MLRGP are 71, 71, 73 and 71 % respectively.

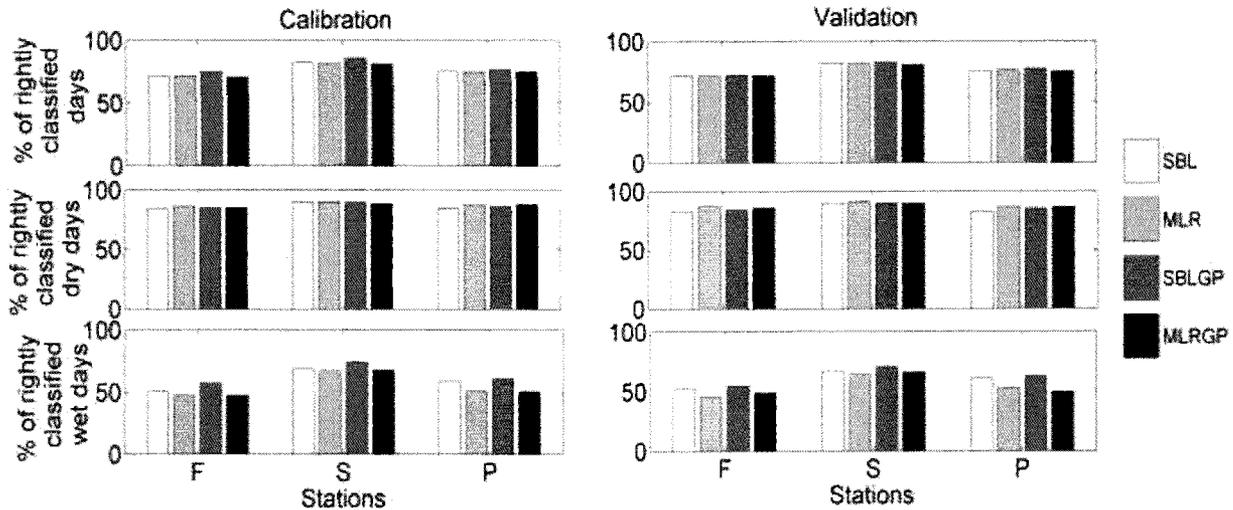


Figure 3.9 Comparison of classification results given by SBL, MLR, SBLGP and MLRGP for combination C1. White bars represent SBL, light gray bars represent MLR, dark gray bars represent SBLGP and black bars show MLRGP results.

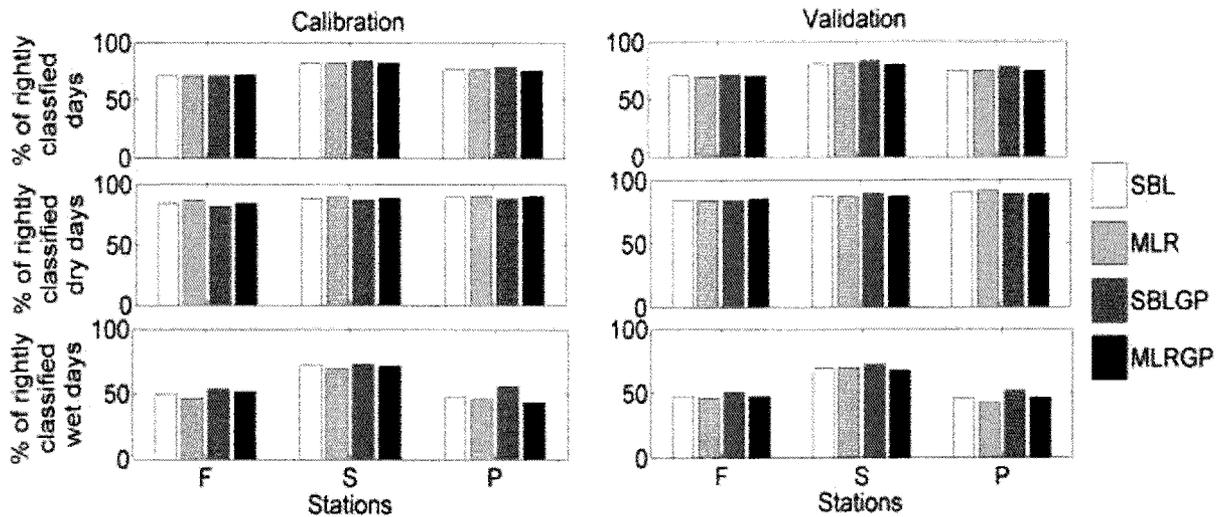


Figure 3.10 Comparison of classification results given by SBL, MLR, SBLGP and MLRGP for combination C2. White bars represent SBL, light gray bars represent MLR, dark gray bars represent SBLGP and black bars show MLRGP results.

5.2.1.1 Comparison of transition probabilities

In another comparison of the classification abilities of the methods, wet and dry day transition probabilities given by SBL, MLR, SBLGP and MLRGP for C1 are compared to the observed values (table 3.6-table 3.7). These probabilities are calculated using the entire dataset (calibration and validation sets corresponding to C1, combined). It is seen that for both combinations, dry day transition probabilities (wet-dry and dry-dry) are overestimated and wet day transition probabilities (dry-wet and wet-wet) are underestimated by both methods. Among all the methods, SBLGP gave better values of the transition probabilities for both combinations except for Fermont. For this station, SBLGP and MLRGP give equal values of $p(w|w)$ (0.43) and $p(d|w)$ (0.57). MLR and MLRGP perform comparably in all cases. SBL is observed to outperform MLR in all cases. The absolute differences between observed and estimated values of $p(w|d)$ and $p(d|d)$ values given for La Pocatiere by SBL are 0.02 and 0.05 and by MLR are 0.02 and 0.07, respectively.

Table 3.6 Comparison of wet day transition probabilities obtained for C1. 'Obs' refers to observed values and 'Stn' indicates the stations. The alphabets denoting the station names are shown in table 3.1.

Stn.	$p(w w)$					$p(d w)$				
	Obs.	SBL	MLR	SBLGP	MLRGP	Obs.	SBL	MLR	SBLGP	MLRGP
F	0.52	0.40	0.40	0.43	0.43	0.48	0.60	0.60	0.57	0.57
S	0.46	0.40	0.39	0.44	0.40	0.54	0.60	0.61	0.56	0.60
P	0.43	0.39	0.35	0.41	0.35	0.57	0.61	0.65	0.59	0.65

Table 3.7 Comparison of dry day transition probabilities obtained for C1. 'Obs' refers to observed values and 'Stn' indicates the stations. The alphabets denoting the station names are shown in table 3.1

Stn	$p(w d)$					$p(d d)$				
	Obs.	SBL	MLR	SBLGP	MLRGP	Obs.	SBL	MLR	SBLGP	MLRGP
F	0.30	0.21	0.21	0.22	0.21	0.70	0.79	0.79	0.78	0.79
S	0.31	0.28	0.26	0.29	0.27	0.69	0.72	0.74	0.71	0.73
P	0.29	0.27	0.22	0.28	0.22	0.71	0.73	0.78	0.75	0.78

5.2.2 Precipitation amount downscaling results

The regression results are shown in figures 3.11 and 3.12. In comparison to the other considered methods, SBLGP gives better values of RRMSE, RMABE and R^2 for all stations except for Fermont. For this station, SBLGP and SBL perform equivalently for the validation sets of both combinations, C1 and C2. The RRMSE, RMABE and R^2 validation values for C1 given by SBLGP are 0.07, 0.03 and 0.20 and the same given by SBL are 0.07, 0.035 and 0.16, respectively. The respective values given for C2 by SBL are 0.08, 0.038 and 0.38 and by SBLGP are 0.082, 0.037 and 0.33.

As observed for classification, in some cases, MLR performs comparably or outperforms MLRGP. For example, for Sept-Iles, MLR outperforms MLRGP for the validation set of C1 and the latter outperforms the former for C2. For Fermont, both methods perform equivalently for both validation sets of C1 and C2. For this station and C1, the RRMSE, RMABE and R^2 values given by MLR are 0.07, 0.036 and 0.16 and for MLRGP are 0.071, 0.034 and 0.15, respectively. For C2, the RRMSE, RMABE and R^2 values given by MLR are 0.08, 0.04 and 0.16 and by MLRGP are 0.08, 0.04 and 0.11, respectively.

Comparison of SBL and MLR shows that both methods performed equally in terms of the chosen performance indices. For La Pocatiere, the RRMSE, RMABE and R^2 validation values given by SBL are 0.058, 0.030 and 0.20. The same indices for MLR are 0.057, 0.028 and 0.20, respectively. Like classification, for regression too SBLGP utilized fewer sample points than SBL for prediction. The percentage of relevant vectors used by SBLGP and SBL for regression is in the range 1-6% and 1-5%, respectively, which is an indication of a relatively parsimonious model.

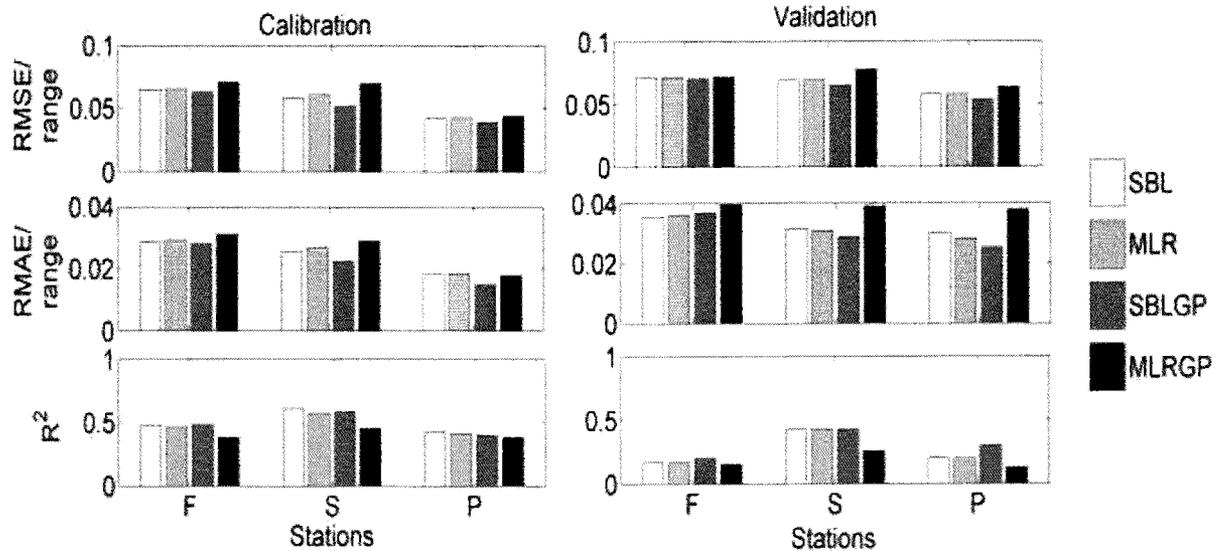


Figure 3.11 Regression results given by SBL, MLR, SBLGP and MLRGP for combination C1. White bars represent SBL, light gray bars represent MLR, dark gray bars represent SBLGP and black bars show MLRGP results.

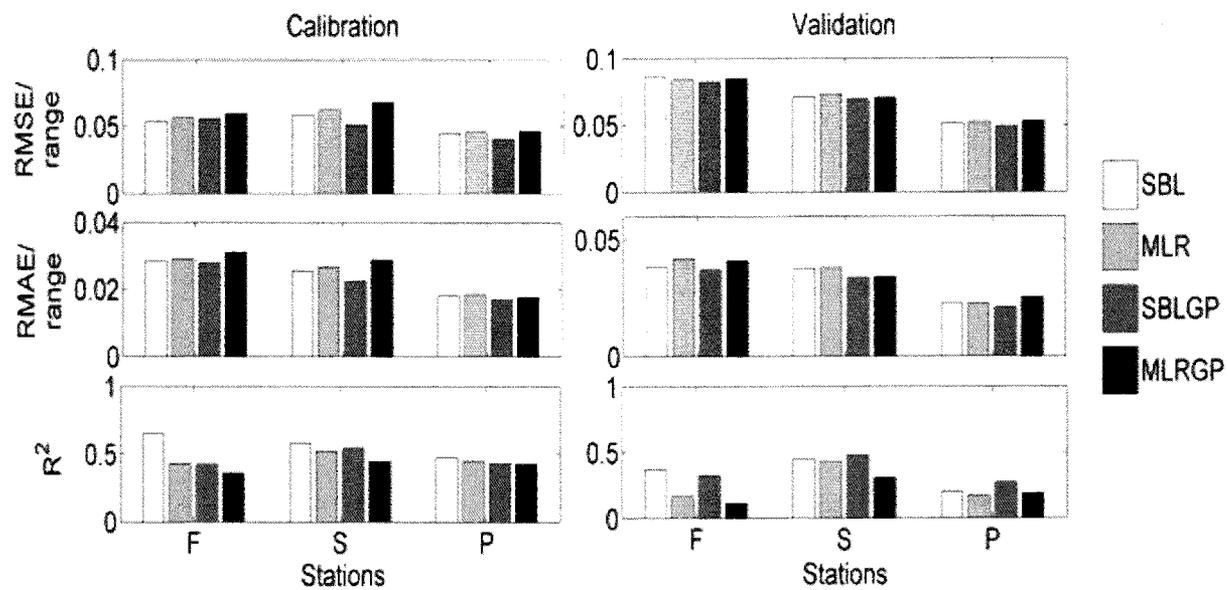


Figure 3.12 Regression results given by SBL, MLR, SBLGP and MLRGP for combination C2. White bars represent SBL, light gray bars represent MLR, dark gray bars represent SBLGP and black bars show MLRGP results.

5.2.2.1 Seasonal results

Further analysis of precipitation amount downscaling was done by comparing the methods for two seasons: Winter (December-March) and Summer (July-October). Figure 3.13 shows RRMSE, RMABE and R^2 validation results given by SBL, MLR, SBLGP and MLRGP for winter and summer seasons for C1. It is seen that SBLGP performs better than the other considered methods for all stations. The RRMSE, RMABE and R^2 values for winter given by this method for Fermont are 0.14, 0.08 and 0.17 and for summer are 0.12, 0.06 and 0.15, respectively. MLRGP is outperformed by MLR for all station for both seasons. The RRMSE, RMABE and R^2 values given for Sept-Iles by MLRGP are 0.08, 0.04 and 0.26 and by MLR are 0.074, 0.032 and 0.41, respectively. Between SBL and MLR, both methods give comparable values of performance indices for all stations. The RRMSE, RMABE and R^2 values given for Fermont by SBL are 0.143, 0.081 and 0.167, respectively. The same given for MLR are 0.144, 0.083 and 0.169, respectively.

For winters, best results are given by Sept-Iles for all methods. The corresponding RRMSE, RMABE and R^2 values given for SBLGP for Sept-Iles are 0.070, 0.028 and 0.40, respectively. For summer, the best results are obtained for La Pocatiere by all methods. The RRMSE, RMABE and R^2 values given SBLGP are 0.062, 0.027 and 0.18, respectively.

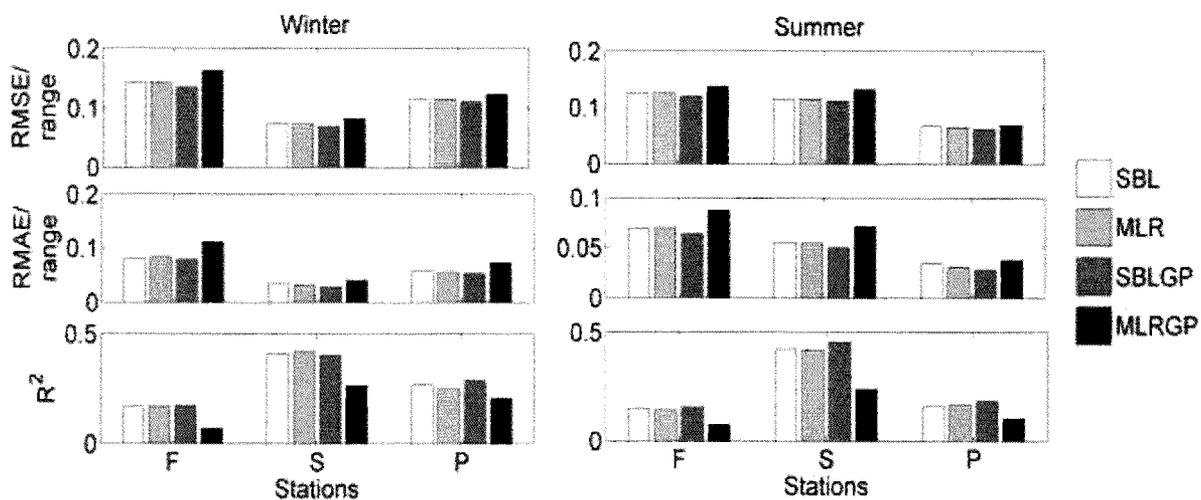


Figure 3.13 RRMSE, RMABE and R^2 results of winter and summer seasons obtained for C1. White bars and gray bars represent SBL and MLR results.

6 DISCUSSION

Based on the results shown in the previous section, it can be said that SBL outperformed MLR in downscaling temperature. Temperature was well downscaled by both methods and resulted in correlation values greater than 0.90, for all stations. According to the R^2 values obtained for SBL, MLR, SBLGP and MLRGP, the corresponding correlation lies between 0.30- 0.77, which for daily climatic time series is satisfactory, in particular considering the stochastic character of daily precipitation (Hessami et al., 2008). The relatively low explained variances given for precipitation by all methods underline the difficulty to downscale the precipitation regime compared to the temperature.

For precipitation, SBLGP outperformed all the other methods in classification results. For all methods, dry days were better classified than wet days. The introduction of GP as predictor selection method did not improve the percentage of rightly identified dry days. In some cases, SBL and MLR outperformed both GP frameworks (SBLGP and MLRGP). For all stations, the percentage of rightly classified wet days did show marked improvements for SBLGP. However, MLRGP was surpassed by MLR, in some cases. For example, the percentages of rightly classified wet days corresponding to La Pocatiere given by MLRGP and MLR, for the validation set of C2 were 50 and 53%, respectively.

In comparison to other methods, SBLGP gave better regression results for all stations. This observation could be attributed to the improved classification results (particularly wet days) given by SBLGP for all stations. Like classification, in some cases MLRGP outperformed MLR in regression results for amounts. This observation may be the result of reduction in the number of correctly identified wet days while dry days remained more or less at the same level. An example of this is the validation result obtained for La Pocatiere for C1. The corresponding RRMSE, RMABE and R^2 values given by MLRGP were 0.063, 0.038 and 0.13 and by MLR were 0.057, 0.028 and 0.20, respectively.

Both SBL frameworks (SBLGP and MLRGP) used fewer numbers of parameters than the MLR frameworks. The former also involved greater computation time and memory, in comparison to the latter. These two factors can be accounted for by implementing the algorithm using lower level languages such as C and C++ and using larger memory computers. MLR, on the other hand used the entire sample space for making prediction and also involved lesser computation time.

An important factor found to influence the results of GP is the fitness function used for optimization. For this study, different optimization functions such as root mean square error (RMSE), coefficient of determination (R^2) and mean absolute bias (MAB), were tried and they were found to give different results. According to a study done by Willmott and Matsuura (2005), MAB was reported to be a better measure of average error, in comparison to RMSE. RMSE was regarded inappropriate because it is a function of 3 characteristics of a set of errors, rather than of one (the average error). RMSE varies with the variability within the distribution of error magnitudes and with the square root of the number of errors ($n^{1/2}$), as well as with the average-error magnitude (MAE). R^2 values may also be high even if the model systematically over- or underpredicts all the time. Therefore, MAB was ultimately selected as the optimization function. Similarly, different results were observed for precipitation classification when a different optimization function was used, such as $N_{wet} + N_{dry}$, where N_{dry} and N_{wet} are percentage of rightly classified dry and wet days, respectively. It was observed that for this optimization function, models resulting in higher values of N_{dry} and lower values of N_{wet} were getting selected if their corresponding sum is higher than the model with comparable values of the two. For example, a model with $N_{dry}=90\%$ and $N_{wet}=10\%$ will get selected over a model with $N_{dry} = 50\%$ and $N_{wet}=40\%$. Therefore, a penalty function $(N_{dry} - N_{wet})^2$ was added to sum, $N_{wet} + N_{dry}$. Keeping aside the extent of convergence criteria, the results of GP may rely on the predictors selected as parents to form the initial population, as they govern the nature of the next generation determined using selection, crossover and mutation processes.

7 CONCLUSION

The present work compares two frameworks to downscale mean temperature and four frameworks to downscale precipitation at three meteorological stations. The first framework involves backward stepwise regression whereas the second is a non-linear SBL framework which includes input preparation using canonical correlation analysis. For precipitation downscaling, two more frameworks involving the application of genetic algorithm as predictor selection method for both SBL and MLR algorithms were applied.

The results indicated that SBL performed better than MLR in downscaling temperature. For all stations, temperature was better downscaled than precipitation. For precipitation downscaling, SBLGP framework gave better classification and regression results, in comparison to the other considered methods. In some cases, MLR was seen to outperform MLRGP for classification as well as regression. Dry days were better classified than wet days. Between SBL and MLR, the latter could be regarded as a better approach for precipitation downscaling. This is because MLR is characterised by a simple, computationally inexpensive algorithm and also performed equally well as SBL.

Both SBL frameworks (SBL and SBLGP) supported sparsity by using fewer parameters. However, both methods also required greater computation time and memory. Applying the algorithm using lower level computer languages may prove helpful in accounting for the computational requirements of the algorithm. The application of SBL with other predictor selection methods (fuzzy logic, classification and regression trees) can be regarded as an extension of this work.

CHAPITRE 4

COMPARISON OF DIRECT STATISTICAL AND INDIRECT STATISTICAL-DETERMINISTIC FRAMEWORKS IN DOWNSCALING RIVER LOW-FLOW INDICES

Deepti Joshi¹, Andre St-Hilaire¹, Taha Ouarda^{1,2}, Anik Daigle^{1,3}, Nathalie Thiemonge⁴

¹ INRS-ETE, University of Quebec, 490 de la Couronne, Quebec G1K 9A9, Canada (joshi.deepti@ete.inrs.ca, andre.st-hilaire@ete.inrs.ca, anik.daigle@ete.inrs.ca)

² Masdar Institute, Professor , Head - Water , Environmental Engineering, PO Box 54224, Abu Dhabi, United Arab Emirates (touarda@masdar.ac.ae, taha.ouarda@ete.inrs.ca)

³ Cégep Garneau, 1600 boulevard de l'Entente, Québec, G1S 4S3, Canada.

⁴ Ingénieure en hydrologie– Équipement, Unité Conception des aménagements de production Hydrauliques et géotechniques (Thiemonge.Nathalie@hydro.qc.ca)

Corresponding author : Deepti Joshi

Article soumis à Hydrological Sciences Journal le 17 juillet 2013

The content of this article is the result of the work done by the first author under the supervision of the co-authors. The implementation of the idea behind the work and evaluation of results were done by Deepti Joshi in collaboration with Professor St-Hilaire, Professor Ouarda and Anik Daigle. The calibration of the considered hydrological model (SSARR) was done by Deepti Joshi with the help of the optimisation algorithm prepared by Anik Daigle and Nathalie Thiemonge. The presentation of results in the form of a manuscript was done by Deepti Joshi and reviewed by the co-authors.



ABSTRACT

This work explores the ability of two methodologies in downscaling hydrological indices (HIs) characterising the low flow regime of three salmon rivers in Eastern Canada: Moisie, Romaine and Ouelle. The selected indices describe four aspects of the low flow regime of these rivers: amplitude, frequency, variability and timing. The first methodology (direct downscaling) ascertains a direct link between large scale atmospheric variables (the predictors) and low flow indices (the predictands). The second (indirect downscaling) involves downscaling precipitation and air temperature (local climate variables) that are introduced into a hydrological model to simulate flows. Synthetic flow time series are subsequently used to calculate the low flow indices. The statistical models used for downscaling low flow HIs and local climate variables are: Sparse Bayesian Learning and Multiple Linear Regression. The results showed that direct downscaling using Sparse Bayesian Learning surpassed the other approaches with respect to goodness of fit and generalization ability.

Keywords: Statistical downscaling, Relevance Vector Machine, Multiple Linear Regression, Canonical Correlation Analysis, Low flows, Hydrological modeling

1 INTRODUCTION

Water-related disasters, i.e. floods and droughts, have been more devastating overall than other natural hazards (earthquakes, volcanoes, etc.) as far as deaths, suffering, and economical damages are concerned. Many climate change scenarios predict that the frequency of occurrence and amplitude of climatic and hydrologic extremes are likely to be affected within the next 100 years. These extremes are important for decision making in water resources. In particular, information on low flows is relevant for several purposes such as industrial needs, agricultural demands, water pollution control requirements and environmental flows.

In the literature, a number of hydrological indices (HIs) describing different aspects of a river low flow regime have been proposed. Indices have been developed and tested in particular regions in terms of biologically relevant flow variables, to describe the overall variability in regional hydrologic regimes and to quantify low flow characteristics sensitive to various forms of human perturbations (Olden and Poff, 2003). Despite the significant amount of specialist knowledge that has accumulated in the field of low flow hydrology, specific understanding of processes associated with low flows in diverse climatic, topographical and geological conditions is rather limited, due to scarce experimental low flow studies. According to Smakhtin (2001), considering the growing attention to climate variability, the specific issue of low flow change under altering climatic conditions requires additional research.

A crucial step in the development of tools for climate change impact assessment was the development of global atmospheric general circulation models (GCMs), which simulate the present climate and generate scenarios of future climate change. GCMs exhibit significant skill at hemispheric and continental spatial scales and incorporate a large proportion of the complexity of the global system but are inherently unable to represent local sub-grid scale features (Wigley et al., 1990) such as topography, cloud cover and land use. The focus of most of the climate change impact studies is primarily on societal responses to local and regional consequences of large-scale changes. As a consequence embedding schemes linking GCMs to meteorological and hydrologic models resolved at finer scales were proposed and implemented. The use of deterministic hydrologic models for assessing the impacts of climate change on hydrological regimes has several advantages (Xu, 1999). Deterministic models are meant to conceptually represent the physical processes underpinning the hydrological budget for a drainage basin or sub-basin. Many models tested for different climatic/physiographic conditions

are readily available. Additionally, the coupling of hydrological models with outputs from large-scale GCMs can be well suited to take advantage of continuing improvements in the resolution of climate models. Although the coupling of GCMs with hydrological models facilitates the understanding of the effects of large scale changes on regional hydrologic variability, this framework is constrained by gaps between the GCMs resolution and the need to describe potential hydrological changes at a relatively fine scale. According to Xu (1999), these gaps are characterized by spatial and temporal scale mismatches, vertical level mismatches and the mismatches between accuracy of GCM outputs and the hydrological importance of the variables.

To narrow these gaps, the climate research community put a considerable effort towards the development of 'downscaling techniques'. Two fundamental approaches exist for the downscaling of GCM outputs (Wilby et al., 2004): dynamical and statistical (also known as empirical) approaches. Dynamical approaches involve running regional climate models (RCMs) with GCM outputs as boundary conditions to simulate processes at a finer scale. However, RCMs are computationally expensive, and their application is sometimes temporally and spatially limited. Statistical Downscaling (SD) approaches derive mathematical relationships between broad scale variables (predictors), obtained from reanalysis data, and fine scale surface conditions (predictands). With the advent of SD techniques, the initial steps of providing hydrological information for impact studies of climate change on hydrology were then typically viewed as a two step approach (referred to as 'indirect downscaling' (ID) henceforth): (1) GCM outputs (predictors) are used to generate local downscaled climate conditions (predictand) such as temperature or precipitation and, (2) the downscaled variables are introduced into a hydrologic model to get future projections of possible hydrological changes.

This two step downscaling framework is usually constrained in space by the domain of calibration of the hydrological model. Additionally the data requirement for adjusting the model parameters may be large, particularly for conceptual and fully distributed hydrological model, for example SWAT (Eckhardt et al., 2005). Simple models have a smaller range of applications and can give adequate results at greatly reduced costs while the models characterized by complexity in terms of structure and data requirements provide adequate results for a wide range of applications. In an attempt to circumvent these shortcomings, few studies (Canon and Whitfield, 2002; Ghosh and Majumdar, 2008; Tisseuil et al., 2010) tried to establish a direct link between streamflows and GCM outputs. Such a direct link (referred to as direct downscaling (DD) henceforth) has been criticised primarily due to lack of consideration of water stores and

transfers within the soils and groundwater of a catchment (Xu, 1999). However, seeking such a direct association between river flows and GCM outputs may be relevant to facilitate the generalisation and extrapolation of predictand simulations over large scales (Tisseuil et al., 2010).

In this study, DD and ID strategies linking low flow HIs to large scale atmospheric variables were explored for three salmon rivers in the province of Quebec, Canada. The statistical models experimented for their downscaling abilities were Sparse Bayesian Learning (SBL) and Multiple Linear Regression (MLR). On the basis of literature review, it was found that the former finds scarce applications in downscaling studies, particularly in North America, while the latter has been frequently applied (Nieto and Wilby, 2005; Gachon and Dibike, 2007; Dibike et al., 2008). Also, to our knowledge no downscaling study has been conducted for low flow HIs. This study will thus address the following questions:

1. Which of the two statistical models (SBL and MLR) performs best in downscaling low flow HIs from NCEP reanalysis atmospheric variables?
2. Does the inclusion of a hydrological model (ID framework) improve the downscaling performance, or could the characteristics of low flow HIs be well reproduced by establishing a direct link to NCEP reanalysis atmospheric variables (DD framework)?
3. Is the considered downscaling framework relevant with respect to future climate change impact studies? As an example, future projections of low flow indices are shown using three emission scenarios (A1B, A2 and B1) of GCM (ECHAM5) and one scenario (A2) of Canadian Regional Climate Model (CRCM; Driving GCM: CGCM3).

2 STATISTICAL DOWNSCALING FRAMEWORK

The statistical downscaling framework (figure 4.1) used in this work is built on a comparative approach that has three aspects. Two statistical models were applied to two downscaling methodologies to quantify the relationship between NCEP atmospheric variables and low flow HIs for three rivers: Moisie, Romaine and Ouelle. As mentioned in the introduction, the two downscaling methodologies were

- Direct Downscaling (DD)
- Indirect Downscaling (ID)

DD methodology directly links NCEP atmospheric variables with the low flow HIs. ID is a two step approach where the NCEP atmospheric variables are first linked with local climate variables (such as precipitation and air temperature) and thereafter, the downscaled local climate variables are introduced into a hydrological model to simulate flows from which low flow HIs are calculated. The statistical models selected to establish these links were

- Relevance Vector Machine (RVM), that enforces SBL algorithm (described in the following section), and
- The Automated Statistical Downscaling (ASD; Hessami et al., 2008) tool that implements MLR

In the ID methodology, the hydrological model chosen for simulating flows from the downscaled local climate variables was the Streamflow Synthesis and Reservoir Regulation (SSARR) model. Details of RVM, ASD and SSARR are given in the following subsections. Inputs to both the methodologies were prepared in the following manner:

1. Correlations were calculated between monthly, seasonal and yearly values of NCEP reanalysis variables and predictands. The predictands for DD were low flow HIs. For ID, the predictands were inputs to the hydrological model, SSARR, i.e. mean air temperature and precipitation.
2. The significantly correlated series ($\alpha < 0.05$) were then subjected to canonical correlation analysis (CCA) and the canonical variable scores were introduced into the RVM algorithm. CCA (Busuoic et al., 2007) looks for a linear combination of predictors that are optimally correlated with the predictand.

3. For ASD, the significantly correlated variables underwent backward stepwise regression. Backward stepwise regression (McCuen, 2003) starts with all the terms in the model and removes the least significant terms until all the remaining terms are statistically significant.

Combining the two statistical downscaling models (RVM and ASD) and two downscaling methodologies (DD and ID) gave the following approaches:

1. DD using statistical models
 - RVM (DD1)
 - ASD (DD2)
2. ID involving hydrological model, SSARR, with the following inputs:
 - RVM downscaled values of precipitation and temperature (ID1) and
 - ASD downscaled values of precipitation and temperature (ID2)
3. Introducing observed values of precipitation and temperature into SSARR to simulate flows and hence low flow indices. This approach eliminates the biases present in the reanalysis data and is referred to as 'Partial Validation Approach' (PVA).

Projections of low flow HIs were produced to illustrate an application of the downscaling framework for future climate change impact studies. These projections are based on three scenarios, A1B (high emission), A2 (medium-high emission) and B1 (low emission), (IPCC report, Emission Scenarios, 2007) from GCM, ECHAM5 (Roeckner et al., 2003) and one scenario A2 from CRCM (Jiao and Caya, 2006). ECHAM5 is currently the most recent version of ECHAM, a global climate model developed by the Max Planck Institute for Meteorology. CRCM is a regional climate model developed in collaboration between Canadian Regional Climate Modeling and Diagnostics network, the ESCER centre of university of Quebec at Montreal and the Ouranos Consortium on regional climatology and adaptation to climate change. The CRCM model used here is driven by GCM, CGCM3 following greenhouse gas and aerosol concentration according to scenario A2.

Two time periods: 2021-2050 (20s) and 2051-2080 (50s) were investigated for relative change (RC) in median and variability of the low flow HIs with respect to the baseline period (1961-2010). RC was calculated as the difference between future projected and observed (1961–2010) flow condition, divided by the observed condition.

The future projections of low flow HIs were made in the following manner:

1. Daily outputs of the selected atmospheric variables were extracted for scenarios A1B, A2 and B1 for ECHAM5 and scenario A2 for CRCM.
2. These predictors were bilinearly interpolated (Lo et al, 2008; Tisseuil et al 2010) to obtain ECHAM5 and CRCM outputs at the selected discharge/meteorological stations and yearly, monthly and seasonal series of the resulting interpolated variables were calculated.
3. The yearly/monthly/seasonal series of NCEP reanalysis variables, exhibiting significant correlation with the low flow HIs, were selected and the corresponding subsets from ECHAM5 and CRCM outputs (obtained in step 2) were selected as predictors for future projections.
4. These predictors were used as inputs in the statistical models (developed using NCEP reanalysis variables). Canonical variates were used for RVM and predictors selected by stepwise regression were used for ASD to generate scenarios of low flow indices for future time periods (20s and 50s).
5. The criteria of comparison between the projections are relative change (RC) in the median and variability of the indices in the future time periods: 2021-2050 (20s) and 2051-2081(50s) with respect to the baseline period (1961-2010). RC is calculated as:

$$RC = \frac{\text{future projected value} - \text{baseline period value}}{\text{baseline period value}} \quad (4-1)$$

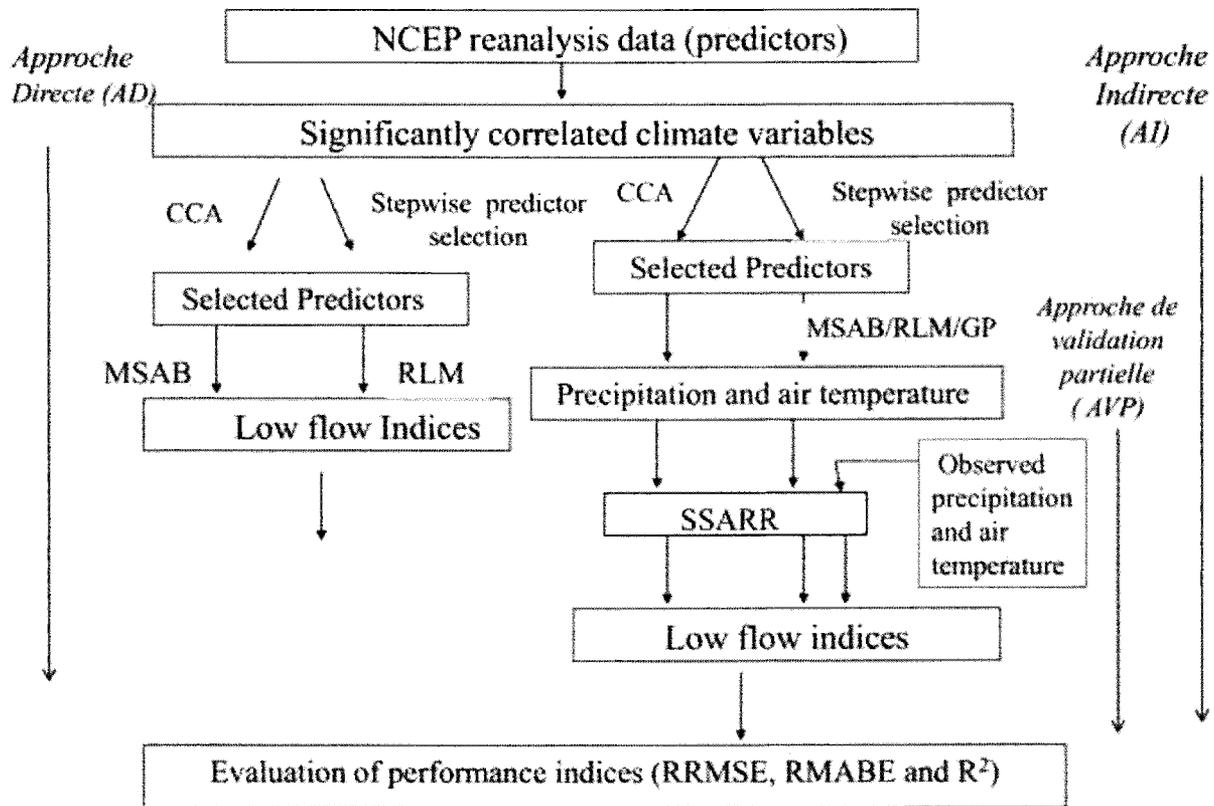


Figure 4.1 Statistical Downscaling Framework.

2.1 Statistical models

The two statistical models used to downscale low flow HIs in the DD framework and meteorological variables (precipitation and temperature) in the ID framework are Sparse Bayesian Learning (SBL; Tipping, 2001) and Multiple Linear Regression (MLR; Gachon and Dibike, 2007). MLR is a statistical method that is used to model linear relationship between a dependent variable (predictand) and one or more independent variables (predictors). It is a least square based method that assumes that the relationship between the predictors and predictand is linear. SBL is a Bayesian framework for obtaining sparse solutions to regression and classification tasks using models linear in the parameters. A key facet of SBL is the incorporation of parameterized prior on the weights that encourages sparsity in representation. The majority of parameters are automatically set to zero during the learning process, giving a

procedure that is extremely effective at discerning those basis functions which are 'relevant' for making good predictions (Tipping, 2001).

2.1.1 Relevance vector machine (RVM)

RVM (Tipping, 2001) uses probabilistic Bayesian learning to capture the underlying relationships between predictors and predictands. It is a Bayesian treatment of the function used in SVM (Cortes and Vapnik, 1995):

$$t = f(\mathbf{x}; \mathbf{w}) = \sum_{i=1}^N w_i K(x, x_i) + w_0 \quad (4-2)$$

where $K(x, x_i)$ is a kernel function, effectively defining one basis function for each example in the training set. Mathematical formulations behind the algorithm and its application in downscaling studies can be found in Joshi et al. (2013). The current work uses a Gaussian kernel function:

$$K(x, x_i) = \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) \quad (4-3)$$

2.1.2 Automated statistical downscaling tool

ASD is capable of performing statistical downscaling automatically, from predictor selection to model calibration, scenario generation and statistical analysis of scenarios. Two methods of predictor selection: backward stepwise regression and partial correlation are incorporated for predictor selection. The current work uses backward stepwise regression for predictor selection. Details about the mathematical formulations behind the ASD algorithm and its application in precipitation and temperature downscaling can be found in Hessami et al. (2008).

2.2 The hydrological model: SSARR

SSARR (Kite, 1978; Cundy and Brooks, 1981) is a lumped conceptual hydrological model which comprises of a generalized watershed model and a streamflow and reservoir regulation model. The current version of SSARR uses two types of watershed models: Integrated-Snowband model and Depletion Curve model. The Integrated snowband model (figure 4.2) divides the basin into a number of bands or zones of equal elevation. Each band is then treated as a separate watershed with its own characteristics. Simulation of snowpack conditions and

moisture input for routing is independently accomplished for each band. The depletion curve model simulates the catchment as an entity and depletes the snow covered area as a function of seasonal accumulated runoff. This work uses the integrated snowband model which has been diagrammatically represented in figure 4.2 (SSARR user manual, 1991).

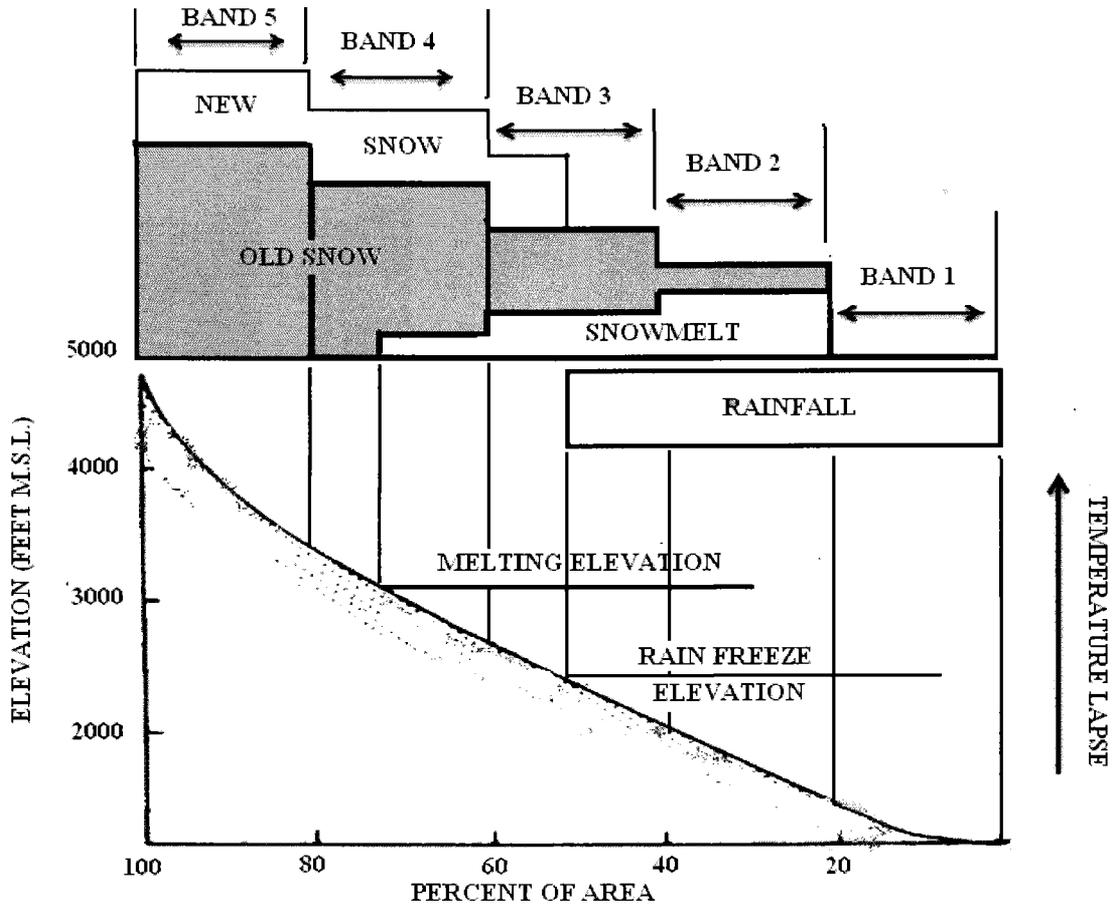


Figure 4.2 Snow -Elevation band example of rain, snow and melt (SSARR manual, 1991).

The River System and Reservoir Regulation Model routes streamflow from upstream to downstream through channel and lake storage and reservoirs under free flow or controlled-flow modes of operation. Flows may be routed as a function of multivariate relationships involving backwater effects from tides or reservoir operations. Diversion and overbank flows can be simulated. The compute-period may be as short as 0.1 hour or as long as 24 hours.

2.2.1 SSARR calibration

SSARR calibration was done using an optimisation subroutine based on an algorithm that makes an iterative search of the parameter space based on performance measures and depth function (Bardossy and Singh, 2008). For the quantification of the performance of hydrological models, most of the performance criteria concentrates on how well the simulated hydrographs, flood peaks and flow volumes match with corresponding observed values (Green and Stephenson, 1986). These criteria provide scarce information about the quality of low flow simulations due to their bias towards high flows. For the current work, the following evaluation performance criterias were used to assess SSARR results

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (4-4)$$

$$NASH = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (4-5)$$

$$MODNASH = 1 - \frac{\sum_{i=1}^n \left(\frac{O_i - P_i}{O_i} \right)^2}{\sum_{i=1}^n \left(\frac{O_i - \bar{O}}{\bar{O}} \right)^2} \quad (4-6)$$

$$LOGNASH = 1 - \frac{\sum_{i=1}^n (\log(O_i) - \log(P_i))^2}{\sum_{i=1}^n (\log(O_i) - \log(\bar{O}))^2} \quad (4-7)$$

where n denotes the number of days in the time series, and O_i and P_i denote observed and simulated daily values, respectively. \bar{O} and \bar{P} denote observed and simulated means, respectively. These performance criterias were quantified for the entire year and separately for two seasons (December-March and July-October).

R^2 and NASH are the most commonly used performance criterias (Legates and McCabe, 1999). The major drawback of using R^2 , if it is considered alone, is that it only quantifies dispersion. Therefore, a model which systematically over- or under predicts can still result in good values of R^2 . With the NASH coefficient, the squaring of the difference between observed and predicted values leads to an overestimation of model performance during peak flows and an underestimation during low flow conditions. Neither performance criteria are sufficiently sensitive to systematic model over- or under prediction, particularly during low flow periods. To reduce the problem of squared differences and the resulting sensitivity to extreme values, LOGNASH is calculated with logarithmic values of O and P . The logarithmic transformation

flattens the peaks of the hydrograph. As a result, the influence of low flows is increased in comparison to flood peaks, thereby increasing the sensitivity of the index to model over- or under prediction of low flows. Another way of increasing the influence of absolute differences between observed and predicted values during low flow periods and reducing the same during high peaks, is to quantify them as relative deviations (MODNASH). As a result, it can be expected that the relative deviations are more sensitive to systematic over- or under prediction, particularly during low flow conditions.

3 STUDY AREA

The considered downscaling methodologies were experimented for three rivers located in the province of Quebec, in Eastern Canada. Moisie and Romaine rivers are located on the North shore whereas Ouelle is located on the south shore of the St. Lawrence River. These rivers were chosen as they sustain Atlantic Salmon (*Salmo salar*) populations, which has been regarded as an endangered species (Committee on the Status of Endangered Wildlife in Canada; COSEWIC, 2011) and is known to be adversely affected by extreme low flows (Armstrong et al., 1998).

Daily streamflow, precipitation and air temperature data for stations representing the three rivers were obtained from Environment Canada database (<http://www.climate.weatheroffice.gc.ca>). Locations of the discharge and meteorological stations on each of these river basins are shown in figure 4.3 which has been reproduced from Joshi et al (2013) (Chapter 1). There is one hydrometric station and two meteorological stations corresponding to Romaine and Moisie and one discharge and one meteorological station for Ouelle. Details of the meteorological stations and hydrological stations are shown in table 4.1 and table 4.2, respectively. Flow duration curves for the three rivers for summer and winter flows are shown in figure 4.4. Moisie and Romaine clearly have more severe winter flows. For Moisie, the Q95 (flows exceeded 95% of days) values for summer (July-October) and winter (December-March) flows are 222.5 m³/s and 60.3 m³/s, respectively and for Romaine the same are 140 and 42.9 m³/s, respectively. Ouelle has more severe summer flows, however, the difference between summer and winter flows is not as pronounced as for Romaine and Moisie. The Q95 values corresponding to Ouelle for summer and winter are 0.65 and 0.86 m³/s, respectively.

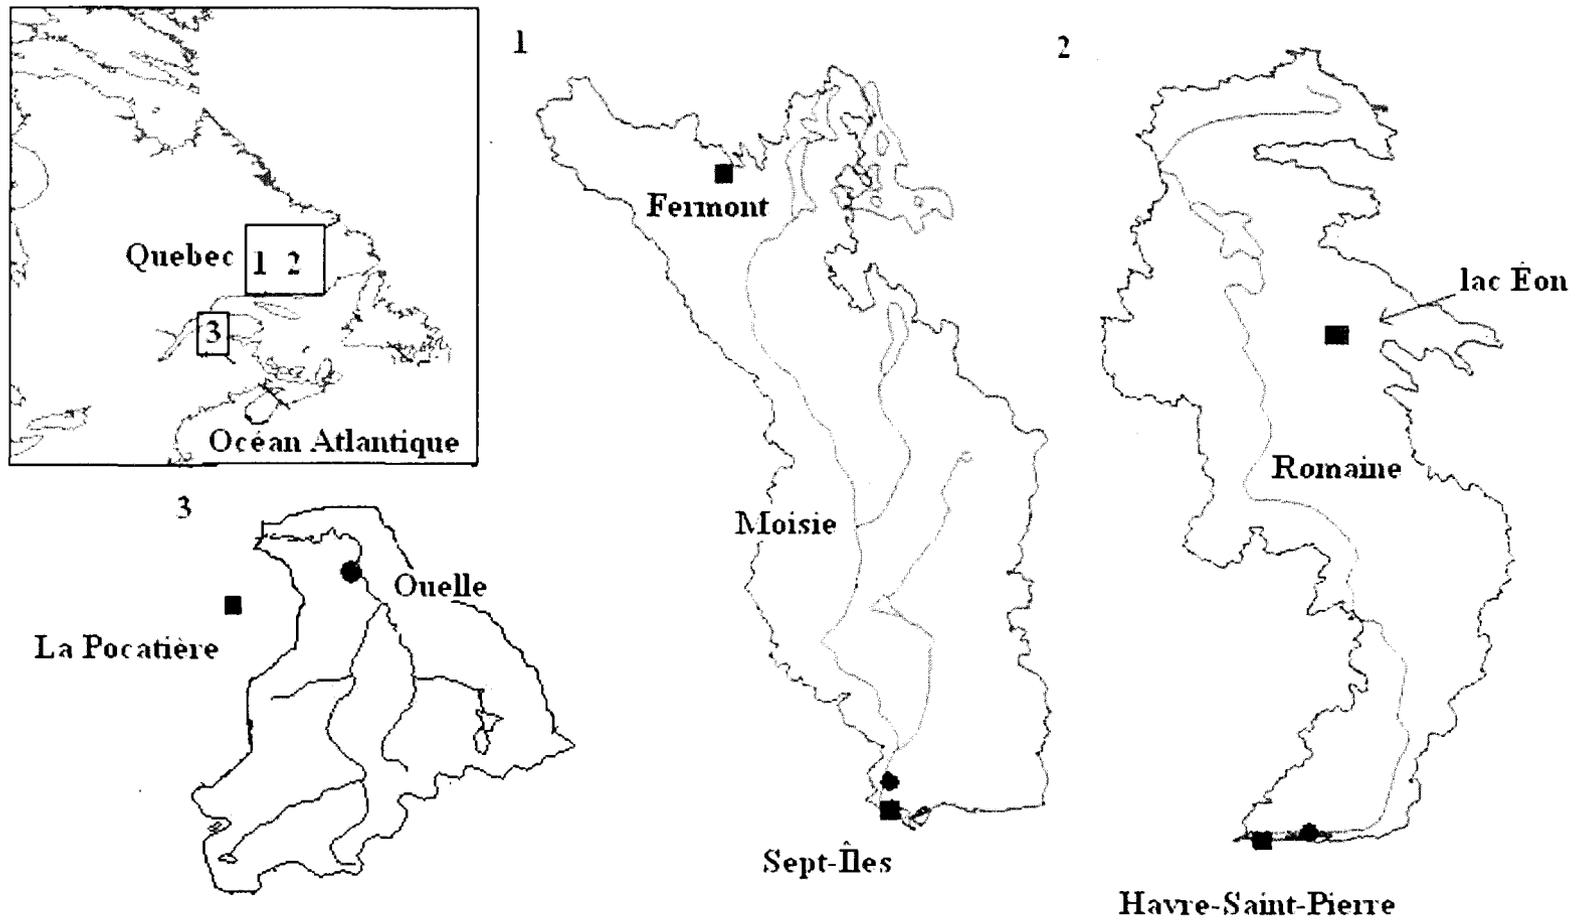


Figure 4.3 The study area map showing the locations of discharge and meteorological stations on each river. The squares and circles denote meteorological and discharge stations, respectively.

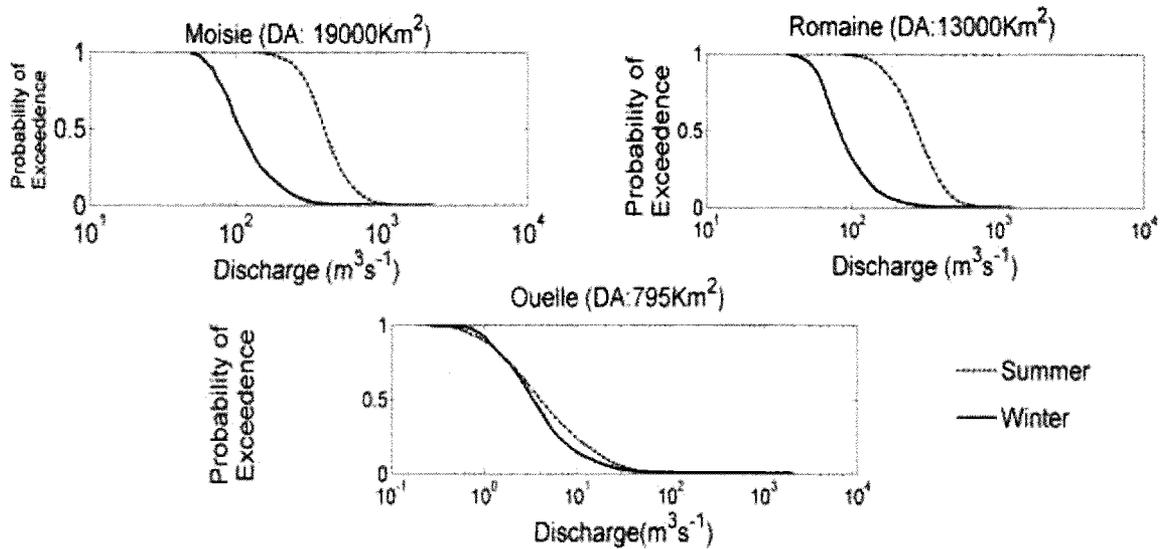


Figure 4.4 Flow duration curves for Romaine, Moisie and Ouelle for summer (dashed line) and winter flows (smooth line). The drainage areas (DA) are indicated in the figure. Data are plotted on semi-logarithmic axis.

Table 4.1 Description of meteorological stations used in the current work.

Station	River	Latitude	Longitude	Elevation	Available years
Fermont	Moisie	52°48'00.000" N	67°05'00.000" W	594.40	Oct 1980-Dec 1996
Sept-Iles	Moisie	50°13'00.000" N	66°16'00.000" W	54.90	Oct 1980-Dec 1996
Lac Eon	Romaine	51°52'02.000" N	63°17'01.000" W	588.90	Jan 1964-Dec 1976
Havre St-Pierre	Romaine	50°16'55.000" N	63°36'41.000" W	37.80	Jan 1964-Dec 1976
La Pocatiere	Ouelle	47°21'21.000" N	70°01'55.000" W	31.00	Oct 1969-Sept 1991

Table 4.2 Description of hydrometric stations (reproduced from Joshi et al., 2013).

Station	Latitude	Longitude	Catchment Area(Km²)	Years	Years Excluded
Romaine	50°18'28" N	63°37'21" W	13000	1961-2010	2007
Moisie	50°21'1" N	66°11'25" W	19000	1966-2010	1967,1999,2000, 2007
Ouelle	47°22'52"N	69°57'29" W	795	1961-2010	1967,1981,1982,1996

4 SELECTION OF LOW FLOW INDICES

Six low flow indices characterizing different aspects of the low flow regime of the three rivers were considered. These indices were selected based on the study presented in Daigle et al. (2011) which dealt with the characterization of low flow regimes of rivers in Eastern Canada using data from 175 discharge stations. 71 indices considered relevant from low flow perspective were identified and categorized into five groups describing different aspects of the low flow regime- magnitude, frequency, duration, variability and timing (Richter et al., 1996). The number of indices was reduced from 71 to eight highly informative and low-correlated HIs using Principal Component Analysis (PCA).

Following this work, low redundant HIs covering four aspects of low flow regime of a river, were selected. These four aspects are magnitude, variability, timing and duration. To account for the impacts of temporal dependence on the validity of statistical estimates, indices exhibiting autocorrelation were avoided. The selected indices were (Table 4.3): Minimums of March flow values for each year (AMP1), ratio of the lowest annual monthly discharge to the mean annual discharge (AMP2), average Julian date of the seven annual one day minimum discharges (T), standard deviation of the Julian date of the seven 1-day minimum discharges (V), 90-day minimum divided by the median of the entire record (D1) and 90-day minimum calculated for July-October, divided by the median of the entire record (D2).

Table 4.3 Selected hydrological indices definition with index code (reproduced from Joshi et al., 2013).

Index	Description	Timing
AMP1	Minimums of all March flow values for each year ($\text{Ls}^{-1}\text{km}^{-2}$)	Yearly
AMP2	Ratio of the lowest annual monthly discharge to the mean annual discharge (unitless)	Yearly
T	Average Julian date of the seven annual 1-day minimum discharges (Julian date)	Yearly
V	Standard deviation of the Julian date of the seven 1-day minimum discharges (days)	Yearly
D1	90-day minimum divided by the median of the entire record(unitless)	Yearly
D2	90-day minimum calculated for July-October, divided by the median of the entire record (unitless)	Seasonal

5 PREDICTOR SELECTION

Statistical downscaling models are based on the fundamental assumptions (Von Storch et al., 2000): (1) The empirical relationship developed between global-scale predictors and local-scale predictands should be stable under future climate conditions, (2) the predictor variables should be adequately produced by GCM/RCM, and (3) the selected predictors should fully incorporate the future climate change signal. In particular connection to point 3, Huth et al (2004), found that for temperature downscaling it is necessary to include among predictors the variables describing radiation-induced changes and not only circulation induces changes. In connection, the use of sea level pressure or 1000 hpa heights predictors as the only predictors lead to unrealistically low temperature change estimates. Some other studies that have investigated appropriate predictor methods in downscaling studies include Benestad (2001), Hessami et al. (2008), Dibike et al. (2008) and Jeong et al. (2012).

For the current work, reanalysis data from the National Center for Environmental Prediction (NCEP; Kalnay et al., 1996) were used as large-scale atmospheric predictors to calibrate the models and validate the approaches. These datasets are 'observed' large-scale data on a regular grid with a spatial resolution of approximately $2.5^{\circ} \times 2.5^{\circ}$ (250 km X 250 km). Each NCEP variable was interpolated to each discharge and meteorological station locations for DD and ID, respectively, using bilinear interpolation. For a given station, the interpolated data were calculated by taking a weighted average of the data from the four nearest points located on a regular grid. The full list of predictors is shown in table 4.4. These variables include Relative Humidity (RH), Specific Humidity (SH), Zonal (U), Meridonal (V) and Vertical (ω) components of wind and geopotential height at different pressure levels (1000, 850 and 500 hPa) and Sea Level Pressure (SLP). The variable Heating Degree Days (HDD) was also included for the DD. HDD indicates exceedence of the daily mean above a certain temperature threshold (base temperature). In the current work, a base temperature equal to 1°C was considered.

Table 4.4 NCEP predictors used in the downscaling framework (reproduced from Joshi et al., 2013).

Number	Predictor Names
1	Mean temperature at 2m
2	Mean sea level pressure
3	Specific humidity at 1000 hPa
4	Specific humidity at 850 hPa
5	Specific humidity at 500 hPa
6	Relative humidity at 1000 hPa
7	Relative humidity at 850 hPa
8	Relative humidity at 500 hPa
9	Zonal wind component at 1000 hPa
10	Zonal wind component at 850 hPa
11	Zonal wind component at 500 hPa
12	Meridonal wind component at 1000 hPa
13	Meridonal wind component at 850 hPa
14	Meridonal wind component at 500 hPa
15	Vertical wind component at 1000 hPa
16	Vertical wind component at 850 hPa
17	Vertical wind component at 500 hPa
18	Geopotential height at 1000 hPa
19	Geopotential height at 850 hPa
20	Geopotential height at 500 hPa
21	Heating Degree Days

6 MODEL VALIDATION AND PERFORMANCE

Cross-validation (Stone, 1974) provides a simple and effective method for both model selection and performance evaluation and is widely employed by the downscaling community. Under k -fold cross-validation the data are randomly partitioned to form k disjoint subsets of approximately equal size. Of the k subsets, one is retained as the validation data for testing the model, and the remaining $k - 1$ subsets are used as training data. A special case of k fold cross validation is split sampling ($k=2$) in which the dataset is divided into two subsets, one for training and the other for testing. The most extreme form of cross-validation is known as leave-one-out cross-validation (LOCV). LOCV consists of omitting one case at a time and building the statistical model on the remaining dataset, then estimating the omitted case with the model. All N available cases are omitted and estimated in turn and the model performance is computed from the N estimation errors.

The low flow HIs selected for this work are yearly and/or seasonal. Therefore, in DD, the total number of samples available for calibrating RVM and ASD is equal to the total number of years of data, and the method was validated through LOCV. In ID methodology, daily values of precipitation and temperature were downscaled and further introduced into SSARR to simulate daily flows and thereafter low flow indices were calculated. Therefore, the dataset was divided into two subsets, that were alternatively used as calibration and validation sets in a split-sample cross-validation

The ability of the DD and ID methodologies to downscale the selected low flow HIs was quantified using the following performance indices: Relative Root Mean Square Error (RRMSE), Relative Mean Absolute Bias Error (RMABE) and Coefficient of Determination:

$$RRMSE = \sqrt{\frac{\sum_{i=1}^n \left(\frac{O_i - P_i}{O_i} \right)^2}{n}} \quad (4-8)$$

$$RMABE = \frac{\sum_{i=1}^n \left| \frac{U_i - P_i}{O_i} \right|}{n} \quad (4-9)$$

and

$$R^2 = \left(\frac{\sum_{i=1}^n (O - \bar{O})(P - \bar{P})}{\sqrt{\sum_{i=1}^n (O - \bar{O})^2 \sum_{i=1}^n (P - \bar{P})^2}} \right)^2 \quad (4-10)$$

7 RESULTS

7.1 Intercomparison of DD approaches (DD1 and DD2)

Comparison of the downscaling efficiencies of DD1 and DD2 are presented in detail in Joshi et al. (2013). The results indicated that DD1 performed better than DD2 in terms of performance indices (RRMSE, RMABE and R^2). The former resulted in lesser variability of the performance indices between calibration and validation sets, implying better generalisation ability. DD1 also supported sparsity by using fewer numbers of parameters to make predictions. Both methodologies were unable to capture the variability present in index V for all rivers. An intercomparison of the rivers showed that the values of RRMSE and RMABE obtained for the indices from Ouelle were higher than those from Romaine and Moisie.

7.2 Downscaling of precipitation and temperature

Comparison of RVM and ASD for downscaling precipitation and mean temperature indicated that both the methods performed comparably in downscaling precipitation RVM outperformed ASD in downscaling temperature. Greater skill was shown in downscaling temperature over precipitation. For temperature, both methods gave R^2 values greater than 0.90 for all stations. Both methods were unable to capture the variability existing in precipitation and yielded R^2 values within the range 0.30-0.70. RVM proved to be a rather sparse model, by basing its predictions on 1-5% and 1-7% of the total number of sample points for the precipitation and temperature models, respectively. With respect to the simplicity and the lower memory requirements, ASD algorithm was regarded as more suitable for downscaling precipitation and mean air temperature.

7.3 SSARR calibration

The calibration of hydrological model is an important component of the ID framework. For the current work, the ability of SSARR to simulate flows was tested using split sampling. The combinations of calibration and validation years (combination1 (C1) and combination 2 (C2)) used in split sampling are indicated in table 4.5. Table 4.6 shows SSARR simulation results (table shown only for C1) for the three rivers. The yearly values of performance indices indicate

that SSARR performs well for Moisie and Romaine, as compared to, Ouelle. The corresponding NASH, MODNASH, LOGNASH and R^2 for Ouelle are 0.66, 0.41, 0.68 and 0.64, respectively. The same for Moisie are 0.71, 0.87, 0.76 and 0.84 and for Romaine are 0.76, 0.89, 0.79 and 0.76, respectively. According to MODNASH winter flows are better simulated than summer flows for all rivers. The MODNASH values (for C1) for Romaine, Moisie and Ouelle for summer are 0.40, 0.16 and 0.20 and for winter are 0.73, 0.73 and 0.24, respectively.

Table 4.5 Calibration and validation sets used in the analysis. Data sizes in years are indicated in brackets.

Sets	Type	Romaine	Moisie	Ouelle
Combination 1 (C1)	Calibration	Jan1964-Dec1969 (5)	Oct 1980-Sep 1990 (10)	Oct 1969-Aug 1981 (~12)
	Validation	Jan 1970-Dec 1976 (7)	Oct 1990-Dec 1996 (6)	Oct 1982-Sep1991 (9)
Combination 2 (C2)	Calibration	Jan 1970-Dec 1976 (7)	Oct 1990-Dec 1996 (6)	Oct 1982-Sep1991 (9)
	Validation	Jan1964-Dec 1969 (5)	Oct 1980-Sep 1990 (10)	Oct 1969-Aug 1981 (~12)

Table 4.6 SSARR simulation results for C1 for the entire year (YEARLY), summer (SMR) and winter (WNTR). The performance indices were calculated for calibration and validation periods combined.

	Moisie			Romaine			Ouelle		
	Yearly	SMR	WNTR	Yearly	SMR	WNTR	Yearly	SMR	WNTR
NASH	0.71	0.27	0.37	0.76	0.49	0.36	0.66	0.50	0.44
MODNASH	0.87	0.16	0.73	0.89	0.40	0.73	0.41	0.20	0.24
R^2	0.76	0.51	0.61	0.79	0.53	0.65	0.68	0.53	0.48
LOGNASH	0.84	0.34	0.38	0.76	0.40	0.31	0.64	0.51	0.24

7.4 Intercomparison of ID approaches (ID1 and ID2)

For Moisie, both approaches perform comparably for all cases. For index D2 from Romaine, ID1 outperforms ID2 for C1 and the latter surpasses the former for C2. For AMP2, ID2 performs well over ID1 for both combinations. For D1, C1 shows slightly superior performance of ID2 whereas C2 shows comparable results by both the approaches. For the remaining indices both methods yielded similar values of RRMSE and RMABE. Pronounced differences are observed between the performance of ID1 and ID2 for index V from Ouelle for C1. For AMP2, ID2 surpasses ID1 for both combinations. In all other cases, ID1 and ID2 perform comparably, in terms of RRMSE and RMABE.

7.5 Comparison of DD and ID approaches

The comparison of DD and ID downscaling methodologies is shown in figures 4.5-4.10. For all rivers DD1 outperforms all ID approaches in terms of RRMSE, RMABE and R^2 . For Moisie, in terms of RRMSE and RMABE, ID1 and ID2 perform noticeably better than DD2 for index V, for both combinations. The corresponding R^2 results indicate comparable performance, particularly in the case of combination C2. In the case of Ouelle, for all indices except AMP2, RRMSE and RMABE values indicate that both ID approaches perform better than DD2. On the other hand, for Romaine, DD2 always performs better than both ID approaches for all cases.

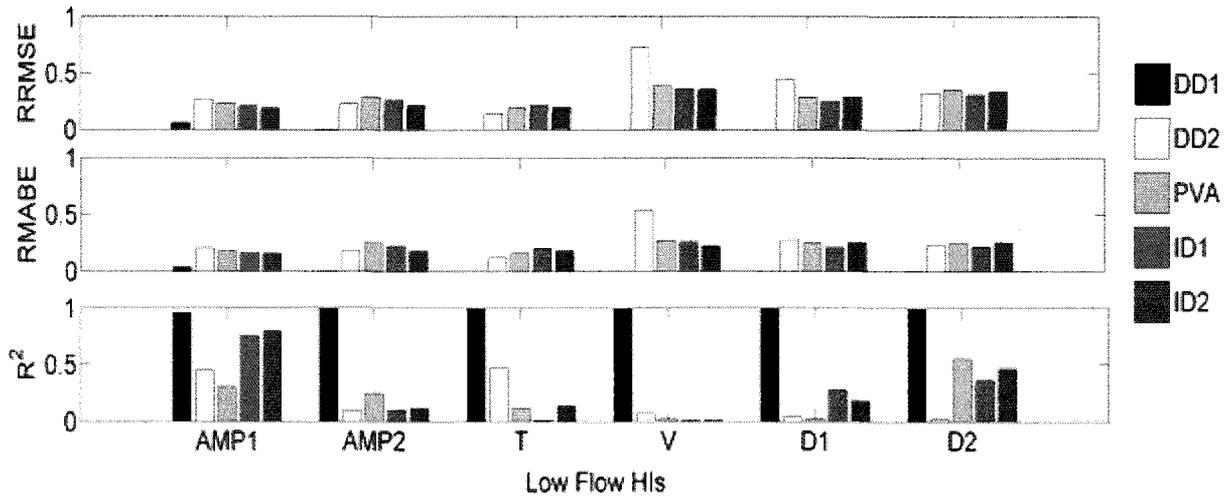


Figure 4.5 Comparison of downscaling results for Moisie for C1. The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.

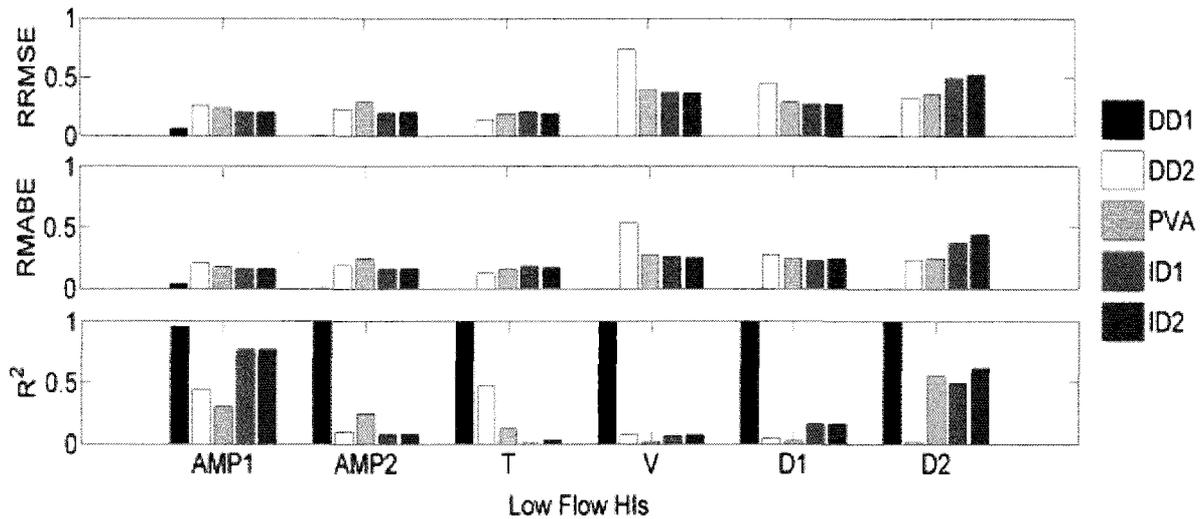


Figure 4.6 Comparison of downscaling results for Moisie for C2. The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.

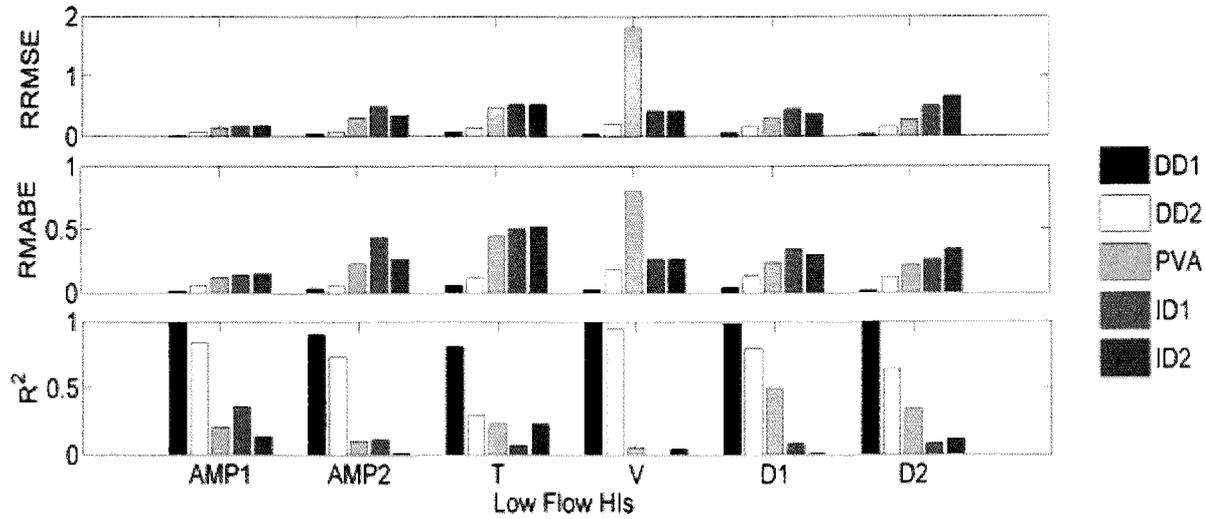


Figure 4.7 Comparison of downscaling results for Romaine for C1. The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.

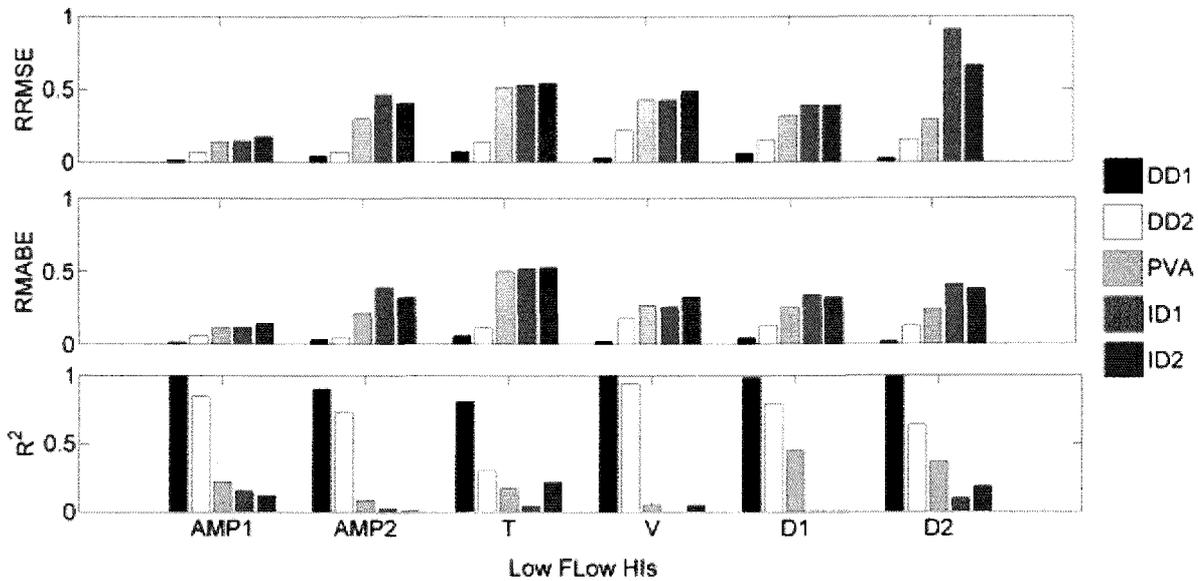


Figure 4.8 Comparison of downscaling results for Romaine for C2. The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.

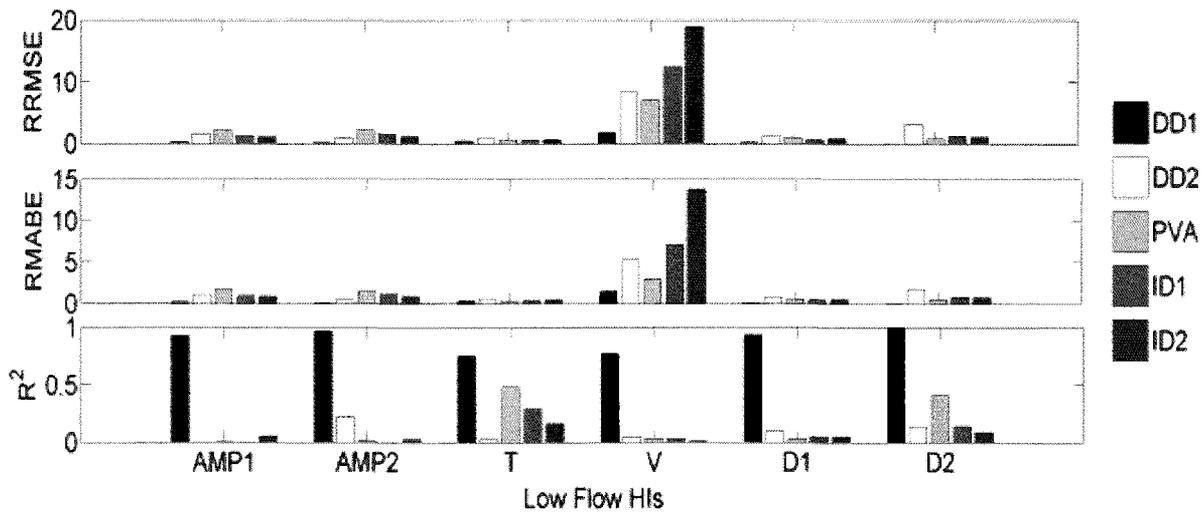


Figure 4.9 Comparison of downscaling results for Ouelle for C1. The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.

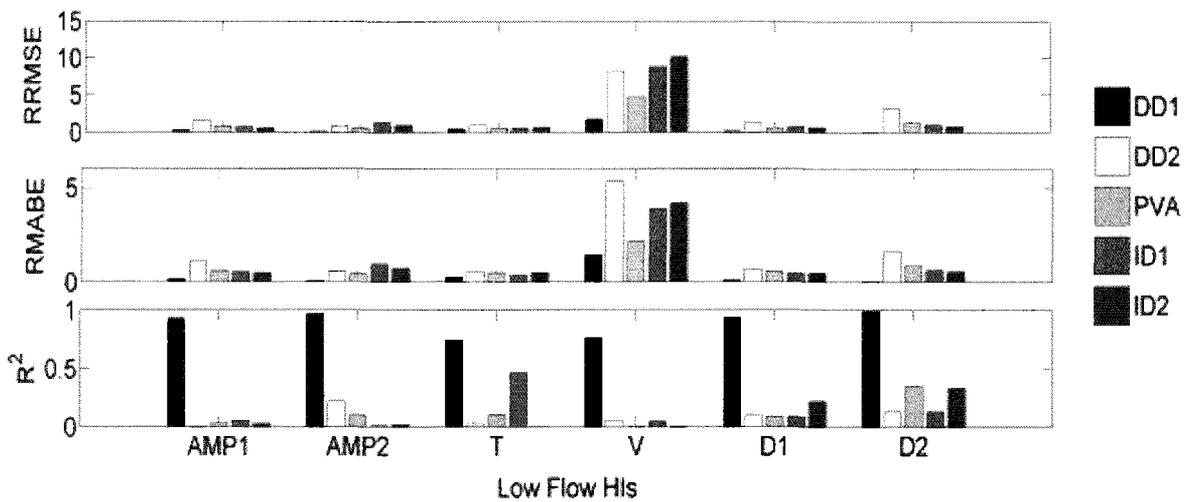


Figure 4.10 Comparison of downscaling results for Ouelle for C2. The downscaling approaches are: Direct downscaling using RVM (DD1) and ASD (DD2), indirect downscaling involving hydrological model SSARR with observed (PVA) and downscaled values of precipitation and temperature using RVM (ID1) and ASD (ID2), as input.

7.6 Comparison of PVA and downscaling approaches (DD and ID)

7.6.1 PVA and DD approaches

DD1 clearly outperforms PVA in all cases with marked differences observed for the variability index from Romaine for C2. For Romaine, DD2 outperforms PVA for all cases. In the case of indices V, AMP1 and D1 from Moisie, PVA outperforms DD2 in terms of RRMSE and RMABE whereas the latter surpasses the former in terms of R^2 . For Ouelle, in terms of RRMSE and RMABE, PVA surpasses DD2 for all cases corresponding to C2 whereas for both amplitude indices from C1, DD2 outperforms PVA.

7.6.2 PVA and ID approaches

For Ouelle, marked differences are observed in the case of index V, where PVA surpasses ID1 and ID2 in terms of RRMSE and RMABE for both combinations. For D1 and T, the three approaches are seen to be comparable. R^2 values corresponding to T indicate that ID1 surpassed ID2 in C1 and the latter exceeded the former in C2. For Moisie, in terms of RRMSE and RMABE, PVA performs comparable to ID1 and ID2 for both combinations and all indices with the exception of index D2 for C2 where it noticeably surpasses the ID approaches and is slightly better than the latter in C1. For Romaine, PVA performs very poorly in the case of V for C1 whereas for C2, the three approaches are comparable. Also, in the case of AMP2, D1 and D2, PVA performs better than ID1 and ID2 for both combinations. Equivalent performances of the three approaches are observed for T and A1 for both combinations in terms of RRMSE and RMABE.

7.7 Future projections of low flow HIs

Box plots showing the comparison of GCM outputs of low flow indices for historical period and future time periods have been shown in figures 4.11-4.14, only for Ouelle and Moisie. Only future projections obtained from DD1 are shown, as DD1 was found to be the best downscaling method.

7.7.1 Amplitude Indices (AMP1 and AMP2)

For index AMP1 from Romaine, with reference to the baseline period, not much difference is observed in the median values of the future projections. In comparison to Romaine and Ouelle, the RC in median is more pronounced for Moisie. The highest RC in the median is given by scenario A1B from ECHAM5 in 20s (14% decrease) for Moisie, by scenario A2 from CRCM in 50s (2% decrease) for Romaine and by scenario B1 from ECHAM5 for Ouelle in 50s (5% decrease). For all rivers, scenario A2 from ECHAM5 and for Ouelle, scenario A2 from CRCM, project a decreasing trend in the IQR.

For Baseflow Index (AMP2) from Romaine, scenario A1B from ECHAM5 projects a decreasing trend in the median values. On the other hand, for Moisie, scenarios A1B and B1 from ECHAM5 project an increasing trend in the median values. For Ouelle, an increasing trend in the median values is seen for scenario A2 from ECHAM5. For the IQR, decreasing trend (49% in 20s and 77% in 50s) is observed for Ouelle for scenario A2 from CRCM.

7.7.2 Timing and Variability Indices (T and V)

For Moisie, all scenarios project decrease in the median and variability for index T, for all future time periods. In particular, decreasing trend in the IQR is observed for scenarios A1B and B1 from ECHAM5. For Ouelle, decreasing trend in the same is shown by scenario A1B for ECHAM5. As in the case of index T, for index V from Moisie, all scenarios project a decrease in the median values for all future time periods. For Ouelle, scenarios A1B from ECHAM5 and A2 from CRCM project an increasing trend in the median values. For the IQR, scenario B1 for Romaine and A1B from Ouelle project a decreasing trend.

7.7.3 Duration Indices (D1 and D2)

For index D1, from Moisie and Ouelle, all scenarios from ECHAM5 project an increasing trend in the median values from 20s to 50s. The difference between the median values for both time periods is more pronounced for Ouelle. For the IQR for Romaine, only scenario A2 projects an increasing trend from 27% in 20s to 64% in 50s. For the IQR from Moisie, scenarios A1B and B1 from ECHAM5 project a decreasing trend, whereas for Ouelle, all considered scenarios project an increasing trend from 20s to 50s. For index D2, scenario A2 from CRCM, projects a decreasing trend in the IQR for both Moisie and Romaine whereas for Ouelle, scenarios A1B and B1 project decreasing and increasing trend, respectively, in the IQR.

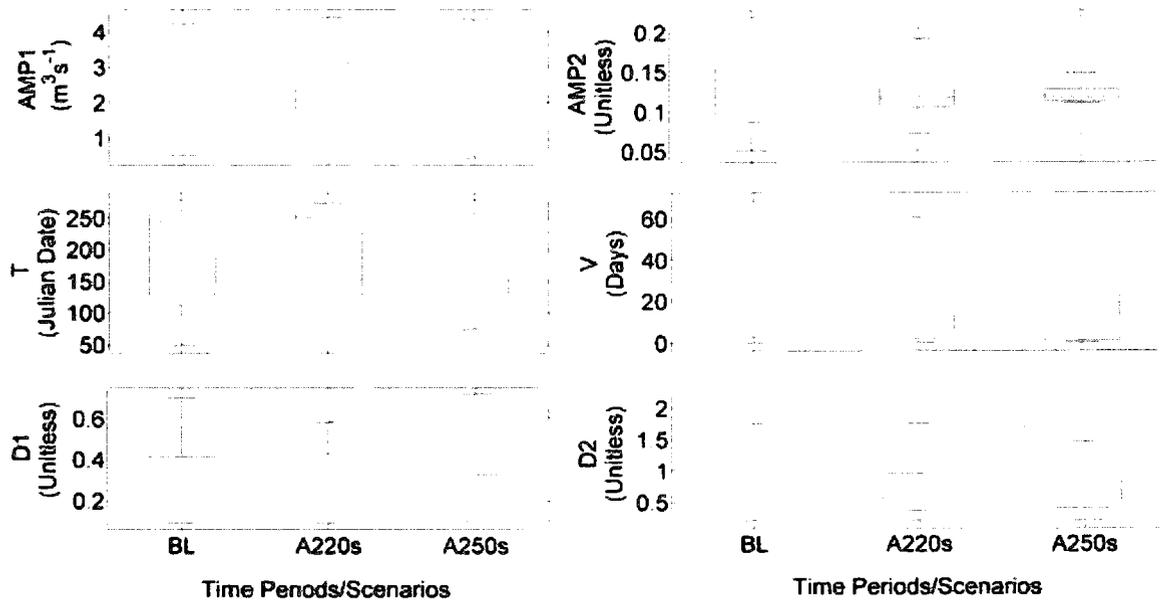


Figure 4.11 CRCM (RCM) projections for Ouelle for scenario A2. BL refers to baseline period (1961-2010). The naming convention is scenario name followed by 20s (2021-2050) or 50s (2051-2080). A220s and A250s refer to A2 scenario corresponding to 2021-2050 and 2051-2080 respectively.

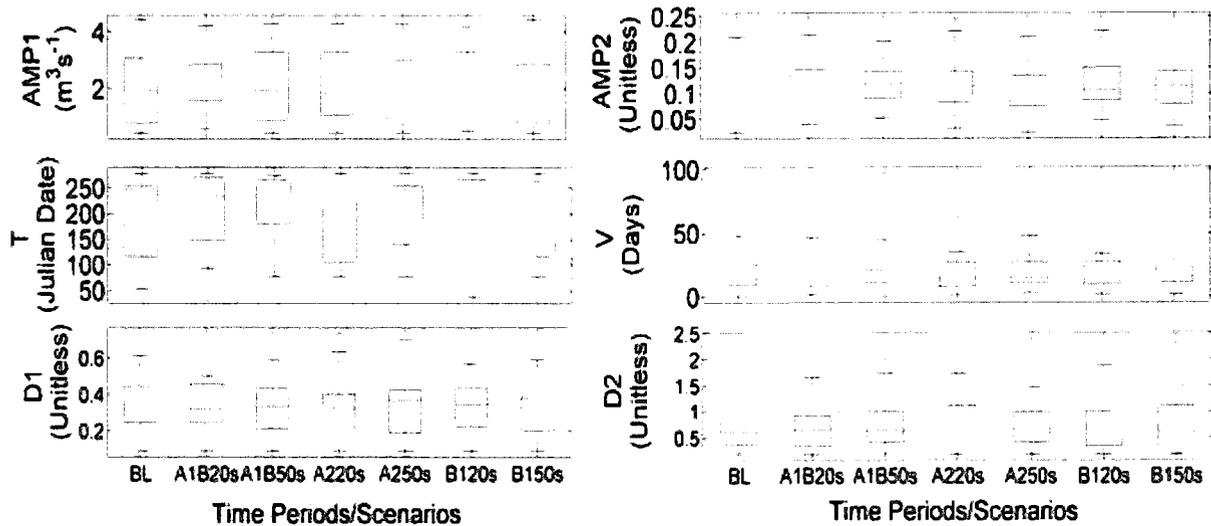


Figure 4.12 ECHAM5 (GCM) projections for Ouelle given by scenarios A1B, A2 and B1. BL refers to baseline period (1961-2010). The naming convention is scenario name followed by 20s (2021-2050) or 50s (2051-2080). A1B20s and A1B50s refer to A1B scenario corresponding to 2021-2050 and 2051-2080 respectively.

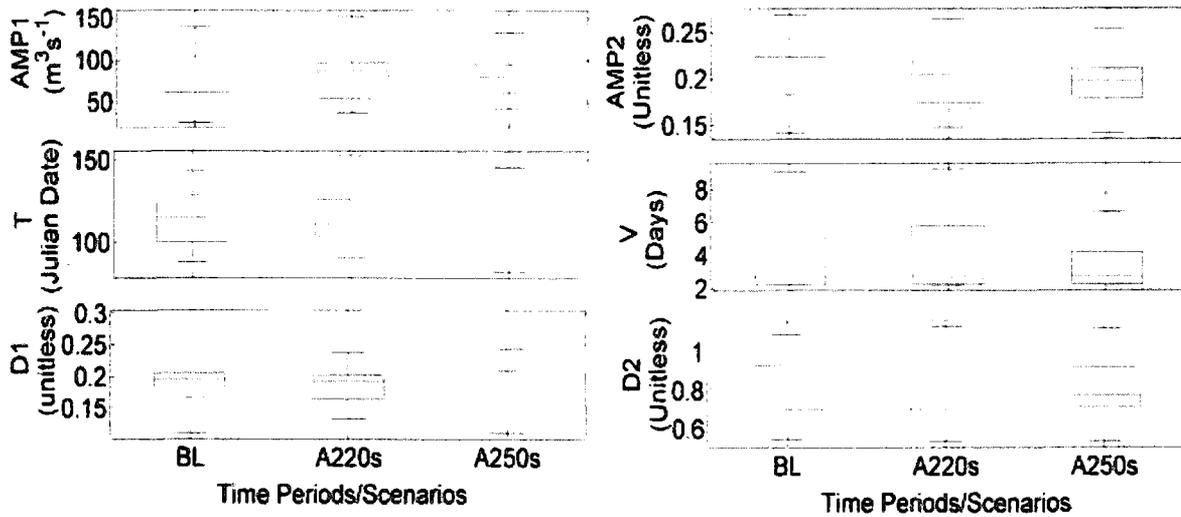


Figure 4.13 CRCM (RCM) projections for Moisie for scenario A2. BL refers to baseline period (1961-2010). The naming convention is scenario name followed by 20s (2021-2050) or 50s (2051-2080). A220s and A250s refer to A2 scenario corresponding to 2021-2050 and 2051-2080 respectively.

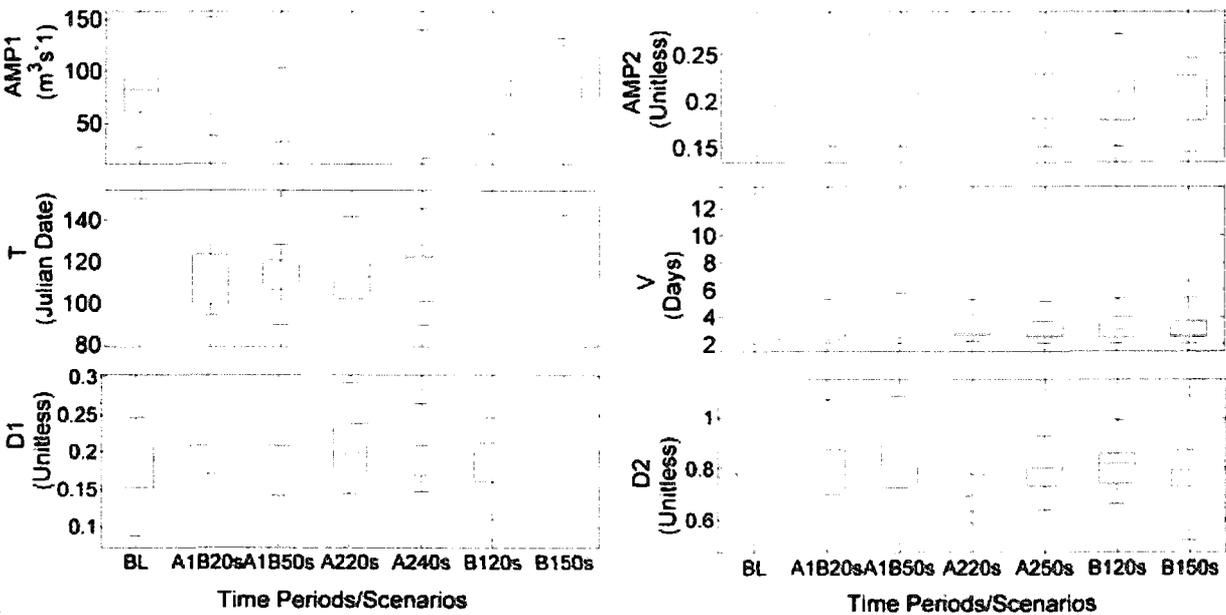


Figure 4.14 ECHAM5 (GCM) projections for Moisie given by scenarios A1B, A2 and B1. BL refers to baseline period (1961-2010). The naming convention is scenario name followed by 20s (2021-2050) or 50s (2051-2080). A1B20s and A1B50s refer to A1B scenario corresponding to 2021-2050 and 2051-2080 respectively.

8 DISCUSSION

8.1 Comparison between statistical models (SBL and MLR)

As mentioned before, the implementations of SBL and MLR used in the current work are RVM and the ASD tool. Results of DD indicates that RVM outperforms ASD in all respects. Its generalisation ability and sparsity supporting nature adds value to the algorithm. For the ID approach, these two algorithms were used to downscale daily precipitation and mean air temperature. With respect to these meteorological variables, ASD was regarded superior to RVM due to its simplicity, lesser computation demands and comparable results obtained for the two in terms of performance indices. Possibilities of improvements in the results encompass experimenting with other predictor selection methods such as genetic algorithms (Coulibaly, 2004), classification and regression trees (Tisseuil et al., 2010). The computationally expensive nature of the RVM algorithm can be dealt with by using low level languages (e.g. C, C++) to program the algorithm and large memory machines.

8.2 Comparison between the two downscaling strategies

This study compares a direct statistical downscaling approach from GCM/RCM to low flow HIs, which is less commonly applied than the approach involving an intermediate hydrological model between GCM/RCM and low flow HIs. Although the former is a single step approach it does not account for the physical factors (such as land use and soil cover) other than climate factors that influence the variability in these indices. These factors are taken care of by a hydrological model to varying extents (depending on the nature of selected hydrological model: lumped, semi-distributed, and distributed). A hydrological model integrates these physical factors that interact with climate and influence the movement of water (e.g. infiltration, evaporation etc.).

The comparison of results of DD and ID methodologies presented in the previous section and shown in figures 4.5-4.10 clearly indicates that of all the approaches, DD1 (DD using RVM) performed better than the rest. Although the exclusion of hydrological model in the DD methodology is advantageous in many respects, it does not hold true for the MLR approach, DD2. Simulated values of index V and D1 for Moisie serve as an example to that. For index V from Ouelle, ID1 and outperforms DD2 in both sets. This observation was attributed to the prediction of some negative values of the index by the latter (Joshi et al., 2013).

The most severe low flows generally occur in summer for Ouelle River, while they occur mostly in the winter for Moisie and Romaine. Higher summer temperatures in the Ouelle leading to high evapotranspiration, which may be combined with less sustained summer groundwater influx, than in the Moisie and Romaine, are potential causes of this seasonal difference. Modeling of low flows using deterministic hydrological models is greatly determined by the extent to which low flow processes such as evapotranspiration, freeze-up, drawdown of storage in lakes, stream channels and wetlands are incorporated (Davison and Kamp, 2008). These processes operate over a wide range of spatial and temporal scales. Therefore, representing the associated processes with constant (e.g. melt rate during a rain period) or monthly varying (e.g. rainfall intensity versus percent effectiveness evapotranspiration index (PETI), monthly PETI, monthly percent effective melt rate) values may limit the ability of SSARR to represent low flow governing processes. Beyond the representation of physical processes, proper initialisation and accuracy of meteorological inputs govern hydrological modeling results. This challenge is inherent in all modeling experiments and must receive special attention in low flow studies. As mentioned in the previous section, both RVM and ASD failed to capture the variability present in precipitation. Additionally, the results of optimisation subroutine rely on the initial setting of parameters, the number of iterations made within the parameter space and the performance measures (NASH, LOGNASH, R^2 and MODNASH) used to optimize the results. The errors arising from downscaling local climate variables are getting propagated in the SSARR simulated flows and hence in low flow HIs.

RVM and ASD use NCEP reanalysis predictors interpolated at selected meteorological stations as predictors to downscale precipitation and temperature for the ID methodology. These downscaled and observed values of precipitation and temperature are further input into SSARR to simulate flows. SSARR is a lumped model which uses spatially averaged values of measured precipitation and mean air temperature as a representation of the meteorological conditions of the entire watershed. It may happen that the average of the downscaled meteorological variables better represents the true average, when compared with an average obtained from sparse (maximum of two stations) observed values over the watershed. As an example to that is index AMP2 from Moisie where both ID approaches outperform PVA for both combinations.

In many cases, different results were obtained about the performances of two approaches based on RRMSE, RMABE and R^2 values. In such cases, even though the simulated points are under predicted or over predicted but are close to the 1:1 line, R^2 can give misleading results. The variability index V from Ouelle serves as an example to that. It was observed that DD

results in higher values of RRMSE and RMABE (>1 in both the cases) but gives reasonable values of R^2 (0.77).

8.3 Future projections given by GCM and RCM

Ouelle exhibits highest daily flow variability and more severe low flows in summer whereas Moisie and Romaine both exhibit severe low flows in winters and similar low flow characteristics (figure 4.4). Therefore, the future projections of the indices corresponding to Ouelle and Moisie only are shown. The results indicate that DD1 outperformed the other methods in downscaling low flow indices. Therefore, the ability of downscaling framework for future climate change impact studies has been illustrated using the DD1 approach.

No increasing or decreasing trends have been observed for any index from all rivers. However, changes in the variability and median values of the indices for future time periods relative to the baseline periods have been observed. For example, AMP2 projected by CRCM for Ouelle (figure 4.11) shows a considerable decrease in the variability from 20s to 50s and the number of outliers corresponding to 50s has increased.

Although these projections may be informative, definitive conclusions about the future nature of the considered low flow indices cannot be drawn as only one GCM and RCM have been compared.

9 CONCLUSION

To the knowledge of the authors, this work is the first of its kind to compare two statistical downscaling approaches in projecting the variability of low flow HIs using GCM/RCM outputs. The superiority of RVM as a downscaling model was clearly established in downscaling low flow indices but the model performed comparably to ASD in capturing the uncertainties present in precipitation. Both models performed well in downscaling temperature. Of all the methods, DD involving RVM (DD1) clearly exceeded the other approaches. It not only performed well in terms of goodness of fit but also displayed superior generalization ability. The choice of statistical model used is a governing factor in the DD approach. The variability index V from Moisie serves as an example to that where both ID approaches outperformed DD2 for both combinations.

The ID results indicated that this methodology was governed by selected statistical downscaling models and the hydrological model used to simulate flows. Simple hydrological models lack proper representation of related physical processes and complex models are demanding in terms of data input. Also, the downscaling of meteorological variables is a crucial source of error particularly with reference to downscaling precipitation as both statistical models were unable to capture its variability. Since the simulation performance of a hydrological model is greatly determined by its input, downscaling errors get combined with hydrological modeling errors and affect the simulated flows and therefore low flow HIs.



BIBLIOGRAPHIE

- Adamowski K. & Bocci C (2001) Geostatistical regional trend detection in river flow data. *Hydrological Processes* 15: 3331-3341.
- Afifi AA & Clark V (1996) *Computer-aided Multivariate Analysis*, third ed. Chapman & Hall, London.
- Akaike H (1974) A new look at the statistical model identification, *IEEE Transactions on Automatic Control*. 19 (6): 716–723, doi:10.1109/TAC.1974.1100705.
- Aksornsingchai P & Chutimet S (2011) Statistical downscaling for rainfall and temperature prediction in Thailand. *Proceedings for the International MultiConference of Engineers and Computer Scientists (IMECS)*, Vol I, March 16-18th, Hong Kong.
- Amusja AZ, Gutnichenko VG & Shelutko VA (1988a). On the estimation of mean annual value of minimum winter flow of ungauged rivers. *Trudy GGI (Trans. State Hydrol. Inst., Leningrad, USSR)* 335, 43–53.
- Amusja AZ, Ratner NS & Sokolov BL (1991) Minimum river flow: state of art and prospects for research. *Trudy GGI (Trans. State Hydrol. Inst. Leningrad USSR)* p 3–28
- Anderson MG & Burt TP (1980) Interpretation of recession flow. *Journal of Hydrology* 46(1-2): 89–101.
- Arihood LD & Glatfelter DR (1991) Method for estimating lowflow characteristics of ungauged streams in Indiana. *USGS Water Suppl. Pap. No. 2372*, 22 p.
- Armstrong JD, Braithwaite VA and Fox M (1998) The Response of Wild Atlantic Salmon Parr to Acute Reductions in Water Flow. *Journal of Animal Ecology* 67(2):292-297
- Arnell NW (1989) Changing frequency of extreme hydrological events in northern and western Europe. In *FRIENDS in Hydrology. The International Association of Hydrological Sciences (IAHS)*. p 237–249.
- Arnell NW (1992) Factors controlling the effects of climate change on river flow regimes in a humid temperate environment. *Journal of Hydrology* 132(1-4): 321–342.
- Arthington AH, King JM, O’Keeffe JH, Bunn SE, Day JA, Pusey BJ, Bluhdorn BR, Tharme R (1992) Development of an holistic Approach for assessing environmental flow requirements of riverine ecosystems. In: Pigram JJ & Hooper BP (Eds.) *Water Allocation for the Environment*. The Centre for Policy Research University of New England, Armindale. p 69–76.
- Arthington, AH, Bunn, SE, Poff, NL, Naiman RJ (2006) The challenge of providing environmental flow rules to sustain river ecosystems. *Ecological Applications* 16, 1311-1318.
- ASCE Task Committee (2000b) Artificial neural networks in hydrology I: Hydrologic applications, *Journal of Hydrologic Engineering*, Vol. 5, no.2, pp.124-137.

- Bachner S, Kapala A & Simmer C (2008) Evaluation of daily precipitation characteristics in the CLM and their sensitivity to parameterizations. *Meteorol. Z.* 17(4): 407-419, Doi:10.1127/0941/2948/2008/0300.
- Bae DH, Jung IW & Lettenmaier DP (2011) Hydrologic uncertainties in climate change from IPCC AR4 GCM simulations of the Chungju Basin, Korea, *J. of Hydrol.*, 401:90-105.
- Bastola S, Murphy C & Sweeney J (2011) The role of hydrological modelling uncertainties in climate change impact assessments of Irish river catchments, *Adv. Water Res.* 34: 562-576.
- Bardossy A, Bogardi I & Matyasovszky I (2005) Fuzzy rule-based downscaling of precipitation. *Theoretical and Applied Climatology* 82(1-2): 119–129.
- Bardossy A, Stehlík J & Caspary HJ (2002) Automated objective classification of daily circulation patterns for precipitation and temperature downscaling based on optimized fuzzy rules. *Climate Research* 23(1): 11–22.
- Bardossy A & Singh SK (2008) Robust estimation of hydrological model parameters. *Hydrol Earth Syst Sci* 12: 1273–1283.
- Bellone E, Hughes JP & Guttorp P (2000) A hidden Markov model for downscaling synoptic atmospheric patterns to precipitation amounts. *Climate Research* 15: 1–12.
- Benestad RE (2001) The cause of warming over Norway in the ECHAM4/OPYC3 GHG integration. *Int. J. Climatol.* 21:371-387.
- Beran MA & Gustard A (1977) A study into the low-flow characteristics of British rivers. *Journal of Hydrology.* 35(1-2):147–157.
- Berger, JO (1985). *Statistical Decision Theory and Bayesian Analysis* (Second edition). Springer-Verlag: New York. 386.
- Bonsal B & Shabbar A (2008) Impacts of large-scale circulation variability. *Canadian Water Resources Journal.* 33(2):37-154.
- Bretherton CS, Catherine, S and Wallace JM (1992) An Intercomparison of Methods for Finding Coupled Patterns in Climate Data. *Journal of Climate* 5, 541-560.
- Burger G, Murdock TQ, Werner AT, Sobie SR, Cannon AJ (2012) Downscaling extremes—an intercomparison of multiple statistical methods for present climate. *Journal of Climate.* 25(12):4366–4388. doi:10.1175/jcli-d-11-00408.1
- Burn DH. and Elnur MAH (2002) Detection of hydrologic trends and variability. *Journal of Hydrology* 225, 107-122.
- Burn DH (2008) Climatic influences on streamflow timing in the headwaters of the Mackenzie River Basin. *Journal of Hydrology* 352(1-2):225-238.
- Burn DH, Buttle JM, Caissie D, MacCulloch G, Spence C and Stahl K (2008) The Processes, Patterns and Impacts of Low Flows Across Canada. *Canadian Water Resources Journal* 33(2), 107-124.

- Burnash RJC, Ferral RL & McGuire RA (1973) *A generalized streamflow simulation system conceptual modeling for digital computer*. U.S. Department of Commerce, National Weather Service and State of California Department of Water Resources Sacramento CA.
- Busuioac A, Von Storch H & Schnur R (1999) Verification of GCM generated regional precipitation and of statistical downscaling estimates. *J. Clim.* 12 (1): 258–272.
- Busuioac A, Tomozeiu R and Cacciamani C (2007) Statistical downscaling model based on canonical correlation analysis for winter extreme precipitation events in the Emilia-Romagna region, *Int. J. Climatol.*, doi: 10.1002/joc.1547.
- Cannon AJ and Whitfield PH (2002) Downscaling recent streamflow conditions in British Columbia, Canada using ensemble neural network models. *Journal of Hydrology*, 259: 136-151.
- Cavazos T & Hewitson BC (2005) Performance of NCEP variables in statistical downscaling of daily precipitation. *Climate Research*, 28: 95–107.
- Charles SP, Bates BC, Whetton PH & Hughes JP (1999) Validation of downscaling models for changed climate conditions: Case study of southwestern Australia. *Clim Res*, 12(1): 1-14
- Chen CT & Knutson T (2008) On the verification and comparison of extreme rainfall indices from climate models. *J. Climate* 21(7):1605-1621.
- Chen H, Xiong W & Guo J (2008) Application of Relevance Vector Machine to downscale GCMs to runoff in hydrology. Fifth International Conference on Fuzzy Systems and Knowledge Discovery.
- Chen ST, Yu PS & Tang YH (2010) Statistical downscaling of daily precipitation using support vector machines and multivariate analysis. *Journal of Hydrology* 385(1–4):13–22. doi:10.1016/j.jhydrol.2010.01.021.
- Chen J, Brissette FP and Leconte R (2011a) Uncertainty of downscaling method in quantifying the impact of climate change on hydrology. *Journal of Hydrology* 401: 190-202.
- Christensen JH & Christensen OB (2007) A summary of the PRUDENCE model projections of changes in European climate by the end of this century. *Clim Change* 81 (1): 7-30.
- Clausen B and Biggs B (1997) Relationships between benthic biota and hydrological indices New Zealand streams. *Freshwater Biology* 38: 327-342.
- Conway D, Wilby RL & Jones PD (1996) Precipitation and air flow indices over the British Isles. *Climate Research* 7(2): 169–183.
- Cortes C & Vapnik V (1995) Support vector networks. *Machine Learning* 20: 273-297.
- Comité sur la situation des espèces en péril au Canada (COSEPAC) (2011) COSEPAC status report on Atlantic salmon *Salmo salar* (anadromous form) in Canada Ottawa: Committee on the Status of Endangered Wildlife in Canada.
- Coulibaly P (2004) Downscaling daily extreme temperatures with genetic programming, *Geophysical Research Letters* 31, L16203, doi: 10.1029/2004GL020075.

- Coulibaly P, Boubee B & Anctil F (2001) Improving extreme hydrologic events forecasting using a new criterion for artificial neural networks selection. *Hydrological processes* 15:1533:1536.
- Coulibaly P & Dibike YB (2004) *Downscaling of Global Climate Model Outputs for Flood Frequency Analysis in the Saguenay River System*. Project report to the Science Sub-Component of Climate Change Action Fund Environment Canada.
- Crane RG & Hewitson BC (1998) Doubled CO₂ precipitation changes for the susquehanna basin: down-scaling from the GENESIS general circulation model. *International Journal of Climatology* 18(1):65-76. Doi: 10.1002/(SICI)1097-0088(199801)18:1<65::AID-JOC222>30CO;2-9.
- Cristianini N & Shawe-Taylor J (2000) *An Introduction to Support Vector Machines and other Kernel-based Learning Methods*. Cambridge University Press, Cambridge.
- Cundy TW & Brooks KN (1981) Calibrating and verifying the SSARR model-Missouri river watersheds study. *Water Resources Bulletin* 17(5): 775-782.
- Daigle A, St-Hilaire A, Beveridge D, Cassie D and Benyahya L. (2011) Multivariate analysis of the low flow regimes in eastern Canadian rivers. *Hydrological Sciences Journal* 56(1): 51-67.
- Davison B & Kamp GVD (2008) Low flows in Deterministic Modelling: A brief Review *Canadian Water Resources Journal* 33(2): 181-194.
- Dibike YB & Coulibaly P (2006) Temporal neural networks for downscaling climate variability and extremes. *Neural Networks* 19(2): 135-144.
- Dibike YB, Gachon P, St-Hilaire A, Ouarda TBMJ & Nguyen VTV (2008) Uncertainty analysis of statistically downscaled temperature and precipitation regimes in northern Canada. *Theoretical and Applied climatology* 91(1-4): 147-170.
- Dobler C, Hagemann S, Wilby RL & Stotter J (2012) Quantifying different sources of uncertainty in hydrological projections at the catchment scale. *Hydrol. Earth Syst. Sci* 9: 8173-8211.
- Droque G, Pfister L, Leviandier T, Idrissi AE, Iffly JF, Matgen P, Humbert J & Hoffmann L (2004) Simulating the spatio-temporal variability of streamflow response to climate change scenarios in a mesoscale basin. *Journal of Hydrology* 293, 255-269.
- Eckhardt K, Fohrer N & Frede HG (2005) Automatic model calibration. *Hydrological Processes* 19(3): 651-658.
- Eheart JW & Tornil DW (1999) Low-flow frequency exacerbation by irrigation withdrawals in the agricultural midwest under various climatic scenarios. *Water Resour Res* 35 (7): 2237-2246.
- Ehsanzadeh, E & Adamowski K (2007) Detection of trends in low flows across Canada. *Canadian Water Resources Journal* 32 (4), 251-264.
- Evans J & Schreider S (2002) Hydrologic impacts of climate change on inflows to Perth Australia. *Clim Change* 55(3): 361-393.

- Extence CA, Balbi DM. and Chadd RP (1999) River flow indexing using British benthic macroinvertebrates: a framework for setting hydroecological objectives. *Regulated Rivers: Research and Management* 15: 543-574.
- Faul AC. & Tipping ME (2002) Analysis of sparse Bayesian learning, *Advances in Neural Information Processing Systems* 14: 383–389.
- Flato GM, Boer GJ, Lee WG, McFarlane NA., Ramsden D, Reader MC & Weaver AJ (2000) The Canadian Centre for Climate Modelling and Analysis Global Coupled Model and Its Climate. *Climate Dynamics* 16: 451-467.
- Fowler HJ, Blenkinsop S & Tebaldi C (2007a) Linking climate change modelling to impact studies: recent advances in downscaling techniques for hydrological modelling. *Int. J. Climatol.* 27(12): 1547-1578.
- Fowler HJ, Ekstrom M, Kilsby CG & Jones PD (2005a) New estimates of future changes in extreme rainfall across the UK using regional climate model integrations 1 Assessment of control climate. *Journal of Hydrology* 300(1-4): 212 – 233.
- Fowler HJ & Kilsby CG (2007) Using regional climate model data to simulate historical and future river flows in northwest England. *Climatic Change* 80 (3 – 4): 337 – 367.
- Fowler HJ, Kilsby CG & O’Connell PE (2000) A stochastic rainfall model for the assessment of regional water resource systems under changed climatic conditions. *Hydrology and Earth System Sciences* 4(2): 263–281. Doi: 105194/hess-4-263-2000.
- Fowler HJ, Kilsby CG, O’Connell PE & Burton A (2005b) A weathertype conditioned multi-site stochastic rainfall model for generation of scenarios of climatic variability and change. *Journal of Hydrology* 308(1–4): 50–66.
- Fowler HJ, Kilsby CG and Stunell J (2007) Modelling the impacts of projected future climate change on water resources in north-west England. *Hydrol. Earth Syst. Sc.* 11(3):1115-1126.
- Frei C, Chistensen JH, Déqué M, Jacob D, Jones RG & Vidale PL (2003) Daily precipitation statistics in regional climate models: Evaluation and intercomparison for the European Alps. *J Geophys Res* 108 (D3): 4124. Doi:[101029/2002JD002287](https://doi.org/10.1029/2002JD002287).
- FREND: Flow Regimes from Experimental And Network Data (1989) I: Hydrological Studies; II: Hydrological Data Wallingford UK.
- Frenette M, Caron M, Julien P & Gibson, RJ (1984) Interaction entre le debit et les populations se tacons (Salmon salar) de la riviere Matamec, Quebec. Canadian. *Journal of Fisheries and Aquatic Sciences* 41: 954-963.
- French MN, Krajewski WF & Cuykendall RR (1992) Rainfall forecasting in space and time using a neural network. *J. of Hydrol.* 137(1-4): 1-31.
- Gachon P & Dibike YB (2007) Temperature change signals in northern Canada: convergence of statistical downscaling results using two driving GCMs. *Int. J. Climatol.* 27(12):1623–1641.

- Gachon P, St-Hilaire A, Ouarda T, Nguyen VTV, Lin C, Milton J, Chaumont D, Goldstein J, Hessami M, Nguyen T D, Selva F, Nadeau M, Roy P, Parishkura D, Major N, Choux M & Bourque A (2005) A First Evaluation of the Strength and Weaknesses of Statistical Downscaling Methods for Simulating Extremes Over Various Regions of Eastern Canada Sub-component Climate Change Action Fund (CCAF): Environment Canada Montreal Quebec 209 pp.
- Gachon, P & Dibike YB (2007) Temperature change signals in northern Canada: convergence of statistical downscaling results using two driving GCMs. *Int. J. Climatol.*, 27, 1623–1641, doi: 10.1002/joc.1582.
- Geman S, Bienenstock E & Doursat R (1992) Neural networks and the Bias/Variance dilemma. *Neural Computation* 4:1-58.
- GIEC (2000) Special report on emission scenarios. Summary for policymakers. ISBN: 92-9169-113-5.
- GIEC (2007) Summary for Policymakers Climate Change 2007: The Physical Science Basis Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change S Solomon D Qin M Manning Z Chen M Marquis KB Averyt M Tignor and HL Miller Eds Cambridge University Press Cambridge, p 1-18.
- GIEC (2007a) Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change (2007a). Cambridge University Press Cambridge United Kingdom and New York, NY, USA.
- GIEC (2007b) Climate change. Impacts adaptation and vulnerability working group II contribution to the Intergovernmental Panel on Climate Change. Fourth Assessment Report Intergovernmental Panel on Climate Change, Geneva, Switzerland.
- Ghosh S & Majumdar P (2008) Statistical downscaling of GCM simulations to streamflow using Relevance Vector Machine. *Advances in Water Resources* 31(1):132-146.
- Giorgi F & Mearns LO (1991) Approaches to the simulation of regional climate change: A review. *Rev Geophys* 29(2):191–216.
- Gleckler PH (1986) Methods of evaluating the regional hydrologic impacts of global climate changes. *Journal of Hydrology* 88(1-2):97-116.
- Goodess CM & Palutikof J (1998) Development of daily rainfall scenarios for southeast Spain using a circulation-type approach to downscaling. *International Journal of Climatology* 18(10): 1051–1083.
- Gosling SN, Taylor RG, Arnell NW & Todd MC (2011) A comparative analysis of projected impacts of climate change on river runoff global and catchment-scale hydrological models. *Hydrol. Earth Syst. Sci* 15: 279-294. Doi: 10.5194/hess-15-279-2011.
- Govindaraju RS & Rao AR (2000) Artificial neural networks in hydrology. Kluwer Academic Publishers Dordrecht, 329 pp.

- Graham LP, Andreasson J & Carlsson B (2007b) Assessing climate change impacts on hydrology from an ensemble of regional climate models model scales and linking methods: a case study on the Lule River basin. *Climatic Change* 81(Suppl 1):293-307.
- Graham LP, Hagemann S, Jaun S & Beniston M (2007a) On interpreting hydrological change from regional climate models. *Climatic Change* 81(Suppl 1): 97-122
- Green IRA & Stephenson D (1986) Criteria for comparison of single event models. *Hydrological Sciences Journal* 31(3), 395-411
- Grotch SL & MacCracken MC (1991) The use of general circulation models to predict regional climatic change. *Journal of Climate* 4(3): 286 – 303.
- Gustard A, Bullock A & Dixon JM (1992) Low flow estimation in the United Kingdom Institute of Hydrology Report No 108, p 88.
- Hangemann S, Machenhauer B, Jones R, Christensen OB, Déqué M, Jacob D & Vidale PL (2004) Evaluation of water and energy budgets in regional climate models applied over Europe. *Clim. Dyn.* 23(5): 547-567.
- Hashmi MZ, Shamseldin AY & Melville BW (2009) Statistical downscaling of precipitation: state-of-the-art and application of bayesian multi-model approach for uncertainty assessment. *Hydrol. Earth Syst. Sci.*, 6: 6535–6579.
- Hashmi MZ, Shamseldin AY & Melville BW (2011) Statistical downscaling of watershed precipitation using Gene Expression Programming (GEP). *Environmental Modelling & Software* 26(12): 1539-1646.
- Hassanzadeh E, Nazemi A & Elshorbagy A (2013). Quantile-Based Downscaling of Precipitation using Genetic Programming: Application to IDF Curves in the City of Saskatoon. *J. Hydrol. Eng.*, 10.1061/(ASCE)HE.1943-5584.0000854.
- Hayhoe HN (2000) Improvements of stochastic weather data generators for diverse climates *Climate Research* 14(2): 75–87.
- Haykin S (2003) *Neural Networks: A Comprehensive Foundation* Fourth Indian Reprint Pearson Education: Singapore
- Hertig E & Jacobeit J (2008) Assessments of Mediterranean precipitation changes for the 21st century using statistical downscaling techniques, *Int. J. Clim.* 28: 1025–1045. Doi: 10.1002/joc.1597
- Hessami M, St-Hilaire A, Gachon P & Ouarda TBMJ (2008) Automated regression-based statistical downscaling tool. *Environmental Modelling & Software* 23(6): 813-834
- Hewitson BC & Crane RG (1994) *Neural nets: applications in geography*. Dordrecht: Kluwer Academic, Vol 29,p 196, ISBN 978-94-011-1122-5.
- Hewitson BC & Crane RG (1996) Climate downscaling: techniques and application. *Climate Research* 7(1): 85-95. Doi: 103354/cr007085.

- Hewitt CD & Griggs DJ (2004) Ensembles-based predictions of climate changes and their impacts. *Eos Trans AGU* 85(52):566–566. *Doi:101029/2004EO520005*.
- Hinchliffe MP, Willis MJ, Hiden H, Tham MT, Mckay B & Barton GW (1996) Modelling chemical process systems using a multi-gene genetic programming algorithm. In *Genetic Programming: Proceedings of the first Annual conference*. The MIT press, USA.
- Hoerl AE & Kennard RW (1970) Ridge regression: application to nonorthogonal problems. *Technometrics* 12 (1): 69-82.
- Hsieh W (2009) *Machine learning methods in environmental sciences: Neural networks and kernels*. Cambridge University Press.
- Hsu K, Gao X, Sorooshain S & Gupta HV (1997) Precipitation estimation from remotely sensed information using artificial neural networks. *J. Appl. Meteorology* 36(9):1176–1190.
- Hughes JMR (1989) A hydrological regionalization of streams in Victoria, Australia, with implication for stream ecology. *Australian Journal of Marine and Freshwater Research* 40, 303-326.
- Huth, R (2000) A circulation classification scheme applicable in GCM studies. *Theoretical. Appl. Climatology*, 67: 1-18.
- Huth R (2004) Sensitivity of local daily temperature change estimates to the selection of downscaling models and predictors. *Journal of Climate Change* 17(3): 640-652.
- Huth, R., Kliegrova S, Metelka, L. (2008) Non-linearity in statistical downscaling: does it bring an improvement for daily temperature in Europe. *International Journal of Climatology* 28 (4), 465–477.
- Jasper K, Calanca P, Gyalistras D & Fuhrer J (2004) Differential impacts of climate change on the hydrology of two alpine rivers. *Clim. Res.* 26(2):113-125.
- Jeong, DI, Daigle A & St-Hilaire A (2012) Development of a Stochastic Water Temperature Model and Projection of Future Water Temperature and Extreme Events in the Ouelle river basin in Québec, Canada. *River Research and Applications* DOI: 10.1002/rra.2574.
- Jiao Y & Caya D (2006) An investigation of the summer precipitation simulated by the Canadian Regional Climate Model. *Mon. Wea. Rev.* 134(3): 919-932.
- Jones PD, Hulme M & Briffa KR (1993) A comparison of Lamb circulation types with an objective classification scheme. *International Journal of Climatology* 13(6): 655-663.
- Jones PD & Salmon M (1995) Development and Integration of a Stochastic Weather Generator into a Crop Growth Model for European Agriculture MARS Project. Final Report to Institute of Remote Sensing Applications, Agricultural Information Systems (ISPRA), UK; Contract No 5631-93-12 ED ISP GB
- Joshi D, St-Hilaire A, Daigle A and Ouarda TBMJ (2013) Databased comparison of Sparse Bayesian Learning and Multiple Linear Regression for statistical downscaling of low flow indices, *Journal of Hydrology* DOI:10.1016/j.jhr.2011.03.031.
- Kalnay E, Kanamitsu M, Kistler R, Collins W, Deaven D & Gandin L (1996) The NCEP/NCAR 40-year reanalysis project. *Bull. Am. Meteorolog. Soc.* 77(3): 437-471.

- Karl TR, Wang WC, Schlesinger ME, Knight RW & Portman D (1990) A method of relating general circulation model simulated climate to observed local climate Part I: Seasonal statistics. *J Clim.* 3(10):1053-1079.
- Karunanithi N, Grenney WJ, Whitley D & Bovee K (1994) Neural networks for river flow prediction. *J. Comp. in Civ. Engg.* 8(2) :201-220.
- Katz RW (1996) Use of conditional stochastic models to generate climate change scenarios. *Climatic Change* 32: 237–255.
- Kim JW, Chang JT, Baker NL, Wilks DS & Gates WL (1984) The statistical problem of climate inversion: Determination of the relationship between local and large-scale climate. *Monthly Weather Review* 112: 2069-2077.
- Kite GW (1978) Development of a hydrologic model for a Canadian Watershed. *Can J Civ Eng* 5:126-134.
- Kite GW (1993) Application of a land class hydrological model to climatic change. *Wat Resour Res.* 29(7): 2377-2384.
- Koza JR, Bennett HB, Andre D & Keane MA (1999) Genetic Programming III: Darwinian Invention and Problem Solving. Morgan Kaufmann Publishers.
- Krause P, Boyle DP & Base E (2005) Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences* 5: 89-97. Doi: 10.5194/adgeo-5-89-2005.
- Krishnamurti TN & Kumar V (2012) Improved Seasonal Precipitation Forecasts for the Asian Monsoon Using 16 Atmosphere–Ocean Coupled Models. Part II: Anomaly. *J. Climate* 25: 65–88.
- Landman WA, Mason SJ, Tyson PD & Tennant WJ (2001) Statistical downscaling of GCM simulations to streamflow. *J. of Hydrol.* 252(1): 221 – 236
- Legates DR & McCabe Jr. GB (1999) Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation, *Water Resour. Res.*, 35 (1): 233–241
- Leith RMM & Whitfield PH (1998) Evidence of climate change effects on the hydrology of streams in south-central BC. *Canadian Water Resour. J.* 23(3): 219-230.
- Lettenmaier DP & Gan TY (1990) Hydrologic sensitivities of the Sacramento-San Joaquin River Basin to global warming. *Water Resour. Res* 26(1): 69-86.
- Leung LR, Qian Y & Bian X (2003a) Hydroclimate of the western United States based on observations and regional climate simulation of 1981–2000 Part I: seasonal statistics. *J Climate* 16(2): 1912–1928.
- Leung LR, Qian Y, Bian X, Washington WM, Han J & Roads JO (2004) Mid-century ensemble regional climate change scenarios for the Western United States. *Climatic Change* 62(1-3): 75 – 113.
- Liu RY, Parelius JM & Singh K (1999) Multivariate analysis by data depth: Descriptive statistics graphics and inference (with discussion and a rejoinder by Liu and Singh). *Ann Stat* 27(3): 783–858.

- Loaiciga HA, Valdes JB, Vogel R, Garvey J & Schwarz H (1996) Global warming and the hydrologic cycle. *J. Hydrol.* 174(1-2):83–127.
- Loukas A, Vasiliades L & Dalezios NR (2002) Potential Climate Change Impacts on Flood Producing Mechanisms in Southern British Columbia, Canada Using the CGCMA1 Simulation Results. *Journal of Hydrology* 259:, 163-188.
- Mackay DJC (1994) Bayesian methods for backpropagation networks. In E. Dormany, J.L. van Hemmen and K. Schulten, editors, *Model of Neural Networks III*, chapter 6, pages 211-254. Springer, 1994.
- Maier HR & Dandy GC (2000) Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling and Software* 15 (1): 101–124.
- Majercakova O, Fendekova M & Leskova D (1997) The variability of hydrological series due to extreme climate conditions and the possible change of the hydrological characteristics with respect to potential climate change. FRIEND'97 — Regional Hydrology: concepts and models for sustainable Water Resource Management. The International Association of Hydrological Sciences (IAHS), Publication No 246, p 59–66.
- Majercakova O, Leskova D & Sedik P (1995) Selected characteristics of low flows of Slovak rivers. *J Hydrol. Hydromech.* 43(4-5) 331–353.
- Manuel de l'utilisateur de Streamflow synthesis and reservoir regulation model (SSARR) (1991) US Army Corps of Engineers. North Pacific Division.
- Markus M, Salas JD & Shin H-K (1995) Predicting streamflows based on neural networks. Proceeding of 1st Int Conf on Water Resour. Engg., San Antonio Texas, August 14-18.
- Maurer EP, Hidalgo HG, Das T, Dettinger MD & Cayan DR (2010) The utility of daily large-scale climate data in the assessment of climate change impacts on daily streamflow in California. *Hydrology and Earth System Sciences* 14(6): 1125-1138 doi:105194/hess-14-1125-2010.
- McCuen R H (2003) *Modeling Hydrologic Change*, CRC press , p 261-263.
- McCulloch WS & Pitts W (1943) A logic calculus of the ideas immanent in nervous activity. *Bull. of Math Biophys.* 5(4):115-133.
- Mimikou M, Kouvopoulos Y, Cavadias G & Vayianos N (1991) Regional hydrological effects of climate change. *J. Hydrol.* 123(1-2):119–146.
- Monk WA, Wood PJ, Hannah DM, Wilson DA, Extence CA & Chadd RP (2006) Flow Variability and Macroinvertebrate Community Response Within Riverine Systems. *River Research and Applications* 22(5): 595-615.
- Monk WA, Wood PJ, Hannah DM & Wilson DA (2007) Selection of river flow indices for the assessment of hydroecological change. *River Research and Applications* 23(1):113-122.
- Moore D (1993) Application of a conceptual streamflow model in a glacierized drainage basin. *J. of Hydrol.* 150:151-168.

- Morin, G. and Slivitzky M (1992) Impacts de changements climatiques sur le régime hydrologique: le cas de la rivière Moisie. *Rev. Sci. Eau*.5: 179-195.
- Mortsch L, Henry Hengeveld, Murray L, Wenger L , Lofgren B, Quinn F & Slivitzky M (2000) Climate Change Impacts on the Hydrology of the Great Lakes-St Lawrence System. *Canadian Water Resources Journal* 25:2 153-179 DOI: 104296/cwrj2502153.
- Müller-Wohlfeil D-I, Bürger G & Lahmer W (2000) Response of a river catchment to climatic change in northern Germany. *Climatic Change* 4(1): 61-89.
- Murphy J (1999) An evaluation of statistical and dynamical techniques for downscaling local climate. *J. of Clim.* 12(8):2256–2284.
- Najafi, M., Moradkhani H & Wherry S (2011). Statistical Downscaling of Precipitation Using Machine Learning with Optimal Predictor Selection. *Journal of Hydrologic Engineering* 16:650–664.
- Nash L & Gleick P (1991). Sensitivity of streamflow in the Colorado basin to climatic changes. *Journal of Hydrology* 125, 119–146.
- Navone HD & Ceccatto HA (1994). Predicting Indian monsoon rainfall: a neural network approach. *Climate Dyn.* 10, 305-312.
- Neocleous C & Schizas C (2002) Artificial neural network learning: A comparative review. *Methods and Applications of Artificial Intelligence* 2308, p 300–313.
- Ng HYF & Marsalek J (1992) Sensitivity of streamflow simulation to changes in climatic inputs *Nordic Hydrol* 23(4): 257–272.
- Nieto JD & Wilby RB (2005) A comparison of statistical downscaling and climate change factor methods: impacts on low flows in the river Thames United Kingdom. *Climate Change* 69(2-3):245-268
- Olden JD & Poff NL (2003) Redundancy and the choice of hydrologic indices for characterizing streamflow regimes. *River Research and Applications* 19(2):101-121
- Ouarda TBMJ, Christian C & St-Hilaire A (2008) Statistical models and the estimation of low flows. *Canadian Water Resources Journal*. 33(2): 195-206.
- Phillips ID, McGregor GR, Wilson CJ, Bower D & Hannah DM (2003) Regional climate and atmospheric circulation controls on the discharge of two British rivers. *Theoretical and Applied Climatology* 76 (3):141–164.
- Poff NL & Allan JD (1995) Functional organization of stream fish assemblages in relation to hydrological variability. *Ecology* 76, 606-627.
- Poff NL, Allan JD, Bain MB, Karr JR, Prestegard PL, Richter BD, Sparks RE & Stromberg JC (1997) The natural flow regime: a paradigm for river conservation and restoration. *BioScience* 47(11): 769-784
- Poff NL & Ward JV(1989). Implications of streamflow variability and predictability for lotic community structure: a regional analysis of streamflow patterns. *Canadian Journal of Fisheries and Aquatic Sciences* 46, 1805-1818.

- Poff NL(1996). A hydrogeography of unregulated streams in the United States and an examination of scale-dependence in some hydrological descriptors. *Freshwater Biology* 36, 71-91
- Poulin A, Brissette F, Leconte R, Arsenault R & Malo JS (2011) Uncertainty of hydrological modelling in climate change impact studies in a Canadian, snow dominated river basin. *J.of Hydrol.* 409: 626-636.
- Prudhomme C, Reynard N & Crooks S (2002) Downscaling of global climate models for flood frequency analysis: Where are we now? *Hydrol. Process.* 16(6): 1137-1150.
- Puckridge JT, Sheldon F, Walker KF.& Boulton AJ (1998). Flow variability and the ecology of large rivers. *Marine and Freshwater Research* 49: 55-72.
- Pyrce R (2004). Hydrological Low Flow Indices and their Uses, WSC Report No. 04-2004, August 2004.
- Qian B, Hayhoe H & Gameda S (2005) Evaluation of the stochastic weather generators LARS-WG and AAFC-WG for climate change impact studies. *Clim. Res.* 29(1): 3–21.
- Quintana-Segui P, Ribes A, Martin E, Habets F and Boe J (2010) Comparison of three downscaling methods in simulating the impact of climate change on the hydrology of Mediterranean basins. *J. Hydrol.* 383:111-124.
- Racsko P, Szeidl L & Semenov M (1991) A serial approach to local stochastic weather models. *Ecological Modelling* 57(1-2):27–41.
- Richardson CW (1981) Stochastic simulation of daily precipitation temperature and solar radiation. *Wat Resour Res* 17 (1):182-190. Doi: 10.1029/WR017i001p00182.
- Richter BD, Baumgartner JV, Powell J & Braun DP (1996) A method for assessing hydrologic alteration within ecosystems. *Conservation Biology* 10(4):1163–1174. Doi: 101046/j1523-1739199610041163x.
- Richter BD, Baumgartner JV, Wigington R & Braun DP (1997) How much water does a river need? *Freshwater Biology* 37(1):231–249. Doi: 101046/j1365-2427199700153x.
- Richter BD, Baumgartner JV, Braun DP & Powell J (1998) A spatial assessment of hydrologic alteration within a river network. *Regulated Rivers* 14, 329-340.
- Riggs HC, Caffey JE, Orsborn JF, Schaake JC, Singh KP, & Wallace, JR (Task Committee of Low-Flow Evaluation, Methods, and Needs of the Committee on Surface-Water Hydrology of the Hydraulics Division) (1980) Characteristics of low flows. *Journal of the Hydraulics Division, Proceedings of the American Society of Civil Engineers* 106, 717-731.
- Roeckner EA, Rhodin A, Tompkins E, Manzini G, Bäuml I, Kirchner L, Bonaventura L, Kornblueh M, Esch M, Giorgetta R, Brokopf S, Hagemann U, Schlese U, Schulzweida U & Tompkins A (2003) The atmospheric general circulation model ECHAM5 Part I: Model description. *Max Planck Institute for Meteorology Rep.*, p 349 127.
- Rogers JD & Armbruster JT (1990) Low flows and hydrologic droughts. *Surface Water Hydrology: Geological Society of America the Geology of America, Boulder, CO*, p 121–130.

- Roosmalen VL, Sonnerborg TO, Jensen KH & Christensen JH (2011) Comparison of hydrological simulations of climate change using perturbation of observations and distributed-based scaling. *Vadose Zone J.* 10(1):136-150.
- Rousseeuw PJ & Struyf A (1998) Computing location depth and regression depth in higher dimensions. *Statistics and Computing* 8:193–203.
- Rousseeuw PJ & Hubert M (1999) Regression depth. *J. Am. Stat. Assoc.* 94 (446): 389– 433.
- Roy L, Leconte R, Brissette FP and Marche C (2001). The Impact of Climate Change on Seasonal Floods of a Southern Quebec River Basin. *Hydrological Processes* 15, 3167-3179.
- Sakovich VM (1990) The representation of minimum runoff series in Karelia and North-Western region. *Trans. Hydrolmeteorol. Center, USSR* 308, p 129–136.
- Salathe EP (2003) Comparison of various precipitation downscaling methods for the simulation of streamflow in a rainshadow river basin. *Intl J. of Clim.* 23(8): 887 – 901.
- Sastry PS (2003) *An introduction to support vector machines In: Misra JC (Ed) Computing and Information Sciences: Recent Trends.* Narosa Publishing House, New Delhi, India.
- Schmidli JC, Frei C & Vidale PL (2006) Downscaling from GCM precipitation: A benchmark for dynamical and statistical downscaling methods. *Int. J. Climatol.* 26(5) 679-689.
- Schulze RE (1997) Impacts of global climate change in a hydrologically vulnerable region: challenges to South African hydrologists. *Progress in Physical Geography* 21(1): 113-136.
- Searson DP, Leahy DE & Willis MJ (2010) GPTIPS: An Open source Genetic Programming Toolbox For Multigene Symbolic Regression. Proceedings of the International Multi-Conference of Engineers and Computer Scientists (IMECS) (Hong Kong 17-19 March 2010).
- Semenov MA, Brooks RJ, Barrow EM & Richardson CW (1998) Comparison of the WGEN and LARS-WG stochastic weather generators for diverse climates. *Clim. Res.* 10(2): 95–107.
- Shabbar A & Kharin V (2007) An assessment of cross-validation for estimating skill of empirical seasonal forecasts using a global coupled model simulation. *CLIVAR Exchanges* 12(4):10-12.
- Simonovic SP & Li LH (2003) Methodology for assessment of climate change impacts on large-scale flood protection system. *Water Resour Plann Manager* 129(5), 361–372.
- Smakhtin VY & Watkins DA (1997) Low-flow estimation in South Africa Water Research Commission Report No 494/1/97, Pretoria, South Africa.
- Smakhtin VU, Sami K, Hughs DA (1998) Evaluating the performance of a deterministic daily rainfall-runoff model in a low flow context. *Hydrological Processes* 12:797-811.
- Smakhtin VU (2001) Low Flow Hydrology-A review. *J. Hydrol.* 240(3-4):147-136.
- Smola AJ, Scholkopf B & Muller KR (1998) The connection between regularization operators and support vector kernels. *Neural Networks* 11(4):637–649.

- Sparks RE (1992) Risks of altering the hydrologic regime of large rivers. In Predicting Ecosystem Risk. Vol XX. Advances in Modern Environmental Toxicology, Cairns J, Nierderlehner BR, Orvos DR (eds). Princeton Scientific Publishing Co.: Princeton, New Jersey; 119-152.
- Stanford JA, Ward JV, Liss WJ, Frissell CA, Williams RN, Lichatowich JA & Coutant CC (1996) A general protocol for restoration of regulated rivers. *Regulated Rivers: Research and Management* 12(1): 391–413.
- Stefanova L & Krishnamurti TN (2002) Interpretation of Seasonal Climate Forecast Using Brier Skill Score, The Florida State University Superensemble, and the AMIP-I Dataset. *J. Climate*, 15: 537–544. Doi:[http://dx.doi.org/10.1175/1520-0442\(2002\)015<0537:IOSCFU>2.0.CO2](http://dx.doi.org/10.1175/1520-0442(2002)015<0537:IOSCFU>2.0.CO2).
- Stone M (1974) Cross-validators choice and the assessment of statistical predictions. *Journal of the Royal Statistical Society* 36(2):111-133.
- Stoll S, Franssen HJ, Butts M et Kinzelbach W (2011) Analysis of the impact of climate change on groundwater related hydrological fluxes: a multi-model approach including different downscaling methods. *Hydrol. Earth Syst. Sci.* 15, p 21-38. Doi: 10.5194/hess-15-21-2011.
- Suykens J (2001) Nonlinear modeling and support vector machines. In Proceeding of the 18th IEEE. Instrumentation and Measurement Technology Conference, Budapest Hungary 1, p 287–294.
- Tharme RE (2003) A global prespective on environmental flow assessment: emerging trends in the development and application of environmental flow methodologies for rivers. *River Research and Applications* 19: 397-441.
- Thiémonge N & Daigle A (2012) Automation of SSARR calibration process. CWRA-CGU Conference, Banff, Canada, June 5-8 2012.
- Tipping ME (2001) Sparse Bayesian learning and the relevance vector machine. *Journal of Machine Learning Research*, 1: 211-244.
- Tisseuil C, Vrac M, Lek S and Wade AJ (2010) Statistical downscaling of river flows. *Journal of Hydrology* 385, 279-291.
- Teutschbein C, Wetterhall F & Seibert J (2011) Evaluation of different downscaling techniques for hydrological climate-change impact studies at the catchment scale. *Clim. Dynam*, 37: 2087-2105.
- Tohma S & Igata S (1994) Rainfall estimation from GMS imagery data using neural network. Hydraulic engineering software Volume 1, W.R. Blain and K.L. Katsifarakis eds., Computational Mechanics Publications, Southampton, U.K, pp 123-130.
- Tripathi S, Srinivas VV & Nanjundiah RS (2006) Downscaling of precipitation for climate change scenarios: a support vector machine approach. *Journal of Hydrology*, 330(4):621-640. Doi: 101016/jjhydrol200604030.
- Turner J, Connolley WM, Lachlan-Cope TA & Marshall GJ (2006) The performance of the Hadley centre climate model (HadCM3) in high latitudes. *International Journal of climatology*, 26, 91-112.

- User Manual SSARR (1991) Model Streamflow Synthesis and Reservoir Regulation US Army Corps of Engineers North Pacific Division.
- Vapnik VN (1995) *The Nature of Statistical Learning Theory* Springer: New York.
- Vapnik VN (1998) *Statistical Learning Theory* Wiley: New York.
- Vogel RM & Fennessey NM (1994) Flow duration curves I: A new interpretation and confidence intervals. *J. Water Resour. Plan Manag.* 120 (4): 485–504.
- Von SH (1999) On the use of "inflation" in statistical downscaling. *J Clim.* 12 (12):3505-3506.
- Von SH (1999) On the Use of "Inflation" in Statistical Downscaling. *J. Clim.* 12(12): 3505–3506. Doi: [http://dx.doi.org/10.1175/1520-0442\(1999\)012<3505:OTUOII>2.0.CO;2](http://dx.doi.org/10.1175/1520-0442(1999)012<3505:OTUOII>2.0.CO;2).
- Von SH, Langenberg H & Feser F (2000) A spectral nudging technique for dynamical downscaling purposes. *Mon Weather Rev.* 128(10): 3664–3673.
- Walker KF & Thoms MC (1993) Environmental Effects of Flow Regulation on the Lower River Murray Australia. *Regul Rivers Res Manag* 8 (1/2):103–119.
- Wang B, Kang IS & Lee JY (2004) Ensemble simulations of Asian-Australian monsoon variability by 11 AGCMS. *J Clim.* 17(4): 803–818.
- Watts M, Goodess CM & Jones PD (2004) *The CRU Daily Weather Generator BETWIXT* Technical Briefing Note 1, Version 2, February 2004.
- Westmacott JR & Burn DH (1997) Climate change effects on the hydrologic regime within the Churchill-Nelson River Basin. *J of Hydrol.* 202(1): 263-279.
- Whitfield PH Reynolds CJ & Cannon AJ (2002) Modelling Streamflows in Present and Future Climates: Examples from Georgia Basin British Columbia Canadian. *Water Res. J.* 27(4): 427-456.
- Wigley TWL, Jones PD, Briffa KR & Smith G (1990) Obtaining sub-grid scale information from coarse resolution general circulation model output. *J. Geophys. Res.* 95 (D2): 1943-1953. Doi: 10.1177/030913339702100403.
- Wilby RL, Dawson CW, Barrow EM (2002) SDSM – a decision support tool for the assessment of regional climate change impacts. *Environmental Modelling and Software* 17: 145-157.
- Wilby RL, Charles SP, Zorita E, Timbal B, Whetton P, Mearns LO (2004) Guidelines for use of climate scenarios developed from statistical downscaling methods available from the DDC of IPCC TG CIA 27 pp Available from: IPCC-DDC: <<http://www.ipcc-data.org/>>.
- Wilby RL & Wigley TML (1997) Downscaling general circulation model output: a review of methods and limitations. *Progress in Physical Geography* 21(4):530-548.
- Wilby RL & Wigley TML (2000) Precipitation predictors for downscaling: observed and general circulation model relationships. *International Journal of Climatology* 20(6): 641-661.
- Wilby RL (1998) Statistical downscaling of daily precipitation using daily airflow and seasonal teleconnection indices. *Clim Res.* 10(3):163–178.

- Wilby RL, Charles SP, Zorita E, Timbal B, Whetton P & Mearns LO (2004) Guidelines for use of climate scenarios developed from statistical downscaling methods. http://www.ipcc-data.org/guidelines/dgm_no2_v1_09_2004.pdf.
- Wilby RL, Dawson CW & Barrow EM (2002) SDSM – a decision support tool for the assessment of regional climate change impacts. *Environmental Modelling and Software* 17(2):145-157.
- Wilby RL, Hay LE & Leavesly GH (1999) A comparison of downscaled and raw GCM output: implications for climate change scenarios in the San Juan River Basin, Colorado. *Journal of Hydrology* 225, 87-91.
- Wilby RL, Wigley TML, Conway D, Jones PD, Hewitson BC, Main J & Wilks DS (1998) Statistical downscaling of general circulation model output: a comparison of methods. *Water Resources Research* 34(11): 2995-3008.
- Wilks, DS & Wilby RL (1999) The weather generation game: a review of stochastic weather models. *Progress in Physical Geography* 23: 329-357.
- Wood AW, Leung AL, Sridhar V & Lettenmaier DP (2004) Hydrologic Implications of Dynamical and Statistical Approaches to Downscaling Climate Model Outputs. *Clim. Change* 62(1-3):189-216.
- Xu CY (1999) Climate Change and Hydrologic Models: A Review of Existing Gaps and Recent Research Developments. *Water Resources Management* 13 369–382.
- Xu CY & Halldin S (1997) The effect of climate change on river flow and snow cover in the NOPEX area simulated by a simple water balance model. *Nordic Hydrol.* 28(4-5):273–282.
- Xu CY & Singh V P (1998) A review on monthly water balance models for water resources investigations. *Water Resour. Manage.* 12(1): 31–50.
- Xu CY (1999) Climate Change and Hydrologic Models: A Review of Existing Gaps and Recent Research Developments. *Water Resour. Manage.* 13(5): 369–382.
- Yevstigneev VM (1990) Rechnoj stok and gidrologicheskie raschety (River runoff and hydrological calculations). Moscow University, Moscow, 304 p.
- Yue S & Pilon P (2003) Interaction between deterministic trend and autoregressive process. *Water Resour. Res.* 39(4) pp. TNN 1-1, CiteID 1077. Doi: 101029/2001WR001210.
- Zeng Z, Hsieh WW, Shabbar A & Burrows WR (2011) Seasonal prediction of winter extreme precipitation over Canada by support vector regression. *Hydrology and Earth system sciences* 15(1): 65-74.
- Zhang M, Fulcher J & Scofield RA (1997) Rainfall estimation using artificial neural network group. *Neurocomputing* 16(2):97-115.
- Zhang, X, Harvey KD, Hogg WD & Yuzuk TR (2001) Trends in Canadian Streamflow. *Water Resources Research* 37(4), 987-998.
- Zhu M, Fujita M & Hashimoto N (1994) Application of neural networks to runoff prediction. *Stochastic and statistical method in hydrology and environmental engineering* 10(3): 205-216.

Zorita E & von Storch H (1999) The analog method - a simple statistical downscaling technique: comparison with more complicated methods. *J Clim.* 12(8):2474–2489.

Zuo Y & Serfling R (2000) General notions of statistical depth function. *Ann. Stat.* 28 (2): 461–482.

