

UNIVERSITÉ DE SHERBROOKE
Faculté de génie
Département de génie civil et de génie du bâtiment

PRÉVISION HYDROLOGIQUE À COURT
TERME PAR RÉSEAUX DE NEURONES
ARTIFICIELS POUR DIFFÉRENTES
COMBINAISONS, SPATIALISATIONS ET
SOURCES DES INTRANTS.

Thèse de doctorat
Spécialité : génie civil

Renaud JOUGLA

Sherbrooke (Québec) CANADA

Octobre 2022

MEMBRES DU JURY

Robert LECONTE

Département de génie civil et de génie du bâtiment, Université de Sherbrooke

Directeur de thèse

Marie-Amélie BOUCHER

Département de génie civil et de génie du bâtiment, Université de Sherbrooke

Rapporteure, évaluatrice interne

Jonathan ROY

Hydro-Québec

Évaluateur externe

Fateh CHEBANA

Institut National de la Recherche Scientifique, Eau, Terre, Environnement

Évaluateur externe

RÉSUMÉ

Le potentiel de l'utilisation des réseaux de neurones artificiels en prévision hydrologique à court terme (un à sept jours à l'avance) a été démontré dans plusieurs études. Toutefois, les exemples d'utilisation en opérationnel restent limités et la compréhension de l'intérêt de plusieurs variables d'intrants au modèle pas encore entièrement déterminée. Le rôle de la spatialisation des intrants dans ce type de modèle n'est pas connu. Cette thèse examine le rôle de différents intrants, de leur discrétisation spatiale à un modèle de prévision hydrologique à court terme. Elle vise également à confronter différentes sources de données utilisées comme intrants au modèle.

Le modèle de réseaux de neurones développé est un modèle à rétropropagation avec une couche cachée à six neurones. Quatre bassins versants situés en Nouvelle Angleterre (Androscoggin et Susquehanna) ou dans le sud du Québec (Au saumon et Magog) servent de cas d'étude pour faire la prévision durant l'été, défini du 1^{er} mai au 31 octobre. Le modèle de prévision hydrologique vise à prévoir le débit au pas de temps journalier. Au minimum une variable météorologique et une variable d'état sont utilisées comme intrants au modèle ; la variable d'état est aussi mise à jour à chaque pas de temps en étant une sortie du modèle.

Deux environnements de travail sont exploités. L'environnement virtuel sert à identifier les variables d'intrants et la spatialisation les plus pertinentes pour la prévision hydrologique à court terme sur les bassins à l'étude. Le modèle hydrologique à base physique HYDROTEL est utilisé pour générer des séries de pseudo-observations hydrométéorologiques sur chaque site d'étude. Les expériences menées dans cet environnement virtuel révèlent que la meilleure configuration d'intrants utilise la température, la précipitation, l'humidité du sol en surface et le débit. De plus, elles révèlent que les modèles global et spatialisé ont des résultats équivalents.

Basé sur les résultats obtenus en environnement virtuel, l'environnement réel utilise des données d'observations pour le débit et l'humidité et des données de réanalyses de température et de précipitation pour la météo. Les résultats montrent un réel potentiel dans l'utilisation d'un réseau de mesure *in situ* de l'humidité au sol pour faire de la prévision hydrologique. En revanche, la qualité des prévisions est très réduite pour les faibles débits.

Mots-clefs : Prévision hydrologique, réseaux de neurones artificiels, débit, humidité du sol, spatialisation.

REMERCIEMENTS

Je remercie avant tout mon directeur de thèse Robert Leconte pour son écoute, ses conseils, ses questionnements et les discussions autant scientifiques qu’humaines. Je le remercie grandement pour l’autonomie qu’il m’a laissé et pour sa vision et sa passion de la recherche qu’il m’a partagé. Merci pour cet encadrement humain et scientifique !

Je remercie l’ensemble des membres du jury pour la lecture faite et les commentaires apportés sur cette thèse. Je remercie donc Marie-Amélie Boucher, Jonathan Roy et Fateh Chebana.

Mon aventure doctorale a été rendue possible grâce à l’évaluation faite par Marie-Amélie Boucher et Alexandre Roy de mon projet de recherche lors de son commencement. Merci à eux.

Merci aux partenaires industriels d’avoir appuyé cette chaire de recherche et donc ce projet de doctorat : Hydro-Québec (et en particulier Jonathan Roy pour ses nombreuses idées), Énergie renouvelable Brookfield (en particulier Bruno Benedetti) et Hydro-Sherbrooke.

Merci à Manon Ahlouché et Morgan Buire de m’avoir épaulé sur la fin de cette thèse et de m’avoir poussé à me mettre à Python. Le travail effectué et les échanges ont été fort appréciés.

Merci à mes compagnons de sorties terrain (ce fut toujours agréable de sortir de ce bureau sans fenêtre), à Jean Bergeron et Marie-Amélie Boucher pour leur confiance dans les tâches d’auxiliaire d’enseignement et aux comités étudiant et de direction de CentrEau.

Merci à l’équipe hydro pour sa compagnie ! Les moments passés ensemble ont adouci la rudesse académique : sport, soirées jeux, *gossip tea* et discussions en tout genre. Un merci particulier à Charles, Dipti, Khaled, Sepehr, Shimelis, Sergio, Nicolas, Jean, Bijan et Gaby (et Thierry).

Mes remerciements vont aussi aux amis d’ici, Clément, Guillaume, Olivia, Pedro et Joachim, et de là-bas, entre autres, Ambroise et Axel et les chums. Merci à Max pour son support quotidien et les nombreux repas partagés et à la Gaillarde pour leur si bon accueil. Je remercie tendrement Anna pour la richesse de sa présence et de son accompagnement. Merci à Willow pour sa joie de vivre. Le temps passé avec Fleur, Adèle et Marjane ainsi que Manou et Davy fut précieux.

Enfin, je remercie du fond du cœur mes parents pour leur soutien indéfectible, ma sœur et mes frères pour les modèles qu’ils sont depuis toujours et continuent d’être pour moi.

TABLE DES MATIERES

RÉSUMÉ.....	iv
REMERCIEMENTS	v
TABLE DES MATIERES	vi
LISTE DES FIGURES.....	x
LISTE DES TABLEAUX.....	xix
LISTE DES ACRONYMES	xxi
CHAPITRE 1 INTRODUCTION	1
1.1. Mise en contexte.....	1
1.2. Question de recherche	4
1.3. Objectifs du projet de recherche.....	5
1.4. Contributions originales	6
1.5. Plan du manuscrit	8
CHAPITRE 2 REVUE DE LITTÉRATURE.....	9
2.1. La modélisation hydrologique.....	9
2.1.1. Généralités.....	9
2.1.2. Prévision hydrologique	15
2.1.3. Modélisation par apprentissage automatique	17
2.1.4. Comparaisons de performance de modèles d'apprentissage automatique pour la prévision hydrologique.....	31
2.2. Rôle des intrants	35
2.2.1. Introduction	35
2.2.2. Intrants physiographiques	35
2.2.3. Intrants hydrométéorologiques.....	36

2.2.4.	Intrants relatifs à l'état du bassin versant	38
2.3.	Utilisation d'un environnement virtuel contrôlé.....	41
CHAPITRE 3 CADRE MÉTHODOLOGIQUE		45
3.1.	Sites d'étude.....	45
3.1.1.	Introduction	45
3.1.2.	Androscoggin	47
3.1.3.	Susquehanna	48
3.1.4.	Magog.....	49
3.1.5.	Au Saumon	50
3.2.	Matériel	51
3.2.1.	Introduction	51
3.2.2.	Modèle de Réseaux de Neurones Artificiels	52
3.2.3.	HYDROTEL.....	58
3.3.	Environnement virtuel	69
3.4.	Données utilisées	70
3.4.1.	En environnement virtuel : pseudo-observations via HYDROTEL.....	70
3.4.2.	En environnement réel.....	71
3.5.	Méthodes.....	80
3.5.1.	Chaîne de prévision	80
3.5.2.	Configuration d'intrants	81
3.5.3.	Spatialisation des intrants	86
3.5.4.	De l'environnement virtuel à l'environnement réel	90
3.6.	Métriques et outils d'évaluation	92
3.6.1.	Critère de Nash-Sutcliffe	92

3.6.2.	Racine de l'erreur quadratique moyenne	93
3.6.3.	Hydrogrammes	93
CHAPITRE 4	LA PRÉVISION HYDROLOGIQUE À COURT TERME PAR RNA DANS UN ENVIRONNEMENT VIRTUEL	94
4.1.	Avant-propos	94
4.2.	Abstract.....	96
4.3.	Introduction	96
4.4.	Materials and methods.....	101
4.4.1.	Study area.....	101
4.4.2.	Hydrometeorological inputs.....	103
4.4.3.	Artificial Neural Network (ANN) model.....	108
4.4.4.	Methodology	110
4.5.	Results	113
4.5.1.	Preliminary analysis: definition of the number of neurons in the hidden layer	113
4.5.2.	Forecast evaluation according to horizon forecast and inputs	115
4.5.3.	Spatial discretization of inputs	127
4.6.	Discussion.....	131
4.6.1.	Selection of inputs for hydrological forecasting	132
4.6.2.	Spatial distribution of inputs	134
4.6.3.	Comparison with physically based models	135
4.7.	Conclusions	136
CHAPITRE 5	MATÉRIEL SUPPLÉMENTAIRE EN ENVIRONNEMENT VIRTUEL	138
5.1.	Matériel complémentaire à l'article.....	138
5.1.1.	Sélection de la période d'apprentissage	138

5.1.2.	Modèle singulier pour le BV Androscoggin	142
5.1.3.	Comparaison entre modèle spatialisé et modèle global.....	148
5.2.	Configuration d'intrants sur les quatre BV à l'étude	149
5.3.	Rôle de la spatialisation pour le BV Au Saumon	155
5.4.	Sommaire	161
CHAPITRE 6 DE L'ENVIRONNEMENT VIRTUEL À L'ENVIRONNEMENT RÉEL		163
6.1.	Éléments méthodologiques	163
6.1.1.	Présentation des données d'observation <i>in situ</i>	163
6.1.2.	Modèles testés	174
6.2.	Résultats.....	176
6.2.1.	Comparaisons du NSE.....	176
6.2.2.	Analyse des hydrogrammes de validation en environnement réel	186
6.2.3.	Analyse des hydrogrammes de validation en environnement adapté.....	204
6.3.	Discussion.....	212
6.3.1.	Selon l'année	212
6.3.2.	Selon l'essai pour les configurations avec l'humidité du sol	214
6.3.3.	Selon le BV.....	218
6.4.	Sommaire	220
CHAPITRE 7 CONCLUSION		222
7.1.	Résumés des travaux réalisés.....	222
7.2.	Contributions originales.....	225
7.3.	Perspectives de recherche et travaux futurs	227
ANNEXE.....		231
LISTE DES RÉFÉRENCES.....		248

LISTE DES FIGURES

Figure 2.1 - Schéma des éléments constitutifs d'un modèle hydrologique	10
Figure 2.2 – Étapes nécessaires pour la mise en place d'un modèle d'apprentissage automatique.	15
Figure 2.3 – Structure en matriochka de l'intelligence artificielle à l'apprentissage profond en passant par les réseaux de neurones.	19
Figure 2.4 - Schématisation du fonctionnement d'un Réseau de Neurones Artificiels.....	24
Figure 2.5 – Exemple de fonctionnement d'un arbre décisionnaire.	29
Figure 2.6 – Couplage température – humidité du sol (adapté de Seneviratne et al. (2010)) : Humi sol = humidité du sol, Évap = évapotranspiration, Temp = température ; en rouge : action dans le même sens, en bleu : action dans le sens inverse.....	40
Figure 2.7 - Présentation des différentes façons de mesurer l'humidité du sol (issu de Babaeian et al. (2019))	41
Figure 3.1 - Localisation des BV sur la partie nord-est du continent d'Amérique du Nord, avec les BV Susquehanna (vert), Magog (bleu), Au Saumon (rouge) et Androscoggin (ocre).	46
Figure 3.2 – Débit moyen annuel (1975-2015) pour le BV de la rivière Androscoggin à la station USGS1059000 la plus proche de l'exutoire calculé à partir d'une moyenne glissante sur sept jours.....	48
Figure 3.3 – Débit moyen annuel (1975-2015) pour le BV de la rivière Susquehanna à la station USGS1578310 la plus proche de l'exutoire calculé à partir d'une moyenne glissante sur sept jours.....	49
Figure 3.4 – Débit moyen annuel (1975-2015) pour le BV de la rivière Magog calculé à partir d'une moyenne glissante sur sept jours sur le débit reconstitué à partir des stations USGS04296500 et USGS01153000 dans la partie aval du BV.	50
Figure 3.5 – Débit moyen annuel (1975-2015) pour le BV de la rivière Au Saumon à la station 030282 la plus proche de l'exutoire calculé à partir d'une moyenne glissante sur sept jours. .	51

Figure 3.6 – Représentation schématique des environnements a) virtuel et b) réel développés dans cette thèse.	52
Figure 3.7 - Schématisation du transfert d'information entre deux neurones biologiques	53
Figure 3.8 - Schéma d'ensemble d'un RNA à une couche cachée à quatre neurones, avec trois neurones dans la couche d'entrée et deux dans la couche de sortie.....	54
Figure 3.9 - Types de fonction d'activation communément utilisées et testées.....	57
Figure 3.10 - Représentation des schémas d'écoulement vertical CEQUEAU (gauche) et BV3C (droite)	64
Figure 3.11 – Hydrogrammes après calage avec les données NRCan (Au Saumon et Magog) et USGS (Androscoggin et Susquehanna) sur la période 2007-2013 pour les quatre BV à l'étude.	68
Figure 3.12 – Localisation des stations hydrométriques (triangles rouges) sur les BV Magog et Au Saumon et des points de grille ERA5-land (croix noires)	73
Figure 3.13 - Illustrations d'installation de sondes d'humidité du sol en milieu ouvert (gauche) et en milieu forestier (droite).....	76
Figure 3.14 – Localisation des sondes d'humidité du sol (losange) et de la station hydrométrique (triangle rouge) sur le BV Au Saumon pour les étés 2018, 2019, 2020 et 2021.....	77
Figure 3.15 – Localisation des sondes d'humidité du sol (losange) et de la station hydrométrique (triangle) sur le BV Magog pour les étés 2018, 2019, 2020 et 2021.....	78
Figure 3.16 - Illustrations d'installation de sondes d'humidité du sol en surface (gauche) et en profondeur (droite)	79
Figure 3.17 - Chaîne de prévision générale (exemples jusqu'à deux jours à l'avance). Le tilde représente une sortie du modèle de RNA. La journée à laquelle est associée chaque valeur est inscrite en indice.....	81
Figure 3.18 – Corrélation API modifié – HU (lignes pleines et pointillés) + corrélation API classique – HU (ligne horizontale à ~0,48). Comparaison selon les valeurs de δ et API_{max} sélectionnant les données que sur l'été.....	84

Figure 3.19 - Représentation des différentes spatialisations d'intrants possibles : (a) semi-spatialisé, (b) global et (c) spatialisé. 87

Figure 3.20 - Représentation schématique de construction des intrants spatialisés à partir des intrants semi-spatialisés..... 89

Figure 4.1 – Land cover of Susquehanna (a) and Androscoggin (b) watersheds. Red triangles indicate the location of the United States Geological Survey (USGS) streamflow stations used (reference number 1,578,310 and 1,059,000 for the Susquehanna and the Androscoggin watersheds respectively). 102

Figure 4.2 – Mean annual streamflow for (a) Susquehanna and (b) Androscoggin watersheds, generated with datasets covering 47 years (1969–2015). 103

Figure 4.3 – Schematic representation of BV3C simulation option for vertical water budget in HYDROTEL. The thicknesses of the 3 soil layers are represented by Z_1 , Z_2 , and Z_3 , and the associated soil moisture are Θ_1 , Θ_2 , and Θ_3 , and the relative real evapotranspiration ETR_1 , ETR_2 , and ETR_3 , respectively. Total evaporation, precipitation and surface runoff are designed by E , P , and R , respectively. The interflow and the baseflow are represented by Q_2 and Q_3 , and the baseflow, respectively. 106

Figure 4.4 – Schematic representation of a three-layer back-propagated ANN with 3 inputs, 4 hidden neurons, and 2 outputs..... 109

Figure 4.5 – Schematic representation of the forecast chain used (example for forecasts one and two days in advance and exactly represented 2-SMP and 3-dSMP with update of watershed state variable at each time step). The tilde represents outputs of the ANN model. The index represents the forecast horizon day, with 0 the day of forecasting. 111

Figure 4.6 – Evaluation of the number of neurons in the hidden layer for (a) the Androscoggin and (b) the Susquehanna watersheds. Blue boxplots are relative to the training step, while red are for the validation step. Each boxplot is plotted with the 16 summers used in the cross-validation process..... 115

Figure 4.7 – Evolution of NSE across the 7-day forecast window for the Androscoggin watershed. The training step is in full line, while leave-one-out validation is in dotted line. QP results are represented in red, SMP in blue, dSMP in cyan, and QSMP in green. Each subplot

corresponds to a specific step of our cross-validation approach with the year used in validation in sub-title.	121
Figure 4.8 – Evolution of NSE across the 7-day forecast window for the Susquehanna watershed. The training step is in full line, while leave-one-out validation is in dotted line. QP results are represented in red, SMP in blue, dSMP in cyan, and QSMP in green. Each subplot corresponds to a specific step of our cross-validation approach with the year used in validation in sub-title.	122
Figure 4.9 – Hydrographs for the Androscoggin watershed for summer 2009 (validation period) (a) 1, (b) 3, (c) 5 and (d) 7 days in advance.	123
Figure 4.10 – Hydrographs for the Susquehanna watershed for summer 2009 (validation period) (a) 1, (b) 3, (c) 5 and (d) 7 days in advance.	124
Figure 4.11 – Hydrographs for the Androscoggin watershed for summer 2010 (validation period) (a) 1, (b) 3, (c) 5 and (d) 7 days in advance.	125
Figure 4.12 – Hydrographs for the Susquehanna watershed for summer 2010 (validation period) (a) 1, (b) 3, (c) 5 and (d) 7 days in advance.	126
Figure 4.13 – For the Androscoggin watershed, the evolution of the NSE across the 7-day forecast window for 3 types of input spatialization: (a) global (i.e., grid average), (b) distributed (i.e., full-grid), and (c) single pixel (i.e., each of the 28 grid points individually). Each boxplot represents the dispersion across the 16 years used in cross-validation, blue is training, red is validation.	128
Figure 4.14 – NSE evolution for the Androscoggin watershed in 2009. (a) Training, (b) Validation. Colored lines for each pixel, dotted line for the distributed model, and full line for the global one.	130
Figure 4.15 – NSE evolution for Androscoggin watershed in 2012. (a) Training, (b) Validation. Colored lines for each pixel, dotted line for the distributed model, and full line for the global one.	130
Figure 5.1 – Évolution du RMSE (gauche) et du NSE (droite) selon l’horizon de prévision en apprentissage (traits pleins) et en validation (traits pointillés) pour la configuration HUP avec	

l'année 2009 ou 2010 en validation et les années sèches (respectivement rose et bleu), humides (respectivement rouge et cyan) ou toutes (respectivement vert et jaune) en apprentissage.... 141

Figure 5.2 - Évolution du RMSE (gauche) et du NSE (droite) selon l'horizon de prévision en apprentissage (traits pleins) et en validation (traits pointillés) pour la configuration Q avec l'année 2009 ou 2010 en validation et les années sèches (respectivement rose et bleu), humides (respectivement rouge et cyan) ou toutes (respectivement vert et jaune) en apprentissage.... 141

Figure 5.3 - Indice des cellules pour le BV Androscoggin 143

Figure 5.4 - Hydrogrammes pour l'année 2009 en validation de 1 à 7 jours à l'avance avec superposition de l'observation (rouge), la sortie du modèle spatialisé (bleu) et les sorties des modèles singuliers (gris). La dernière sous-figure montre le NSE et le RMSE en apprentissage (appr, en bleu) et la validation (vali, en rouge) sur la fenêtre de prévision de 7 jours avec les lignes pour le modèle spatialisé et les boîtes à moustache pour les modèles singuliers. 146

Figure 5.5 - Hydrogrammes pour l'année 2012 en validation de 1 à 7 jours à l'avance avec superposition de l'observation (rouge), la sortie du modèle spatialisé (bleu) et les sorties des modèles singuliers (gris). La dernière sous-figure montre le NSE et le RMSE en apprentissage (appr, en bleu) et la validation (val, en rouge) sur la fenêtre de prévision de 7 jours avec les lignes pour le modèle spatialisé et les boîtes à moustache pour les modèles singuliers. 147

Figure 5.6 – NSE en a) apprentissage et b) validation après avoir considéré l'ensemble des 16 étés comme période de validation via une validation croisée, pour le modèle spatialisé (rouge) et le modèle global (vert) pour le BV Androscoggin. 149

Figure 5.7 – Évolution du NSE selon l'horizon de prévision sur la période d'apprentissage lorsque 2009 est la période de validation pour 17 configurations d'intrants pour les BV a) Au Saumon, b) Magog, c) Androscoggin et d) Susquehanna. 153

Figure 5.8 – Évolution du NSE selon l'horizon de prévision sur la période de validation (2009) pour 17 configurations d'intrants pour les BV a) Au Saumon, b) Magog, c) Androscoggin et d) Susquehanna. 154

Figure 5.9 – Boîtes à moustache du NSE en validation construites sur les sept horizons de prévision et les quatorze années de la validation croisée pour les trois spatialisations et les deux combinaisons d'intrants testés. glo faisant référence au modèle global, spat au spatialisé et

semispat au semi-spatialisé. HU et QHU font références à la variable d'état utilisée, l'humidité du sol seule ou combinée avec le débit.....	157
Figure 5.10 – Évolution du NSE en validation sur les sept horizons de prévision pour chaque année de validation (correspondant à une sous-figure) et pour les trois spatialisations et les deux combinaisons d'intrants testés.....	158
Figure 5.11 – Hydrogrammes en validation pour les années 2003 à J+1 (a) et J+7 (b) et 2009 à J+1 (c) et J+7 (d) avec la configuration d'intrants utilisant débit et humidité du sol comme variables d'état.....	160
Figure 6.1 – Différence absolue entre les données d'humidité du sol observées in situ et simulées par HYDROTEL par année d'instrumentation (2018 à 2021) pour le BV Au Saumon, avec les numéros des stations et d'UHRH correspondants. Le nombre de jours pour lesquels on dispose de données d'observations est indiqué à titre indicatif en titre de chaque sous-figure.	166
Figure 6.2 - Débit moyen journalier à la station Au Saumon pour les années 2018 – 2022 avec superposition des précipitations moyennes journalières issues des réanalyses ERA5-land. En rouge, les périodes pour lesquelles on dispose d'observations in situ d'humidité du sol.	168
Figure 6.3 – Différence absolue entre les données d'humidité du sol observées in situ et simulées par HYDROTEL par année d'instrumentation (2018 à 2021) pour le BV Magog, avec les numéros des stations et d'UHRH correspondants. Le nombre de jours pour lesquels on dispose de données d'observations est indiqué à titre indicatif en titre de chaque sous-figure.	171
Figure 6.4 - Localisation de la station fictive après confluence des rivières Clyde et Black. .	172
Figure 6.5 - Débit moyen journalier reconstruit au pont de la route 5 à Newport (VT) pour les années 2018 – 2022 avec superposition des précipitations moyennes journalières issues des réanalyses ERA5-land. En rouge, les périodes pour lesquelles on dispose d'observations in situ d'humidité du sol.....	173
Figure 6.6 – Évolution du NSE avec l'horizon de prévision en apprentissage (colonne de gauche), validation en environnement virtuel (colonne centrale) et validation en environnement réel (colonne de droite) pour le BV Au Saumon sur les années 2018 à 2021 pour six configurations différentes ne faisant pas intervenir le débit comme intrant au modèle (scénarios	

1, 2, 5 et 6 avec l'humidité du sol en surface (traits pleins) et 9 et 10 en profondeur (traits pointillés)). 182

Figure 6.7 – Évolution du NSE avec l'horizon de prévision en apprentissage (colonne de gauche), validation en environnement virtuel (colonne centrale) et validation en environnement réel (colonne de droite) pour le BV Au Saumon sur les années 2018 à 2021 pour six configurations différentes faisant intervenir le débit comme intrant au modèle (scénarios 3, 4, 7 et 8 avec l'humidité du sol en surface (traits pleins) et 11 et 12 en profondeur (traits pointillés)). 183

Figure 6.8 – Évolution du NSE avec l'horizon de prévision en apprentissage (colonne de gauche), validation en environnement virtuel (colonne centrale) et validation en environnement réel (colonne de droite) pour le BV Magog sur les années 2018 à 2021 pour six configurations différentes ne faisant pas intervenir le débit comme intrant au modèle (scénarios 1, 2, 5 et 6 avec l'humidité du sol en surface (traits pleins) et 9 et 10 en profondeur (traits pointillés)). 184

Figure 6.9 – Évolution du NSE avec l'horizon de prévision en apprentissage (colonne de gauche), validation en environnement virtuel (colonne centrale) et validation en environnement réel (colonne de droite) pour le BV Magog sur les années 2018 à 2021 pour six configurations différentes faisant intervenir le débit comme intrant au modèle (scénarios 3, 4, 7 et 8 avec l'humidité du sol en surface (traits pleins) et 11 et 12 en profondeur (traits pointillés)). 185

Figure 6.10 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2018 à 2021 pour le BV Au Saumon avec l'humidité du sol en surface pour les configurations 1 à 4 qui utilisent l'approche d'extrapolation moyenne (couleurs) et le débit observé (noir). 191

Figure 6.11 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2018 à 2021 pour le BV Au Saumon avec l'humidité du sol en surface pour les configurations 5 à 8 qui utilisent l'approche d'extrapolation ppv (couleurs) et le débit observé (noir). 193

Figure 6.12 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2019 à 2021 pour le BV Au Saumon avec l'humidité du sol en profondeur pour les

configurations 9 à 12 qui utilisent l'approche d'extrapolation moyenne (couleurs) et le débit observé (noir).....	194
Figure 6.13 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2018 à 2021 pour le BV Magog avec l'humidité du sol en surface pour les configurations 1 à 4 qui utilisent l'approche d'extrapolation moyenne (couleurs) et le débit observé (noir)....	200
Figure 6.14 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2018 à 2021 pour le BV Magog avec l'humidité du sol en surface pour les configurations 5 à 8 qui utilisent l'approche d'extrapolation ppv (couleurs) et le débit observé (noir).	202
Figure 6.15 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2019 à 2021 pour le BV Magog avec l'humidité du sol en profondeur pour les configurations 9 à 12 qui utilisent l'approche d'extrapolation moyenne (couleurs) et le débit observé (noir).	203
Figure 6.16 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement adapté sur 2018 à 2021 pour le BV Au Saumon avec l'humidité du sol en surface pour les configurations 1 à 4 (couleurs) et le débit observé (noir).....	207
Figure 6.17 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement adapté sur 2018 à 2021 pour le BV Au Saumon avec l'humidité du sol en profondeur pour les configurations 9 à 12 (couleurs) et le débit observé (noir).....	208
Figure 6.18 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement adapté sur 2018 à 2021 pour le BV Magog avec l'humidité du sol en surface pour les configurations 1 à 4 (couleurs) et le débit observé (noir).....	210
Figure 6.19 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement adapté sur 2018 à 2021 pour le BV Magog avec l'humidité du sol en profondeur pour les configurations 9 à 12 (couleurs) et le débit observé (noir).....	211
Figure A2.1 – Hydrogrammes et hyétogrammes annuels pour le BV Androscoggin à l'exutoire du BV (simulation HYDROTEL) pour les années 2000 à 2007.	237
Figure A2.2 – Hydrogrammes et hyétogrammes annuels pour le BV Androscoggin à l'exutoire du BV (simulation HYDROTEL) pour les années 2008 à 2015.	238

Figure A2. 3 – Hydrogrammes en validation pour les années 2000 à 2013 (excluant 2003 et 2009) à J+1 (panneau de gauche) et J+7 (panneau de droite) avec la configuration d'intrants utilisant débit et humidité du sol comme variables d'état. 244

Figure A3. 4 – Profils d'humidité du sol pour quatre sondes installées en 2020 (haut) et 2021 (bas) en milieux forestier (gauche) et ouvert (droite), avec superposition des précipitations et des mesures in situ en surface (bleu) et en profondeur (rouge). 246

Figure A3.5 – Profils d'humidité du sol en surface issues des observations in situ (rouge) et issues des simulations HYDROTEL (bleue) pour quatre sondes installées en 2020 (en haut) et 2021 (en bas) avec superposition des précipitations. 247

LISTE DES TABLEAUX

Tableau 2.1 - Exemples extraits de la littérature d'utilisation de modèles d'apprentissage automatique pour la prévision hydrologique à court terme.....	34
Tableau 3.2 - Occupation du sol et superficie des quatre BV à l'étude.	47
Tableau 3.3 - Variables de sortie du modèle HYDROTEL.....	60
Tableau 3.4 – Épaisseur des couches de sol pour les quatre BV après calage d'HYDROTEL. La couche 1 correspond à la couche de surface, la couche 2 à la couche intermédiaire et la couche 3 à la couche profonde.....	64
Tableau 3.5 - Dates d'installation et de retrait des sondes d'humidité du sol pour les BV Au Saumon et Magog.....	76
Tableau 3.6 - Configurations d'intrants testées. P représente la précipitation, T la température moyenne, ETP l'évapotranspiration, Q le débit, Hu l'humidité du sol en surface et Hupro l'humidité du sol en profondeur. Les indices font référence au jour auquel on prend ces variables pour une prévision faite un jour à l'avance.	85
Tableau 3.7 - Origine des données pour les échantillons d'apprentissage et de validation en environnements adapté et réel.	91
Table 4.1 – Return streamflow for four specific return periods: 2, 10, 25, and 100 years for the two watersheds, generated with datasets covering 47 years (1969–2015).	103
Table 4.2 – Summary of HYDROTEL's defined sub-models and associated simulation options. Simulation options used in this study to generate hydrometeorological 'observations' are bolded.	105
Table 4.3 – Combinations of variables defined as artificial neural network (ANN) inputs.	107
Table 4.4 – Number of inputs for the ANN model depending on the combination of variables and the spatial distribution. With a regular grid, information is only given for the Androscoggin watershed (An.).	112
Table 4.5 – Nash–Sutcliffe efficiency (NSE) values for Susquehanna and Androscoggin for summer 2009, a relatively wet year, as validation period.	119

Table 4.6 – NSE values for Susquehanna and Androscoggin for summer 2010, a relatively dry year as validation period.	120
Tableau 5.1 – Sept meilleurs indices (par ordre croissant du meilleur au 7 ^e meilleur) du modèle singulier présentant les meilleurs NSE pour chaque horizon de prévision en apprentissage et en validation selon l’utilisation de l’été 2009 ou 2012 comme échantillon de validation, avec utilisation de la configuration HUP.....	144
Tableau 5.2 – Configurations d’intrants testées. Les indices 0 et 1 correspondent au pas de temps présent et au jours suivant	151
Tableau 6.1 – Corrélations moyennes entre données d’humidité du sol en surface et en profondeur selon l’année de validation pour les BV Au Saumon et Magog en apprentissage et validation en environnement adapté et en validation en environnement réel.	165
Tableau 6.2 – Caractérisation des essais effectués. P = précipitation, T _n = température minimale, T _x = température maximale, H _{u_{surf}} = humidité du sol en surface, Q = débit, H _{u_{prof}} = humidité du sol en surface en profondeur.	174
Tableau A1.1 - Avantages et inconvénients des différents capteurs pour la télédétection de l’humidité du sol.....	231
Tableau A1.2 – Options des méthodes disponibles dans HYDROTEL pour l’interpolation des données météorologiques.	231
Tableau A1.3 – Méthode disponible dans HYDROTEL pour l’évolution du couvert nival. ..	232
Tableau A1.4 – Options des méthodes disponibles dans HYDROTEL pour l’évapotranspiration	232
Tableau A1.5 – Équations et pas de temps associés pour les méthodes de calcul de l’évapotranspiration dans HYDROTEL.....	233
Tableau A1.6 – Noms et unités des paramètres utilisés dans les différentes options de calcul de l’évapotranspiration dans HYDROTEL.....	233
Tableau A1.7 – Méthode disponible dans HYDROTEL pour le ruissellement.....	235
Tableau A1.8 – Méthode disponible dans HYDROTEL pour le laminage,	235

LISTE DES ACRONYMES

Acronyme	Définition
RNA (<i>ANN</i>)	Réseaux de Neurones Artificiels (<i>Artificial Neural Network</i>)
BV	Bassin Versant
BV3C	Bilan Vertical à 3 Couches
CART	Arbre de classification et de régression (<i>Classification And Regression Tree</i>)
CEPMMT (<i>ECMWF</i>)	Centre Européen de Prévisions Météorologiques à Moyen Terme (<i>European Centre for Medium-range Weather Forecast</i>)
CNN	Réseaux de neurones convolutifs (<i>Convolutional Neural Network</i>)
DEH	Direction de l'Expertise Hydrique
ERA5-Land	Composantes de surfaces des réanalyses météorologiques de 5 ^e génération du CEPMMT (<i>land component of the 5th generation of the ECMWF ReAnalysis</i>)
LSTM	Longue mémoire à court terme (<i>Long Short Term Memory</i>)
NSE	Critère de Nash-Sutcliffe (<i>Nash-Sutcliffe Efficiency</i>)
RMSE	Racine de l'erreur quadratique moyenne (<i>Root Mean Square Error</i>)
SMAP	<i>Soil Moisture Active and Passive</i>
SMOS	<i>Soil Moisture and Ocean Salinity</i>

CHAPITRE 1 INTRODUCTION

1.1. Mise en contexte

L'hydrologie se définit comme la science qui étudie le cycle de l'eau dans sa partie continentale. Les phénomènes étudiés sont nombreux et peuvent faire l'objet de disciplines propres comme l'hydrogéologie pour l'étude des échanges des flux dans les couches de sol, l'hydrologie urbaine pour la compréhension de l'interaction entre réseau hydrographique et réseau urbain anthropique ou encore l'hydrologie glaciaire pour l'évaluation de l'impact des glaciers continentaux et de la glace de mer sur un régime hydrologique. Lorsqu'on parle d'hydrologie, on évoque avant tout l'étude du cheminement de l'eau dans un environnement particulier. On cherche alors à comprendre les flux qui régissent l'écoulement et les échanges qu'il peut y avoir entre les différentes sections de cet environnement (transferts de chaleur et de matière, changement de type de sol, changement d'état). Finalement, l'hydrologie est la science qui veut comprendre le cheminement d'une goutte de pluie une fois tombée du nuage.

La réponse à cette question n'est pas aussi triviale qu'elle y paraît. Dans les contrées du Québec et de la Nouvelle-Angleterre, à l'échelle d'un bassin versant (BV), le régime hydrologique est soumis à des accumulations importantes de neige en hiver qui constituent une réserve d'eau remise à disposition sous forme liquide lors de la fonte. Au printemps, avec la hausse des températures, la fonte de ce stock fournit au réseau hydrographique des apports en eau très importants, souvent les plus importants à l'échelle d'une année. En été et en automne, l'évolution du régime hydrologique est principalement régie par le débit de base des cours d'eau et par les apports venant de dépressions et de cellules orageuses. Quelle qu'en soit la source, l'estimation des apports en eau à un BV consiste en une quantification des écoulements du réseau hydrographique qui confluent à l'exutoire du BV et qui contribuent au débit du cours d'eau principal. Cette estimation des apports se fait avec l'aide d'un modèle hydrologique.

La connaissance de ces apports s'avère importante pour les organismes veillant à la sécurité des biens et des personnes tout comme pour les gestionnaires de ressources hydriques. Un des enjeux de taille est de prévenir et d'alerter au besoin la population, les services publics et les différents secteurs d'activités sensibles ou impactées par les extrêmes hydrologiques du cours

d'eau. L'anormalité évoquée ici renvoie au dépassement de seuils de sécurité, niveaux à partir desquels les cours d'eau peuvent sortir de leur lit et impacter de façon critique, voire parfois catastrophique, la population, la société dans tout son ensemble et l'environnement. Le dépassement de seuil se caractérise en fait soit par un excédent d'eau (crues et inondations), soit par un déficit d'eau (étiages et sécheresses).

La prévision hydrologique a pour objectif d'anticiper ces événements, de se prémunir au mieux des dangers qui peuvent en découler et vise à atténuer les coûts éventuels, qu'ils soient humains, environnementaux, matériels ou financiers. Cette réduction des coûts, associée à une maximisation des gains, dépend en particulier des plans d'action mis en œuvre par les différents acteurs et aussi d'une bonne connaissance de l'état du BV, de ses caractéristiques physiographiques et des apports futurs. La modélisation hydrologique permet entre autres d'établir des prévisions hydrologiques utiles aux gestionnaires et décisionnaires de ressources hydriques. Elles fournissent de l'information sur le débit d'une rivière, sur le niveau d'eau d'un réservoir, sur la quantité de neige au sol et/ou sur la teneur en eau du sol qui sont anticipés dans les heures, les jours ou les semaines à venir.

La prévision hydrologique est une discipline de l'hydrologie à part entière. Elle vise à répondre à des besoins précis sur des territoires différents aux problématiques diverses. Il est ainsi possible de fournir une tendance saisonnière sur une grande région rassemblant plusieurs BV, de prévoir à un pas de temps de l'ordre de quelques minutes le comportement de cours d'eau soumis à des crues-éclair ou de quantifier de façon déterministe ou probabiliste le débit d'une rivière quelques jours à l'avance.

La littérature regorge d'une pléthore de modèles hydrologiques. La méthode rationnelle présentée dans sa première forme en 1851 par Mulvany semble être la plus ancienne. Cette méthode est décrite par l'équation 1.1. Elle lie de manière empirique le débit maximum à l'exutoire d'un BV (Q) associé à l'intensité d'une précipitation (i), aux caractéristiques du BV à l'étude comme sa superficie (A) et au coefficient de ruissellement (C) qui est fonction du type de sol et de la pente moyenne du BV.

$$Q = CiA \quad (1.1)$$

De nos jours, des méthodes développées font appel à une description « à base physique » des processus d'écoulement à l'échelle du BV (Devi et al., 2015). D'autres méthodes font preuve d'originalité en utilisant des ressources inhabituelles dans ce domaine telles que la participation citoyenne (Shein, 2022). Enfin, certaines reposent sur les technologies et avancées informatiques les plus récentes en intelligence artificielle (Mosavi et al., 2018).

Depuis deux décennies, les développeurs et utilisateurs explorent un florilège de modèles basés sur l'apprentissage machine parmi lesquels se trouvent les Réseaux de Neurones Artificiels (RNA). Inspirés du fonctionnement neuronal biologique, l'utilisation des RNA fait consensus pour le potentiel d'action qu'ils offrent à des domaines très variés, tels que l'hydrologie. Cela ne veut pas dire qu'ils font systématiquement mieux qu'un modèle traditionnel (en se basant sur des métriques évaluatrices de performances), mais qu'il y a des approches et possibilités ouvrant de nouveaux pans de modélisation et par extension de prévision. Par exemple, contrairement aux approches à base physique, un modèle basé sur une structure de RNA n'est pas tenu d'intégrer de l'information relative à la physiographie du BV.

Les variables utilisées comme intrants au modèle peuvent être de natures différentes. Il est par exemple courant de recourir à des variables d'état, des variables météorologiques et des variables physiographiques. Elles décrivent respectivement la quantité d'eau stockée sur et dans le BV, les variations à venir d'un point de vue hydrométéorologique et les caractéristiques liées à la physique du BV et à son occupation.

Quelle que soit la variable considérée, il s'agit d'apporter une part de l'information nécessaire permettant de décrire l'état passé, présent ou futur du BV. Selon le BV à l'étude, on constate une grande hétérogénéité : type de sol, occupation du sol, variation de l'intensité d'une pluie, épaisseur du manteau neigeux. Il devient alors important de les intégrer dans le modèle de prévision afin de représenter au mieux le BV et donc de prédire au mieux le futur comportement du réseau hydrographique associé. Cette hétérogénéité du territoire est décrite par la résolution spatiale des intrants utilisés. Cela peut ensuite influencer la capacité du modèle hydrologique à décrire certains phénomènes de fine échelle.

Comme évoqué un peu plus tôt, la communauté scientifique s'accorde sur le potentiel d'utilisation des modèles construits sur une structure de RNA pour faire de la prévision

hydrologique. Cependant, le nombre d'exemples en opérationnel reste modéré, d'où le besoin de continuer à explorer les capacités d'une telle structure. Il n'est donc pas futile de chercher à en apprendre plus sur le comportement d'un RNA pour faire de la prévision hydrologique et en particulier d'explorer son comportement avec de multiples intrants.

1.2. Question de recherche

Ce projet de doctorat s'intègre dans la chaire de recherche industrielle du Conseil de Recherches en Sciences Naturelles et en Génie (CRSNG) sur la valorisation des observations de la Terre en ressources hydriques. Les trois partenaires industriels que sont Hydro-Québec, Énergie renouvelable Brookfield et Hydro-Sherbrooke sont gestionnaires de parcs hydroélectriques. Ils travaillent suivant leur échelle à maximiser leur production d'énergie électrique tout en tenant compte, parmi d'autres, des facteurs techniques, scientifiques, environnementaux, légaux et humains. Selon leur taille, la structure et les équipes mises à disposition, ils poursuivent des objectifs distincts. Toutefois, en s'associant à cette chaire, et en soutenant le présent projet de doctorat, ils témoignent d'un intérêt certain pour le potentiel des résultats et des impacts qu'ils peuvent avoir sur « la gestion de leur parc d'équipement tout en tenant compte des intérêts des riverains potentiellement touchés par cette gestion » (tiré de la proposition d'établissement d'une chaire de recherche industrielle par Beauvais et Leconte en 2017).

L'axe de recherche de la chaire de recherche industrielle qui nous intéresse ici porte sur une évaluation des produits hydrométéorologiques obtenus à partir des capteurs satellitaires pour l'amélioration de la prévision hydrologique. Le présent projet de doctorat s'intègre parfaitement dans cet axe en se positionnant dans un cadre expérimental virtuel contrôlé intégrant des jeux de données de différentes sources. Étant donné la complexité potentielle à accéder à des jeux de données de qualité similaire en longueur (profondeur temporelle) et en contenu (variables disponibles) pour plusieurs BV, l'appel à des données générées numériquement offre un cadre d'étude vaste et prometteur. Cette recherche amènera donc à tester plusieurs combinaisons d'intrants et à explorer différentes spatialisations de ces intrants. Le cadre expérimental virtuel offre cette latitude de changer la spatialisation sans perdre la profondeur temporelle et la mise en application sur chaque variable.

Par ailleurs, les modèles existants pour prévoir le débit sont divers et, comme introduits plus tôt, les modèles d'apprentissage machine, parmi lesquels se trouvent les RNA, offrent des opportunités techniques intéressantes. Les ressources nécessaires sont moindres qu'avec des modèles traditionnels. De plus, les données physiographiques, parfois délicates à obtenir sur un ensemble de BV, peuvent être « ignorées » dans le cadre d'une prévision par RNA. Cette approche de modélisation par RNA requiert des moyens humains différents et moins d'efforts pour la validation continue des paramètres internes du modèle. Toutefois, un des enjeux majeurs dans l'utilisation d'un RNA est la nécessité d'avoir une grande quantité de données pour l'apprentissage. L'avantage d'être dans un environnement virtuel est justement de contourner, au moins partiellement, ce problème en ayant accès à des bases de données plus grandes.

Considérant ces différents éléments, il apparaît prometteur d'utiliser un modèle de RNA dans un cadre expérimental virtuel. Les essais réalisés pourront être menés pour des configurations différentes d'intrants (en termes de variables, mais aussi de spatialisation) ; cela permettra donc de voir le potentiel de la modélisation par RNA dans des situations diverses et d'ensuite concentrer les efforts sur des situations précises dans un cadre réel avec de vraies données d'observation.

Se pose donc la question de recherche suivante : **quel est l'apport des intrants et de leur spatialisation dans un modèle de prévision hydrologique basé sur une structure de RNA ?**

1.3. Objectifs du projet de recherche

L'objectif de la thèse vise à prévoir le débit à l'exutoire d'un BV avec la meilleure discrétisation spatiale des données d'entrée à un modèle de prévision hydrologique construit sur une structure de RNA. Comme mentionné dans la section précédente, la prévision hydrologique peut être réalisée sur un horizon temporel allant de quelques heures à plusieurs semaines. Dans le cadre de cette recherche, la prévision hydrologique à court terme, soit sur un horizon temporel de un à sept jours, sera examinée. Pour répondre à cet objectif, trois axes de recherche ont été définis et chacun cherche à offrir des éléments novateurs.

Les trois objectifs de cette thèse de doctorat sont :

1) comprendre le comportement du modèle de RNA pour faire de la prévision hydrologique à court terme selon l'utilisation de différentes variables d'état comme intrants au modèle. L'apport de chaque variable est évalué et cet objectif cherche à proposer la meilleure combinaison possible d'intrants pour bâtir le modèle de prévision hydrologique, basé sur une structure de RNA, le plus robuste possible, en environnement virtuel ;

2) caractériser le comportement du modèle de RNA pour faire de la prévision hydrologique à court terme à partir de différentes spatialisations des intrants.

Le modèle de RNA sera pris avec une configuration d'intrants particulière. Selon la discrétisation spatiale retenue, les sorties de débit seront évaluées. La comparaison sera également proposée sur des BV de tailles contrastées. Les processus hydrologiques étant régis par les variations dans l'espace et dans le temps, cette comparaison permettra d'estimer l'influence de la spatialisation des intrants sur la prévision du débit à l'exutoire ;

3) à partir d'un modèle de RNA construit dans un environnement virtuel avec des données synthétiques, faire une évaluation de ce modèle lors de l'utilisation de données réelles issues de données d'observations au sol.

Ce troisième objectif soulève la question de la mise en application d'un modèle de RNA en opérationnel. Sans se rendre jusqu'à la mise en place d'un système de prévision complet centré autour d'un modèle hydrologique par RNA, la différence de comportement selon l'origine des intrants au modèle sera examinée, avec ici le cas des données d'observations au sol.

1.4. Contributions originales

Trois contributions scientifiques ressortent de cette thèse.

La principale contribution de ce travail est de proposer une comparaison de l'apport de la spatialisation des intrants pour faire de la prévision hydrologique à court terme à partir d'un

modèle de RNA. Cet axe de développement vise à comprendre le rôle de la discrétisation spatiale de l'intrant d'humidité du sol sur les performances du modèle de prévision. On compare les discrétisations globale, semi-spatialisée et spatialisée. On ajoute également une discrétisation appelée singulière qui est une approche utilisant un pixel du modèle spatialisé pour représenter l'ensemble du BV. Cette première contribution vise à donner des pistes de développement pour renforcer le passage en opérationnel des modèles de prévision hydrologique basé sur des RNA.

Une deuxième contribution originale vient du travail de transfert réalisé entre l'environnement virtuel et l'environnement réel. Travailler en environnement virtuel permet une grande liberté dans les expériences menées afin de converger vers une sélection restreinte d'essais qui sont consistants d'un point de vue scientifique et en particulier en termes de méthodologie déployée. L'environnement virtuel sert donc de cadre synthétique idéal de travail : on dispose d'un large panel de variables à des discrétisations temporelles et spatiales identiques. Cela permet de déceler des tendances, des promesses et de servir de référence pour les expériences à mener ensuite en environnement réel. Cette contribution mélangeant deux environnements de travail renforce également le potentiel des RNA en prévision hydrologique avec l'utilisation de deux bases de données différentes entre l'apprentissage (environnement virtuel) et la validation (environnement réel).

Enfin, une dernière innovation vient de la construction même de la chaîne de prévision. L'horizon de prévision visé va de un à sept jours à l'avance. Le système de prévision proposé est itératif et utilise la sortie d'un modèle pour la prévision au jour J comme intrant pour le modèle de prévision au jour J+1. Par conséquent, on obtient une mise à jour constante des variables d'entrée au modèle de RNA. Chaque jour, ce n'est pas un modèle qui tourne avec des sorties allant de un à sept jours à l'avance, mais bien sept modèles qui tournent avec tous un horizon de un jour, mais qui sont successifs. La chaîne de prévision ici développée utilise donc des modèles qui ont appris avec des erreurs relatives spécifiques : le modèle à J+1 avec les erreurs associées aux données d'observation et au-delà de J+1, le modèle de RNA apprend avec des intrants imparfaits. Cette imperfection vient de l'incertitude liée à la prévision qui vient d'être faite au pas de temps précédent et qui est utilisée comme nouvel intrant.

1.5. Plan du manuscrit

Cette thèse est composée de sept chapitres. Le chapitre 2 résume l'état des connaissances actuelles par rapport au contexte du projet. Il s'agit d'apporter les informations utiles pour comprendre comment produire une prévision hydrologique à partir d'approches d'apprentissage automatique et en particulier de RNA. On y présente les variables utilisées en prévision hydrologique à court terme : quelles sont-elles ? d'où viennent-elles ? quelles sont leurs caractéristiques ? Ensuite, on parle d'environnement de modélisation, en cherchant à comprendre quels sont les cadres de modélisation qui existent en hydrologie et où on se place parmi ceux-là. Le chapitre 3 présente les sites à l'étude, le matériel utilisé, à savoir les modèles et les données, et la méthodologie déployée. Ce chapitre vise à présenter l'ensemble des outils utilisés et la façon dont on les a maniés.

Les trois chapitres suivants présentent les résultats de cette thèse et apportent donc des réponses dans chacun des axes définis. Le chapitre 4 correspond à l'étude des variables utilisées comme intrants au modèle de prévision et propose une évaluation de différentes spatialisations des intrants. Il est constitué d'un article publié dans la revue *Water*. Le chapitre 5 apporte des éléments supplémentaires pour compléter l'étude publiée. Tous les résultats issus de ces chapitres 4 et 5 viennent d'expériences menées en environnement virtuel. Le chapitre 6 propose une évaluation du modèle de prévision hydrologique à court terme par RNA dans un contexte réel.

Enfin, le chapitre 7 clôture l'ensemble de cette dissertation avec une conclusion et une présentation des perspectives offertes par le travail effectué.

CHAPITRE 2 REVUE DE LITTÉRATURE

2.1. La modélisation hydrologique

2.1.1. Généralités

Introduction

Qu'il s'agisse d'enjeux opérationnels ou d'enjeux scientifiques auxquels font face des industriels ou des organismes publics, la modélisation hydrologique est utile à des fins :

- a. d'études d'impacts,
- b. d'amélioration des connaissances sur le comportement des bassins,
- c. d'aide à la conception d'ouvrages hydriques,
- d. d'aide à la prévision hydrologique,
- e. de test de différentes conceptualisations de l'hydrosystème,
- f. d'aide à la gestion des systèmes hydriques.

Ces six types d'application ne se dissocient pas les uns des autres et peuvent se recouper entre eux : plusieurs applications peuvent servir la même cause. Par exemple, les applications a. et c. peuvent être jointes pour évaluer l'impact d'ouvrages hydriques sur des bassins et voir différents comportements à venir selon des scénarios sélectionnés ; c'est le cas par exemple des études publiées par Hecht et al. (2019) sur le Mékong et Annys et al. (2020) sur le Nil. Un autre exemple est de coupler les applications b. et d. en développant un modèle de prévision en contexte actuel et en le soumettant aux changements climatiques. Cela permet alors d'évaluer la robustesse du modèle de prévision dans ce contexte changeant (Kourgialas et al., 2015). Dans le cadre de ce doctorat, l'application principale est la prévision mais il n'est pas exclu de rendre disponible le modèle développé pour renforcer des études sur d'autres applications.

Quel que soit l'objectif, la modélisation est une représentation simplifiée d'un phénomène pour s'approcher au plus près de la réalité par l'écriture de lois physiques et équations mathématiques (Hingray et al., 2009). La résolution de tels problèmes requiert très fréquemment (pour ne pas dire tout le temps pour les problèmes de modélisation traités de nos jours) de grandes puissances de calcul. L'utilisation de supercalculateurs n'est pas futile et peut même se révéler nécessaire

pour certaines études intégrant plusieurs BV et des intrants aux modèles « lourds », tels que des images satellitaires.

La complexité d'un modèle est principalement liée à trois choses : la connaissance du problème à résoudre (processus entrant en jeu, interactions entre les variables), les données disponibles pour définir le problème et la capacité de calcul disponible.

Un modèle a besoin d'être défini mais aussi d'être nourri. En hydrologie, sa définition repose sur la schématisation du BV, des processus, le choix de ses paramètres et des variables d'état. La « nourriture » vient des conditions initiales, des variables d'entrée et des conditions aux limites. En sortie, une fois que le modèle a exploité les entrées grâce aux schémas de sa structure interne, des variables de sortie sont disponibles pour l'utilisateur (Figure 2.1). Il s'agit typiquement de flux tels que le débit en rivière, les apports aux réservoirs et l'évapotranspiration, ou de variables d'état comme le stock de neige, l'humidité du sol et la hauteur d'eau de lacs et de réservoirs.

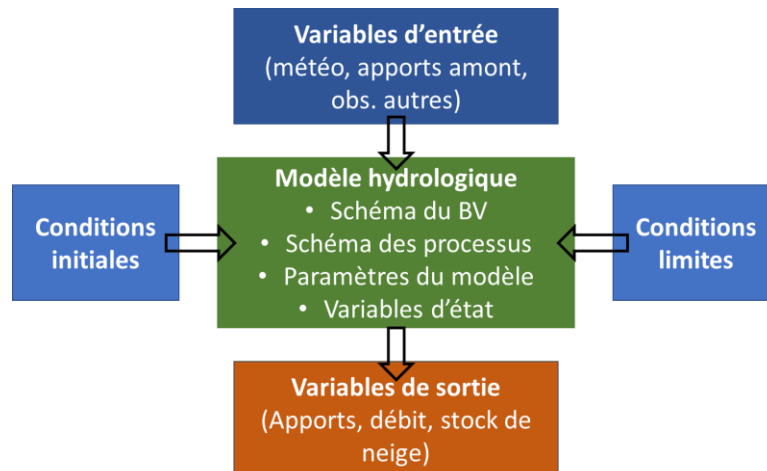


Figure 2.1 - Schéma des éléments constitutifs d'un modèle hydrologique

Les modèles hydrologiques sont des outils numériques représentant de manière simplifiée la totalité ou une partie des processus physiques en jeu dans la partie terrestre du cycle de l'eau. Les modèles hydrologiques se caractérisent à partir de leurs discrétisations spatiale et temporelle et de leur degré d'abstraction. Ces discrétisations peuvent être étroitement liées, notamment à cause des phénomènes hydrométéorologiques en jeu sur les échelles spatiales et temporelles (Singh, 1997).

Discrétisation spatiale

Quel que soit le modèle hydrologique développé, il est nécessaire de définir la façon de tenir compte de l'hétérogénéité spatiale du BV dans la structure du modèle. Plusieurs modèles conceptuels ou à base physique permettent d'intégrer des intrants avec diverses discrétisations. Ces modèles-là font ensuite une interpolation spatiale sur la base d'unités hydrologiques préalablement définies. On peut citer en particulier HYDROTEL qui utilise les unités hydrologiques relativement homogènes (UHRH) (Fortin et al., 1995), le Soil and Water Assessment Tool (SWAT) qui emploie les sous-bassins (Arnold et al., 1998). Il demeure que la discrétisation spatiale des intrants se définit comme la façon d'intégrer avec précision de l'information spatialisée au modèle. L'utilisateur est souvent contraint de choisir à partir des données qui sont disponibles et de l'application du modèle qui sera faite.

Trois grandes familles de discrétisation spatiale existent et sont étroitement liées aux processus modélisés. Ils se distinguent par leur façon de représenter les unités hydrologiques utilisées dans la modélisation.

Les modèles globaux considèrent le BV comme entité unique. Ainsi, il n'y a qu'une seule unité hydrologique prise en compte et les processus hydrologiques modélisés le sont à l'échelle de l'ensemble du BV. Aucune variabilité spatiale n'est donc prise en compte avec ce type de modèle. Les modèles Génie Rural (GR) peuvent être cités à titre d'exemple (Michel, 1983). Cette approche est particulièrement intéressante pour les BV sur lesquels peu de données sont disponibles et dont la variabilité spatiale n'est pas connue. Il peut aussi être pertinent d'utiliser ce type de modèle si le BV à l'étude est homogène d'un point de vue de sa variabilité géospatiale.

Les modèles semi-spatialisés divisent le BV en unités hydrologiques à partir de données topographiques, d'occupation du sol et de type de sol. Les processus hydrologiques sont modélisés à l'échelle de chacune de ces unités. La taille de chaque unité n'est pas fixe et les caractéristiques de chaque zone sont homogènes d'un point de vue physiographique. Un découpage selon le réseau hydrographique peut aussi être fait. Les unités hydrologiques peuvent être appelées sous-bassins. Certains modèles comme SWAT (Arnold et al., 1998) proposent ces deux compositions, avec des sous-bassins qui contiennent des Unités de Réponses

Hydrologiques (URH). Les URH sont dans ce cas construits à partir de la pente (marqueur topographique), de l'occupation du sol et du type de sol.

Enfin, les modèles spatialisés découpent le BV sur une maille régulière de forme géométrique. La taille du maillage peut entraîner des difficultés lors du calage du modèle. En effet, un grand nombre de mailles entraîne une paramétrisation plus longue du modèle, car la variabilité spatiale est alors très précise et les informations peuvent parfois être délicates à obtenir à l'échelle de la grille avec consistance. TOPMODEL (Beven et Kirkby, 1979) est un exemple commun qui offre la possibilité d'ajuster la taille des mailles dépendamment de la précision du modèle d'élévation disponible et de la taille du BV étudié.

L'utilisation d'une discrétisation plutôt qu'une autre ne fait pas consensus et il plutôt établi que cela dépend de l'application faite du modèle et de l'information sur le BV dont dispose l'utilisateur (Moulin, 2009 ; Oddos, 2002).

Plus de détails sont fournis à ce propos ultérieurement mais il est pertinent d'annoncer dès à présent que les modèles d'apprentissage machine ne sont pas limités dans leur structure interne par une discrétisation spatiale plutôt qu'une autre. Au contraire, la structure interne des modèles déterministes est très régulièrement définie par une spatialisation particulière. Les exemples de modèle déterministe dont la structure interne est flexible sont plus rares. HEC-HMS est un modèle qui permet une grande palette d'options à l'utilisateur dans la définition de la discrétisation spatiale du BV à modéliser. En effet, les étapes sont sensiblement les mêmes que le modèle monté soit global ou semi-spatialisé.

Discrétisation temporelle

Deux types de discrétisation temporelle sont possibles : la modélisation continue ou la modélisation événementielle. En modélisation continue, les processus hydrologiques sont simulés à chaque pas de temps et un historique de données peut être fourni au modèle pour simuler une période passée tout comme des données de prévision pour simuler une période future. Le modèle est contraint par des conditions aux limites, que sont les forçages atmosphériques. Une modélisation continue peut s'échelonner sur de longues périodes de temps,

de l'ordre de dizaines d'années dans le cadre d'études des impacts des changements climatiques sur le régime hydrologique de BV (Clark et al., 2016). Dans le cas d'une modélisation événementielle, comme un événement pluvieux ou une saison hydrologique, la modélisation peut être simplifiée et les processus lents sont en particulier éliminés de la modélisation. Si cela s'y prête par rapport à l'étude réalisée, plusieurs processus peuvent être ignorés, comme l'évapotranspiration si l'événement modélisé se limite à un événement précipitant ou les processus de fonte de neige si la modélisation porte seulement sur la saison estivale.

Discretisation selon le degré d'abstraction

Deux grandes familles sont ici distinguées avec d'une part les modèles conceptuels et à base physique et d'autre part les modèles empiriques, parfois appelés boîtes noires, dont font notamment parti les modèles d'apprentissage automatique. Ces derniers feront l'objet d'une sous-section à part entière, mais des éléments descriptifs généraux seront dès à présent exposés.

Les modèles à base physique reposent sur l'établissement de relations physiques comme les équations de Saint Venant par exemple. Les modèles conceptuels fonctionnent sur la base de concepts comme les fonctions de production (représentant par exemple un ensemble de réservoirs conceptuels) et des fonctions de transfert comme dans les modèles HSAMI (Fortin, 2000) et HYDROTEL (Fortin et al., 1995). Les deux types de modélisation sont illustrés par de nombreux de modèles qui ne cessent d'évoluer (Devi et al., 2015; Singh et Woolhiser, 2002). Ces modèles ne restent pas figés au cours du temps et évoluent au gré des besoins, des connaissances et des moyens à disposition (notamment la puissance de calcul). Le SHE (Système Hydrologique Européen) a par exemple inclus une fonction de transfert des sédiments à l'échelle du bassin versant (Bathurst, 1995). Par ailleurs, TOPMODEL (Beven et Kirkby, 1979) a été modifié pour proposer une approche plus physique et améliorer l'estimation de certains paramètres (Beven et al., 2021). Enfin, tant pour les modèles à base physique que conceptuel, une étape de calage est toujours nécessaire. Préalable à celle-ci une analyse de sensibilité est à faire afin de connaître les paramètres les plus influents. Le calage du modèle vise à ajuster au mieux ces paramètres pour que le modèle simule le mieux possible les séries de données observées (Turcotte, 2010).

Dans la typologie des modèles empiriques, on s'intéresse ici aux modèles d'apprentissage automatique. Un modèle statistique d'apprentissage automatique fait partie de la grande famille de l'intelligence artificielle. En hydrologie et plus largement dans les ressources hydriques, cette branche se distingue des approches déterministes traditionnelles par une structure interne du modèle qui décèle des schémas et de l'information directement dans les données fournies en entrée. Un modèle d'apprentissage automatique ajuste des paramètres d'une « boîte » qui prend en entrée des données et fournit en sortie un résultat. Un modèle d'apprentissage automatique est plus rapide à installer et moins coûteux que les modèles déterministes (Mosavi et al., 2018). Deux éléments régissent le fonctionnement même des modèles d'apprentissage automatique : leur robustesse et leur facteur de généralisation (Mosavi et al., 2018). La robustesse est la capacité du modèle à apprendre d'une série de données ; il faut donc que celle-ci couvre, autant que possible, l'ensemble des situations. Le facteur de généralisation est la capacité du modèle à être performant pour détecter des événements qu'il n'a pas appris. Pour tous les modèles d'apprentissage automatique, le schéma d'utilisation est commun (Figure 2.2). Cinq étapes sont requises : 1) la collecte des données ; 2) le pré-traitement des données : vérification de la qualité des données et si nécessaire des corrections peuvent être faites, choix de la méthode de normalisation et application de celle-ci et sélection des variables explicatives et des variables cibles ; 3) la construction de l'architecture du modèle ; 4) l'entraînement¹ : à partir d'un jeu de données, apprentissage par le modèle des différents schémas qui régissent les relations entre les variables d'entrée ; 5) la validation : à partir d'un jeu de données différent de celui d'apprentissage, évaluation de la qualité du modèle lors d'une utilisation en mode prédictif ; si le résultat n'est pas satisfaisant, un retour à l'étape 3) peut être effectué.

¹ Dans cette thèse, le choix est fait de confondre les termes apprentissage et entraînement. Pour simplifier la lecture, au-delà de cette note, c'est le terme d'apprentissage qui est retenu.




Figure 2.2 – Étapes nécessaires pour la mise en place d'un modèle d'apprentissage automatique.

2.1.2. Prévision hydrologique

La prévision hydrologique consiste en l'anticipation du comportement hydrologique d'un BV via le niveau d'eau souterraine (Gong et al., 2016), le ruissellement de surface (Ali et Shahbaz, 2020), le débit d'un cours d'eau (Anctil et al., 2004 ; Demirel et al., 2009 ; Kratzert et al., 2018) ou le niveau d'un réservoir (Seo et al., 2015). Selon les besoins et selon les données disponibles, la prévision peut être faite de quelques heures (Lovat et al., 2020) à plusieurs mois voire saison à l'avance (Bazile et al., 2017). La précision associée à ces différentes prévisions varie. En effet, on peut s'attendre à ce qu'une prévision quelques heures à l'avance fournisse des valeurs précises avec un intervalle de confiance relativement petit. En revanche, une prévision faite quelques mois ou saisons à l'avance fournira une tendance des événements à venir. Il est donc important de bien préciser la variable à prédire et de bâtir le modèle de prévision hydrologique adéquat. Dans l'ensemble des sciences liées aux ressources hydriques, chaque modèle de prévision répond à un besoin particulier. L'échéance de prévision est un attribut important qui définit dans les grandes lignes le modèle de prévision qui va être mis en place. L'échéance de prévision dépend généralement des variables à prédire. Quatre classes peuvent être définies : le temps réel (de 1 h à 24 h à l'avance), le court terme (de 1 à 10 jours à l'avance), le moyen terme (d'une semaine à quelques mois à l'avance) et le long terme ou saisonnier (de quelques mois à plusieurs saisons à l'avance). Les crues rapides de type méditerranéenne sont généralement prévues en temps réel (Javelle et al., 2021). Les débits de rivière et hauteur de réservoir sont des variables fréquemment prévues à court et moyen termes (Belvederesi et al., 2020 ; Lefaiivre et al., 2009 ; Zhu et al., 2020). À long terme, les modèles de gestion sont pertinents à mettre en

place à long-terme (Haguma et Leconte, 2018), mais on y retrouve toujours des prévisions de débit de rivière sous forme cette fois de tendance (Bazile et al., 2017).

Le temps de réponse du BV à l'étude dicte fortement l'horizon et le pas de temps de la prévision. En effet, faire de la prévision journalière sur un BV ayant un temps de réponse de quelques heures seulement sera un défi car la dynamique du BV ne sera pas correctement prise en compte (Obled et al., 2009). Il convient alors de bien construire son modèle et les données d'entrée. Le pas de temps du modèle étant supérieur au temps de réponse du BV, des phénomènes hydrologiques peuvent être manqués par le modèle. Il est ainsi recommandé d'utiliser un modèle de prévision à un pas de temps inférieur ou égal au temps de réponse du BV (Obled et al., 2009). Avec une application dans un schéma d'assimilation de données, Li et al. (2013) illustre bien l'importance de tenir compte du temps de réponse du BV pour faire la meilleure prévision possible du débit à l'exutoire du BV. Dans les schémas d'assimilation de données qu'ils ont développés, la qualité des prévisions est la meilleure pour le schéma qui intègre le mieux le temps de réponse du BV, notamment grâce à une meilleure estimation de l'humidité du sol.

Par ailleurs, il est important de mentionner la différence entre prévision déterministe et prévision probabiliste. La prévision déterministe fournit, pour chaque pas de temps, une valeur unique en sortie. Les conditions initiales et conditions aux limites ne sont paramétrées qu'une seule fois. À partir des intrants fournis (hydrométéorologiques, physiographiques), le prévisionniste ne dispose que d'une simulation. Au contraire, une prévision probabiliste met en parallèle un ensemble constitué de membres (Cloke et Pappenberger, 2009). Chaque membre est une version du modèle avec des conditions initiales et/ou aux limites qui varient et qui permettent de tenir compte de l'incertitude liée à ces conditions (Buizza et al., 2007). Il est parfois possible à l'utilisateur d'imposer cette variation ou celle-ci peut être aléatoire. En sortie, on dispose alors d'un ensemble de possibilités/prévisions, à savoir une valeur pour chaque membre de l'ensemble. Cet ensemble attribue une probabilité égale à chacun de ses membres. Le prévisionniste dispose donc d'une prévision sous forme probabiliste avec notamment des informations plus variées qu'un modèle déterministe, disposant entre autres de la médiane et de la dispersion. La prévision fournie par un modèle probabiliste avec une faible dispersion (décrite ici comme l'écart entre la valeur minimale prévue et la valeur maximale prévue ou entre les 25^e et 75^e percentiles) sera considérée avec un niveau de confiance élevée. En revanche, une large

dispersion sera perçue comme une difficulté du modèle à prévoir ce qui arrive et donc une instabilité forte (Pappenberger et al., 2013). Le prévisionniste aura alors une prédisposition pour livrer une tendance plus qu'une valeur précise. L'apprentissage de l'utilisation en opérationnel d'une telle information est d'ailleurs un enjeu majeur, de même que la communication auprès des destinataires finaux à qui est adressée une telle prévision (Cloke et Pappenberger, 2009).

Bien que ces deux types de modèles puissent être utilisés sur toutes les échéances de prévision, il est plus courant d'utiliser les modèles déterministes seulement pour le court terme (jusqu'à une semaine à l'avance) ou le moyen terme, où les conditions initiales et aux limites sont plus facilement connues avec précision. Les modèles probabilistes peuvent, quant à eux, être utilisés pour toutes les échéances de prévision.

Il est important de noter qu'un modèle probabiliste est très souvent issu d'un modèle déterministe ; seules des itérations supplémentaires sont faites. Il semble important de mentionner ici que les arbres de décisions et les forêts aléatoires constituent en fait les versions déterministe et probabiliste d'un même type de modèle.

Dans le cadre de cette recherche, on montera un modèle de prévision hydrologique déterministe. Cette thèse cherche à comprendre le comportement d'un modèle de RNA selon différents intrants et dépendamment de leur spatialisation ; l'utilisation d'un modèle déterministe suffit donc pour remplir cet objectif. Dans un cadre de passage à l'opérationnel, on comparerait sûrement avec un modèle de prévision d'ensemble, mais ceci ne constitue pas un objectif de cette thèse.

2.1.3. Modélisation par apprentissage automatique

Introduction

L'intelligence artificielle a été définie par Arthur Samuel en 1959 comme l'étude qui donne aux ordinateurs un potentiel d'apprentissage sans programmation explicite². En 1997, Tom Mitchell offre quant à lui une définition plus pragmatique affirmant qu'un programme peut apprendre

² Citation originale : *Machine learning is the study that gives computers the ability to learn without being explicitly programmed* (librement traduit).

d'une expérience E à l'aide de certaines tâches T et d'une mesure des performances P si les performances des tâches T , mesurées par P , s'améliorent au cours de l'expérience E ³. À partir de ces deux définitions, il est possible de reformuler en affirmant qu'un modèle dit d'intelligence artificielle va apprendre par lui-même grâce à l'expérience qu'il aura acquise et sans que le programmeur/utilisateur/humain lui fournisse explicitement les règles d'apprentissage. L'intelligence artificielle est utilisée et toujours en cours de développement dans quasiment tous les domaines, de la finance à la médecine, en passant par le militaire, la robotique et les sciences de l'atmosphère et des ressources hydriques.

L'apprentissage automatique, ou *machine learning* en anglais, est le sous-élément de l'intelligence artificielle d'intérêt pour cette recherche (Figure 2.3). Ce type d'approche se base sur des règles mathématiques et/ou statistiques pour développer des modèles d'apprentissage. Un des plus simples et meilleurs exemples est la régression. En ayant connaissance des caractéristiques descriptives d'un jeu de données (par exemple ses coordonnées dans un référentiel constitué de deux axes), il est possible d'en déduire le meilleur polynôme (une fonction linéaire comme un polynôme d'ordre n) approchant l'ensemble du jeu de données. D'autres modèles basés sur des approches d'apprentissage automatique plus complexes existent : les forêts aléatoires, les machines à vecteur de support (SVM, de *Support Vector Machine* en anglais) et les RNA étant parmi les approches les plus connues (Figure 2.3). L'apprentissage automatique est utile tant pour des problèmes de classification que pour des problèmes de régression (Shen, 2018) ; il revient alors à l'utilisateur de se renseigner sur les propriétés internes des modèles existants pour retenir celui (ceux) qui sera (seront) le(s) plus approprié(s) au problème à traiter.

³ Citation originale : *A program can be said to learn from experience E with respect to some class of tasks T and performance measure P , if its performance of tasks in T , as measured by P , improves with experience E (librement traduit).*

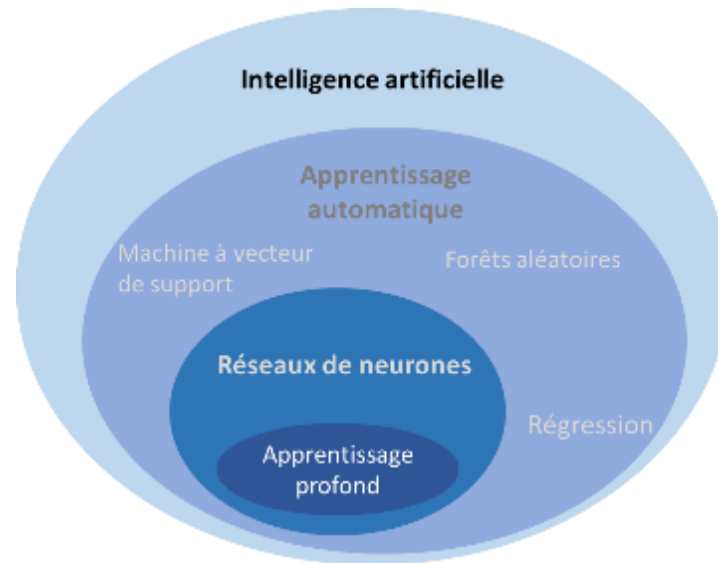


Figure 2.3 – Structure en matriochka de l'intelligence artificielle à l'apprentissage profond en passant par les réseaux de neurones.

Quel que soit le modèle choisi, l'apprentissage automatique repose sur le concept d'apprentissage – validation – test (Mosavi et al., 2018). La phase d'apprentissage consiste en une étape de paramétrisation du modèle développé durant laquelle entrées et sorties sont fournies au modèle pour optimiser au mieux les relations entre les deux. La phase de validation consiste à vérifier la paramétrisation faite en apprentissage sur un jeu de données indépendants. Selon les résultats obtenus, il peut être décidé de revenir à l'étape d'apprentissage et faire de nouveaux essais en modifiant les paramètres ou les intrants au modèle. Une évaluation par validation est faite à chaque nouvel essai. Enfin, la phase de test est une évaluation finale qui consiste à fournir un échantillon de données inconnu et indépendant des deux autres (Bishop, 2006). Quel que soit le résultat sur cet échantillon-là, aucun retour ne sera fait sur les étapes précédentes ; l'idée ici est de faire une évaluation finale du modèle sur un jeu de données qui lui est inconnu (comme en mode prévision en fait). Cette étape est très souvent ignorée. Dans cette thèse, compte tenu de la faible profondeur temporelle des séries de données utilisées, on choisira également de ne pas intégrer d'échantillon test.

Dans le domaine des ressources hydriques, plusieurs applications font appel aux modèles d'apprentissage automatique. Des réponses, ou au moins des pistes de réponse, à certains défis sont fournies par ce type d'approche, tels que ceux présentés par Shen (2018) :

- résoudre des problèmes interdisciplinaires (aide à la décision, couplage avec des données socio-économiques) ;
- apprendre et construire des schémas de distribution complexe (relations surface-couches profondes pour les échanges de polluants dans le sol, lien processus géophysiques et actions humaines) ;
- extraire de l'information à partir d'images satellitaires (précipitation, humidité du sol, température de surface, indices foliaires, neige, zones inondables) ;
- modéliser la dynamique de la variabilité spatio-temporelle de certains processus hydro-météorologiques dans différentes applications (gestion de barrages (requiert des historiques *robustes*), hydrologie et hydraulique en milieu urbain, développement de modèles pluie-débit).

Les principales limites des modèles d'apprentissage automatique concernent leur rapport avec les utilisateurs et la mise en place de ces structures (Sit et al., 2020). Contrairement aux modèles traditionnels pour lesquels on peut se pencher sur les équations internes qui décrivent les phénomènes hydrologiques ayant un sens physique, avec les modèles d'apprentissage automatique, la structure interne repose davantage sur une boîte grise⁴. Il peut ainsi être délicat de prendre en main le modèle et de trouver un sens aux hyperparamètres à définir lors de la phase d'apprentissage. Bien que très répandus dans la littérature scientifique, les exemples d'utilisation de ces modèles en opérationnel sont plutôt rares (on peut cependant citer l'exemple de trois jeunes entreprises nord-américaines qui développent/emploient de tels modèles en opérationnel : GeoSapiens⁵, FlowWorks⁶ et UpstreamTech⁷). Cela entraîne en partie un

⁴ On entend souvent parler de boîte noire pour se référer à la structure interne des modèles d'apprentissage automatique en avançant son obscurité et son manque de réel sens physique. Bien qu'en accord avec ce second argument, nous tenons à modérer ces propos car une bonne compréhension des équations qui régissent la structure interne permet de maîtriser bien mieux le modèle et donc d'en avoir la main lors de la phase de paramétrisation. À l'image de Chen et al. (2019), de Kingston et al. (2006) et de Nearing et al. (2021), qui cherchent à déconstruire cette idée fallacieuse, nous sommes convaincus que le terme de boîte grise est plus approprié : une structure interne, certes sans sens physique en comparaison aux modèles traditionnels mais, qui reste accessible aux modélisateurs qui peuvent toujours personnaliser les paramètres du modèle. Pour conclure cette note, citons Nearing et al. (2021) : "The idea that ML [Machine Learning] models are "black boxes" is more of a testament to a lack of inspection, rather than to a limitation of the models themselves."

⁵ <https://www.geosapiens.ca/>

⁶ <https://www.flowworks.com/>

⁷ <https://www.upstream.tech/hydroforecast>

problème de communication au sein de la communauté scientifique (pas juste en ressources hydriques d'ailleurs). Les termes utilisés, qui n'ont pas parfois aucun lien avec la physique, peuvent contrarier certains potentiels utilisateurs ; le manque de vulgarisation des développeurs et la relative jeunesse de ces approches ne font pas encore consensus, à ce jour. À cela s'ajoute une difficulté à interpréter les sorties du modèle. Par ailleurs, d'un point de vue plus technique, il peut y avoir des problèmes de stabilité, en particulier pour des problèmes de classification (important en ressources hydriques pour le traitement de certaines images satellitaires). Enfin, les résultats issus de ce type d'approche s'améliorent lorsqu'on dispose d'un grand volume de données (Shen, 2018). La force du modèle est aussi intimement liée à la qualité du jeu de données d'apprentissage. Pour améliorer la qualité de ces données, il est couramment admis que sa longueur est primordiale, permettant au modèle d'apprendre sur un échantillon couvrant un grand nombre des événements possibles (dont les événements extrêmes). En effet, contrairement à un modèle traditionnel qui pourrait « trouver » un événement extrême lié par exemple à une forte précipitation même si un tel événement n'a jamais été utilisé pour caler le modèle, un modèle d'apprentissage automatique aurait bien plus de mal à générer un événement extrême avec une fiabilité similaire à celui produit par un modèle traditionnel. Il pourrait par exemple plafonner ses sorties à un maximum qui serait issu du jeu d'apprentissage ; le modèle réagit alors comme si toutes les valeurs possibles à prédire se trouvent parmi celles du jeu d'apprentissage. Cette limite rend également difficile le transfert d'apprentissage, car les valeurs de débit de rivière étant intimement liées aux caractéristiques physiographiques du BV, dont la superficie. L'enjeu lié à la superficie du BV peut cependant être contourné en faisant appel à la notion de débit modulé ou spécifique, c'est-à-dire un débit qui est homogénéisé en fonction de l'aire totale de drainage (on obtient alors un débit par km^2).

L'accès à de grands jeux de données est parfois limité par l'absence de base de données adéquates accessibles. Toutefois, il est important de noter l'effort continu qui est fait par la communauté scientifique en ressources hydriques pour pallier ce manque et offrir à ses membres la possibilité de s'inscrire dans une démarche de science libre. Il existe malgré tout plusieurs accès à des bases de données avec des profondeurs temporelles plus ou moins longues, qu'il s'agisse de données météorologiques, hydrologiques ou physiographiques.

Élaborer un modèle d'apprentissage automatique comprend plusieurs étapes. Oyebode et Stretch (2018) proposent un schéma général en sept niveaux pour construire un modèle hydrologique à partir de RNA. Ce schéma peut s'appliquer à n'importe quel modèle d'apprentissage automatique : 1) prétraitement des données, 2) détermination des intrants, 3) échantillonnage (apprentissage – validation – test), 4) définition de l'architecture du modèle (dont définition des hyperparamètres du modèle), 5) apprentissage du modèle, 6) mise en pratique pour la modélisation hydrologique et 7) application sur les cas d'intérêt.

Les types de modèle d'apprentissage automatique sont nombreux. La section suivante présente le fonctionnement des RNA ; pour les autres modèles, une introduction plus succincte des principales composantes est faite afin de fournir aux lecteurs les éléments clefs. Des exemples d'application en prévision hydrologique seront fournis pour chacun. Mais quelques références peuvent déjà être fournies et des analyses tirées de certains articles de revue tels que ceux de Chang et Guo (2020), Mosavi et al. (2018) et Yaseen et al. (2015).

Enfin, on reconnaît en intelligence artificielle trois grands types d'apprentissage :

- supervisé : établissement de relations entre intrants et sorties (certaines classifications, régression) ;
- non-supervisé : définition de structures communes dans les intrants (d'autres classifications, composantes principales, clusters) et
- par renforcement : apprentissage des actions à prendre à partir d'expériences avec une récompense à la clef.

Dans le domaine des ressources en eau et plus particulièrement celui de l'hydrologie, dans la très grande majorité des cas, ce sont les modèles dits supervisés, comme les RNA et les SVM, qui sont employés lorsque l'intelligence artificielle est utilisée comme outil de modélisation (Mosavi et al., 2018). Un modèle supervisé est soumis à une étape d'apprentissage durant laquelle il apprend une règle de classement à partir d'un jeu de données pour lequel le classement est déjà connu. La règle apprise, le modèle la met en application sur de nouvelles données au classement inconnu. Ces quelques lignes parlent de classification mais cela s'adapte parfaitement à des problèmes de régression. La principale différence par rapport à un modèle non-supervisé est que le modèle connaît les sorties. Un modèle non-supervisé doit fournir lui-

même des structures qui constituent les sorties du modèles (clusters dans le cadre d'une classification, composantes principales en régression).

Modélisation par RNA

En algorithmie, les Réseaux de Neurones Artificiels (RNA ou ANN, de l'anglais *Artificial Neural Network*) font leur apparition au milieu du XX^e siècle avec la volonté de reproduire les connexions neuronales du cerveau humain (Lettvin et al., 1968). Depuis, les avancées et évolutions sont régulières mais le principe de base persiste : des connexions entre différentes couches avec un transfert de l'information.

À la différence de la biologie, on parle de nœuds au lieu de corps cellulaires et de transfert au lieu de synapse. Une première couche est la couche d'entrée, constituée des données qui vont servir à produire la couche de sortie ; ceux sont les descripteurs des variables de la couche de sortie. La dernière couche est la couche de sortie, typiquement le débit d'une rivière en hydrologie. Entre les deux, les couches cachées servent à transmettre les informations venant de la couche d'entrée vers la couche de sortie (Camacho Olmedo et al., 2018). Plus le nombre de couches cachées est important, plus la complexité du modèle croît et plus le modèle établit des relations complexes et plus il est susceptible de générer une couche de sortie avec exactitude par rapport aux observations lors de la phase d'apprentissage. Le nombre de couches cachées et le nombre de neurones dans ces couches peut varier (Stathakis, 2009). L'apport de plusieurs couches cachées augmente la complexité et le temps de calcul et peut amener à un modèle sur-paramétré dont la généralisation décroît (Karsoliya, 2012 ; Liu et al., 2007). Avec un modèle de RNA à plusieurs couches cachées, on parlerait alors d'apprentissage profond.

Dans l'exemple illustré par la Figure 2.4 où on retrouve une couche cachée, les neurones de la couche cachée vont transformer l'information pour en « extraire » les éléments d'intérêt. Les fonctions $s^{(1)}_k$ transforment l'information venant des x_i pour la transmettre et fournir finalement y_j . Ainsi, l'entrée $e^{(1)}_k$ de la couche 1 dépend des trois sorties x_1 , x_2 et x_3 de la couche d'entrée précédente, pondérée par w . Un biais est ajouté ; il joue le rôle de seuil à partir duquel le neurone sera significativement actif.

Une fonction dite d'activation établit la relation entre les données d'entrée et la donnée de sortie de ce neurone (fonction notée s dans la Figure 2.4). Cette fonction d'activation peut prendre différentes formes. Les plus communes sont l'Unité de Rectification Linéaire (ReLU, *Rectified Linear Unit*), la tangente hyperbolique et la sigmoïde et sont, en pratique, retenues à la suite d'une étape d'analyse préliminaire.

L'algorithme de rétropropagation sert à propager l'erreur du modèle lors de la phase d'apprentissage. Cette erreur consiste en fait en un critère d'évaluation qui évolue selon les changements de poids et de biais faits en entraînement lors d'itérations successives (Salvail-Bérard, 2012). Les algorithmes les plus communément utilisés et comparés dans cette thèse dans une étape d'analyse préliminaire sont celui de régularisation bayésienne et celui de Levenberg-Marquardt car leur convergence est plus rapide et le risque de sur-apprentissage moins important qu'avec d'autres algorithmes (Kayri, 2016 ; Payal et al., 2013).

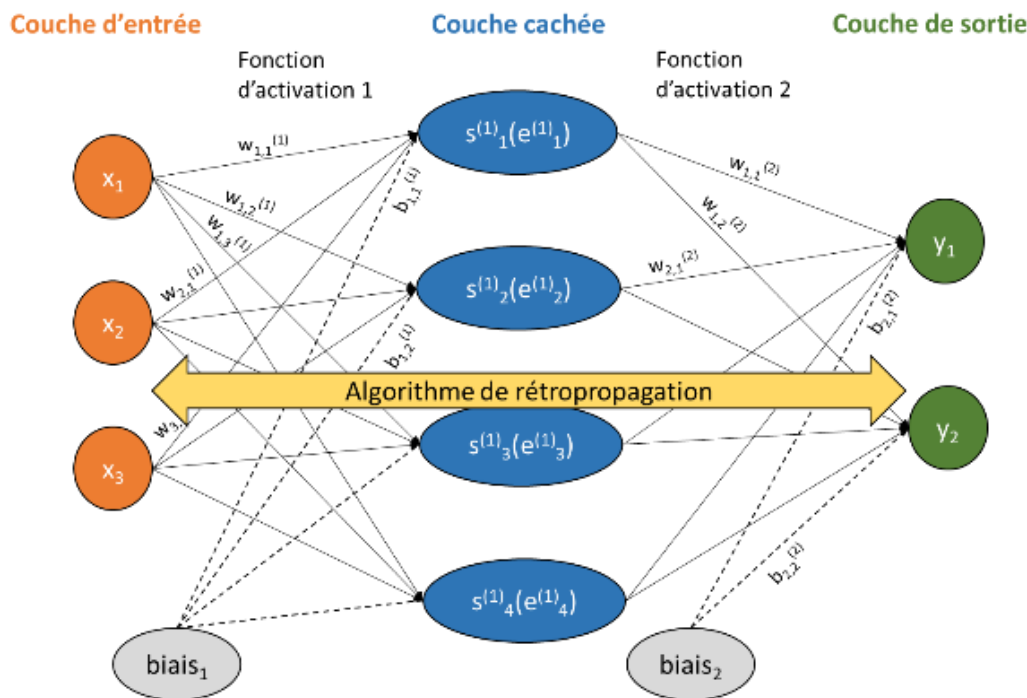


Figure 2.4 - Schématisation du fonctionnement d'un Réseau de Neurones Artificiels

Parmi les limites partagées avec les autres modèles d'apprentissage automatique, on retrouve la difficulté à paramétrer le modèle et le risque élevé d'hyper-paramétrisation durant la phase d'apprentissage. Un risque bien plus spécifique au RNA est la lente convergence lors de

l'apprentissage (Dawson et al., 2006 ; Jain et al., 1999) ; c'est d'ailleurs un sujet de recherche qui est encore en plein développement et une question qui continue à intéresser les développeurs de RNA (Jagtap et al., 2020).

On va passer maintenant à quelques exemples d'application avec en particulier ces deux études qui offrent une approche opérationnelle de la prévision hydrologique par RNA : Cai (2010) et Fleming et al. (2015). Tout d'abord, Cai (2010) compare dans sa thèse le développement de deux architectures de RNA pour faire une prévision à un jour d'avance : un RNA avec algorithme de rétropropagation (comme celui développé dans la présente thèse) et un RNA à régression généralisée (qui correspond à un RNA sans algorithme de rétropropagation mais qui se base sur des structures similaires entre les intrants pour établir des relations dans la couche cachée). Cette étude propose de comparer la prévision au jour J à trois sites différents de la rivière Humber en Ontario avec comme intrants la température, la précipitation du jour J et du débit du jour J-1. Il est intéressant de noter qu'au-delà de leur architecture sensiblement différente, les fonctions d'activation varient aussi. Malgré ces différences, les résultats restent satisfaisants sur les trois sites, mais plus particulièrement sur ceux les plus en aval (cela s'explique par la configuration des stations et le choix des intrants communs pour les sites qui favorisent les stations avec les aires de drainage les plus grandes). Cela met donc de l'avant la bonne capacité d'un RNA pour faire de la prévision hydrologique (pour autant que l'apprentissage et les intrants soient pertinents).

De leur côté, Fleming et al. (2015) développent un modèle de prévision pour la rivière Englishman en Colombie Britannique avec six combinaisons d'intrants différentes prenant en compte des informations sur le débit passé, l'état du stock de neige au sol, la température et la précipitation passées et futures. Ils se basent sur un modèle probabiliste construit à partir d'un RNA avec une incertitude introduite liée aux conditions météorologiques. Après avoir développé leur modèle, ils l'ont soumis à un test en opérationnel sur une saison. Leur conclusion est prometteuse avec une bonne capacité du RNA à fournir de l'information pertinente aux prévisionnistes alors même que ce type de modèle ne permet pas de faire un suivi des processus hydrologiques qui ont lieu et qui lient les intrants aux sorties.

Enfin, dans l'utilisation d'un modèle de RNA pour la prévision hydrologique, il convient de rappeler la difficulté qu'il peut y avoir à paramétrer un modèle qui puisse fournir des résultats

satisfaisants pour un ensemble de problèmes (Oyebode et Stretch, 2018). Des exemples d'études spécifiques sur le transfert d'apprentissage comme Kratzert et al. (2018) montrent que la communauté scientifique prend cette question avec sérieux et proposent certaines pistes de solution encourageantes. Mais au-delà d'un transfert de modèle entre différents sites d'étude, il peut être difficile d'utiliser un modèle sur un même cas d'étude pour des conditions de modélisation différentes (Oyebode et Stretch, 2018), comme on pourra d'ailleurs le constater dans le chapitre 6.

Modélisation inspirée du RNA

Il existe plusieurs modèles d'apprentissage automatique qui sont basés sur le principe du RNA et son fonctionnement.

Il est possible de pousser plus loin l'architecture d'un RNA en considérant des approches plus développées dites d'apprentissage profond (*deep learning* dans la version anglaise). Ces architectures créent des liens plus forts entre les nœuds, donc entre les couches, et par conséquent entre les variables. C'est un développement plus complexe mais aussi plus complet des relations entre variables. L'apprentissage profond consiste en une augmentation du nombre de couches cachées dans le RNA. Ensuite, on trouve des modèles qui s'inspirent du fonctionnement de base d'un RNA, appelés *shallow learning*. Parmi ceux-là, les réseaux de neurones récurrents (RNN, *Recurrent Neural Network*) et les réseaux de neurones à longue mémoire à court terme (LSTM, *Long Short-Term Memory Neural Network*) sont les plus développés et les plus couramment rencontrés (Kratzert et al., 2018 ; Vos et Rientjes, 2005). Un RNN ajoute une entrée à chaque neurone, l'entrée qu'il a lui-même fourni au pas de temps précédent. Ainsi cela peut être comparé à un modèle autorégressif à un seul degré. Les LSTM remontent plus loin, en utilisant potentiellement plusieurs pas de temps passés pour établir une nouvelle sortie. Pour l'introduction d'une mémoire à long terme, il est également possible de faire appel à un réseau de neurones avec décalage temporel (TDNN, *Time Delay Neural Network*) (Peddinti et al., 2015). Enfin, on peut aussi parler des modèles convolutifs (CNN, *Convolutional Neural Network*). Ces approches permettent d'utiliser des images directement comme intrants du modèle. Un traitement en trois étapes majeures permet de faire le lien entre

les intrants et les sorties. Il s'agit d'un traitement par la fonction de convolution (traitement d'une sous-section de l'image qui couvre l'entièreté de l'image par un système de fenêtre glissante), l'étape de *pooling* (agrégation de l'information par un sous-échantillonnage sans chevauchement) et enfin la connexion avec la sortie sur le même principe que pour un RNA (Rajabi et Estebarsari, 2019).

Le nombre de publications dans le domaine ne cesse de croître d'année en année ; Abrahart et al. (2012) émettent ainsi une certaine critique sur le développement de l'ensemble de ces modèles en invitant les développeurs à surveiller ce qui se fait et à échanger entre eux. Malgré tout, on peut de manière optimiste et réaliste penser à utiliser ces approches plus complexes pour estimer l'évolution du couvert nival au sol à partir de CNN (Wang et al., 2018) et à utiliser ensuite cette variable comme intrant d'un modèle d'anticipation de la crue printanière (Marcil et al., 2016). De manière plus directe, l'utilisation d'images comme intrant du modèle de CNN pour prévoir le débit est déjà documentée (C. Chen et al., 2021; Shu et al., 2021).

Modélisation par Machines à Vecteurs de Support

Le principe des SVM est établi en premier dans les années 1960 mais son développement a essentiellement eu lieu à partir des années 1990 (Vapnik, 1999). Son intérêt vient en particulier de son élégance et des bonnes performances obtenues sur des applications dans divers domaines, dont les ressources hydriques et plus spécifiquement la prévision hydrologique.

Les principaux avantages des SVM viennent du bon contrôle des paramètres par l'utilisateur, d'une facilité à limiter le sur-apprentissage et d'une capacité à traiter des données non-linéaires (ce qui est le cas en ressources hydriques). Le principal inconvénient à relever est la perte d'exactitude du modèle SVM lorsque le nombre de prédicteurs (i.e. de variables explicatives d'entrée) est important. Le nombre de relations peut engendrer trop de complexité et réduire alors la qualité du modèle développé.

L'utilisation des SVM est faite pour des problèmes de classification comme pour des problèmes de régression. En classification, il s'agit de trouver le bon hyperplan qui sépare les données adéquatement dans différentes classes. En régression (le cas de la prévision hydrologique), il

s'agit d'établir le bon modèle pour représenter la variable cible en intégrant une marge d'erreur acceptée.

Les SVM permettent de résoudre des problèmes linéaires ou non-linéaires. Comme pour les autres modèles de la famille des modèles d'apprentissage automatique, plusieurs hyperparamètres des SVM sont à optimiser lors de la phase d'apprentissage. Les phases de validation et de test permettent finalement de déterminer si les hyperparamètres ont bien été définis.

Les applications en hydrologie concernent principalement l'estimation du débit et du niveau de lac. Entre autres, un exemple montre la bonne habilité d'un SVM à prévoir le débit à un pas de temps journalier sur la rivière Fenhe en Chine, avec en particulier de très bonnes performances en périodes d'étiage. Les intrants utilisés sont constitués du débit et des précipitations sur plusieurs pas de temps passés (Cai-hong Hu et al., 2011). En comparant notamment avec un RNA, certaines études préfèrent l'utilisation de SVM pour éviter le surentrainement même si les ressources de calcul nécessaires pour avoir des résultats satisfaisants sont élevées (Lin et al., 2006). Enfin, sur le BV de la rivière Rio Grande aux États-Unis, une prévision à long terme du débit avec des indicateurs climatiques de grande échelle a été menée (Bhandari et al., 2019). Les résultats montrent de bons résultats sur les trois horizons testés : un, quatre et treize mois à l'avance, dans un ordre de performance décroissant. Le modèle de SVM semble donc présenter une bonne intégration des différents intrants utilisés selon l'horizon prévisionnel.

Modélisation par arbre décisionnel et forêt aléatoire

Le principe d'un arbre de régression et de classification (CART, *Classification And Regression Tree*) (Breiman, 2001) se rapproche sensiblement de celui des SVM : séparer des données selon les valeurs prises pour chaque variable. Le jeu de données de base est utilisé, une première variable est sélectionnée, celle avec le plus fort niveau de séparabilité des données. Une règle est imposée au niveau d'un nœud. Suivant le respect ou non de la règle, deux branches filles sont créées. Pour chacune des branches, il y a une nouvelle itération avec une nouvelle variable séparatrice. Ce processus itératif est poursuivi jusqu'à ce qu'une règle d'arrêt soit atteinte, comme le nombre minimal de données dans une branche fille nouvellement créée, ou le nombre

maximal de nœuds (Figure 2.5). Pour déterminer la meilleure coupure au niveau d'un nœud, il faut choisir une fonction d'impureté à minimiser. Le critère de Gini est un des plus courants (Ishwaran, 2015) ; c'est une mesure de la fréquence à laquelle un élément aléatoire de l'ensemble serait mal classé si l'attribution de l'étiquette était aléatoire. L'arbre peut être élagué une fois le travail de séparation terminé. Cette étape supplémentaire réduit la complexité tout en gardant

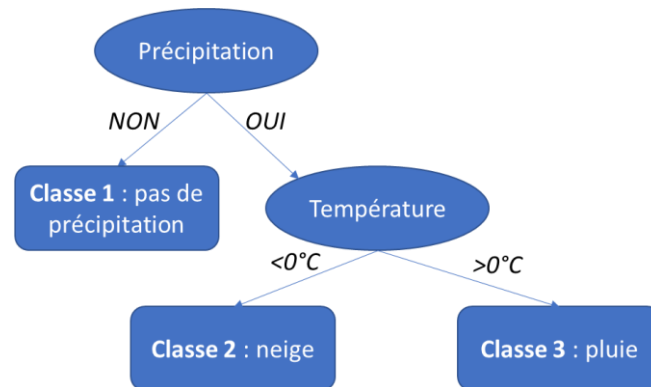


Figure 2.5 – Exemple de fonctionnement d'un arbre décisionnaire.

une capacité prédictive satisfaisante. Un facteur de risque d'erreur est alors introduit ainsi qu'un facteur de complexité de l'arbre.

Les CART sont rarement utilisés seuls ; on en utilise habituellement plusieurs afin de construire une forêt, dite forêt aléatoire (RF, de l'anglais *Random Forest*). Un certain nombre d'arbres sont créés avec un aléa introduit sur chacun d'entre eux. L'ajout de cet aléa permet de quantifier l'incertitude et une convergence au problème plus rapide (Breiman, 2001). En fait, c'est comme une prévision d'ensemble : plusieurs arbres sont étudiés conjointement, un aléa est introduit dans une ou plusieurs étape(s) de construction. Quatre principaux types de forêts existent (Scornet, 2012), différenciés selon la manière d'introduire l'aléa : *Tree Bagging* (Breiman, 2001), *Random Subspace* (Kam Ho, 1998), *Random Forest* (Breiman, 2001) et *Random Select Split* (Dietterich, 2000).

Le type de forêt aléatoire le plus est littéralement le *Random Forest* (Ishwaran, 2015). Quelques avantages des forêts aléatoires sont une bonne convergence des résultats, une mise en place simple notamment due au nombre de paramètres à implémenter et une évaluation simple de l'incertitude inhérente à l'approche. Seuls deux paramètres sont ajustés : le nombre de variables discriminantes à chaque nœud et le nombre d'arbres dans la forêt (Liaw et Wiener, 2002). Les

forêts aléatoires, en particulier grâce au caractère aléatoire introduit et au nombre potentiel élevé d'arbres, évitent assez facilement le sur-apprentissage (Yang et al., 2016).

En hydrologie, l'utilisation des arbres de régression permet, comme pour les autres approches présentées jusqu'ici, de modéliser à la fois le débit d'un cours d'eau que le niveau d'eau d'un réservoir. Yang et al. (2016) proposent de comparer les résultats issus d'un CART et d'un RF pour simuler des opérations sur neuf réservoirs californiens. Une vaste gamme d'intrants est sélectionnée afin de tenir compte entre autres des conditions actuelles du réservoir, de l'état du BV et d'indicateurs climatiques saisonniers. L'utilisation combinée du modèle CART en mode probabiliste (dans un RF donc) montre les meilleurs résultats, en particulier pour la prévision des pics de crue. De plus, les auteurs se sont aperçus que les prises de décision (ouverture ou fermeture des vannes pour gérer le niveau du réservoir) sont également bien prévues par le modèle selon les conditions à venir. Cette évaluation s'est faite en comparaison avec les décisions prises par les gestionnaires des réservoirs sélectionnés.

Pham et al. (2021) utilisent les forêts aléatoires pour faire de la prévision du débit un jour à l'avance sur quatre-vingt-six BV au nord-ouest des États-Unis. Ils distinguent les BV selon trois zones hydro-climatiques. Leurs résultats sont encourageants et démontrent entre autres de meilleures aptitudes du modèle développé pour la zone nordique (en opposition aux zones transitoire et tempérée). Un autre résultat est que l'utilisation de la pente et du pourcentage de sable dans le BV détériorent le modèle de prévision. Alors que ce ne sont pas les seules caractéristiques physiographiques introduites, cela révèle qu'une sélection adéquate des intrants est importante et devrait être faite judicieusement pour chaque BV dans une étape préliminaire.

Autres types de modélisation par apprentissage automatique

Bien que plus complexes, les modèles hybrides ou combinés sont prometteurs et présentent dès à présent des résultats satisfaisants dans le domaine de la prévision hydrologique (Nourani et al., 2011 ; Seo et al., 2015). Souvent, il s'agit de joindre deux modèles l'un à la suite de l'autre, avec le premier modèle qui extrait les éléments les plus significatifs des données d'entrée, puis ensuite un passage dans un second modèle qui fournit la sortie de simulation hydrologique à proprement parler. Le second modèle fait très souvent appel à un de ceux présentés

précédemment. Le premier peut l'être aussi, mais de nombreuses études introduisent une décomposition par ondelettes pour cette étape, permettant entre autres la création d'intrants indépendants au RNA. Les études qui introduisent ces approches hybrides proposent souvent une comparaison entre modèles hybrides et modèles simples (Anctil et Tape, 2004 ; Partal et al., 2015 ; Seo et al., 2015).

Enfin, certains auteurs favorisent des approches comme le Système d'Inférence Neuro-Flou Adaptatif (ANFIS, *Adaptive Neuro-Fuzzy Inference System*), la Programmation Génétique (GP, *Genetic Programming*) ou le *Boosting*. Ces techniques apparaissent depuis une dizaine d'années dans les études hydrologiques (Gong et al., 2016 ; Kisi et al., 2012 ; Ni et al., 2020 ; Seo et al., 2015 ; Zhang et al., 2018).

2.1.4. Comparaisons de performance de modèles d'apprentissage automatique pour la prévision hydrologique

La littérature fournit un large éventail de cas d'études en prévision hydrologique, surtout depuis le début des années 1990. Les modèles de prévision observés sont variés tant sur le type de modèle retenu ainsi que sur l'horizon de prévision. Ici, le choix est fait de regarder les exemples sur le court et le moyen terme. Le court terme est défini comme un horizon allant de J à J+7, avec généralement un pas de temps allant de l'heure à la journée ; le moyen terme va ici de quelques semaines (en fait, démarre au-delà de sept jours) à quelques mois (quatre au maximum, pour la durée d'une saison en fait) d'avance (avec un pas de temps variable selon les applications).

Par ailleurs, tout modèle de prévision est associé à une variable de sortie. En prévision hydrologique, les deux variables les plus couramment répandues sont le débit du cours d'eau et la hauteur du niveau d'eau d'un réservoir (Tableau 2.1). Quelques études plus spécifiques proposent de prévoir d'autres variables. C'est le cas, par exemple, pour l'étude de la sécheresse avec l'indice standardisé de précipitation et évapotranspiration (SPEI, *Standardized Precipitation Evapotranspiration Index*) (Vicente-Serrano et al., 2010).

Deux exemples sont à présent détaillés. Le premier compare RNA, SVM et forêts aléatoires sur le moyen terme (Yang et al., 2017). Le pas de temps est d'un mois pour déterminer la hauteur d'eau de deux réservoirs, un en Californie (volume de 3 Gm^3) et l'autre dans le nord de la Chine (volume de $290 \times 10^8 \text{ m}^3$). Dix-sept indicateurs climatiques sont testés en entrée des modèles. En plus de ceux-ci, des données de précipitation, évapotranspiration et apports sont disponibles. Différentes combinaisons d'intrants sont testées pour aboutir aux résultats suivants : les trois modèles testés présentent des résultats satisfaisants (critère de Nash-Sutcliffe toujours supérieur à 0,6 pour les deux réservoirs sauf pour les RNA avec un score de 0,44 pour le réservoir chinois) mais les forêts aléatoires sont privilégiées car elles offrent des résultats légèrement meilleurs, leur interprétation est plus facile et une incertitude est associée au résultat. De plus, les résultats pour les trois modèles testés sont meilleurs en saison estivale (avril à septembre).

Le second exemple fait de la prévision des apports au lac Como, en Italie à court terme, de un à trois jours à l'avance (Pini et al., 2020). L'aire de drainage du lac est de 1320 km^2 et quatre modèles sont comparés : RNA, SVM, RF et régression linéaire. Dix-sept intrants sont en compétition avec une description des conditions météorologiques (température, pluie, neige), des conditions de niveau d'eau, d'apports et de débit sortant à un ou deux jours passés. Bien que les trois modèles d'apprentissage automatique surpassent en qualité de prévision le modèle de régression, le RNA est celui qui fournit les meilleurs résultats avec notamment de bonnes performances sur les trois jours d'avance sur lesquels porte la prévision.

La littérature montre une diversité dans les modèles utilisés (Tableau 2.1). Les études portent tant sur des bassins semi-arides que tempérés et se concentrent de façon indépendante sur différentes variables à prédire. Il est intéressant de relever que lorsque les comparaisons de modèles portent sur des approches d'apprentissage automatique et des modèles statistiques plus « simples » (type ARIMA ou régression linéaire simple), les premiers l'emportent toujours sur les seconds. De même, lorsque les modèles hybrides sont comparés à des modèles d'apprentissage automatique avec une architecture classique, il ressort que les premiers sont plus satisfaisants que les seconds. Toutefois, il faut également noter que, dans ce dernier cas, il n'est jamais fait mention de résultats mauvais de la part des modèles avec une architecture classique ; les résultats qu'ils fournissent sont bons et acceptables, seulement les modèles hybrides font encore mieux.

À partir de cet éventail de modèles qui montre à voir des exemples d'utilisation en hydrologie ainsi que les forces et faiblesses de ces approches de manière générale, on a choisi de retenir une approche par RNA pour le modèle de prévision développé dans la suite de cette thèse. Les résultats, selon les études considérées, peuvent être très bons pour chacun des modèles considérés. En prenant maintenant en compte la mise en œuvre de ces modèles (paramétrisation) et les possibilités d'ajustement pour « imiter » une chaîne de prévision hydrologique opérationnelle, on s'aperçoit que les RNA présentent certains avantages. En effet, les architectures qui en découlent (LSTM et CNN notamment) présentent un fort potentiel d'utilisation et de développement, mais sont très gourmands en ressources de calcul et en données pour l'apprentissage. L'historique utilisé dans cette thèse, c'est donc plus naturellement qu'on se tourne vers les RNA. Un modèle plus complexe nécessiterait des séries de données plus longues, dont on ne dispose pas ici. De plus, les RNA offrent une facilité de gestion des séries utilisées en apprentissage et validation, avec la possibilité de faire de la validation croisée aisément.

Quoi qu'il en soit, la diversité de ces modèles et les résultats obtenus pour chacun d'entre eux montrent qu'il est légitime de s'intéresser à ce type d'approche. De plus, les architectures « classiques » des modèles d'apprentissage automatique, utilisées en modélisation hydrologique depuis maintenant au moins deux décennies, ont fait leur preuve mais sont exploitées au mieux par leur développement continu via des extensions (comme RNN) et leurs combinaisons potentielles (modèles hybrides). Les éléments avancés dans cette première partie, aussi succincts peuvent-ils être parfois, mettent en avant un grand potentiel. Enfin, comme cela peut rapidement être vu dans les sous-sections précédentes, les intrants de ces modèles sont variés ; c'est ce que va s'attarder à révéler la partie suivante de cet état de l'art : quels indicateurs hydrométéorologiques et climatiques pour de tels modèles de prévision hydrologique ?

Tableau 2.1 - Exemples extraits de la littérature d'utilisation de modèles d'apprentissage automatique pour la prévision hydrologique à court terme.

Études	Modèles comparés	Horizon de prévision	Intrants	Variable à prédire	Terrain d'étude	Résultats majeurs
Pini et al. (2020)	RNA, RF, SVM, régressions linéaires	1 à 3 jours	Apports au pas de temps précédents, hauteur d'eau, données météo	Apports	Lac Como, Italie : 1320 km ²	Meilleurs résultats obtenus avec les RNA
Wagena et al. (2020)	SWAT, RNA, modèle auto-régressif, modèle bayésien basé sur les 3 précédents	1 à 8 jours	Précipitations	Débit	BV expérimental WE-38, États-Unis : 8,3 km ²	RNA et SWAT ont les meilleurs résultats sur le volume total prédit et les pics de crues mais sous-estiment les étiages. Meilleures prévisions du RNA en mode prévisionnel.
Seo et al. (2015)	RNA, ANFIS, neuro-ondelettes, ANFIS-ondelettes	1 jour	Hauteur d'eau	Hauteur d'eau	Réservoir du BV de l'Adong, Corée du Sud : 1248M m ³	Améliorations significatives des résultats avec l'ajout des ondelettes
Coulibaly et al. (2001)	RNA, RNN, TDNN	1 à 7 jours	Apport, précipitation, fonte de neige, températures	Apport au réservoir	Bassin de la Chute-du-Diable (QC), Canada : 9700 km ²	RNN avec les meilleurs résultats surtout en remontant loin dans le passé
Huang et al. (2021)	RNA, LSTM, ANFIS, SOBEK	Événementiel avec pas de temps horaire.	Élévation, météo (précipitation, température et vent), débit et profil de rivière.	Débit.	BV des rivières Maozhou et Pingshan, Chine : 388 et 129 km ²	RNA le plus rapide, LSTM meilleur en moyenne et ANFIS meilleur sur les pics de crues.

2.2. Rôle des intrants

2.2.1. Introduction

On peut décomposer les intrants d'un modèle hydrologique en trois classes : les intrants physiographiques, les intrants hydrométéorologiques et ceux relatifs à l'état du BV. Les données associées à chacun de ces types sont distinctes et jouent un rôle particulier dans le modèle et dans la description des phénomènes hydrologiques. Par ailleurs, le choix des intrants est aussi soumis à leur accessibilité, c'est-à-dire que l'utilisateur peut être contraint par un accès limité à certaines données, que ce soit en raison de leur coût, de leur qualité ou de leur rareté. Cette section de la revue de littérature va éclairer ces différents points.

2.2.2. Intrants physiographiques

Les intrants physiographiques sont là pour caractériser le BV de manière physique : topographie, pente, type de sol, occupation du sol, superficie. Ces éléments jouent tous un rôle dans le type d'écoulement d'un BV et influent donc les régimes hydrologiques. Dans un système de prévision hydrologique classique, il s'agit de caractéristiques qui sont considérées constantes dans le temps, c'est-à-dire qu'elles sont définies une seule fois pour tout le BV et n'évoluent plus dans le système de prévision. Bien sûr, si des changements sont opérés sur le BV à l'étude, il convient de mettre à jour ces variables et de relancer le modèle avec la configuration ajustée. Aussi, si le modélisateur s'aperçoit que des changements liés à la physiographie ne permettent pas de bien représenter certains phénomènes, il convient de changer ces informations et de procéder à un nouveau calage du modèle (Tremblay, 2020).

Ainsi, les informations issues de la topographie et de la pente permettent de mieux représenter le ruissellement de surface. La superficie du BV joue clairement un rôle sur l'importance d'intégrer des variables spatialisées et permet aussi, indirectement, d'intégrer une estimation du temps de concentration du site à l'étude. L'occupation du sol entre en jeu pour représenter le ruissellement de surface, mais aussi les échanges d'énergie surface-air en lien notamment avec l'évapotranspiration et le manteau neigeux. Enfin, le type de sol intervient directement dans les

calculs d'infiltration et donc permet de caractériser au mieux, en plus de l'infiltration, l'écoulement hypodermique et le débit de base.

Ce type de variables sont courantes lors de la mise en place de modèles à base physique et conceptuel car il est alors nécessaire de caractériser le territoire afin d'en déduire les processus hydrologiques en cours. Lors de l'utilisation d'un modèle d'apprentissage machine, et donc d'un RNA, il n'est plus nécessaire de représenter directement les processus hydrologiques. Il n'est pas insensé de vouloir tout de même intégrer des variables physiographiques comme intrants à un RNA. En effet, on peut légitimement penser qu'utiliser ce genre d'informations va renforcer l'apprentissage du modèle en particulier avec des approches comme les CNN qui utilisent des images comme intrants, donc qui permettent d'intégrer une spatialisation du BV. L'information physiographique pourrait par exemple aider le RNA à modéliser l'humidité du sol ou, indirectement, les processus d'infiltration et de ruissellement. Dans cette thèse, le choix est fait de n'intégrer que des variables qui évoluent dans le temps (au moins sur les échelles de temps sur lesquelles on travaille, c'est-à-dire qu'on fait l'hypothèse que l'occupation du sol ne change pas – au moins de manière significative – sur la quinzaine d'années sur laquelle on fait la modélisation). L'idée est donc de proposer un modèle qui pourrait intégrer des données hydrométéorologiques issues de mesures au sol, réanalyses modèle ou observations satellitaires, donc des données qui sont mise à jour à chaque pas de temps.

2.2.3. Intrants hydrométéorologiques

Les intrants hydrométéorologiques fournissent de l'information sur les conditions hydrométéorologiques présentes et à venir. Il s'agit de variables qui évoluent à chaque pas de temps et qui représentent à la fois les apports directs en eau (précipitation) ou indirects exerçant une influence sur les stocks d'eau déjà présent (température). Les intrants hydrométéorologiques que sont la précipitation et la température, et dans certains cas l'évapotranspiration sont souvent utilisés pour « forcer » les modèles hydrologiques traditionnels afin de simuler et prévoir les débits et variables d'état des bassins versants. On les utilise aussi comme uniques intrants pour entraîner les modèles d'apprentissage pour la prévision hydrologique.

Les précipitations sont une des variables les plus importantes du cycle de l'eau (Prigent, 2010). Deux types de mesures peuvent être déployées : une qualitative avec le nombre et la taille des hydrométéores et une quantitative avec le volume d'un ensemble d'hydrométéores (Michaelides et al., 2009). Lorsqu'est mesurée la lame d'eau, on dispose soit d'une mesure directe via des pluviomètres, soit d'une mesure indirecte via des capteurs au sol, comme des radars, ou embarqués dans des satellites. Cela permet de fournir une information sur la variabilité spatiale et temporelle de la précipitation. Celle-ci est importante à intégrer dans un modèle de prévision hydrologique afin de tenir compte de l'évolution des processus hydrologiques sur différents sous bassins (Loritz et al., 2021).

De plus, en mode opérationnel, il faut disposer de données de prévision de la précipitation. Il s'agit donc d'avoir accès à une information de qualité sur l'ensemble du territoire. Aujourd'hui, de nombreux centres météorologiques mettent à disposition leurs données de prévision, c'est le cas par exemple du Centre Européen de Prévisions Météorologiques à Moyen Terme (CEPMMT). L'évaluation de tels produits pour des applications en prévision hydrologique est d'ailleurs un sujet d'actualité (ex. Bazile et al., 2017).

La température est une variable qui prend part dans les échanges de flux surface – atmosphère en transformant l'eau sous différents états : elle joue un rôle important dans l'évolution du stock de neige, au printemps en particulier, de l'évapotranspiration et de l'humidité du sol, notamment en été. De plus, quand on parle de température, il est généralement admis (et ce sera le cas dans cette thèse) qu'il s'agit de la température mesurée à 2 m au-dessus de la surface (Basist et al., 1998). D'autres températures sont parfois mentionnées. Il peut s'agir de la température de surface du sol qui correspond à la température radiométrique de la Terre (Mildrexler et al., 2011), i.e. la température qui prend directement en compte les échanges Terre-atmosphère en considérant la chaleur émise par la surface. Celle-ci peut être utile pour mieux représenter les échanges entre le sol et la couche supérieure de l'atmosphère et donc potentiellement utile pour améliorer l'estimation de l'évapotranspiration ou de l'humidité du sol. On trouve aussi la température du sommet des nuages qui peut servir à déterminer s'il y aura ou non précipitations (Huffman et al., 2007) et la température de brillance qui dépend de la température du corps visé et de son émissivité, i.e. de l'énergie reçue que le corps est capable d'émettre à son tour. Pour cette dernière variable, plusieurs exemples existent pour l'utiliser afin d'en extraire une

estimation de l'humidité du sol (Bindlish et al., 2009 ; Rains et al., 2018), des caractéristiques de la neige au sol (Takala et al., 2011), des précipitations (Nasrollahi et al., 2013 ; Sanò et al., 2015). Certaines de ces études proposent des applications directes en hydrologie (Bindlish et al., 2009 ; Sanò et al., 2015) et une utilisation de la température de brillance comme intrant d'un RNA (Sanò et al., 2015).

Enfin, il y a l'évapotranspiration. C'est une variable dérivée de la température et un marqueur des échanges sol-atmosphère en entrant en jeu dans le flux de chaleur latente (Kustas et al., 2003). Son intérêt est qu'elle prend en compte à la fois l'évaporation du sol et la transpiration des végétaux et joue un rôle majeur dans les échanges climatiques. C'est souvent l'évapotranspiration potentielle qui est utilisée ; elle se définit comme l'évapotranspiration qu'il y aurait pour un sol totalement saturé, cela représente la quantité d'eau qui pourrait revenir à l'atmosphère depuis le couple sol-végétation (Oudin, 2005). Les méthodes d'estimation de l'évapotranspiration sont nombreuses (Oudin, 2005; Xu et Singh, 2001). C'est par exemple un intrant des modèles de Génie Rural comme GR à 4 paramètres journalier (GR4J, Perrin et al., 2003).

2.2.4. Intrants relatifs à l'état du bassin versant

Une variable d'état est une variable qui fournit une quantité d'eau présente sur le BV (humidité dans le sol, niveau de réservoir, équivalent en eau de la neige (ÉEN)). On fait le choix ici de considérer également le débit comme une variable d'état. Cela se justifie par le fait que cette variable représente aussi une quantité d'eau. On ne souhaite pas intégrer dans cette catégorie les précipitations car il s'agit d'une variable indépendante des caractéristiques physiographiques du BV à l'étude. Bien sûr les types de sol favorisant une forte évaporation et les reliefs importants influent directement sur le cycle de l'eau et donc sur les précipitations, mais le lien n'est pas aussi immédiat et surtout l'échelle spatiale à laquelle se développent ces phénomènes est généralement bien plus grande que celle des BV étudiés.

Ces variables d'état sont importantes à fournir au modèle car elles apportent de l'information sur l'eau déjà présente sur le BV, jouant le rôle de conditions initiales. L'eau déjà présente permet de mieux intégrer l'information des intrants hydrométéorologiques qui eux fournissent

l'eau entrante sur le BV. En effet, si le débit à l'exutoire ou le niveau d'un réservoir sont déjà élevés, une précipitation, même faible, aura un impact bien plus critique que si le débit ou le niveau est faible.

L'humidité du sol se définit comme étant une variable clef dans les bilans de masse et d'énergie entre la surface et l'atmosphère (Brocca et al., 2017). Physiquement parlant, c'est le volume d'eau contenu dans un certain volume de sol lorsque l'humidité du sol est exprimée en m^3 d'eau par m^3 de sol (elle peut également être exprimée en kg d'eau par kg de sol, on parle alors d'humidité du sol massique) ; en fait, c'est la quantité d'eau contenue dans un sol non-saturé (Romano, 2014). L'humidité du sol régit la répartition de l'eau entre ruissellement et infiltration (Das et Paul, 2015) et contrôle les échanges entre les phénomènes d'infiltration et de ruissellement (Kornelsen et Coulibaly, 2013).

L'estimation de l'humidité du sol la plus précise est par mesure gravimétrique. L'approche consiste à prélever un échantillon de sol et à le peser avant et après séchage pour calculer l'humidité massique, ou l'humidité volumique si après avoir mesuré le volume de l'échantillon de sol. Il existe une panoplie de mesures non destructives (sans prélèvement d'échantillons de sol) qui découlent généralement de mesures de la permittivité diélectrique du sol (Vereecken et al., 2014) que l'on convertit en humidité volumique avec l'aide d'équation. Pour les mesures *in situ*, outre les techniques gravimétrique et basées sur la mesure de la permittivité, les techniques existantes sont nombreuses et variées (Brocca et al., 2017) : utilisation des propriétés tensiométriques, nucléaires du sol (Romano, 2014), capteurs de conductivité électrique du sol ou capteurs de mesure électromagnétique (Bogena et al., 2017).

L'alternative télédétection est intéressante et il y a de nombreuses méthodes développées pour déduire la donnée d'humidité du sol à partir des données brutes de télédétection dans le domaine des micro-ondes actives et passives, i.e. passer de la permittivité diélectrique à l'humidité du sol (Kornelsen et Coulibaly, 2013). Toutefois ces estimations ne sont possibles que dans les premiers centimètres de la couche de surface étant donnée la faible pénétration des micro-ondes dans le sol (Kornelsen et Coulibaly, 2013).

L'utilisation de la donnée d'humidité du sol est diverse en hydrologie ; cette variable peut être utilisée dans les différentes étapes de modélisation hydrologique : estimation des conditions

initiales, calage du modèle et dans le processus d'assimilation de données pour la mise à jour de l'état du bassin versant (Brocca et al., 2017). C'est une variable importante dans l'échange de flux dans le trio atmosphère – sol de surface – sol profond. Des rétroactions positives ou négatives peuvent intervenir avec les couples humidité du sol – température (Figure 2.6) et humidité du sol – précipitations (Seneviratne et al., 2010). Les processus d'écoulement de l'eau sont dépendants du taux d'humidité dans le sol (ruissellement en surface, la percolation dans le sol et évaporation). Quelques études montrent significativement la valeur ajoutée de la donnée d'humidité du sol dans un modèle hydrologique (Anctil et al., 2004 ; Berthet et al., 2009 ; Tayfur et al., 2014 ; Tayfur et Brocca, 2015).



Figure 2.6 – Couplage température – humidité du sol (adapté de Seneviratne et al. (2010)) : Humi sol = humidité du sol, Évap = évapotranspiration, Temp = température ; en rouge : action dans le même sens, en bleu : action dans le sens inverse.

Babaeian et al. (2019) donnent à voir les différentes façons de mesurer l'humidité du sol. Ils distinguent trois types de mesure : les mesures par télédétection, les mesures par détection à proximité et les mesures *in situ* (Figure 2.7). Cette décomposition est valable pour toutes les mesures de variables hydrométéorologiques. Les capteurs sont ajustés en fonction de la variable à mesurer mais le principe de fonctionnement général reste le même et plusieurs avantages sont simplement liés à la méthode de mesure plus qu'à la variable qui est mesurée. On ne s'attardera pas sur les mesures par détection à proximité.

Selon la longueur d'onde utilisée en télédétection, les mesures peuvent être soumises aux aléas météorologiques et il peut ne pas être possible de prendre une mesure avec une couverture nuageuse (mesure par réflectance pour l'humidité du sol) et/ou à cause de la nuit (longueurs d'onde du visible pour la précipitation ou la neige). Pour les mesures par télédétection, un autre inconvénient peut venir de la résolution temporelle. Ceci est en particulier vrai pour les satellites à défilement qui couvrent l'ensemble du globe ; selon la vitesse du satellite et la localisation du site à l'étude, deux passages successifs au-dessus de ce site peuvent être séparés de plusieurs

jours (douze jours pour Sentinel 1, contre un à trois jours pour SMOS). L'avantage de telles mesures vient principalement de la couverture spatiale. La fauchée offerte par ces satellites est large par rapport aux sondes déployées au sol. Cela permet d'avoir accès à une couverture globale. La résolution spatiale est parfois limitée pour les plus petits BV. En effet, les satellites à défilement étant à une altitude d'environ 600 km, un pixel (unité sur laquelle on dispose d'une valeur) peut couvrir près de 900 km² (SMOS ou SMAP). D'autres produits satellitaires offrent une résolution bien plus fine ; c'est le cas de Radarsat-2 avec une résolution de moins d'1 km².

À l'inverse, les mesures *in situ* offrent une fine résolution temporelle mais une faible résolution spatiale. En effet, il faut déployer un grand nombre de sondes pour avoir une discrétisation spatiale fine ; cela à un coût financier mais aussi organisationnel. Les ressources sont importantes pour calibrer chaque sonde, les installer, s'assurer de la bonne communication entre les sondes et les systèmes d'enregistrement puis de transport de l'information et faire la maintenance. Pour la mesure des propriétés de la neige au sol (hauteur, quantité d'eau liquide), cela peut être compensé par un choix d'installation stratégique sur un site qui offre une bonne représentativité du site à l'étude ou d'une bonne partie de celui-ci.

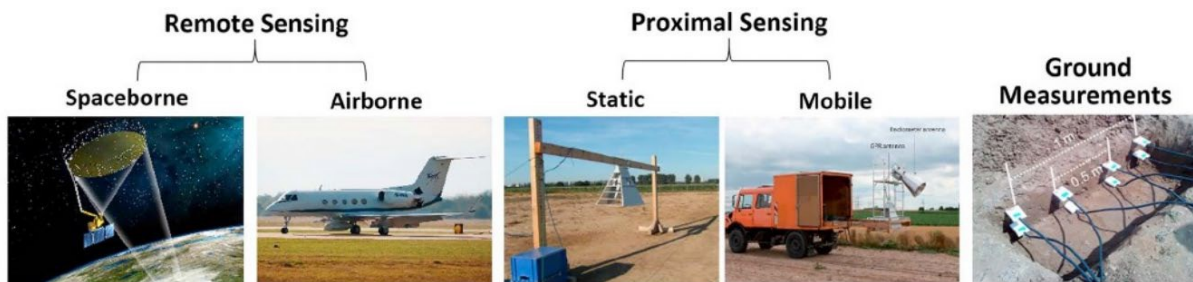


Figure 2.7 - Présentation des différentes façons de mesurer l'humidité du sol (issu de Babaeian et al. (2019))

2.3. Utilisation d'un environnement virtuel contrôlé

Une note s'impose pour débiter cette sous-section : par environnement virtuel contrôlé, on n'évoque et n'évoquera aucun élément en lien avec la réalité virtuelle. On se place bien dans une sorte de *monde parallèle*, mais il convient de ne pas se confondre et de bien comprendre que ce *monde parallèle* est défini en appui à la recherche faisant l'objet de cette thèse et ne vise

pas à supplanter le *monde réel* dans lequel sont appliqués les modèles de prévision hydrologique développés.

Les exemples de modèle de prévision hydrologique développé en environnement virtuel contrôlé sont rares et difficiles à trouver. On fait appel ici à un environnement qui fournit des séries temporelles complètes et identiques pour un ensemble de variables d'intérêt à l'étude, c'est-à-dire que l'utilisateur n'est plus contraint par la recherche de sources de données recouvrant des périodes identiques, par le remplacement des données manquantes ou par la qualité de certaines variables. Dans un environnement virtuel contrôlé, toutes les variables ont la même source, une qualité connue, une profondeur temporelle similaire et une distribution spatiale connue et possiblement modulable. C'est par exemple ce qui est appelé cadre synthétique par Bergeron (2017) dans son étude sur l'assimilation de données pour la prévision hydrologique. Cela permet de faire une première sélection des variables les plus prometteuses pour la prévision hydrologique, en l'absence de biais dans les intrants météorologiques. D'autres exemples en assimilation de données utilisent le terme de bancs d'essai pour décrire ce type d'expérience (Weerts et El Serafy, 2006 ; Xie et Zhang, 2010).

C'est à cette approche qu'on se rattache ici. Il est cependant plus courant de rencontrer d'autres définitions derrière les termes « environnement virtuel contrôlé ». Cela peut faire référence à l'utilisation d'un type de modélisation numérique particulier, en opposition à une modélisation expérimentale en laboratoire par exemple. D'autres études utilisent ces termes pour parler d'une opposition entre l'utilisation de réanalyses modèle et de données d'observation au sol en entrée d'un modèle. Il est important de mettre en garde le lecteur qui pourrait se laisser à penser que l'on rentre dans ce cadre. Les études auxquelles on fait allusion ici font appel aux données de réanalyses modèle dans un cadre plus proche de l'opérationnel, c'est-à-dire en voulant les utiliser comme intrants en remplacement des données d'observation. C'est dans ce sens que vont Wood et Lettenmaier (2006) en proposant un banc d'essai pour investiguer et évaluer des nouvelles méthodes mais aussi différentes sources de données pour une potentielle utilisation par les centres de prévision hydrologique. On est dans une démarche différente, car on fait appel à des sorties d'un modèle déterministe traditionnel (donc indirectement à des réanalyses) dans l'optique de comprendre le fonctionnement du modèle de prévision construit à l'aide d'un RNA. L'idée n'est pas de supplanter les données d'observation. Enfin, un autre exemple d'usage des

termes « environnement virtuel contrôlé » vient des applications de visualisation de résultats. On sort alors d'un travail de modélisation à des fins de prévision pour se tourner vers une modélisation numérique à des fins d'illustration et d'appui aux analyses en post-traitement (Habib et al., 2010). Ces exemples se retrouvent plus dans l'industrie et dans des projets appliqués qu'en recherche.

Dans la présente recherche, on oppose à cet environnement virtuel contrôlé un environnement qualifié de réel. Il s'agit d'un milieu de travail qui fait appel à des vraies données d'observation ou de réanalyses issues d'un modèle hydrologique ou météorologique avec tous les avantages et les contraintes associés. La qualité et la profondeur temporelle des séries de données utilisées ne peuvent plus être déterminées par l'utilisateur. Il peut y avoir une perte d'homogénéité entre les variables, issue entre autres de l'hétérogénéité des sources de mesure de ces variables et donc d'une incertitude qui n'est pas constante et qui peut parfois être délicate à estimer.

Entre ces environnements virtuel et réel, on définit l'environnement adapté. Celui-ci vise à injecter des éléments de l'environnement virtuel dans l'environnement réel lorsqu'on ne dispose pas de l'entièreté des données pour que ce dernier soit complet. Il s'agit donc d'un environnement réel partiel.

L'intérêt de faire appel à ce type d'environnement virtuel contrôlé est de pouvoir avoir la main sur les expériences qu'on souhaite mener et de pouvoir ensuite limiter les efforts et les coûts en environnement réel en se concentrant sur les essais les plus concluants. Ce passage entre deux environnements offre cependant certaines contraintes. En effet, une expérience positivement concluante en environnement virtuel ne sera pas forcément satisfaisante en environnement réel. Des différences, parfois importantes, peuvent être relevées; il faut donc savoir rester critique et sélectionner les expériences de l'environnement virtuel à répliquer en réel au mieux, avec raison. Parmi les difficultés, on peut trouver la disponibilité des données nécessaires. Même si les expériences en environnement virtuel sont orientées en fonction du réel, il n'en reste pas moins que le champ des possibles est vaste. L'environnement virtuel permet par exemple d'avoir accès à des données d'humidité du sol à différentes profondeurs via l'utilisation d'un modèle hydrologique déterministe ou d'un modèle de sol. En pratique, les données d'humidité du sol à plusieurs profondeurs ne sont pas courantes. Les satellites fournissent des mesures sur les

premiers centimètres, tandis que les mesures in-situ n'offrent pas une large couverture spatiale horizontale (Babaeian et al., 2019).

Finalement, l'utilisation faite de l'environnement virtuel dans le cadre de cette thèse se rapproche sensiblement de ce qui est fait dans les études sur le changement climatique. Les modèles sur lesquels se base le groupe intergouvernemental d'experts sur l'évolution du climat sont finalement des simulateurs de l'évolution des processus entre l'océan, la surface et l'atmosphère (IPCC, 2022). Les informations fournies par ces modèles finissent certes par être couplées avec des données d'observation, mais il n'en reste pas moins qu'ils fournissent une représentation simplifiée de la circulation à l'échelle globale à laquelle on n'aurait pas accès autrement.

CHAPITRE 3 CADRE MÉTHODOLOGIQUE

3.1. Sites d'étude

3.1.1. Introduction

Quatre sites d'étude ont été ciblés : les BV des rivières Androscoggin, Susquehanna, Au Saumon et Magog (Figure 3.1). Les deux premiers cités sont situés en Nouvelle Angleterre aux États-Unis, tandis que les deux autres se trouvent en Estrie, région du sud du Québec au Canada. Ces quatre BV sont tous soumis à des régimes hydrologiques d'un milieu continental humide et tempéré. Ils se décrivent par un enneigement important en hiver et un débit en rivière bas et qui présente habituellement peu de variations au cours de la saison. Au printemps, avec les températures qui remontent, la neige stockée sur le territoire fond. Associée aux précipitations qu'il peut y avoir, les apports en eau au réseau hydrographique peuvent être très importants et c'est une période de l'année où le risque de crue majeure est élevé. L'été et l'automne sont les saisons où le risque d'étiage est le plus grand. Les températures soutenues pendant plusieurs jours et le manque de précipitations peuvent entraîner un assèchement des réservoirs naturels et des apports naturels très faibles voire nuls. Le débit des cours d'eau majeurs est alors principalement assuré par la contribution de la nappe aquifère. Ces BV connaissent toutefois des périodes plus humides, avec des précipitations résultant de dépressions ou de cellules orageuses. Les dépressions qui arrivent sur ces régions se forment souvent plus au sud dans le Golfe du Mexique. Il peut aussi s'agir d'ouragans qui remontent la côte est des États-Unis avant d'arriver sous forme de tempêtes dans les régions de la Nouvelle Angleterre et de l'Estrie. Le terrain est également favorable au développement de cellules orageuses orographiques sur les reliefs des Appalaches (Androscoggin, Au Saumon et Magog), des Adirondacks (Susquehanna) ou sur les Montérégiennes (Au Saumon).

Ces quatre BV ont été sélectionnés en accord avec les partenaires industriels qui soutiennent ce projet. Des systèmes hydriques sur ces BV sont gérés par Énergie renouvelable Brookfield pour Androscoggin et Susquehanna et Hydro-Sherbrooke pour Magog (dans sa partie canadienne). Les caractéristiques très différentes en termes de taille ou d'occupation en font des candidats pertinents afin de s'assurer d'une certaine robustesse des résultats obtenus. Par ailleurs, comme

il s'agit de BV avec des régimes hydrologiques soumis au même climat et aux mêmes contraintes saisonnières, cela permet de conforter les résultats obtenus en s'assurant d'avoir une bonne généralisation des résultats sur des sites d'étude avec des caractéristiques climatiques relativement proches.

Le Tableau 3.2 fournit des caractéristiques générales sur les quatre BV à l'étude, avec des informations sur la superficie et l'occupation du sol. La suite de cette section fournit davantage de renseignements sur chacun de ces quatre BV afin de se familiariser un peu plus avec les sites d'étude.

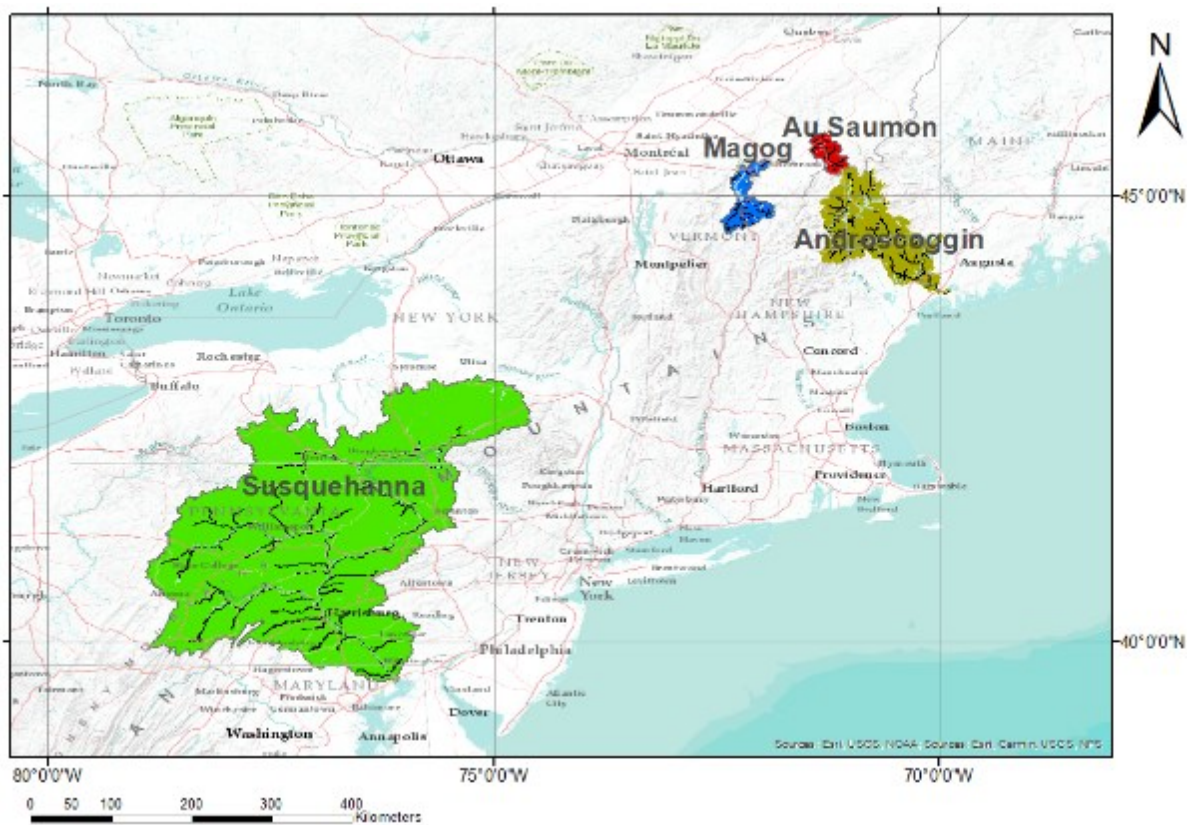


Figure 3.1 - Localisation des BV sur la partie nord-est du continent d'Amérique du Nord, avec les BV Susquehanna (vert), Magog (bleu), Au Saumon (rouge) et Androscoggin (ocre).

Tableau 3.2 - Occupation du sol et superficie des quatre BV à l'étude.

BV	Forêts (%)	Terres agricoles (%)	Milieus humides (%)	Sols nus et urbanisés (%)	Superficie (km²)
Androscoggin	83.5	3.5	8.5	8.5	8935
Susquehanna	59	31.5	3	6.5	71 225
Magog	61	17	14	8	1979
Au Saumon	89	9	1	1	1022

3.1.2. Androscoggin

Le BV de la rivière Androscoggin est principalement situé dans l'état du Maine (ME) aux États-Unis. Sa superficie est de 8935 km², avec une altitude maximale de 1941 m dans les Montagnes Blanches du New-Hampshire (NH) et un exutoire au niveau de la mer dans la Baie de Casco dans l'Océan Atlantique nord, près de la ville portuaire de Brunswick. La rivière Androscoggin prend sa source dans le lac Umbagog (NH) et s'écoule du nord-ouest au sud-est sur une distance de 280 km avec un dénivelé de près de 380 m. Les forêts couvrent la majorité du bassin (83,5 %). Le reste du territoire est couvert par des milieux humides (8,5 %, incluant les lacs), des sols nus ou urbanisés (8,5 %) et des terres agricoles (3,5 %).

Le United States Geological Survey (USGS) a en charge la gestion de quatre barrages au fil de l'eau qui ne perturbent que de façon mineure le régime d'écoulement de la rivière. On peut donc continuer à considérer la rivière Androscoggin comme ayant un régime d'écoulement naturel (Figure 3.2).

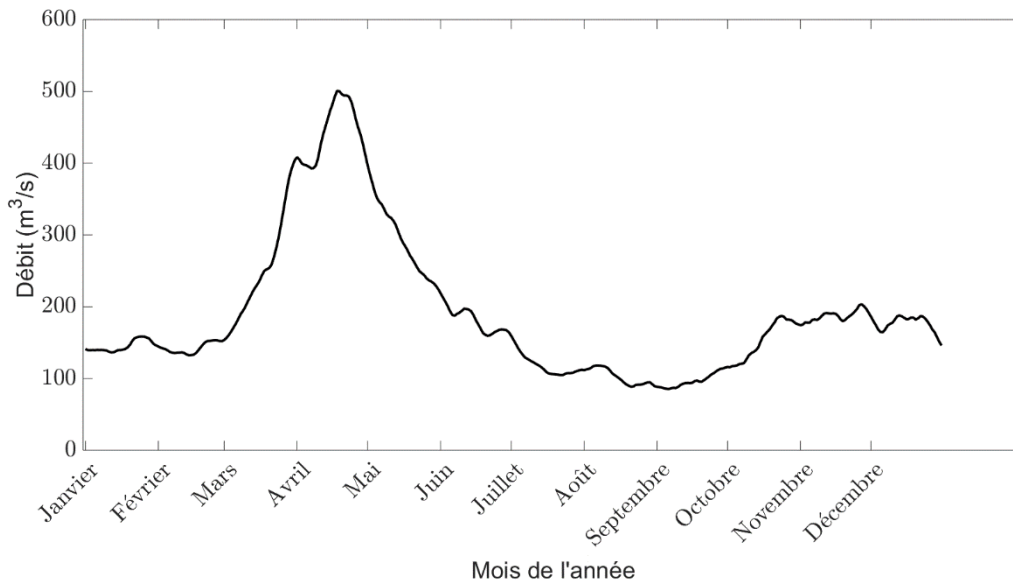


Figure 3.2 – Débit moyen annuel (1975-2015) pour le BV de la rivière Androscoggin à la station USGS1059000 la plus proche de l'exutoire calculé à partir d'une moyenne glissante sur sept jours.

3.1.3. Susquehanna

Le BV de la rivière Susquehanna se situe principalement dans les états de New-York (NY) et de Pennsylvanie (PA) aux États-Unis et couvre une superficie de 71 225 km² avec une altitude maximale de 958 m ; c'est le plus grand BV étudié. La rivière Susquehanna est la plus longue de Nouvelle Angleterre, s'écoulant vers le sud sur 715 km avec un dénivelé de 360 m. La rivière est constituée de deux branches principales : une branche nord qui prend sa source à Cooperstown (NY) et une branche ouest à West Branch (PA). Elles se rejoignent à Northumberland (PA) au milieu du cours principal de la rivière. L'exutoire se situe dans la baie de Chesapeake dans l'océan Atlantique nord près de Havre de Grâce et de Perryville dans le Maryland.

Le bassin versant de la rivière Susquehanna est le moins forestier des quatre étudiés ici, avec 59 % du territoire couvert par des forêts. Le reste du bassin est recouvert à 31,5 % de terres agricoles, 6,5 % de roches et sols urbanisés et 3 % de milieux humides (incluant les lacs). Depuis environ deux siècles, une série d'ouvrages couvrent le réseau hydrographique du BV de la

rivière Susquehanna. Malgré ces installations anthropiques, aucun contrôle majeure la rivière n'est exercé et le cycle hydrologique de la rivière peut être considéré comme naturel (Figure 3.3).

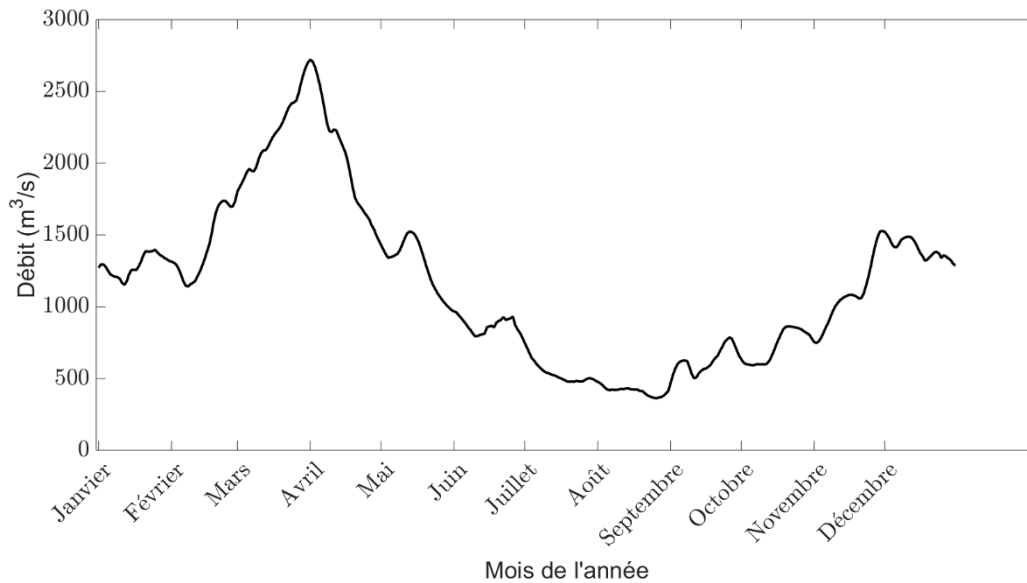


Figure 3.3 – Débit moyen annuel (1975-2015) pour le BV de la rivière Susquehanna à la station USGS1578310 la plus proche de l'exutoire calculé à partir d'une moyenne glissante sur sept jours.

3.1.4. Magog

Le BV de la rivière Magog a la particularité d'être transfrontalier entre le nord du Vermont (VT) aux États-Unis et le sud du Québec (QC) au Canada. Le lac Memphrémagog couvre une large partie du bassin et est transfrontalier. Le BV est plus petit comparé aux deux BV américains déjà présentés ; la rivière Magog draine un territoire de 1 979 km² dont près de 1 010 km² au Vermont. L'élévation du bassin varie de 1 004 m à 150 m au niveau de l'exutoire dans la rivière Saint-François à Sherbrooke (QC). Dans sa partie canadienne, la rivière Magog s'écoule du sud au nord sur environ 32 km en prenant sa source dans le lac Memphrémagog (lac frontalier couvrant 6 % de la superficie totale du BV). Dans sa partie étatsunienne, les rivières Black, Clyde et Barton constituent les principaux affluents au lac Memphrémagog. Le BV dans sa

partie canadienne est couvert à 61 % par des forêts, 17 % par des terres agricoles, 14 % par des lacs et 8 % par des milieux urbains.

Des ouvrages hydroélectriques ont été installés sur le BV de la rivière Magog. Du côté canadien, une série de barrages au fil de l'eau se succèdent en aval entre le lac Magog et la confluence avec la rivière Saint-François au niveau de l'exutoire. L'écoulement reste considéré comme naturel car ces barrages, une fois installés, n'ont pas une grande influence comme ce peut être le cas avec des barrages avec réservoir (Figure 3.4).

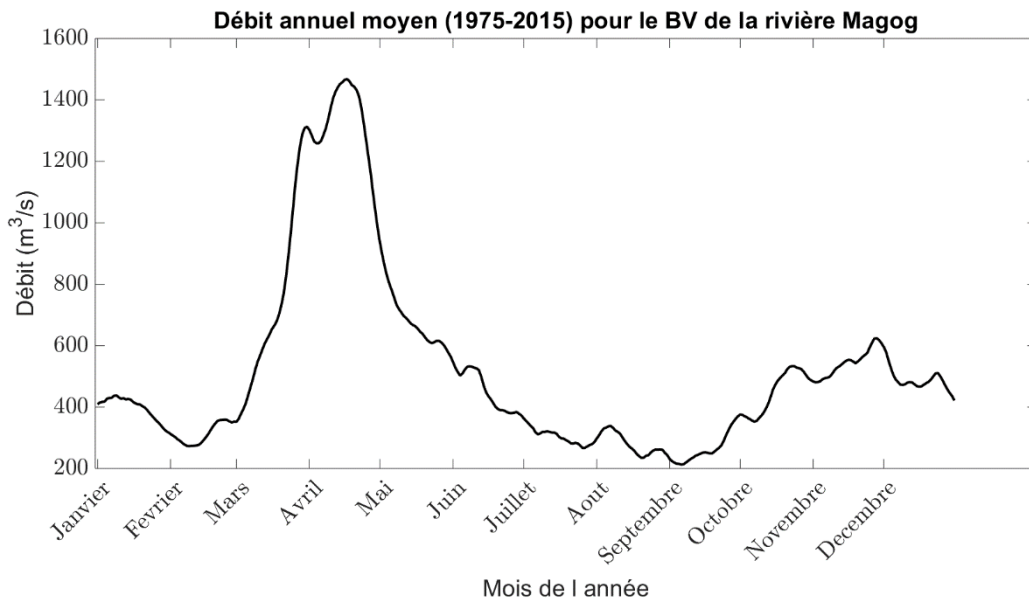


Figure 3.4 – Débit moyen annuel (1975-2015) pour le BV de la rivière Magog calculé à partir d'une moyenne glissante sur sept jours sur le débit reconstitué à partir des stations USGS04296500 et USGS01153000 dans la partie aval du BV.

3.1.5. Au Saumon

Le BV de la rivière Au Saumon est situé en Estrie dans le sud du Québec au Canada. Sa superficie est de 1 022 km², c'est le plus petit des quatre BV à l'étude. La rivière prend sa source dans le lac Danger situé à la frontière avec le Maine aux États-Unis et s'écoule du sud-est au nord-ouest sur environ 80 km jusqu'à la rivière Saint François près de Weedon. L'élévation varie entre 1 097 au sommet du Mont Mégantic jusqu'à 243 m à l'exutoire. Le territoire est couvert à 89 % de forêts, 9 % de terres agricoles, 1 % de milieux humides (incluant les lacs) et

1 % de sols nus dont urbanisés. Aucun ouvrage n'est à relever sur le réseau hydrographique de la rivière Au Saumon ; il s'agit donc d'un écoulement entièrement naturel (Figure 3.5).




Figure 3.5 – Débit moyen annuel (1975-2015) pour le BV de la rivière Au Saumon à la station 030282 la plus proche de l'exutoire calculé à partir d'une moyenne glissante sur sept jours.

3.2. Matériel

3.2.1. Introduction

Cette courte introduction sert à disposer d'une vue d'ensemble des éléments qui vont être présentés dans cette section Matériel. Plusieurs appellations ne sont pas franchement décrites ici car elles le seront plus loin dans la section.

La Figure 3.6 représente une vue d'ensemble des deux environnements développés dans cette thèse. L'environnement virtuel (Figure 3.6a) a été utilisé sur les quatre BV présentés antérieurement. Il se base sur l'utilisation du modèle conceptuel HYDROTEL pour générer une base de données de variables hydrométéorologiques qui servent ensuite d'intrants au modèle de RNA. On dispose ainsi d'un grand jeu de données équivalent sur tous les sites d'étude pour tester différentes configurations d'intrants et différentes spatialisations. L'environnement réel (Figure 3.6b) diffère de l'environnement virtuel dans sa première partie avec les intrants au

modèle de RNA qui sont issus d'une combinaison de réanalyses ERA5-land et d'observations *in situ*. Entre les deux, pour pallier le manque de données, on a défini l'environnement adapté qui consiste en une utilisation de certaines variables issues d'HYDROTEL sélectionnées et présentées ultérieurement avec des données d'observation et de réanalyses.

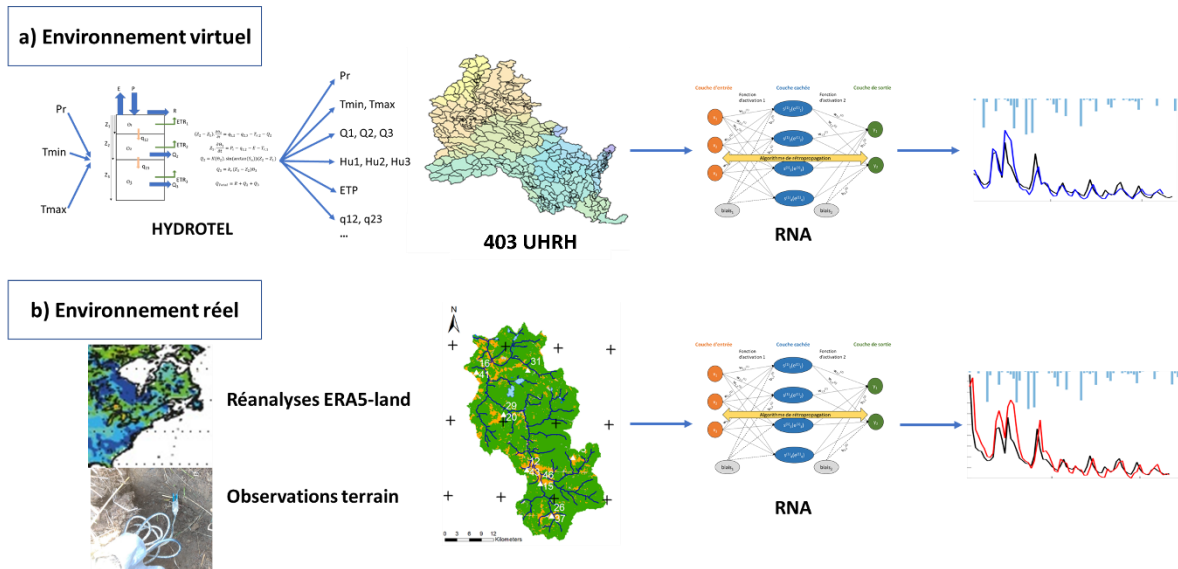


Figure 3.6 – Représentation schématique des environnements a) virtuel et b) réel développés dans cette thèse.

3.2.2. Modèle de Réseaux de Neurones Artificiels

En neurobiologie, un neurone se compose de trois éléments : le corps cellulaire, l'axone et les dendrites (Figure 3.7). Le corps cellulaire peut être associé à un espace de stockage, l'axone à un émetteur de messages vers d'autres neurones et les dendrites à des récepteurs des signaux émis par les autres neurones. Les dendrites ont chacune un poids qui leur est propre. L'information reçue par chaque dendrite constitue un signal d'entrée. Celui-ci est multiplié par le poids de la dendrite sur lequel il arrive. Le corps cellulaire traite ensuite l'ensemble de ces signaux. Un seuil permet de « filtrer » cet assemblage de signaux selon sa pertinence. Si le signal passe ce seuil, il est transmis vers l'axone, sinon il est ignoré. Le potentiel d'action gère le niveau de ce seuil et influence donc sur la mise en place de la communication entre un corps cellulaire et ses voisins. Ce potentiel d'action n'est pas fixe et chaque nouvel apprentissage modifie ce seuil, permettant alors d'établir de nouvelles connexions (Stangor et al., 2014).




Figure 3.7 - Schématisation du transfert d'information entre deux neurones biologiques

Inspirés par le fonctionnement des neurones humains, les mêmes éléments sont présents sous d'autres appellations dans un RNA : les corps cellulaires sont appelés nœuds ou neurones (c'est cette dernière désignation qui sera principalement adoptée dans cette thèse), les synapses sont appelées transferts et le potentiel d'action est appelé fonction d'activation. Lors de l'utilisation de RNA, il est d'usage de parler de couches : une couche étant un ensemble de nœuds, donc un ensemble de corps cellulaires qui émettraient et/ou recevraient des signaux.

Un RNA se compose d'au minimum trois couches : une couche d'entrée constituée des données initiales au modèle, une couche cachée traitant et transmettant l'information vers la couche de sortie fournissant la sortie du modèle de RNA (Oyebode et Stretch, 2018 ; Salvail-Bérard, 2012). Le nombre de couches cachées peut varier. Quand il y en a plus d'une, les couches cachées se suivent et constituent des étapes de traitement de l'information supplémentaire. Pour des raisons de clarté des explications des composantes du réseau et du fonctionnement d'un RNA, une seule couche cachée sera utilisée comme composante du RNA dans la suite ; une note sera fournie à la fin pour explicitement clarifier le comportement du RNA lorsqu'il est constitué de plus d'une couche cachée.

La Figure 3.8 (identique à la Figure 2.4 et réintroduite ici pour faciliter la lecture) fournit un exemple d'un modèle de RNA à une couche cachée à 4 neurones, avec 3 neurones dans la couche d'entrée et 2 dans la couche de sortie. À titre d'exemple explicatif, le fonctionnement du neurone 1 de la couche cachée est détaillé ; il sera dénommé par la suite N1CC (Neurone 1 de la Couche Cachée). N1CC reçoit de l'information des trois neurones de la couche d'entrée, x_1 , x_2 et x_3 et va fournir de l'information aux deux neurones de la couche de sortie y_1 et y_2 . Le signal entrant est constitué de la somme pondérée de signaux émis par x_1 , x_2 et x_3 , auquel on ajoute le biais₁.

En algorithmie, l'ajout de ce biais sert à introduire une variable d'ajustement de telle sorte à ce que l'ajustement aux données d'entrées soit réduit afin d'éviter un surapprentissage trop important. Le biais sert donc à renforcer le pouvoir de généralisation du RNA. Dans un contexte hydrologique, cela signifie que le modèle sera capable de prévoir le débit en sortie même à partir de valeurs d'intrants qui n'étaient pas dans le jeu d'apprentissage. L'équation 3.1 montre les différentes contributions au signal d'entrée de NICC.

$$e^{(1)}_1 = w^{(1)}_{1,1} \cdot x_1 + w^{(1)}_{2,1} \cdot x_2 + w^{(1)}_{3,1} \cdot x_3 + b^{(1)}_{1,1} \quad (3.1)$$

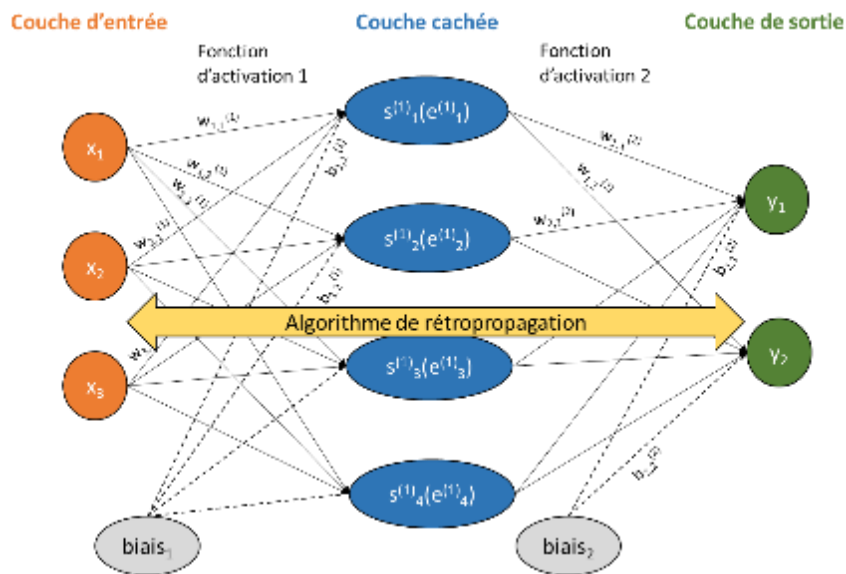


Figure 3.8 - Schéma d'ensemble d'un RNA à une couche cachée à quatre neurones, avec trois neurones dans la couche d'entrée et deux dans la couche de sortie

Les différents poids (w) et le biais (b) sont des paramètres du RNA. Sans qu'il y ait un consensus affirmé dans la communauté scientifique, une étude avance que les poids peuvent être assimilés à une expression de la force de la connexion entre neurones (Kneale et al., 2001). Ceux-ci doivent être ajustés lors d'une étape préliminaire de construction du réseau. La détermination de ces poids et biais se fait automatiquement dans le RNA à l'aide de l'algorithme de rétropropagation. Initialement, les valeurs qui leur sont associées sont aléatoires. Le modèle de RNA dispose d'un critère interne (qui peut être, par exemple, la racine de l'erreur quadratique moyenne ou l'erreur absolue moyenne) qui évalue la performance du réseau avec ces valeurs initiales de poids et biais. Une fois un premier passage effectué, ces valeurs vont être modifiées et le critère recalculé. Si les critères d'évaluation sont meilleurs indiquant qu'il y a amélioration

du modèle, ces nouvelles valeurs sont retenues comme référence et elles vont être modifiées pour tenter de continuer à améliorer le réseau. En revanche, s'il y a détérioration des résultats, le modèle continue à utiliser les valeurs antérieures comme référence et tente de nouvelles modifications. Ce processus itératif est répété un certain nombre de fois pour respecter un critère d'arrêt défini par l'utilisateur. Ce critère d'arrêt peut être un nombre maximal d'itérations, un seuil minimal du critère d'évaluation à atteindre ou une combinaison des deux.

La façon de rétro-propager l'erreur est à définir par l'utilisateur. Plusieurs algorithmes de rétropropagation s'offrent à lui et c'est un des paramètres à déterminer lors de la phase préliminaire de construction du modèle de RNA. La littérature s'accorde à dire que les deux meilleurs algorithmes sont celui de régularisation bayésienne et celui de Levenberg-Marquardt car ceux sont les algorithmes qui diminuent le risque de sur-apprentissage et permettent de converger plus rapidement (Kayri, 2016 ; Payal et al., 2013). Pour un lectorat francophone, il est recommandé de lire l'article de Salvail-Bérard (2012) pour accéder à une démonstration du fonctionnement de l'algorithme de rétropropagation dans un modèle de RNA et voir comment l'erreur (la valeur du critère d'évaluation) est propagée dans le réseau afin d'améliorer les valeurs des poids et biais.

À l'intérieur du neurone N1CC, le signal d'entrée est exploité avec la fonction d'activation (équation 3.2). Celle-ci sert de filtre pour évaluer la pertinence de ce signal pour le réseau et définir ainsi si ce signal doit être transmis à la couche suivante (la couche de sortie) ou ignoré.

$$s^{(1)}_1(e^{(1)}_1) = a^{(1)}(e^{(1)}_1) \quad (3.2)$$

avec $a^{(1)}$ la fonction d'activation définie entre la couche d'entrée e et la couche cachée s .

Deux grands types de fonction d'activation existent : les linéaires et les non-linéaires. Pour des problèmes non-linéaires tels que les problématiques abordées en hydrologie et dans les sciences de l'atmosphère et de l'eau, il est généralement admis de ne pas faire appel à des fonctions d'activation linéaires. En effet, une fonction d'activation linéaire peut ne pas affecter le signal si c'est une fonction constante ($a(x) = x$), ou l'affecte selon un facteur k et cela équivaut alors à l'application d'une règle de proportionnalité ($a(x) = k.x$ avec k une constante). Avec une fonction d'activation non-linéaire, les possibilités d'action sur le signal sont bien plus grandes pour évaluer la pertinence de transmettre ou non ledit signal à la couche suivante.

L'ensemble de fonctions d'activation non-linéaires est grand et un utilisateur peut même être amené à définir une nouvelle fonction appropriée à sa problématique. La littérature et l'usage montrent que les trois fonctions d'activation les plus courantes sont: la sigmoïde, la tangente hyperbolique et l'Unité de Rectification Linéaire (ReLU, *Rectified Linear Unit*). La fonction d'activation est liée à un seuil qui est défini par le modèle et qui peut varier. En dessous du seuil, le neurone n'est pas actif et le signal est stoppé et ne sera pas transmis à la couche suivante. Autour du seuil, c'est une phase de transition. Au-dessus du seuil, le neurone est actif : sa sortie va servir d'entrée pour le neurone suivant et l'information continue à être transmise. Les fonctions d'activation les plus courantes sont ci-après présentées plus en détails.

- Sigmoïde : $a(x) = \frac{1}{1+e^{-x}}$

Par son comportement, cette fonction favorise les plus petites valeurs en absolu car c'est autour d'entrées nulles que la sortie est la plus grande. Les grandes valeurs à la fois positives et négatives sont très peu modifiées. Cette fonction offre une sortie bornée entre 0 et 1. Ces limites imposent donc une sortie assez plate, donc une sortie avec peu de variabilité interne. De plus, la présence de la fonction exponentielle dans le calcul peut engendrer des temps de calcul plus long que pour d'autres fonctions d'activation aux formules plus simples. Enfin, la fonction sigmoïde n'est pas centrée sur 0, cela implique qu'une entrée négative sort positive (Figure 3.9a).

- Tangente hyperbolique : $a(x) = \tanh(x)$

La fonction tangente hyperbolique est très semblable à la fonction sigmoïde, mais sa sortie est bornée entre -1 et 1 et centrée autour de 0, réglant ainsi le problème potentiel de changement de signe entre entrée et sortie. Cependant, il demeure que l'intervalle de sortie reste étroit et donc que la variabilité interne demeure relativement faible, pouvant entraîner un phénomène de saturation du signal de sortie (Figure 3.9b).

- Unité de Rectification Linéaire (ReLU, *Rectified Linear Unit*) : ce type de fonction d'activation est en fait une famille, dont les trois membres sont présentés ci-dessous et qui permet de résoudre le problème de saturation évoqué précédemment.

La fonction *ReLU* se définit par l'équation $a(x) = \max(0, x)$. Cette fonction stipule simplement qu'une entrée négative est considérée comme nulle en sortie et qu'une entrée positive reste identique. Sa convergence est rapide. Considérer comme nulles les sorties pour une entrée négative implique que le modèle de RNA n'apprend pas de ces entrées, les ignore et qu'il n'y a alors aucune mise à jour des poids (Figure 3.9c).

La fonction *Leaky ReLU* suit l'équation $a(x) = \max(0, 1.x, x)$. L'ajout d'un premier critère non nul permet de corriger en partie le problème d'inactivité de la fonction ReLU lorsque l'entrée est négative. Cependant, cela peut ne pas suffire. Ainsi, un troisième type de fonction ReLU est défini (Figure 3.9d).

La fonction *ReLU paramétrique*, qui se base sur l'équation $a(x) = \max(k.x, x)$, avec k un hyperparamètre constant qui est à définir afin d'avoir le meilleur modèle de RNA. Cela permet d'affiner le modèle et de le rendre plus précis. Mais la principale contrainte vient de l'ajout d'un hyperparamètre supplémentaire qu'il faut définir lors de la mise en place du modèle de RNA. À partir de cette formulation, il est facile de se ramener aux deux précédentes expressions : les fonctions ReLU et Leaky ReLU.

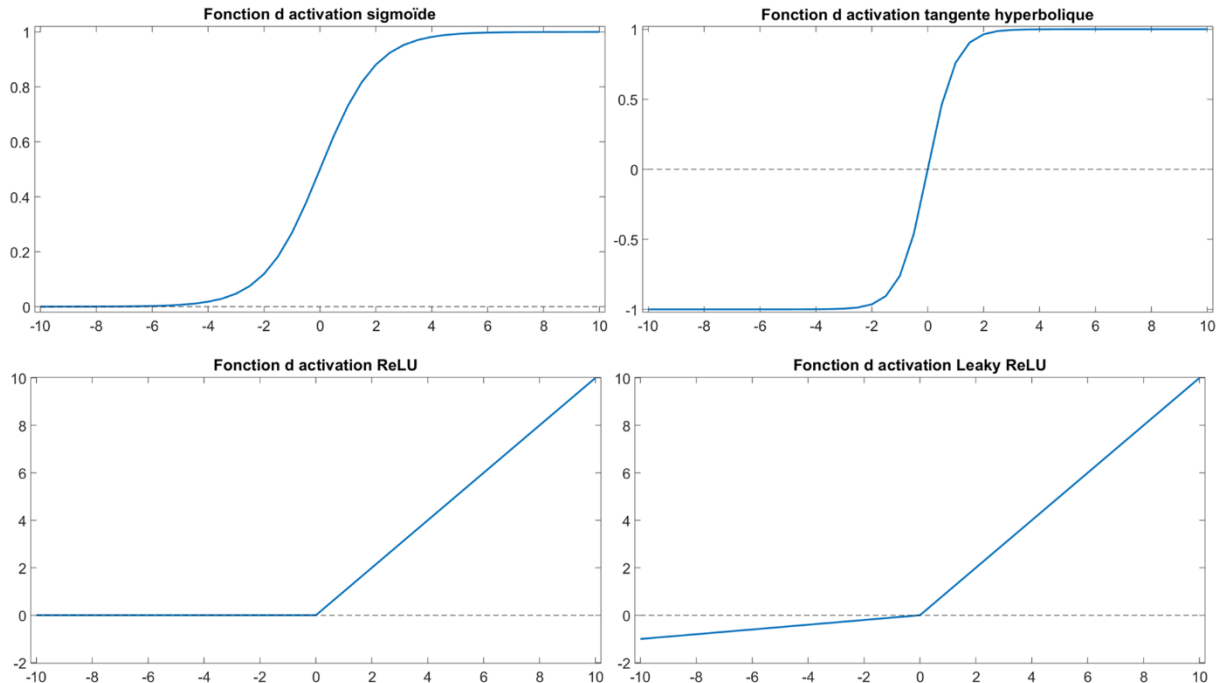


Figure 3.9 - Types de fonction d'activation communément utilisées et testées

Comme illustré par la Figure 3.8, deux fonctions d'activation sont introduites dans le modèle de RNA. Une entre l'entrée et la N1CC et une entre la N1CC et la sortie ; ces deux fonctions peuvent être différentes ou similaires. La détermination du type de fonction d'activation se fait par essai-erreur lors d'une phase préliminaire de construction du modèle. Il s'agit en fait d'une étape de paramétrisation du RNA.

Il est généralement admis qu'il n'existe pas de bonne ou mauvaise manière de construire un RNA et qu'une des tâches majeures, toujours à résoudre, est de définir des règles de base (Yonaba et al., 2010). Il est en tout cas établi lors de la phase d'apprentissage durant laquelle les hyperparamètres du modèle sont aussi sélectionnés (Sheela & Deepa, 2013). Il est important de bien ajuster le nombre de neurones dans la couche cachée (Riad et al., 2004). Enfin, en plus de limiter la complexité du modèle, configurer le RNA avec une seule couche permet de limiter le risque de sur-paramétrisation et donc de sur-apprentissage ; ce qui permet, a priori, de renforcer la robustesse du modèle développé (Karsoliya, 2012 ; Liu et al., 2007).

Dans cette thèse, après une phase d'analyse, le RNA utilisé dispose d'une couche cachée avec six neurones. L'algorithme de rétropropagation utilisé est l'algorithme de régularisation bayésienne. Deux fonctions d'activation sont utilisées : la tangente hyperbolique entre la couche d'entrée et la couche cachée et la sigmoïde entre la couche cachée et la couche de sortie. L'ensemble des hyperparamètres ont été définis dans une étape d'analyse préliminaire.

3.2.3. HYDROTEL

HYDROTEL est un modèle hydrologique distribué spécialement conçu pour recevoir des données spatialisées issues entre autres de la télédétection (Fortin et al., 1995). Sa première version a été développée au début des années 90 par le Centre Eau, Terre et Environnement de l'Institut National de la Recherche Scientifique (INRS-ETE). HYDROTEL permet d'intégrer dans sa structure interne la variabilité spatio-temporelle des processus hydrologiques. PHYSITEL est un logiciel développé en complément d'HYDROTEL et qui permet de définir les UHRH, unités hydrologiques qui discrétisent le BV à l'étude. Les UHRH sont définies à partir de données physiographiques. D'autres variables décrivant l'état physiographique du BV tels que l'occupation du sol et le type de sol peuvent ensuite être projetées à l'échelle de chaque

UHRH. Le logiciel permet aussi d'établir la structure d'écoulement du BV et discrimine le réseau hydrographique du BV en définissant des tronçons du réseau pour l'écoulement par les cours d'eau.

Le modèle HYDROTEL est le modèle utilisé en opérationnel par la DEH au Québec. De plus, il fait partie des modèles déterministes sélectionnés dans le cadre de la chaire de recherche industrielle dans laquelle s'intègre cette thèse. Ces aspects ainsi que la discrétisation spatiale des variables de sorties et les options de simulation du bilan vertical ont favorisé le choix de l'utilisation du modèle HYDROTEL comme modèle déterministe pour utilisation dans l'environnement virtuel de cette thèse.

La météorologie

Trois variables météorologiques sont nécessaires pour faire tourner HYDROTEL : les précipitations totales (neige + pluie ; en mm/pas de temps) et les températures minimales et maximales (°C). Celles-ci peuvent être fournies à un pas de temps inférieur ou égal à celui de simulation. Les localisations géographiques pour lesquelles les données météorologiques sont utilisées doivent être renseignées au modèle. Ces informations géospatiales sont ensuite utilisées par HYDROTEL dans le module d'interpolation des données météorologiques pour les interpoler sur l'ensemble du réseau d'UHRH du BV. Les données interpolées à l'échelle de l'UHRH sont disponibles pour l'utilisateur en tant que sorties du modèle hydrologique. Le fait que l'interpolation des données météorologiques soit faite en interne du modèle hydrologique offre une grande latitude à l'utilisateur quant à l'origine des données météorologiques. Celles-ci peuvent donc provenir d'observations *in situ*, satellitaires, de réanalyses modèle ou encore de prévision.

Les sorties du modèle

Un total de vingt-deux sorties du modèle hydrologique sont disponibles. Celles-ci peuvent se classer dans les variables météorologiques, les variables d'état et les flux (Tableau 3.3). Les variables de débits amont et aval sont disponibles pour chaque tronçon du réseau

hydrographique. Les vingt autres variables, quant à elles, sont disponibles à l'échelle de chaque UHRH. Un tronçon est associé à la majorité des UHRH. Quand ce n'est pas le cas, cela signifie soit que l'UHRH est un lac, soit que le modèle PHYSITEL n'a pas défini de tronçon de rivière car celui-ci était alors jugé trop peu significatif. Le modèle hydrologique fournit l'ensemble de ces sorties sous forme de séries temporelles au pas de temps de simulation retenu par l'utilisateur.

Tableau 3.3 - Variables de sortie du modèle HYDROTEL

Variables météorologiques	Neige Pluie Températures minimale et maximale
Variables d'état	Couvert nival Évapotranspiration potentielle Évapotranspiration réelle totale et dans chaque couche de sol Teneur en eau dans chaque couche de sol
Flux	Apport Apport latéral Débits amont et aval Productions de base, hypodermique et de surface Transfert vertical entre les couches de sol 1 et 2 et 2 et 3

La structure interne

Six modules internes composent le modèle hydrologique HYDROTEL : l'interpolation des données météorologiques, l'évolution de la fonte du couvert nival, l'évapotranspiration potentielle, le bilan d'eau vertical, l'écoulement sur la partie terrestre du BV et l'écoulement par le réseau hydrographique.

Les fonctions utilisées pour chaque module ont été sélectionnées lors d'une étape préliminaire à celle du calage du modèle. Seul le module de bilan vertical n'a pas l'objet d'une étude comparative. En effet, l'option offerte avec CEQUEAU ne permet pas de discrétiser le sol en différentes couches verticales. Or, pour les besoins de cette étude, il était pertinent d'avoir accès à une donnée d'humidité du sol à différentes profondeurs. Ainsi, la fonction de Bilan Vertical à 3 Couches (BV3C) a été retenue pour le module de bilan vertical.

Pour les six modules disponibles avec HYDROTEL, les valeurs de chaque paramètre peuvent être distinguées selon l'UHRH. Lors de la phase de calage, il est ainsi recommandé de procéder à un calage automatique afin de balayer un vaste ensemble de possibilités.

Interpolation des données météorologiques

Le module d'interpolation des données météorologiques sert à interpoler les précipitations et températures fournies en entrée du modèle sur chaque UHRH. Quelle que soit la fonction utilisée dans ce module, les données d'entrée doivent être fournies avec un fichier pour chaque station et la description de géolocalisation de chaque station doit également être disponible dans le même système de coordonnées géographiques pour que le modèle puisse faire l'interpolation spatiale. Les données météorologiques interpolées sur chaque unité hydrologique sont disponibles comme sorties du modèle.

Évolution du couvert nival

Pour le module d'évolution du couvert nival, seule la méthode mixte degrés jours – bilan énergétique est disponible. Ce module permet de simuler la variable journalière de différentes variables descriptives de l'état du manteau neigeux : son épaisseur, son ÉEN et sa densité, ainsi que son déficit calorifique et son contenu en eau liquide. L'équation de fonte de la neige à l'interface air-neige intègre en particulier la température de l'air, la quantité de pluie et des indices de rayonnement pour des surfaces en pente et horizontales. Ces indices de rayonnement sont estimés à partir des pentes et orientations à l'échelle de chaque UHRH. Une décomposition selon l'occupation du sol est faite uniquement à partir de trois classes : les forêts de feuillus,

celles de conifères et les milieux découverts. Cette classification intervient dans l'attribution du facteur de taux de fonte.

Évapotranspiration

L'évapotranspiration potentielle est le module qui offre le plus d'options différentes, allant de la fonction d'Hydro-Québec qui ne requiert qu'un seul paramètre à celle de Penman-Monteith qui en nécessite six. L'évaporation potentielle est calculée pour chaque classe d'occupation du sol. L'utilisation d'une méthode de calcul plutôt qu'une autre peut être déterminée en fonction de la complexité à apporter au modèle et/ou selon la disponibilité et la connaissance de certaines données/paramètres.

Bilan vertical

Comme mentionné précédemment, deux options sont offertes pour simuler le bilan vertical (Figure 3.10). Même si on s'impose d'utiliser la méthode BV3C, les deux options proposées seront détaillées ci-dessous afin de tenter de justifier au mieux le choix fait. La méthode CEQUEAU est de type conceptuel et tirée du modèle éponyme (Morin et al., 1981). L'autre méthode, BV3C, intègre les processus physiques en jeu et est compatible avec les informations issues de la télédétection (Fortin et al., 1995). Pour ces deux méthodes, la précipitation totale est considérée comme le volume d'eau disponible pour infiltration ou ruissellement, sans prise en compte explicite de l'interception par la végétation. La principale raison à cette « simplification » est principalement due aux difficultés qu'il peut y avoir à estimer une valeur d'interception ; l'erreur issue de la bonne connaissance de la précipitation et de l'évapotranspiration réelle à l'échelle du BV est considérée comme étant supérieure aux valeurs d'interception (Fortin et al., 1995).

Par sa conception, le modèle de bilan vertical CEQUEAU ne permet pas de simuler en deçà du pas de temps journalier (24 h) et n'offre pas de possibilité d'intégration de données issues de la télédétection. Faire appel à ce type de simulation est particulièrement intéressant lorsque l'utilisateur ne dispose pas d'information sur le type de sol du BV étudié. La colonne de sol est

ici représentée par deux réservoirs, le premier (celui du haut) simulant les échanges dans la zone non-saturée (réservoir sol) permettant ainsi de définir le ruissellement (R) et l'écoulement latéral dans la couche supérieure (Q_2) et le second (celui du bas) représente la zone saturée (réservoir nappe) caractérisée le débit de base (Q_3).

Le module BV3C est sensiblement différent et les options de modélisation qu'il offre visent à simuler les variables et flux à des fins de représentation approximatives des macro-processus physiques ayant lieu lors de l'infiltration de l'eau dans le sol et de sa redistribution sur l'ensemble de la colonne verticale. Le sol est verticalement divisé en trois couches. Cette représentation du sol est appropriée pour intégrer des données de télédétection. La première couche est la couche de surface qui permet entre autres de simuler les processus d'évapotranspiration et d'estimer le ruissellement de surface. Sa faible profondeur (une dizaine de centimètres en général) permet de s'approcher de l'épaisseur de couche de sol visible par les satellites d'observation de la Terre qui fournissent des données d'humidité du sol. Cette couche de surface contrôle également l'infiltration. La seconde est associée à l'écoulement retardé, tandis que la troisième est associée au débit de base de la zone saturée. Ces trois couches sont liées entre elles par les échanges verticaux $q_{1,2}$ et $q_{2,3}$. L'épaisseur des trois couches peut être fixée par l'utilisateur et peut être différenciée pour chaque UHRH. Le calcul du bilan vertical se fait à l'échelle de l'UHRH. Selon les conditions de saturation de la première couche de sol, l'infiltration est contrôlée par les précipitations et la fonte de neige (condition non-saturée) ou par les caractéristiques hydrauliques du sol (condition saturée). Le ruissellement (R) est simplement exprimé par la fraction d'eau qui ne s'infiltré pas dans le sol. La teneur en eau des trois couches est disponible et varie pour chaque pas de temps selon l'évolution de l'infiltration. L'évaporation (E) et la transpiration ($ETR_{1,2,3}$) sont également parties intégrantes de l'évolution de la teneur en eau pour chaque couche. Les échanges verticaux entre les couches dépendent eux de l'épaisseur et de la conductivité hydraulique représentative de chaque couche (définie à partir de la valeur à saturation K_S), des valeurs de teneur en eau et de la distribution des pores. Les trois équations traduisent le bilan vertical sur chaque couche.

$$Z_1 \cdot \frac{\partial \theta_1}{\partial t} = P - q_{1,2} - E - ETR_1 \quad (3.3)$$

$$(Z_2 - Z_1) \cdot \frac{\partial \theta_2}{\partial t} = q_{1,2} - q_{2,3} - ETR_2 - Q_2 \quad (3.4)$$

$$(Z_3 - Z_2) \cdot \frac{\partial \theta_3}{\partial t} = q_{2,3} - ETR_3 - Q_3 \quad (3.5)$$

Le Tableau 3.4 présente les épaisseurs des trois couches de sol obtenues après calage du modèle HYDROTEL pour les quatre BV.




Figure 3.10 - Représentation des schémas d'écoulement vertical CEQUEAU (gauche) et BV3C (droite)

Tableau 3.4 – Épaisseur des couches de sol pour les quatre BV après calage d'HYDROTEL. La couche 1 correspond à la couche de surface, la couche 2 à la couche intermédiaire et la couche 3 à la couche profonde

BV	Couche 1 (cm)	Couche 2 (cm)	Couche 3 (cm)
Androscoggin	10	20	60
Susquehanna	10	40	50
Au Saumon	10	10	30
Magog	10	30	50

Ruissellement

Le module d'écoulement sur la partie terrestre du BV représente l'écoulement de l'eau en surface jusqu'à ce qu'elle rejoigne un tronçon du réseau hydrographique. Les écoulements sur chaque UHRH sont calculés à partir du résultat du bilan vertical et en y appliquant un hydrogramme spécifique à partir de la géomorphologie de chaque UHRH. Les hydrogrammes reposent sur l'occupation du sol et le modèle numérique de terrain. L'hydrogramme est recalculé à chaque modification de valeurs de ces caractéristiques physiographiques. La courbe de l'hydrogramme est déterminée à partir de l'équation de l'onde cinématique. À l'issue de ces calculs, chaque UHRH est associé à un tronçon hydrographique (rivière ou lac).

Laminage

Le laminage correspond à l'écoulement de l'eau dans le réseau hydrographique. Il s'agit donc du processus rendant compte du cheminement de l'eau dans le réseau de rivières, lacs et réservoirs en tout point du BV jusqu'à son exutoire. Deux options de simulation du laminage sont disponibles : l'équation de l'onde cinématique modifiée et l'équation de l'onde diffusante. Les deux méthodes font appel à un coefficient de Manning propre à chaque tronçon lié à un UHRH, que l'utilisateur peut choisir de modifier si besoin. L'équation de l'onde cinématique modifiée tient compte les caractéristiques géométriques du cours d'eau.

L'équation de continuité s'exprime :

$$\frac{\partial Q}{\partial x} + \frac{\partial A}{\partial t} = q \quad (3.6)$$

L'équation de l'onde cinématique est :

$$\frac{\partial h}{\partial x} = S_o - S_f \quad (3.7)$$

Où Q est le débit ($\text{m}^3 \cdot \text{s}^{-1}$), A est la surface mouillée (m^2), q est le débit latéral provenant des cellules voisines ($\text{m}^3 \cdot \text{s}^{-1}$) et S_f est la pente de la surface libre ($\text{m} \cdot \text{m}^{-1}$).

L'approche par onde diffusante permet de mieux suivre les ondes de crue dans les zones à faible pente :

$$\frac{\partial Q}{\partial t} = -C \cdot \frac{\partial Q}{\partial x} + \frac{\sigma}{C^2} \cdot \frac{\partial^2 Q}{\partial t^2} + \frac{2\sigma^2}{C^3} \cdot \frac{\partial^3 Q}{\partial x \partial t^2} \quad (3.8)$$

Où C est la célérité de l'onde de surface ($\text{m} \cdot \text{s}^{-1}$) et σ le coefficient de diffusion ($\text{m}^2 \cdot \text{s}^{-1}$). Ces deux paramètres s'obtiennent à partir de relations dépendant du débit moyen et de la géométrie des cours d'eau.

Dans cette thèse, après comparaison des résultats avec utilisation des options de simulation lors de la phase de calage, il est décidé que l'équation de l'onde cinématique modifiée sera utilisée comme simuler le laminage.

Calage du modèle

Dans le cadre de la chaire de recherche industrielle, le modèle HYDROTEL de chacun des BV a été monté et rendu disponible. Dans cette thèse, on s'est directement basé sur le modèle construit pour chaque BV, c'est-à-dire que PHYSITEL avait tourné pour définir les UHRH et le modèle hydrologique prêt à tourner sans égard de la qualité des sorties. Un premier calage a été fait. Le calage était mixte : manuel et automatique avec la méthode Dynamically Dimensioned Research (DDS, Tolson et Shoemaker, 2007). Le calage automatique a permis de déterminer les valeurs optimales des paramètres associés à chacun des modules. Enfin, une dernière étape de calage manuel a pu être faite à l'occasion pour affiner les résultats en testant d'autres valeurs précises des paramètres autour des valeurs fournies par la méthode DDS. C'est le cas en particulier des paramètres d'épaisseur de sol du module BV3C, sélectionné afin de disposer d'une décomposition verticale du sol en trois couches. Les hauteurs de ces couches ont été calées de manière automatique puis ajustées manuellement afin de répondre à des problématiques réelles : une couche trop fine ou trop épaisse ne représente pas l'épaisseur de couche réelle « visible » (captible) par un signal satellitaire.

Les résultats du calage d'HYDROTEL avec les données de Ressources Naturelles Canada (NRCan, *Natural Resources Canada*) et USGS sont présentées Figure 3.11 pour une période restreinte allant de 2007 à 2013. Les données météorologiques utilisées en intrants à HYDROTEL ont été sélectionnées dans le cadre de la chaire de recherche industrielle. Ainsi, de la même manière que le modèle HYDROTEL était monté sur les quatre BV, les données

météorologiques NRCan et USGS étaient déjà mises au bon format pour chaque site d'étude. On note que les BV Au Saumon et Magog présentent des résultats de qualité moindre par rapport aux BV Androscoggin et Susquehanna. En effet, les critères de Nash-Sutcliffe (voir section 3.6.1 pour la description de cette métrique) sont de 0,66 pour Susquehanna, 0,5 pour Androscoggin, 0 pour Au Saumon et -0,3 pour Magog sur la période 2007-2013 illustrée sur la Figure 3.11. Les faibles performances sur les BV Au Saumon et Magog peuvent en particulier s'expliquer par le pas de temps journalier auquel HYDROTEL à tourner et par la taille des BV qui ont d'un temps de réponse à peu près équivalent. Il est donc plus difficile de bien représenter la réalité. Pour le BV Magog, on peut ajouter que les données dites d'observation sont des données reconstruites à partir de deux stations hydrométriques et qu'il s'agit d'une évaluation faite sur un tronçon situé dans la partie avale du BV.

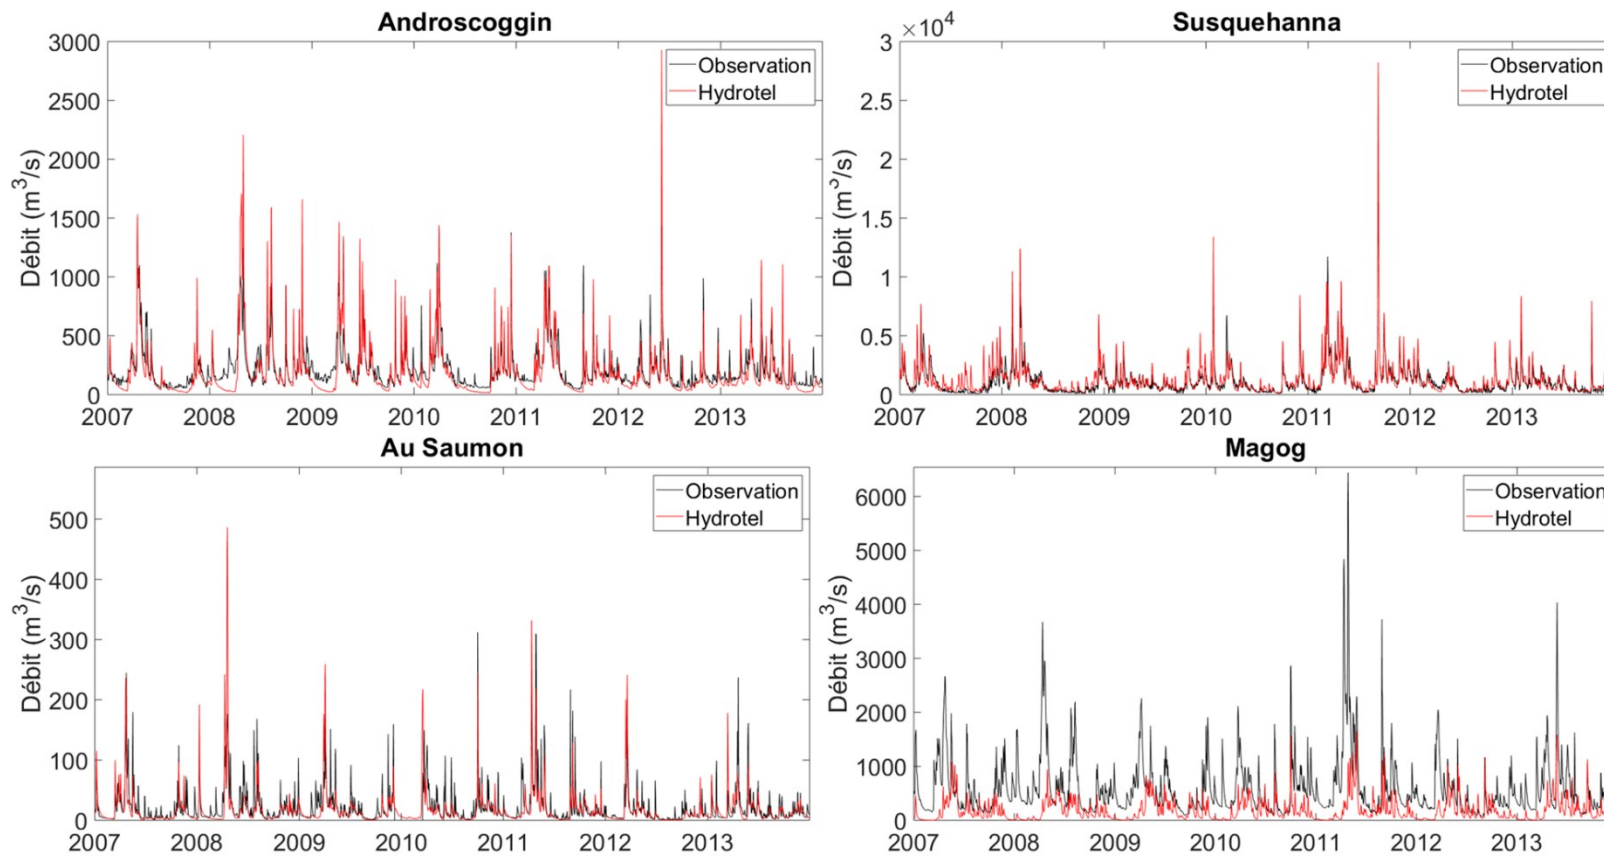


Figure 3.11 – Hydrogrammes après calage avec les données NRCan (Au Saumon et Magog) et USGS (Androscoggin et Susquehanna) sur la période 2007-2013 pour les quatre BV à l'étude.

3.3. Environnement virtuel

Déjà mentionné dans les objectifs de cette thèse et justifié dans la revue de littérature, cette recherche mène plusieurs expériences en environnement virtuel. Celui-ci est constitué de l'utilisation d'un premier modèle déterministe, soit HYDROTEL calé, pour générer un ensemble de séries temporelles pour plusieurs variables hydrométéorologiques qui vont être utilisées dans un second modèle, cette fois-ci d'apprentissage automatique, dans le cas présent un RNA.

Cet environnement virtuel peut être qualifié de contrôlé, car l'utilisateur a la liberté de sélectionner les deux modèles (c'est-à-dire, quel modèle déterministe utilisé pour générer les séries d'intrants à disposition pour le modèle d'apprentissage machine), ainsi que les variables du premier à utiliser dans le second. Cela correspond en fait à un banc d'essai de modélisation hydrologique. Un des avantages d'une telle approche est la possibilité de disposer de longues séries de données d'un vaste ensemble de données hydrologiques et météorologiques entièrement cohérentes. Dans cette recherche, avec l'utilisation du modèle HYDROTEL (calibré conformément à la procédure décrite à la section 3.2.3) comme premier modèle, on a accès à vingt-deux séries temporelles, en conformité avec le Tableau 3.3, de même longueur et avec une discrétisation spatiale identique. Cela permet donc de tester différentes configurations d'intrants au modèle de RNA (grâce au grand nombre de variables disponibles), de le tester sur des événements hydrologiques variés (par la longueur des séries de données) et de ne pas dépenser des efforts infructueux dans la recherche et la construction de tableau de données homogènes à partir de données d'observation. En effet, les expériences menées en environnement virtuel permettent de cibler celles qui seront réalisées en environnement réel et de fournir une idée des tendances auxquelles on peut s'attendre. Les expériences réalisées en environnement virtuel servent donc de préparation aux expériences en environnement réel, à la fois dans la façon de les mener (sélection des variables, spatialisation des intrants) que dans les résultats attendus (tendance similaire entre les deux environnements).

Il faut cependant garder à l'esprit que l'environnement virtuel est contrôlé et que certaines dépendances et défauts des données d'observation ne sont pas présentes. Par exemple, il est fréquent que les données d'observation soient biaisées ou que la qualité soit faible ou différente

selon les variables. Cela peut se traduire par un sous-captage pour les précipitations dans les pluviomètres ou à des données manquantes (bris de matériel ou autre) qu'il faut ensuite combler. Dans cette recherche, l'environnement virtuel contrôlé utilisé n'intègre pas ce genre d'information. La qualité des données est donc optimale (équivalent par exemple à un pluviomètre dont l'incertitude sur la mesure est nulle). Aussi, les données utilisées ne présentent, *a priori*, pas de biais individuel (i.e. une variable seule ne présente pas de biais que les autres variables n'auraient pas). Il a été décidé de ne pas se pencher sur une étape intermédiaire de bruitage de la donnée en environnement virtuel, bien que cela aurait permis de préparer davantage le passage en environnement réel. Cependant, les objectifs de recherche n'étant pas de fournir un modèle réel « clef en main » (soit avec une combinaison d'intrants idéale avec une spatialisation des intrants optimale), on s'est permis de concentrer directement plus d'efforts sur l'environnement réel.

3.4. Données utilisées

3.4.1. En environnement virtuel : pseudo-observations via HYDROTEL

Avec l'utilisation du modèle HYDROTEL, on se génère une base de données constituée de 22 variables au pas de temps journalier (voir le Tableau 3.3 pour une liste des variables). Le modèle tourne sur dix-neuf années, de 1997 à 2015 inclus. Les trois premières années servent de période de chauffe. Pour nos expériences avec les RNA, on dispose donc de seize années « d'observations », de 2000 à 2015 inclus. La sélection des variables utilisées est présentée dans la section 3.5 de ce chapitre.

La variable cible de débit utilisée en environnement virtuel est également celle issue des sorties HYDROTEL. Bien que des séries d'observation de débits soient disponibles, il est plus cohérent d'utiliser celles d'HYDROTEL ; cela permet entre autres d'éviter un biais potentiel entre données estimées (humidité du sol par exemple) et observations réelles (débit).

Pour faire tourner HYDROTEL, des données météorologiques de précipitation et de température sont nécessaires. Elles sont issues NRCan⁸ pour les BV québécois Au Saumon et Magog. Cette base de données met à disposition les précipitations et températures minimales et maximales à un pas de temps journalier sur une grille régulière parallélépipédique d'environ 10 km de côté (Arsenault et al., 2020). Les séries temporelles issues de NRCan sont continues et ne contiennent aucune donnée manquante. Elles couvrent notre période d'intérêt pour tous les BV (1997-2015) sauf Au Saumon (1997-2013). Pour chaque BV, les points de grille de la grille NRCan qui se retrouvent dans un BV sont utilisés comme intrants pour faire tourner HYDROTEL. Pour les BV américains, Androscoggin et Susquehanna, les jeux de données météorologiques sont issus des bases de l'USGS⁹. Les données USGS sont toutes des données d'observations au sol. Pour chacun des BV, le cadre de travail offert par la chaire de recherche industrielle permet de disposer déjà de la sélection des stations à utiliser pour les deux BV concernés.

3.4.2. En environnement réel

Seuls les BV Au Saumon et Magog sont concernés par l'étude faite en environnement réel. Les données auxquelles on fait référence ici sont celles qui sont utilisées comme intrants au RNA.

ERA5-land

En environnement réel, on utilise cette fois-ci les réanalyses ERA5-land fournies par le CEPMMT (Centre Européen de Prévisions Météorologiques à Moyen-Terme ou en anglais *ECMWF, European Centre for Medium range Weather Forecast*)¹⁰ comme source des données météorologiques. Cette base de données met à disposition entre autres les températures minimale et maximale ainsi que les précipitations sur une période allant de 1950 jusqu'à moins trois mois avant le présent. Les données sont mises à disposition à un pas de temps horaire et à une résolution spatiale d'environ 9 km. Compte tenu de la taille des deux BV à l'étude dans

⁸ [Projets de recherche du Service canadien des forêts | Ressources naturelles Canada \(nrcan.gc.ca\)](https://www.nrcan.gc.ca/recherche)

⁹ https://waterdata.usgs.gov/nwis/uv?search_criteria=huc2_cd&submitted_form=introduction

¹⁰ <https://www.ecmwf.int/en/era5-land>

cette partie, il est pertinent de faire appel aux données ERA5-land car elles permettent d'avoir une discrétisation spatiale à la fois fine (bonne représentation de l'hétérogénéité du territoire) et modeste (pas d'excès dans les ressources de calcul nécessaires). De plus, la discrétisation temporelle des données ERA5-land est intéressante : disponibles au pas de temps horaire, on peut aisément se ramener à un pas de temps journalier. La couverture globale de cette base de données permet aussi d'avoir une homogénéité dans la source des intrants météorologiques quel que soit la localisation des BV à l'étude.

Données d'observation au sol

Deux types de mesure au sol sont utilisées : les données hydrométriques, mises à disposition par la Direction de l'Expertise Hydrique (DEH) ou par l'USGS, et les données d'humidité du sol, résultats de 4 campagnes de mesure sur le terrain.

Données hydrométriques

Les données de débit sont issues de la DEH pour le BV Au Saumon. Les données sont disponibles pour la période 2000 – 2021, soit l'ensemble de la période apprentissage et de la période de validation. L'apprentissage des RNA est fait sur la période 2000 – 2017 ; chaque année de 2018 à 2022 est ensuite prise individuellement comme période de validation. C'est la station n°030282 pour laquelle les données sont disponibles. Elle est relativement proche de l'exutoire et son aire de drainage couvre 769 km², soit 75 % du BV (Figure 3.12).

En revanche pour le BV Magog, les 3 stations disponibles sur le BV sont situées aux États-Unis et sont gérées par l'USGS. Les données restent disponibles sur la même période. Les trois stations disponibles sont situées sur la rivière Clyde (n°04296500), la rivière Black (n°04296000) et la rivière Barton (n°04296280). Ces trois rivières se déversent sur le bord sud du lac Memphrémagog. La station de la rivière Barton ne dispose pas des données sur la période complète 2000 – 2021, elle est donc exclue. Seules les rivières Clyde et Black sont utilisés. Étant donné que ces stations sont situées à une certaine distance du lac, une reconstruction du débit de ces deux rivières est faite pour transposer les données au lac : il s'agit de pondérer chacun de ces débits en fonction de la superficie manquante jusqu'au point de confluence des trois cours

d'eau. Cette reconstruction permet ainsi de disposer d'une série de données hydrométriques pour le BV Magog qui draine quasiment toute la partie américaine, dans la partie amont du BV. Plus de détails sur cette reconstruction sont donnés au chapitre 6.




Figure 3.12 – Localisation des stations hydrométriques (triangles rouges) sur les BV Magog et Au Saumon et des points de grille ERA5-land (croix noires)

Données d'humidité du sol

Pour les BV Au saumon et Magog, des mesures *in situ* d'humidité du sol sont disponibles pour quatre étés : de 2018 à 2021 inclus. Ces deux BV ont pu facilement être instrumentés du fait de leur proximité avec l'UdS. Les sites de mesure retenus devaient au départ être dispersés de façon relativement homogène sur chaque BV. Le BV Magog étant transfrontalier, seule sa partie canadienne a été instrumentée. Les données sont relevées avec un pas de temps horaire. On distingue les sondes installées en milieu ouvert (Figure 3.13a) et celles installées en milieu forestier (Figure 3.13b) ; on ne fait pas de distinction supplémentaire à savoir si c'est une prairie ou une terre agricole pour les premiers et le type de forêt (feuillus, conifères, mixtes) pour les seconds.

Le modèle de sonde utilisé est le EC-5¹¹ fourni par METER Group. Ces sondes ont notamment été retenues pour leur facilité d'utilisation et leur faible coût et pour la précision de la mesure effectuée (Vereecken et al., 2014). La mesure repose sur le principe de capacitance. Dans cette méthode, la pointe du capteur est entourée de sol. Selon la teneur en eau du sol, la permittivité diélectrique du milieu mesurée (couche de sol dans laquelle se situe la sonde) est amenée à changer. La permittivité du sol est calculée selon le temps que prend la capacitance à se charger après propagation d'un flux électrique dans le circuit, dépendant donc directement de la teneur en eau du sol entourant le capteur. Une calibration selon le type de sol est nécessaire afin de convertir le temps de charge de la capacitance en valeur d'humidité du sol ; celle-ci est effectuée par le fabricant et ne nécessite pas d'être ajustée avant installation dans les sites retenus dans cette recherche.

L'équation pour passer de la conductivité électrique à l'humidité du sol est proposée par Topp et al. (1980) et repose sur un polynôme d'ordre 3. L'humidité du sol est influencée par différents paramètres physiographiques, dont la pente (Bogena et al., 2017). Cette même étude montre que les sondes EC-5 sont également sensibles aux variations de température, mais que celles-ci sont négligeables par rapport aux variations de permittivité diélectrique du sol.

Les sondes ont toujours été installées en été et, selon les années, couvrent une période allant de deux à six mois (Tableau 3.5)¹². Les sites retenus pour les mesures ont légèrement varié en nombre et en localisation en fonction des mesures faites. Les sites saturés n'ont pas été retenus pour l'année suivante. De même, on a essayé d'ajuster l'équilibre entre les installations en milieu ouvert et celles en milieu forestier, ainsi que la distribution sur le territoire (Figure 3.14 et Figure 3.15).

Sur chaque site instrumenté, une sonde en surface a été installée. La couche de surface est ici définie comme correspondant aux cinq premiers centimètres d'épaisseur de sol. La sonde est

¹¹ <https://www.metergroup.com/en/meter-environment/products/ech20-ec-5-soil-moisture-sensor>

¹² Il arrive que certaines sondes soient installées plus tard dans la saison ou enlevées plus tôt en fonction des équipes qui prennent en main l'installation et le suivi de la campagne de terrain. 2018 fut l'année de lancement de l'instrumentation des BV, il a donc fallu antérieurement préparer les sondes (vérifier leur bon fonctionnement), sélectionner les sites et contacter les propriétaires pour accord. 2020 est une autre année à faible durée d'installation des sondes car l'équipe a changé par rapport aux deux étés précédents. La prise en main du protocole ayant tardé, aucune mesure n'est prise sur le début de l'été. Malgré tout, chaque année les sondes sont mises au sol et retirées la même journée sur chaque BV individuellement.

alors installée verticalement, la fourchette (i.e. le capteur) orientée vers le bas (Figure 3.16a). Deux raisons expliquent ce choix : premièrement le rôle clef joué par la teneur en eau du sol sur la couche superficielle du sol pour contrôler le ruissellement et secondement les mesures satellitaires ne peuvent capter l'humidité du sol que dans les premiers centimètres. En faisant une mesure *in situ* sur la même épaisseur de sol, on s'offre la possibilité de faire une comparaison entre mesures *in situ* et satellitaire (Tremblay, 2020).

En milieu ouvert, une seconde sonde a été installée en profondeur, à 20 cm de la surface, horizontalement (Figure 3.16b), puisque contrairement au milieu forestier, on est davantage susceptible, en milieu ouvert, de rencontrer de plus grandes différences entre l'humidité du sol en surface et celle en profondeur.

Enfin, le BV Magog étant transfrontalier, les sondes installées sur ce BV l'ont été seulement dans sa partie canadienne. Les formalités administratives pouvant être fortement compliquées à obtenir et les délais étant restreints (la campagne de mesure débuta au début de l'été 2018), il fut décidé d'aller au plus simple. Ce choix est cependant moins contraignant qu'on pourrait le penser car l'occupation du territoire et les types de sol sont les mêmes des deux côtés de la frontière. On peut donc de manière légitime faire l'hypothèse que les phénomènes hydrologiques du BV Magog sont régis de manière suffisamment proche sur l'entièreté du territoire pour qu'un ensemble de mesures dans un sous-bassin soit représentatif du reste du BV. Le fait d'avoir plusieurs sondes sur ce sous-bassin et de les disposer dans des milieux différents permet de conserver une certaine hétérogénéité spatiale entre les mesures.

Tableau 3.5 - Dates d'installation et de retrait des sondes d'humidité du sol pour les BV Au Saumon et Magog.

BV	Année	Date d'installation	Date de retrait	Nombre de sondes installées
Au Saumon	2018	5 septembre	14 novembre	14
	2019	2 mai	31 octobre	13
	2020	27 juillet	15 octobre	9
	2021	7 mai	4 novembre	12
Magog	2018	18 septembre	13 novembre	12
	2019	2 mai	30 octobre	12
	2020	30 juillet	4 septembre	10
	2021	17 mai	6 novembre	9



Figure 3.13 - Illustrations d'installation de sondes d'humidité du sol en milieu ouvert (gauche) et en milieu forestier (droite)

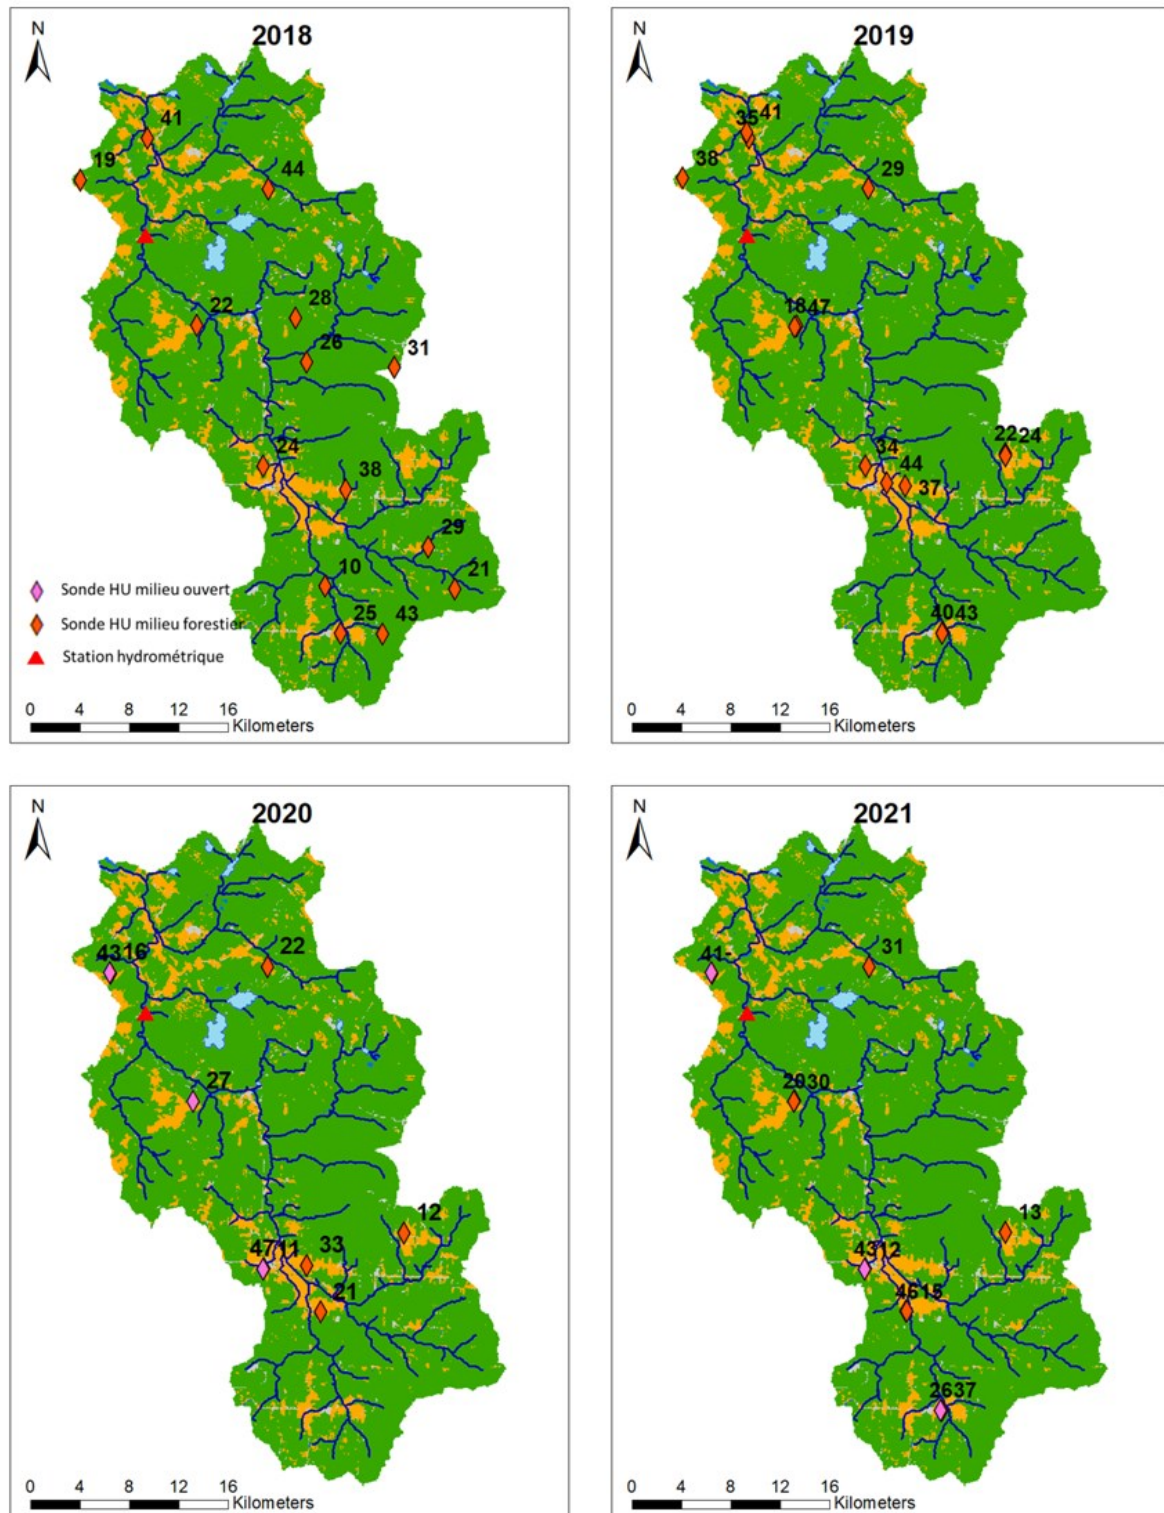


Figure 3.14 – Localisation des sondes d'humidité du sol (losange) et de la station hydrométrique (triangle rouge) sur le BV Au Saumon pour les étés 2018, 2019, 2020 et 2021.

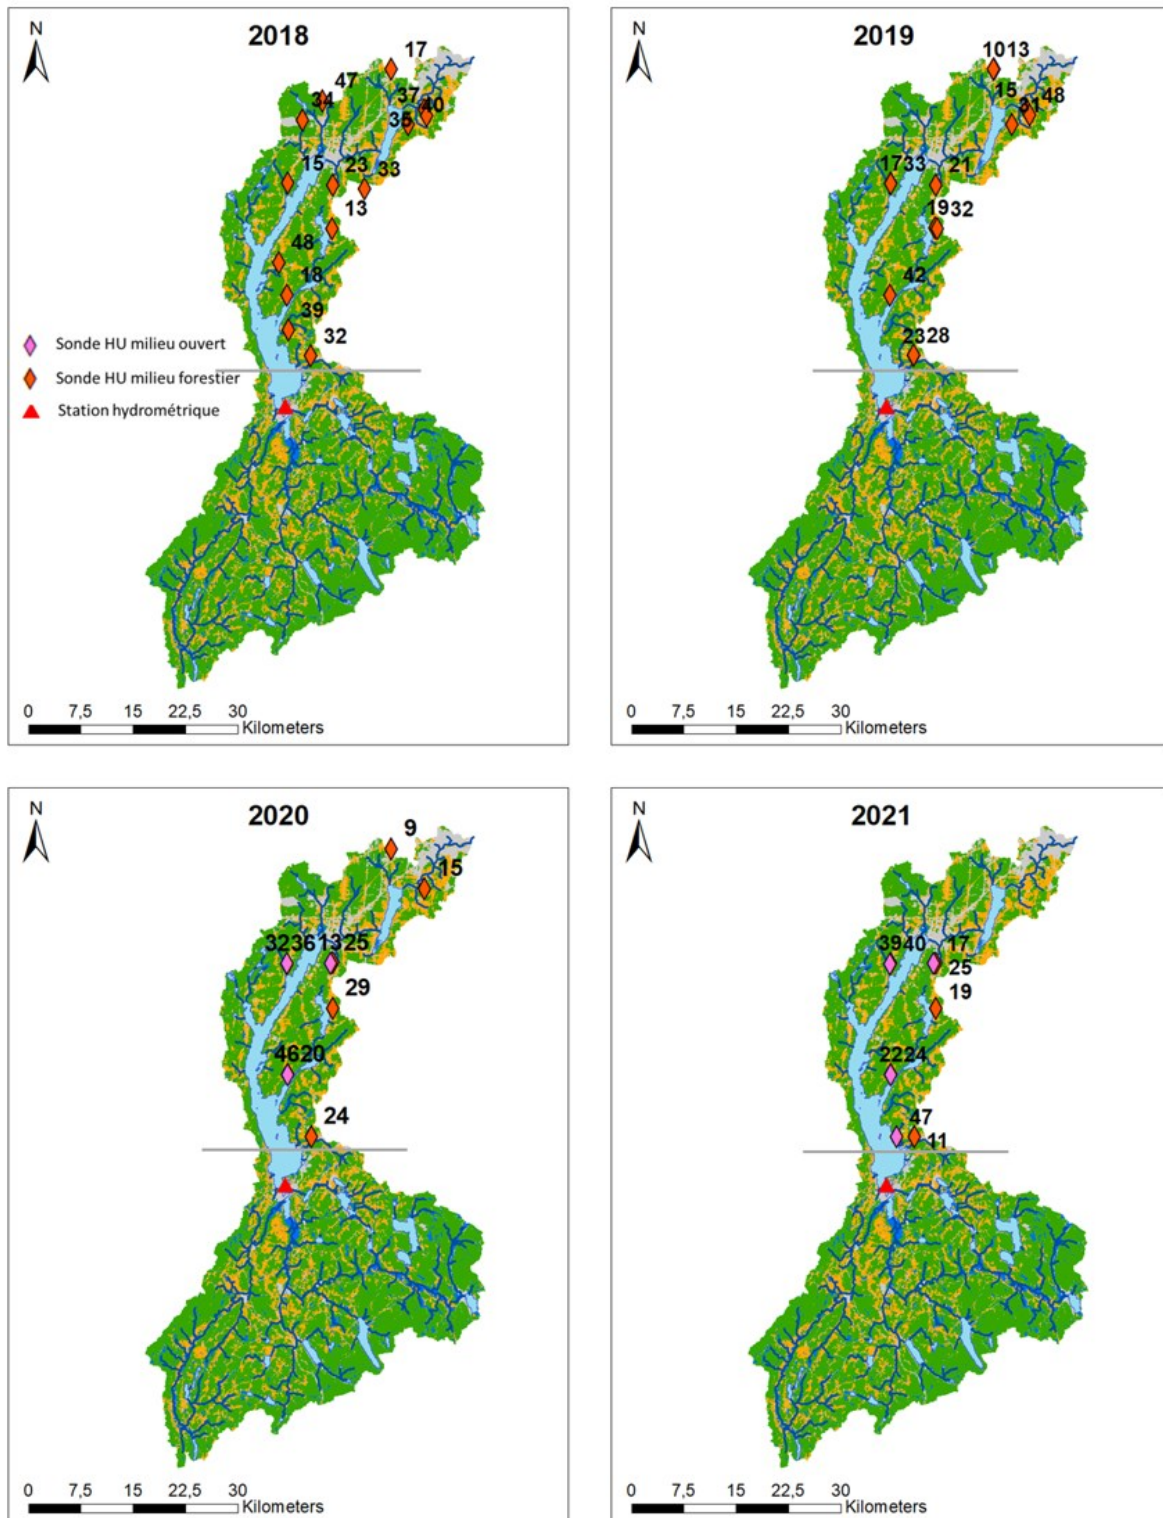


Figure 3.15 – Localisation des sondes d'humidité du sol (losange) et de la station hydrométrique (triangle) sur le BV Magog pour les étés 2018, 2019, 2020 et 2021.



Figure 3.16 - Illustrations d'installation de sondes d'humidité du sol en surface (gauche) et en profondeur (droite)

Cela constitue une première explication mais ces éléments seront rappelés dans le chapitre attribué au traitement de ces données, à savoir le chapitre 6. Avant l'année 2018, aucune mesure *in situ* d'humidité du sol n'a été faite. Avec le modèle de RNA développé et compte tenu de la faible profondeur temporelle des séries de données relevées, il n'est pas pertinent de construire le modèle en mode réel seulement sur 4 années. Ainsi, pour la période d'apprentissage 2000 – 2017, on continuera à utiliser les données d'humidité du sol issues d'HYDROTEL. La phase de validation se fera individuellement sur chaque année de 2018 à 2021, avec une double évaluation, à la fois avec les données réelles et les données issues d'HYDROTEL. Le modèle d'apprentissage alors développé est un modèle qualifié d'adapté, car les variables d'entrées sont issues de l'environnement réel pour la météo et le débit mais de l'environnement virtuel (HYDROTEL) pour l'humidité du sol, faute d'une série de données *in situ* suffisamment longue.

Pour assurer une bonne homogénéité entre apprentissage et validation, seuls les UHRH correspondant à la localisation des sites de mesure sont intégrés comme intrants d'humidité du sol du RNA.

3.5. Méthodes

3.5.1. Chaîne de prévision

Comme mentionné plus tôt dans cette thèse, l'horizon de prévision couvre une fenêtre de sept jours avec un pas de temps journalier ; on est dans un cadre de prévision à court terme. Chaque jour, une chaîne de prévision tourne pour prévoir sur les sept prochains jours. Le système de prévision mis en place ne fonctionne pas avec un modèle qui tournerait qu'une seule fois avec sept sorties (une pour chaque horizon). Il se base sur une itération du roulement du RNA, autant de fois qu'il y a de jours dans la fenêtre de prévision ; les modèles sont imbriqués les uns aux autres. Cette imbrication implique que la sortie d'un modèle pour un horizon J est utilisée comme intrant au modèle pour la prévision à l'horizon $J+1$ (Figure 3.17).

La configuration du modèle préconisée ici prévoit la présence d'au minimum une variable météorologique et une variable d'état comme intrant au RNA. La variable météo est considérée comme tout le temps connue ; elle peut représenter soit une observation (Météo₀) soit une prévision dite parfaite (à partir de l'indice 1). Il fut décidé de ne pas faire appel à de vraies prévisions météorologiques afin de se concentrer sur l'évaluation des différentes variables d'intrants. On ne fait ici que simuler la mise en place d'une chaîne de prévision avec utilisation de prévisions météorologiques. La variable d'état est quant elle mise à jour, c'est-à-dire qu'elle est à la fois en sortie du RNA et en entrée. Cela est bien sûr valable au-delà du jour où la prévision est émise. À $J+0$ (jour d'émission de la prévision), la variable d'état est considérée comme une observation. Le RNA roule une première fois et prévoit, en plus du débit à $J+1$ (variable cible), la variable d'état à ce même horizon (mise à jour). C'est cette valeur de la variable d'état à $J+1$ qui sert d'intrant au RNA suivant pour prévoir le débit à $J+2$. La mise à jour et le schéma de prévision se poursuit jusqu'à $J+7$. Ainsi, un modèle de RNA est utilisé pour chaque horizon ; on a donc entraîné un modèle pour $J+1$, avec les variables d'état qui sont des observations, alors que pour le modèle entraîné pour $J+2$, les variables d'état sont issues des sorties du premier modèle.




Figure 3.17 - Chaîne de prévision générale (exemples jusqu'à deux jours à l'avance). Le tilde représente une sortie du modèle de RNA. La journée à laquelle est associée chaque valeur est inscrite en indice.

3.5.2. Configuration d'intrants

Introduction

Avant de définir et de détailler les configurations d'intrants explorées dans le cadre virtuel, il est important de rappeler que cette recherche vise à faire de la prévision hydrologique à court terme à un pas de temps journalier ; ici, c'est le débit qui est la variable cible. Plus précisément, le débit à l'exutoire du BV.

Avec la discrétisation spatiale accessible grâce au modèle HYDROTEL, le débit sur n'importe quel tronçon du BV est disponible, à la fois le débit amont et le débit aval. Cependant, un cadre est établi afin de se rapprocher d'un système de prévision réel, pour lequel le débit n'est prévu qu'à l'exutoire ou du moins à un site cible du BV. Ainsi, le présent cadre vise à construire le système de prévision basé sur un modèle de RNA en gardant à l'esprit la façon d'opérer en « vrai », c'est la raison pour laquelle seul le débit à l'exutoire est pris en compte en tant que variable de sortie du modèle de RNA. En réalité, les données d'observation hydrométriques ne sont pas toujours disponibles à l'exutoire mais en amont sur le réseau hydrographique. On verra ainsi que, en environnement réel, la localisation du tronçon de rivière sur lequel on fait la prévision est dictée par la position des stations hydrométriques.

Prototype poursuivi

Dans cette sous-section, l'objectif est de pouvoir tester un large ensemble de combinaison d'intrants. Cela va permettre de comprendre les variables les plus significatives pour la prévision

du débit à court terme. Une seule règle est fixée dans cette expérience : la présence d'au moins une variable météorologique et la présence d'au moins une variable d'état.

La variable météorologique vise à fournir de l'information sur les apports d'eau dans le présent et futur. L'objectif est donc de mettre à disposition du modèle de RNA de l'information sur l'eau qui va être ajoutée au BV. Les variables les plus représentatives dans cette catégorie sont les précipitations liquides (pluie) et la température (maximale et/ ou minimale ou moyenne). Lors de la phase d'apprentissage, le modèle de RNA doit ainsi apprendre à faire le lien entre cet apport d'eau et le débit à l'exutoire, cela revient d'une certaine manière au RNA à définir le temps de réponse du BV.

Comme vu dans la revue de littérature, on intègre dans les variables d'état les flux, comme le débit. Les flux décrivent des mouvements dans le BV. L'humidité du sol est ici la *vraie* variable d'état qui nous intéresse. En fait, sous le terme de variable d'état, on fait ici appel à toute variable qui rend compte de l'eau présente dans le BV.

La combinaison permanente d'au moins une variable météorologique et d'une variable d'état permet de s'assurer de fournir de l'information sur la situation dans laquelle se trouve le BV au moment où la prévision est effectuée et de l'information sur les apports que va connaître le BV dans le court terme.

On n'utilise pas de variables physiographiques dans les modèles de RNA exploités. Bien que ce soit une information qui peut s'avérer utile pour mieux comprendre et simuler les processus hydrologiques, le choix est fait ici de ne pas les intégrer. On s'est alors concentré exclusivement sur des variables hydrométéorologiques qui renseignent sur des changements dans les apports en eau au BV et sur la teneur en eau dans le sol, soit des variables qui présentent une évolution dans le temps qui est bien plus grande que les variables physiographiques. En effet, ces dernières peuvent être considérées comme constantes sur les périodes sur lesquelles les prévisions sont faites¹³.

¹³ Si on faisait des prévisions sur de très longues périodes de temps, on pourrait imaginer l'intégration de variables physiographiques qui évolueraient au fil des décennies. En modélisation hydrologique traditionnelle, on est souvent amené à considérer ces variables comme constantes et à faire des changements de caractéristiques de sol manuellement selon différentes simulations. Avec un modèle de RNA, il y a plus de flexibilité à ce niveau-là et on pourrait

Jusqu'à présent, sont citées uniquement des variables « brutes », c'est-à-dire des variables qui sont directement mesurables par des instruments (même si parfois l'installation peut être compliquée ou peu répandue, elle reste techniquement possible). Un travail peut être fait afin de transformer certaines de ces variables et en créer de nouvelles. Ces variables transformées (ce sera l'appellation utilisée comme référence dans le reste de la thèse) permettent *a priori* de fournir un autre type d'information.

Certaines variables transformées intègrent une séquence temporelle, c'est le cas de l'indice de précipitation antécédente (API, de l'anglais *Antecedent Precipitation Index*. Anctil et al., 2004 ; Kohler et Linsley, 1951). Dérivé de l'API, existe l'API modifié (API_{mod}. Zhao et al., 2019). Les équations 3.9 et 3.10 montrent la façon de calculer ces deux indices.

$$API(t) = \sum_{j=1}^N P_{t-j} l^{-j} \quad (3.9)$$

Le facteur l est à choisir par l'utilisateur et définit le coefficient de décroissance. Il est généralement pris entre 0,80 et 0,98 (Heggen, 2001) ; plus il est grand, moins les précipitations des jours précédents sont prises en compte.

$$API_{mod}(t) = k \cdot API(t) + P(\Delta t) \quad (3.10)$$

Avec $k = 0,84 \cdot \delta(20 - T_{moy})$ et sous la contrainte que si $API_{mod}(t) > API_{max}$, alors $API_{mod}(t) = API_{max}$

Les paramètres δ et API_{max} doivent être ajustés. Cela se fait en calculant l'API pour différentes valeurs de δ et API_{max} puis en calculant la corrélation avec l'HU pour chacune (méthode appliquée par Zhao et al., 2019).

La Figure 3.18 est une illustration de choix des valeurs de δ et API_{max} pour le BV Androscoggin.

Il est net que la corrélation est bien plus forte pour (presque) toutes les configurations d' API_{max}

alors imaginer intégrer de longues séries temporelles qui intégreraient ces évolutions des caractéristiques du terrain à l'étude.

testées par rapport à l'API classique. Dans l'exemple illustré, seraient retenues des valeurs d'API_{max} de 80 mm et de δ de 0,004.




Figure 3.18 – Corrélation API modifié – HU (lignes pleines et pointillées) + corrélation API classique – HU (ligne horizontale à ~0,48). Comparaison selon les valeurs de δ et API_{max} sélectionnant les données que sur l'été.

Par leur définition respective, ces deux indicateurs intègrent une composante temporelle. La séquence de temps prise en compte peut dépendre de deux choses : i) dans le cadre de l'API_{mod}, c'est une valeur spécifique au régime hydrologique et météorologique (et en particulier pluviométrique) du BV et ii) l'utilisateur peut être contraint par certains aspects tels que la longueur des données à disposition, leur qualité ou sa connaissance du comportement hydrologique de son site d'étude.

Une autre variable transformée est définie comme un ajustement de la quantité de pluie tombée par la quantité d'eau évapotranspirée, c'est en fait la différence entre la précipitation et l'évapotranspiration. L'usage d'une telle variable pourrait permettre de tenir compte de l'état de stress hydrique potentiel du BV à l'étude selon les périodes de l'année.

Configurations testées

Les combinaisons testées en mode virtuel ont été nombreuses et, comme indiqué plus haut, une seule règle régit les essais : la présence minimale d'une variable météorologique et d'une variable d'état (Tableau 3.6).

Les essais menés se décomposent en différentes phases selon l'information qui est intégrée. Ainsi, se retrouvent des essais sur la précipitation, la température, les variables dérivées de la précipitation, l'humidité du sol, le débit. Le modèle hydrologique développé fait de la prévision à court terme et à travers les lectures faites, il est décidé qu'aucune variable climatique ne sera intégrée comme intrant. Les oscillations d'El Nino, nord Atlantique et de Madden-Julian sont des exemples de variables climatiques courantes pour des études sur les régions sélectionnées.

Tableau 3.6 - Configurations d'intrants testées. P représente la précipitation, T la température moyenne, ETP l'évapotranspiration, Q le débit, Hu l'humidité du sol en surface et Hupro l'humidité du sol en profondeur. Les indices font référence au jour auquel on prend ces variables pour une prévision faite un jour à l'avance.

Configu- ration	Variables météo	Variables d'état	Configu- ration	Variables mé- téo	Variables d'état
1	P ₀ , P ₁	Q ₀	9	P ₀ , P ₁ , ETP ₀	Q ₀ , Hu ₀
2	P ₀ , P ₁ , T ₀ , T ₁	Q ₀	10	P ₀ , P ₁ , ETP ₀	Q ₀ , Hupro ₀
3	P ₀ , P ₁ , T ₀ , T ₁ , ETP ₀	Q ₀	11	P ₀ , P ₁ , T ₀	Q ₀
4	P ₀ , P ₁ , ETP ₀	Q ₀	12	API ₀ , T ₀ , T ₁	Q ₀
5	P ₀ , P ₁ , T ₀ , T ₁	Q ₀ , Hu ₀	13	API _{mod0} , T ₀ , T ₁	Q ₀
6	P ₀ , P ₁ , T ₀ , T ₁	Q ₀ , Hupro ₀	14	API ₀	Q ₀
7	P ₀ , P ₁	Q ₀ , Hu ₀	15	API _{mod0}	Q ₀
8	P ₀ , P ₁	Q ₀ , Hupro ₀	16	API ₀ , T ₀ , T ₁	Q ₀ , Hu ₀
9	P ₀ , P ₁ , ETP ₀	Q ₀ , Hu ₀	17	API _{mod0} , T ₀ , T ₁	Q ₀ , Hu ₀
10	P ₀ , P ₁ , ETP ₀	Q ₀ , Hupro ₀			

3.5.3. Spatialisation des intrants

Modèle semi-spatialisé

Comme vu dans la présentation du matériel utilisé, le modèle HYDROTEL fournit en sortie vingt variables sur la base d'UHRH et les débits amont et aval sur la base d'un découpage des cours d'eau en tronçons. Comme expliqué, le découpage par UHRH est fait à partir d'information physiographiques. La projection des variables météorologiques est faite sur la base de la méthode retenue pour le module d'interpolation (choix entre plus proches voisins et polygone de Thiessen). Ainsi, l'approche de modélisation hydrologique par modèle semi-spatialisé est basée sur le découpage par UHRH (Figure 3.19a). Elle permet, a priori, d'intégrer de l'information sur l'hétérogénéité du BV à l'étude d'un point de vue de ses caractéristiques physiographiques, qui exercent une influence directe sur le comportement hydrologique. Bien qu'aucun concept ou équation physique ne soit intégrée avec une approche par RNA, l'utilisation d'intrants semi-spatialisés permet d'intégrer indirectement cet effet. On s'attend que cela se répercute sur les sorties du modèle, soit que le RNA détecte des motifs¹⁴ hydrologiques lors de la phase d'apprentissage.

Avec ce type de modélisation, le nombre d'intrants est égal au nombre de variables prises en compte multiplié par le nombre d'UHRH couvrant le BV. Ainsi, le nombre d'intrants au modèle est intimement lié à sa superficie. En effet, plus un BV est grand, plus le nombre d'UHRH l'est. Pour de grands BV comme Susquehanna (1025 UHRH), les ressources de calcul requises peuvent alors être importantes et devenir limitantes¹⁵. Cela n'empêche en rien la comparaison des résultats entre BV car les UHRH sont déterminés de façon similaire pour chaque BV. En

¹⁴ Le terme anglais *patterns* est le plus approprié. Afin de ne pas faire d'anglicisme, on choisit ici *motifs* comme substitut ; l'idée qu'on veut transmettre est que durant sa phase d'apprentissage, le modèle de RNA va faire des liens entre intrants et variable(s) cible(s) et que ces liens pourraient être dictés par la physique existante.

¹⁵ Une note s'impose là-dessus, car nous n'y reviendrons pas dans les résultats. Selon le logiciel de modélisation utilisé, les ressources de calcul étaient très différentes. Cette recherche s'est penchée sur une programmation en Matlab et une programmation en Python. Il s'est avéré que Matlab avait plus de mal et nécessitait plus de temps et de ressources. Ainsi, on n'était pas en mesure de développer un modèle semi-spatialisé pour le BV Susquehanna avec Matlab alors que Python offrait une facilité d'exécution plus grande. Cette observation est arrivée bien tard dans le travail de recherche et il ne fut pas possible de compenser en transvasant tout sur Python. Enfin, il faut mentionner que le codage des modèles a été fait maison. Il est probable qu'une optimisation des codes aiderait et demanderait ainsi moins de ressources de calcul à niveau de modélisation équivalent.

revanche, cela impose de développer un modèle de RNA pour chaque BV ; il n'est pas envisageable de faire du transfert d'apprentissage avec une telle approche.



Figure 3.19 - Représentation des différentes spatialisations d'intrants possibles : (a) semi-spatialisé, (b) global et (c) spatialisé.

Modèle global

Un modèle global n'intègre aucune variabilité spatiale (Figure 3.19b). Chaque variable n'est associée qu'à un intrant qui représente l'ensemble du BV à l'étude. Dans cette recherche, les séries temporelles semi-spatialisées fournies en sortie d'HYDROTEL sont spatialement moyennées afin de fournir une donnée unique sur le BV à l'étude.

Cette représentation spatiale est très légère d'un point de vue des ressources de calcul. Elle permet de faire du transfert d'apprentissage et, pour l'utilisateur, il est très facile de voir à quoi correspond chaque intrant (car un intrant est alors simplement équivalent à une variable et non plus plusieurs intrants pour la même variable).

Modèle spatialisé

À l'image du modèle semi-spatialisé qui décompose le territoire en différentes unités hydrologiques, le modèle spatialisé propose lui aussi un découpage avec une représentation de l'hétérogénéité spatiale du BV. En effet, les spécificités du territoire sont prises en compte mais

sur une base géométrique, sans aucune logique physique¹⁶ derrière. Chaque unité géométrique est appelée cellule ou pixel (en référence à la télédétection). Dans cette recherche, le choix est fait de bâtir ces cellules en se rapprochant de la résolution spatiale des données satellitaires d'humidité du sol disponibles à partir des capteurs SMOS et SMAP, qui est respectivement de 35 à 50 km de côté et 36 km de côté. Les BV les plus petits étudiés (Au Saumon et Magog) ne font qu'un peu plus de 1 000 km². Ainsi, afin de s'assurer d'une couverture du territoire par suffisamment de cellules (et ainsi s'assurer de ne pas être trop proche d'un modèle global avec trop peu de dispersion spatiale), on considère un modèle spatialisé avec des cellules de 28x28 km², soit 0.25°x0.25° (Figure 3.19c).

Les valeurs de chaque cellule sont calculées sur une base journalière, au même pas de temps que les sorties HYDROTEL. Tous les UHRH couverts par un pixel sont moyennés et cette valeur moyenne devient alors la valeur de la cellule. Cette étape est répétée sur l'ensemble des cellules qui couvrent partiellement ou totalement une partie du BV (Figure 3.20). Les UHRH couverts par plusieurs cellules sont utilisés pour chaque cellule dans le calcul des moyennes. De plus, aucune distinction n'est faite entre les cellules qui couvrent peu d'UHRH (donc faible ratio de l'aire de la cellule couvrant en réalité une partie du BV ; 2^e cellule, Figure 3.20) et celles qui couvrent beaucoup d'UHRH (3^e cellule, Figure 3.20).

Comme pour le modèle semi-spatialisé, le nombre de cellules couvrant un BV (donc le nombre d'unités hydrologiques du modèle spatialisé) varie d'un BV à l'autre. Il reste donc toujours possible de comparer entre eux les résultats pour chaque BV mais il n'est pas possible de faire du transfert d'apprentissage. En s'avancant un peu sur un chapitre ultérieur à celui-ci, on peut déjà annoncer que, avec un modèle spatialisé tel que celui qui est développé ici, on peut envisager de faire du transfert d'apprentissage de deux manières :

- 1) en fixant un même nombre de cellules pour tous les BV et en faisant varier la taille de celles-ci en fonction de la taille de chaque BV ;
- 2) en fixant une taille de cellule et en prenant une fenêtre de cellules rectangulaires permettant de couvrir le plus grand des BV. Pour les plus petits BV, on masque les cellules ne

¹⁶ Physique peut ici être entendue de deux manières : 1) en référence à la topographie et à la géographique dite physique et 2) en référence aux équations physiques qui permettent de représenter les écoulements dans les modèles traditionnels conceptuels ou à base... physique.

couvrant pas le BV en question ; le nombre d'intrants au modèle reste alors le même, mais l'information contenue dans certaines cellules peut être nulle ou complète en fonction des BV.

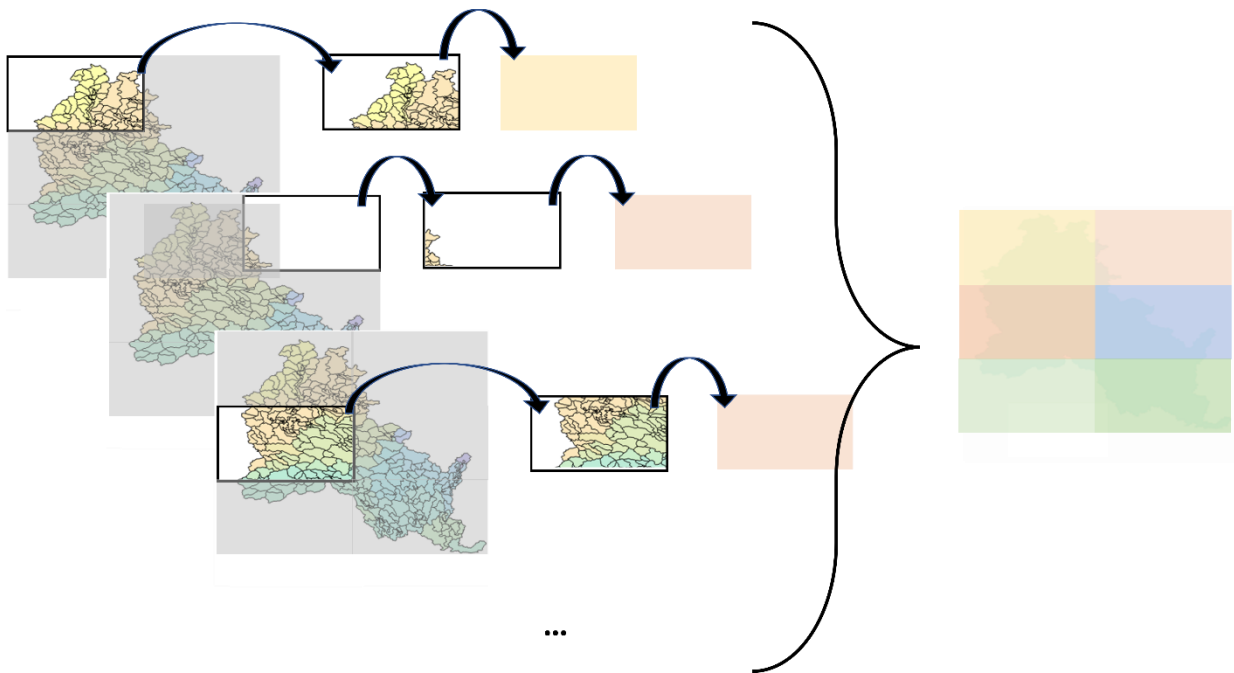


Figure 3.20 - Représentation schématique de construction des intrants spatialisés à partir des intrants semi-spatialisés.

Modèle singulier

Dérivant du modèle spatialisé, on peut considérer un pixel à la fois comme représentatif de l'ensemble du BV (un peu à l'image du modèle global). Cela revient à dire que l'information issue d'une zone particulière du BV (définie ici par une forme géométrique) est suffisamment importante pour pouvoir être utilisée pour modéliser des processus en jeu sur l'ensemble du BV.

À l'échelle d'un BV, on dispose donc d'autant de modèles singuliers que de pixels qui couvrent le territoire.

3.5.4. De l'environnement virtuel à l'environnement réel

La chaîne de prévision avec le modèle de RNA utilisée en environnement réel est la même qu'en environnement virtuel, voir la Figure 3.17. Seules l'origine des données diffère. Par ailleurs, l'objectif ici étant d'évaluer les performances du modèle de prévision en environnement réel, on examinera uniquement le modèle avec la combinaison d'intrants qui fait appel à l'humidité du sol en surface, car cette variable est disponible avec une distribution spatiale relativement satisfaisante¹⁷ sur les BV Au Saumon et Magog durant quatre étés. Une autre raison, et pas des moindres, d'utiliser cette combinaison d'intrants est que c'est celle qui fournit les meilleurs résultats en environnement virtuel, comme il le sera vu au chapitre 4 puis au chapitre 5.

Tel que mentionné plus haut, la disponibilité de seulement quatre étés avec des données d'humidité du sol empêche de faire l'apprentissage du RNA avec de telles observations. L'apprentissage a donc été fait avec l'aide des 'observations' d'humidité du sol produites par HYDROTEL (comme c'est le cas en environnement virtuel, cadre de modélisation dans lequel tous les intrants sont issus d'HYDROTEL) ; c'est ce qu'on appelle l'environnement adapté. Une double validation est cependant mise en place : une avec les données d'humidité du sol issues d'HYDROTEL et une avec les données terrain (Tableau 3.7). Naturellement, il est attendu que les performances soient moins bonnes en validation qu'en apprentissage ; c'est ce qui est observé à partir d'un jeu de données de même origine. C'est à cela que sert la validation 1 dans le Tableau 3.7. Le fait de changer la source des données entre l'échantillon d'apprentissage et l'échantillon de validation rajoute une dégradation dans la performance le modèle, tout du moins, c'est ce qui est attendu. En calculant les performances du modèle en validation 2 (Tableau 3.7) et en comparant ces résultats avec ceux de l'échantillon 1, on pourra déterminer si les observations ponctuelles concordent bien avec les simulations d'humidité du sol issues d'HYDROTEL à l'échelle de l'UHRH.

¹⁷ La satisfaction à laquelle on fait référence se base sur le nombre de stations par rapport à la taille des BV en question et de leur répartition sur chacun des territoires. Comme vu sur les cartes de distribution (Figure 3.14 et Figure 3.15), les sondes ne sont pas concentrées en une seule région du territoire (à part pour Magog où on est contraint par sa localisation de part et d'autre de la frontière) et couvre à la fois des zones ouvertes et des zones boisées (qui sont les deux principales occupations du sol et de loin).

Tableau 3.7 - Origine des données pour les échantillons d'apprentissage et de validation en environnements adapté et réel.

	Intrants		Sortie	Appellation
	Météo	Humidité du sol	Débit	
Apprentissage	ERA5-land	HYDROTEL	DEH (Au Saumon), USGS reconstruit (Magog)	Environnement adapté
Validation 1		HYDROTEL		
Validation 2		Observations <i>in situ</i>		Environnement réel

Ce passage en environnement réel permet entre autres de donner des pistes de réponse aux questionnements suivants¹⁸ :

- 1) les données d'humidité au sol concordent-elles avec les données simulées par HYDROTEL à l'échelle de l'UHRH ?
- 2) quelle est la performance d'un modèle de RNA bâti en environnement adapté lorsqu'il est validé avec des données réelles, i.e. construire un modèle en environnement adapté permet-il d'avoir un modèle de performance similaire en environnement réel ?
- 3) les sites retenus pour l'instrumentation des BV sont-ils pertinents pour faire de la prévision hydrologique à court terme ?
- 4) y a-t-il des situations hydroclimatiques plus favorables que d'autres pour améliorer les performances du modèle de RNA développée (année normale, étiages, forts débits) ?

¹⁸ On notera toutefois qu'il ne s'agit que de pistes de réponse et en aucun une résolution complète de celles-ci. En effet, l'apprentissage et la validation du modèle n'étant pas fait dans le même environnement, on n'est pas en mesure de franchement y répondre. On peut cependant proposer une méthode à développer pour s'approcher un peu plus de la vérité avec le développement d'un modèle statistique pour reconstituer des observations *in situ* à partir des humidités du sol d'HYDROTEL. Si, sur les quatre années pour lesquelles on dispose des données d'observation, on obtient une bonne corrélation dans les données reconstruites, on pourrait alors étendre la série d'observations au sol sur plusieurs années et entraîner le RNA à partir de ces pseudo-observations.

3.6. Métriques et outils d'évaluation

Cette thèse ne présente que trois critères d'évaluation. D'autres métriques ont été explorées durant cette recherche (biais, erreur quadratique moyenne normalisée par exemple). On choisit délibérément de limiter le nombre de métriques dans cette thèse. En effet, les tendances fournies par les métriques non-retenues étant similaires à celles retenues (et présentées dans cette sous-section), les analyses et les conclusions ne sont pas influencées par ce choix.

3.6.1. Critère de Nash-Sutcliffe

Le critère d'efficacité de Nash-Sutcliffe (NSE, *Nash Sutcliffe Efficiency*) s'exprime via l'équation 3.11.

$$NSE = 1 - \frac{\sum_{i=1}^n (x_i - x_{ref,i})^2}{\sum_{i=1}^n (\bar{x}_{ref} - x_{ref,i})^2} \quad (3.11)$$

avec x qui représente la série simulée de durée de n jours à évaluer, x_{ref} la série de référence de même durée et \bar{x}_{ref} la moyenne de la série de référence.

Le NSE est compris dans l'intervalle $[-\infty ; 1]$, avec 1 la valeur associée au modèle parfait. Quand le NSE augmente, il démontre une amélioration. Pour illustration, considérons que la référence est l'historique des observations et que les sorties d'un modèle sont évaluées par le NSE. Une valeur de 1 indique que le modèle est parfait et que ses sorties correspondent exactement aux données observées. Une valeur de NSE de 0 signifie que le modèle fait aussi bien que la moyenne des observations ; dans un modèle de prévision, cela peut se traduire par « prendre la moyenne de l'historique fournira une prévision de qualité similaire à prendre les sorties du modèle de prévision évalué ». Entre 0 et 1, le NSE est un marqueur d'amélioration du modèle par rapport à la moyenne de la référence, donc que le modèle ajoute une plus-value. Un NSE négatif indique que le modèle fait moins bien que la moyenne de la référence, un résultat qu'on ne souhaite pas avoir.

On cherche à maximiser ce critère. De plus, les différences étant à la puissance 2 dans l'équation 1, le NSE est un critère qui pénalise plus fortement les forts débits que les faibles débits. Il pénalise également très fortement les décalages temporels étant donné que c'est un critère qui prend la différence entre référence et modèle pour chaque pas de temps individuellement.

3.6.2. Racine de l'erreur quadratique moyenne

La racine de l'erreur quadratique moyenne (RMSE, *Root Mean Square Error*) est un critère qui évalue l'écart entre deux courbes, l'une de référence et l'autre qu'on cherche à évaluer. Le RMSE est assez proche du NSE car il pénalise aussi davantage les forts débits que les faibles débits. Sa formulation mathématique est décrite par l'équation 3.12 (dont les termes ont les mêmes définitions que pour l'équation 3.11).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x_{ref,i})^2} \quad (3.12)$$

3.6.3. Hydrogrammes

Enfin, au-delà des deux précédentes métriques qui fournissent une évaluation numérique de la performance du modèle, les hydrogrammes fournissent une estimation visuelle et plus globale. En effet, la superposition d'un hydrogramme de référence avec un hydrogramme simulé permet de distinguer un potentiel biais, un retard ou une avance dans le temps, de noter des événements manquants ou mal-estimés. Bref, l'outil visuel que représentent les hydrogrammes est indispensable pour peaufiner une analyse et estimer au mieux de la qualité d'un modèle.

CHAPITRE 4 LA PRÉVISION HYDROLOGIQUE À COURT TERME PAR RNA DANS UN ENVIRONNEMENT VIRTUEL

4.1. Avant-propos

Auteurs et affiliation

Renaud Jouglà : étudiant au doctorat, Département de Génie Civil, Faculté de Génie, Université de Sherbrooke.

Robert Leconte : professeur, Département de Génie Civil, Faculté de Génie, Université de Sherbrooke.

Date d'acceptation : 10 février 2022.

État de l'acceptation : Version finale publiée¹⁹

Revue : Water

Référence : Jouglà R, Leconte R. Short-Term Hydrological Forecast Using Artificial Neural Network Models with Different Combinations and Spatial Representations of Hydrometeorological Inputs. *Water*. 2022; 14(4):552. <https://doi.org/10.3390/w14040552>

Titre français : Prévion hydrologique à court terme à partir d'un modèle de réseaux de neurones artificiels avec différentes combinaisons et discrétisations spatiales des intrants hydrométéorologiques.

Contribution au document : Cet article propose de comparer quatre configurations d'intrants en entrée du modèle de RNA pour faire de la prévion hydrologique de un à sept jours à l'avance sur les BV Androscoggin et Susquehanna. Pour une de ces configurations d'intrants, trois spatialisations des intrants sont testées pour le BV Androscoggin. Ces expériences sont réalisées en environnement virtuel contrôlé et permettent de comprendre le comportement du RNA en

¹⁹ <https://www.mdpi.com/2073-4441/14/4/552>

fonction de la variable d'état retenue et selon la discrétisation spatiale de l'humidité du sol en surface. Quelques analyses supplémentaires non publiées dans cet article montrent plus de comparaisons d'intrants et plus de détails sur les résultats selon les spatialisations (Chapitre 5). Elles permettent aussi de préparer les expériences similaires sur les BV Au Saumon et Magog, toujours en environnement virtuel contrôlé (Chapitre 5) en vue d'un passage en environnement réel (Chapitre 6).

Résumé français :

En modélisation hydrologique, les modèles de réseaux de neurones artificiels (RNA) sont de plus en plus populaires depuis une vingtaine d'années et la communauté scientifique élabore de plus en plus là-dessus. Cet article vise à faire de la prévision hydrologique à court terme, définie comme allant de un à sept jours à l'avance, à l'aide d'un modèle de RNA pour deux BV du nord-est du continent nord-américain : ceux des rivières Androscoggin et Susquehanna. On développe un environnement virtuel de modélisation dans lequel on génère des pseudo-observations à l'aide du modèle hydrologique HYDROTEL. Celles-ci sont utilisées comme intrants au modèle de RNA sur seize étés (de 2000 à 2015 inclus). La première expérience consiste à évaluer l'influence de différentes combinaisons d'intrants sur la qualité des prévisions. Pour cela, quatre variables d'état sont testées : l'humidité du sol en surface, l'humidité du sol en profondeur, le débit au pas de temps précédent et un couplage du débit au pas de temps précédent avec l'humidité du sol en surface. Pour les deux BV à l'étude, la meilleure combinaison d'intrants est celle utilisant à la fois le débit au pas de temps précédent et l'humidité du sol en surface. La seconde expérience vise à déterminer s'il y a une discrétisation spatiale qui améliore les résultats de prévision. Trois discrétisations spatiales de l'humidité du sol en surface sont ainsi comparées pour le BV Androscoggin : globale, spatialisée et singulier (tenant compte d'une seule cellule du modèle spatialisé à la fois). Les performances pour le modèle global sont comparables à celle du modèle spatialisé. Cependant, tous deux surpassent le modèle singulier. Les travaux futurs devraient inclure une évaluation du modèle de RNA développé en environnement virtuel avec de vraies données d'observation, issues d'observation au sol ou de la télédétection.

4.2. Abstract

In hydrological modelling, artificial neural network (ANN) models have been popular in the scientific community for at least two decades. The current paper focuses on short-term streamflow forecasting, 1 to 7 days ahead, using an ANN model in two northeastern American watersheds, the Androscoggin and Susquehanna. A virtual modelling environment is implemented, where data used to train and validate the ANN model were generated using a deterministic distributed model over 16 summers (2000–2015). To examine how input variables affect forecast accuracy, we compared streamflow forecasts from the ANN model using four different sets of inputs characterizing the watershed state—surface soil moisture, deep soil moisture, observed streamflow the day before the forecast, and surface soil moisture along with antecedent observed streamflow. We found that the best choice of inputs consists of combining surface soil moisture with observed streamflow for the two watersheds under study. Moreover, to examine how the spatial distribution of input variables affects forecast accuracy, we compared streamflow forecasts from the ANN using surface soil moisture at three spatial distributions—global, fully distributed, and single pixel-based—for the Androscoggin watershed. We show that model performance was similar for both the global and fully distributed representation of soil moisture; however, both models surpass the single pixel-based models. Future work includes evaluating the developed ANN model with real observations, quantified *in situ* or remotely sensed.

Keywords: hydrological forecast; artificial neural network models; watershed state input; spatial discretization; soil moisture; streamflow

4.3. Introduction

Among natural disasters, hydrological-related damage has the greatest impact on humanity and its activities (Jain et al., 2018). Major events can be either floods or droughts. According to the United Nations, 2437 million people were affected by floods from 1992 to 2012, with an estimated cost of 480 USD billion (UNISDR, 2012). In northern regions, floods are typically caused by: (i) snowmelt in the spring, which can be compounded by ice jams and/or rainfall,

and (ii) high rainfall due to severe thunderstorms or very active low-pressure systems during the summer and fall. More specifically in the northeastern part of North America, large rainfalls events are associated with the tail of hurricanes, originating from the Atlantic Ocean and reaching the Caribbean and the Gulf of Mexico. In this context, flood forecasting agencies and research centers are developing and improving hydrological models and forecasting systems to anticipate floods and mitigate their impacts (Fortin et al., 2001; Perrin et al., 2003; Viterbo et al., 2020). Hydropower companies are also involved in model development and contribute to knowledge in hydrological modelling.

Central to a hydro-meteorological forecasting chain is the hydrological model. To date, conceptual and physically based deterministic hydrological models have typically been used by flood forecasting agencies; for example, HYDROTEL (Fortin et al., 2001) at the *Direction de l'Expertise Hydrique et de l'Atmosphère* (DEHA, in English: Center for Water and Atmosphere Expertise) of Québec (Canada); Distributed Hydrological-Soil-Vegetation Model (Wigmosta et al., 1994) at the Advanced Hydrologic Prediction Services, associated with the National Oceanographic and Atmospheric Administration in the USA; Weather Research and Forecasting produced by Hydro at River Forecast Centers across the USA; and MODCOU (Morin et al., 1981) at the *Service Central d'Hydrométéorologie et d'Appui à la Prévision des Inondations* (in English: Hydrometeorological and Flood Forecasting Central Service) in France. They all have several years of applicability and performance in common and are being continuously developed by their respective agencies and affiliated research centers. These agencies and others involved in operational streamflow forecasting face four main challenges, described by Pagano et al. (2014) as follows: “(1) making the most of available data, (2) making accurate predictions using models, (3) turning hydrometeorological forecasts into effective warnings, and (4) administering an operational service” (Pagano et al., 2014, p. 1692). The authors highlight several weaknesses of current models, among which are the high computational resources and the difficulty in simulating fine spatial resolution hydrological processes. While they propose some opportunities to improve the streamflow forecasting chain, data-driven models present a high potential to answer some of these issues (Kratzert et al., 2018).

One type of data-driven model is machine learning (ML), commonly defined as a process in which a computer learns from a historical dataset and then makes predictions. ML models can

be used across a wide range of applications such as finance, marketing, medicine, and hydrology, among others and advantages include the efficiency in handling multi-dimensional data and complex environments, improving accuracy and successful over time, and reducing costs (Faizollahzadeh ardabili et al., 2019; Mosavi et al., 2018). However, some limitations should be noted, in particular the need for a large amount of geomorphological and hydrometeorological data and the poor efficiency in transfer learning. A wide range of ML models are available and found in the literature (Chang et Guo, 2020; Faizollahzadeh ardabili et al., 2019; Yaseen et al., 2015). To the best of the authors' knowledge, and although ML models in hydrology have been investigated by the scientific community, such models used operationally by companies or public services to produce flood forecasts are still scarce. GeoSapiens, FlowWorks, and UpstreamTech are three North American companies that illustrate the use of ML in a direct operational application in hydrology—specifically, in flood risk-reduction systems. Several articles have compared the performance of traditional deterministic models versus ML models; however, there is no clear consensus for which approach is better for hydrological modelling. (Cai, 2010; Fleming et al., 2015; Fleming et Goodbody, 2019) are three good examples of testing artificial neural networks (ANNs) for flood forecasting. ANN models are a popular ML approach for hydrological modelling and forecasting (Abrahart et al., 2012). Several papers have demonstrated hydrological applications of ANN models, mostly for forecasts issued a few hours up to a season in advance (Abrahart et al., 2012; Dtissibe et al., 2020; Oyebode et Stretch, 2018; Zealand et al., 1999). Typical of ML models, ANN is efficient in resolving non-linear problems. However, compared to other ML approaches, the primary advantage of ANN models is their capacity to learn continuously—their internal structure allows the model to update the learning process at each timestep without a high cost in time and resources. Moreover, compared to physically based hydrological models, using ANN models operationally does not require extensive hydrological expertise; flood forecasting agencies that use physically based models usually host specific teams devoted to the various tasks involved in a traditional hydro-meteorological forecasting chain. For example, running a physically based hydrological model requires human checks and decisions at each step, from the inputs to the internal parameters of the model to the outputs. Such tasks require considerable resources, including updating and maintaining physiographic and hydrometeorological databases that are needed to calibrate and run models. The three national agencies cited above are good examples

of the wealth of expertise needed to issue accurate hydrological forecasts from physically based models. The procedure should be largely reduced with ANN models. The main issue that arises using ANN models is overfitting the model to the training data. Another challenge is the low convergence of models during the learning step with some structures of ANN models (Dawson et al., 2006; Jain et al., 2018).

In ML hydrological modelling, including via ANN models, clear identification of the inputs and output(s) is necessary. Inputs are a key element to train an efficient model (Phukoetphim et al., 2014) and are likely to differ according to the forecasting horizon. For long-term forecasts (i.e., several months or seasons in advance), variables describing climatic trends are most commonly used as inputs. In contrast, for short-term forecasts (i.e., from 1 h to a few days in advance), inputs should be variables that have a rapid effect on the hydrological processes of interest. These are generally variables that are measured at discrete locations using ground probes (e.g., temperature, precipitation, and snow depth), but also can be quantified across large spatial extents using remote sensing (e.g., soil moisture, snow water equivalent, and precipitation). At least one watershed state variable—variables describing water stored by the watershed (e.g., streamflow the day before), soil (e.g., soil moisture), or land surface (e.g., snow depth and/or snow water equivalent)—should be included as inputs. Hydrological watershed behavior is directly related to streamflow, therefore streamflow provides information on water storage across the entire watershed. Soil moisture is particularly relevant to forecasts in summer and fall because it plays an important role in runoff and infiltration, while snow is relevant in winter and spring forecasts as it contains information about the water stored during the frozen season. Users should select one or more of these watershed state variables depending on model intended use (e.g., spring or summer/fall flood events) and on the availability of information describing watershed state variables. For short-term hydrological forecasts, model outputs are commonly streamflow (Anctil et al., 2004; Demirel et al., 2009; Kratzert et al., 2018), runoff (Ali et Shahbaz, 2020), or water level (Seo et al., 2015).

Regardless of the type of model implemented (i.e., conceptual, physically-based, or ML approaches), decisions surrounding how watershed heterogeneity is represented need to be made; primarily dependent on the dominant hydrological process being modeled or forecasted. Global models, such as the family of GR models (Coron et al., 2017; Michel, 1983), consider

the watershed as a single unit whereas, semi-distributed models divide the watershed into hydrological units that are considered homogeneous; for example, relative homogeneous hydrological units (RHHU) in HYDROTEL (Fortin et al., 2001) and hydrological response units (HRU) in the Soil and Water Assessment Tool model (Arnold et al., 1998). Finally, fully distributed models subdivide the watershed into a grid, which is usually regular, such as TOPMODEL (Beven et Kirkby, 1979) and WRF-Hydro (Viterbo et al., 2020). Moulin (2009) and Oddos (2002) highlight that there is not a clear advantage in using one spatial distribution over another. For ML modelling, the user should decide on the spatial distribution of the model based on the available data and the application the model will be used for. For example, Chen et al. (2019) applied a fully distributed model to predict water level where ANN inputs were remotely sensed, satellite-gridded data from CHIRPS, GLDAS-2, and TRMM-V7.

In this study, we investigate different means to represent the watershed hydrological state in an ANN model used for short-term hydrological forecasts related to runoff events triggered by rainfall alone. Specifically, we first aimed to understand how current soil moisture at different depths and streamflow affect short-term streamflow forecasts by assessing the performance of an ANN rainfall-runoff model using different combinations of hydrometeorological inputs. Then, we examined how global and spatialized inputs affect ANN model performance. To do so, we generated a virtual hydrological environment with a semi-distributed hydrological model simulating watershed state variables and the hydrological response of two real watersheds under real meteorological forcings. The simulated hydrometeorological observations (i.e., outputs from the semi-distributed hydrological model) were then used as inputs—using different combinations and spatial configurations—to the ANN model. We found that hydrological forecasts are better across a 7-day forecast window when combining streamflow and soil moisture as watershed state variables inputs instead compared to forecasts made using them separately as inputs. Moreover, we found that considering the spatial heterogeneity of soil moisture improved forecasting compared to a global model.

4.4. Materials and methods

4.4.1. Study area

This study was conducted using two watersheds in the northeastern United States: the Susquehanna watershed, mainly in New York and Pennsylvania, and the Androscoggin watershed, primarily located in Maine (Figure 4.1). The Susquehanna watershed is the larger of the two, with an area of 71.225 km². The Susquehanna River is the longest in the New England region, originating in the Allegheny Plateau and draining into the Chesapeake Bay on the Atlantic Ocean. The Susquehanna River is relatively flat, spanning approximately 360 m in elevation, with its maximum elevation at the Ostego Lake headwater located in the northeast of the watershed. Land use across the Susquehanna watershed is diverse, where 59% of the watershed area is forested, 31.5% is agricultural lands, 6.5% is rocks and urbanized areas, and 3% is wetlands. In contrast, the Androscoggin watershed is relatively small, with an area of 8.935 km². The Androscoggin River has comparatively elevation, spanning approximately 379 m in elevation, with its maximum elevation located along the western border of the watershed. The Androscoggin River drains into Merrymeeting Bay on the Atlantic Ocean. The Androscoggin watershed is primarily forested, with forests covering 83.5% of the watershed area. Other land covers are wetlands, rocks, and urbanized soils, and agricultural lands representing 8.5%, 8.5%, and 3.5% of the total watershed area, respectively. The United States Geological Survey (USGS) has streamflow stations located close to the outlets of both watersheds (as indicated by the red triangles in Figure 4.1).

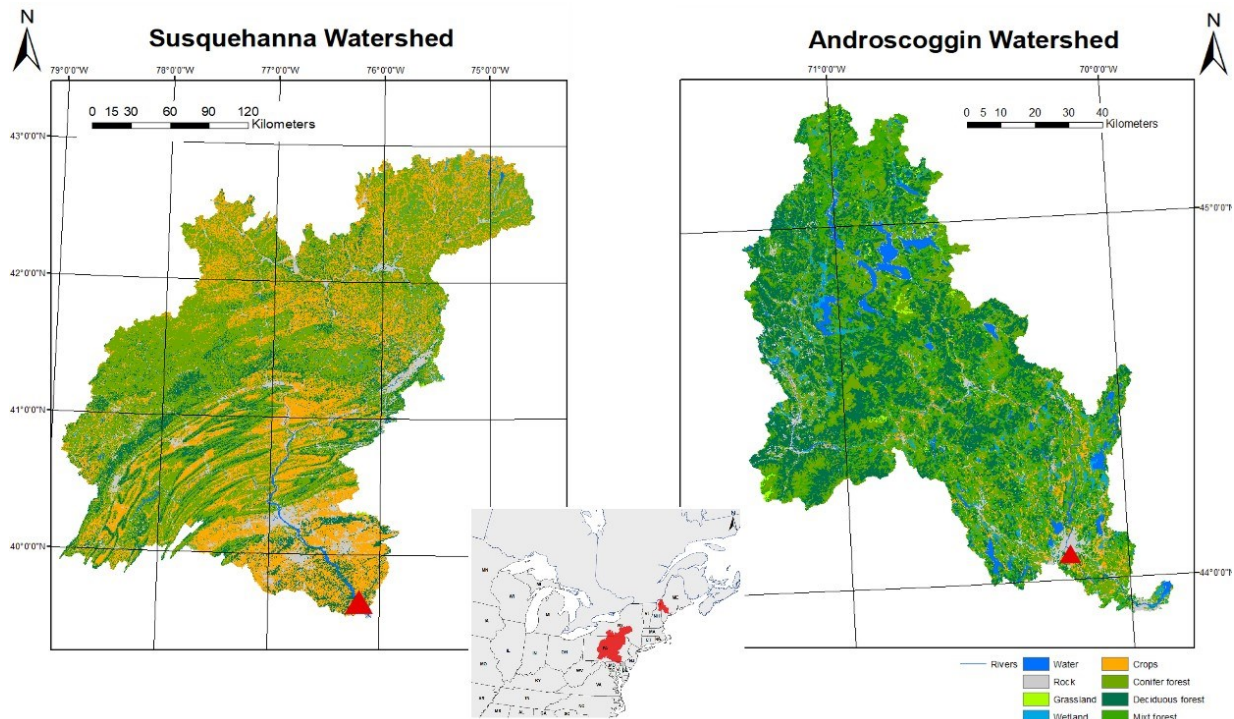


Figure 4.1 – Land cover of Susquehanna (a) and Androscoggin (b) watersheds. Red triangles indicate the location of the United States Geological Survey (USGS) streamflow stations used (reference number 1,578,310 and 1,059,000 for the Susquehanna and the Androscoggin watersheds respectively).

The climatic and hydrological regimes of both watersheds are typical of northern watersheds. Heavy spring floods are the result of large volumes of meltwater following cold and snowy winters, while summer and fall floods are mainly the results of heavy precipitation and storms. Typical of medium to large watersheds in northern latitudes, the spring flood is more significant than the summer and fall floods for both watersheds—as visually evident in the mean annual streamflow hydrographs derived from the USGS streamflow stations (Figure 4.2). The size of each watershed largely explains the differences in streamflow (Table 4.1), where the Susquehanna watershed is about eight times bigger than the Androscoggin watershed and has a maximum streamflow of 2.828 m³/s compared to Androscoggin’s maximum streamflow of 516 m³/s.




Figure 4.2 – Mean annual streamflow for (a) Susquehanna and (b) Androscoggin watersheds, generated with datasets covering 47 years (1969–2015).

Table 4.1 – Return streamflow for four specific return periods: 2, 10, 25, and 100 years for the two watersheds, generated with datasets covering 47 years (1969–2015).

<i>Watershed</i>	<i>Q2 (m³/s)</i>	<i>Q10 (m³/s)</i>	<i>Q25 (m³/s)</i>	<i>Q100 (m³/s)</i>
<i>Androscoggin</i>	<i>161</i>	<i>424</i>	<i>556</i>	<i>751</i>
<i>Susquehanna</i>	<i>939</i>	<i>2772</i>	<i>3695</i>	<i>5059</i>

4.4.2. Hydrometeorological inputs

We conducted this study in a virtual hydrological environment. Consequently, the time-series data sets used as ANN inputs do not contain any missing data or outliers and have a similar level of confidence. Inputs to the ANN model were derived from HYDROTEL, a deterministic model (Fortin et al., 2001), as described below.

We chose to use HYDROTEL to generate ANN inputs for two main reasons, (i) HYDROTEL is a semi-distributed model and, therefore, allows us to explore the possibilities of how spatial discretization of model inputs affects ANN model performance and (ii) the simulation option BV3C (Bilan Vertical à 3 Couches, in English: Three-Layer Vertical Budget) within HYDROTEL, presented below, models the vertical water budget and thus allows us to incorporate soil moisture ‘observations’ at various depths as input to the ANN.

HYDROTEL is a semi-distributed hydrological model that simulates a large set of hydrological processes across discrete spatial units, called RHHU, which collectively represent the watershed of interest. RHHUs are characterized as areas with relatively homogeneous land cover and soil

properties that are drained by one river segment, or reach. PHYSITEL uses different layers of physiographic information, including: soil type, land cover, and topography, to first determine the drainage network of watersheds and subsequently discretize watersheds into RHHUs (Fortin et al., 2001). Using PHYSITEL, we defined 1 025 and 403 RHHUs for the Susquehanna and Androscoggin watersheds, respectively.

HYDROTEL has six internal sub-models that offer different simulation options (Table 4.2). Requiring only three meteorological inputs (precipitation, minimum temperature, and maximum temperature), HYDROTEL simulates 23 outputs at a daily timestep and across all RHHUs (outputs include: snow, soil moisture at different soil depths, evapotranspiration, inflow, etc.) or river reaches (outputs include: upstream and downstream streamflow). For each sub-model, we chose one simulation option to generate hydrometeorological observations (i.e., the HYDROTEL outputs) that were subsequently used as inputs to the ANN model for both the Susquehanna and Androscoggin watersheds (Table 4.2; the selected simulation options are bolded). One of our motivations for using HYDROTEL is the simulation option BV3C in the vertical water budget sub-model, as it incorporates infiltration and vertical flows in the soil column (Figure 4.3). Briefly, BV3C divides the soil column into three layers (Z_1 , Z_2 , and Z_3 in Figure 4.3). The first layer represents a thin soil layer at the soil surface that controls infiltration, the second layer is associated with interflow (Q_2 in Figure 4.3), and the third layer simulates base flow (Q_3 in Figure 4.3) (Fortin et al., 2001). This vertical water budget is computed individually for each RHHU. Soil moisture and evapotranspiration are then available for the three layers (θ_1 , θ_2 , and θ_3 , and ETR_1 , ETR_2 , and ETR_3 , respectively). More details can be found by interested readers on Figure 4.3 and reading (Fortin et al., 2001).

The Thiessen polygon approach had been selected as the simulation option for the interpolation of precipitation. The watershed area is then divided based on polygons of influence of each precipitation station; any point in a polygon is closer to the station associated to the polygon than any other stations. The modified degree-day simulated snowmelt using temperature and precipitation to approximate energy-budget based on meteorological inputs of the HYDROTEL models and on geomorphological information like slope, surface orientation, and land use. The evapotranspiration is defined with the Hydro-Québec option that is relatively simple, requiring only maximal and minimal temperatures as input. The kinematic wave equation describes how

the water runoffs at the surface based on the vertical water budget and RHHU spatial discretization. Finally, the modified kinematic wave equation was used to simulate channel routing. This option permits to consider the geometry of the hydrological reaches (Table 4.2).

Table 4.2 – Summary of HYDROTEL’s defined sub-models and associated simulation options. Simulation options used in this study to generate hydrometeorological ‘observations’ are bolded.

<i>Sub-Models</i>	<i>Simulation Options</i>
<i>Interpolation of precipitation</i>	<i>Thiessen polygon</i> <i>Weighted mean of nearest 3 stations</i>
<i>Snowmelt</i>	<i>Modified Degree-day</i>
<i>Evapotranspiration</i>	<i>Thornthwaite</i> <i>Linacre</i> <i>Penman</i> <i>Priestley-Taylor</i> <i>Hydro-Québec</i>
<i>Vertical water budget</i>	<i>CEQUEAU</i> <i>Three-Layer Vertical Budget (BV3C)</i>
<i>Surface and subsurface runoff</i>	<i>Kinematic wave equation</i>
<i>Channel routing</i>	<i>Modified kinematic wave equation</i> <i>Diffusive wave equation</i>

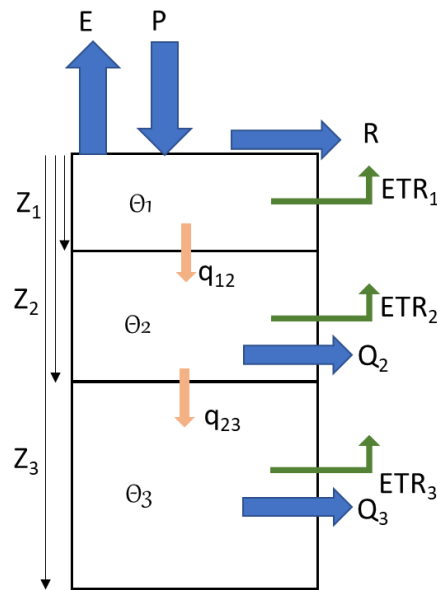


Figure 4.3 – Schematic representation of BV3C simulation option for vertical water budget in HYDROTEL. The thicknesses of the 3 soil layers are represented by Z_1 , Z_2 , and Z_3 , and the associated soil moisture are θ_1 , θ_2 , and θ_3 , and the relative real evapotranspiration ETR_1 , ETR_2 , and ETR_3 , respectively. Total evaporation, precipitation and surface runoff are designed by E , P , and R , respectively. The interflow and the baseflow are represented by Q_2 and Q_3 , and the baseflow, respectively.

Prior to generating the hydrometeorological ‘observations’, which were used as input data to the ANN, we calibrated HYDROTEL for each watershed using meteorological inputs and observed streamflow data extracted from the USGS database. Model calibration for the Susquehanna and Androscoggin watersheds resulted in soil layer thicknesses of 10 cm, 40 cm, and 50 cm for layers 1, 2, and 3 respectively for Susquehanna; and of 10 cm, 20 cm, and 60 cm for Androscoggin. HYDROTEL was then run over 19 years (1997–2015), including 3 years of warm-up. We selected four HYDROTEL output variables (i.e., the hydrometeorological observations) to be used as input data to the ANNs: total precipitation (solid and liquid), streamflow at the watershed outlet, and soil moisture in the first two layers of soil. Going forward, we refer to the first two layers of soil as either surface soil moisture (i.e., the depth of the first soil layer; 10 cm for both watersheds) or deep soil moisture (i.e., the sum of the depth of the first two layers of soil; top 50 cm and 30 cm for the Susquehanna and Androscoggin, respectively).

It is known that soil moisture (Cenci et al., 2016) and streamflow (Abaza et al., 2014) affect short-term hydrological forecasts. Here the objective is to decipher how ML models can effectively represent this causal relationship. To that end, we ran the ANN model using four different combinations of the hydrometeorological observations as input variables (Table 4.3). The ANN streamflow forecast was undertaken on a daily timestep over a 7-day window. We classified ANN inputs in two categories: meteorological variables—precipitation taken at the forecast horizon (D) and taken one day before (D-1), and the watershed state variables—antecedent streamflow, surface soil moisture, and deep soil moisture taken 1 day before the forecast horizon (D-1) (Table 4.3 – Combinations of variables defined as artificial neural network (ANN) inputs.). The meteorological variables represent the incoming water at the forecast day D, while the watershed state variables represent the water already present in the watershed. Here, streamflow is considered as a watershed state variable, although strictly speaking it should be categorized as a flux. To remove the arbitrary effect of similarity between objects (Riad et al., 2004), including those caused by differences in units between variables, that can confuse ANN models and reduce performance, we normalized the hydrometeorological observation input data before running the ANN model. The normalization process we applied is based on the standardization formula (i.e., subtracting the dataset mean from each element of the dataset and then dividing the difference by the dataset standard deviation).

Table 4.3 – Combinations of variables defined as artificial neural network (ANN) inputs.

<i>No. and Name</i>	<i>Watershed State Variables</i>	<i>Meteorological Variables</i>
	<i>At Day D-1</i>	<i>At Day D and Day D-1</i>
<i>1—QP</i>	<i>Downstream Streamflow</i>	<i>Precipitation</i>
<i>2—SMP</i>	<i>Surface Soil Moisture</i>	<i>Precipitation</i>
<i>3—dSMP</i>	<i>Deep Soil Moisture</i>	<i>Precipitation</i>
<i>4—QSMP</i>	<i>Downstream Streamflow</i>	<i>Precipitation</i>
	<i>Surface Soil Moisture</i>	

4.4.3. Artificial Neural Network (ANN) model

ANN models are drawn from the operating philosophy of the human brain. This type of model builds on relationships within a data set, connecting inputs (i.e., feature variables) and output(s) (i.e., variable(s) of interest) (Oyebode et Stretch, 2018). ANN models are composed of at least three layers: the input, the hidden, and the output (Figure 4.4). The input layer introduces the inputs used by the ANN model with one independent node, commonly referred to as a neuron, for each feature variable. Similarly, the output layer is based on one independent node, or neuron, for each variable of interest. The hidden layer establishes relationships between the inputs and outputs, where the number of nodes, or neurons, defines the number of relationships that are prescribed. Depending on the complexity of the problem, more than one hidden layer can be chosen. However, Riad et al. (2004) found that multiple hidden layers can always be simplified to a single hidden layer, as long as it has an appropriate number of nodes. The number of nodes in the hidden layer are defined by the user and the appropriate number is dependent on the model's complexity (Stathakis, 2009). Defining the number of nodes is undertaken in a pre-analysis, where the best ANN model is that which maximizes model performance and minimizes the number of nodes in the hidden layer (Sheela et Deepa, 2013). The ANN models can be structured with a single hidden layer, this configuration is a good compromise between model efficiency and complexity (Dawson et Wilby, 2001). Moreover, configuring ANN models with one hidden layer reduces the risk of over parametrization and, therefore, should improve model robustness (Karsoliya, 2012; Liu et al., 2007).

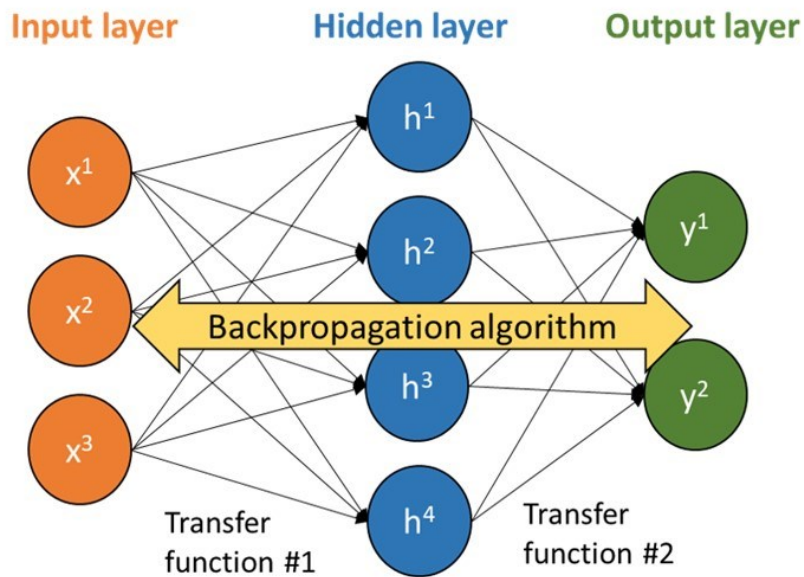


Figure 4.4 – Schematic representation of a three-layer back-propagated ANN with 3 inputs, 4 hidden neurons, and 2 outputs.

At each node, the ANN model makes connections across the layers through the attribution of weights and biases, where weights represent the strength of the connection and biases introduce noises in the relation (Kneale et al., 2001). More specifically, the information that enters a node is processed by a specific weight and activation function, in addition to a bias. Weights and biases are initially randomly defined by the ANN model and then optimized by a backpropagation algorithm, an inherent process of the ANN model. We defined the activation functions and the backpropagation algorithm by trial and error analysis. When configuring our ANN model, we compared two backpropagation algorithms that have been found to perform well for ANN modelling of non-linear relationships: Bayesian regularization and Levenberg–Marquardt (Kayri, 2016; Payal et al., 2013). After optimization (Sheela et Deepa, 2013), we selected Bayesian regularization as the backpropagation algorithm. For the activation functions, we compared a total of 10 functions in a preliminary analysis (results not shown here) and (Stathakis, 2009) selected the hyperbolic tangent sigmoid as the activation function between the input and hidden layer and the symmetric saturating linear functions between the hidden layer and the output layer.

4.4.4. Methodology

Training and validation periods

To train and validate our ANN model, we used 16 years of data from 2000 to 2015 (i.e., the period HYDROTEL was run minus the three warm-up years). We defined the training period as 15 years and the validation period as the remaining year and repeated this process 16 times so that each year was the validation period, based on the leave-one-out process of validation which is part of the cross-validation approach. We adopted the cross-validation approach because of its advantages of being able to assess the robustness and generalization power of an ANN model (Bergmeir et al., 2018).

In this study, we only examined the summer season, where we defined summer as 1 May to 31 October of each year.

Updating watershed state variables

In the forecast chain, whose general structure is detailed in Figure 4.5, it is necessary to update the watershed state variable along the time. At each timestep, the watershed state variable is forecasted for the next timestep using the ANN model, and this output is used as the input for the next ANN model timestep. The forecast is undertaken over a short-term horizon, defined from 1 to 7 days ahead. Note that the virtual environment operates in a hindcast mode, where observed daily precipitation is integrated as a meteorological forecast (referred as *Meteo* in Figure 4.5).

The outputs of the ANN model are dependent on the combination of input variables used (see Table 4.2). For example, the ANN model using only streamflow as the watershed state variable (1-QP) only has the streamflow forecast as the output. The ANN model with surface or deep soil moisture as the watershed state variable (2-SMP or 3-dSMP respectively) has both the streamflow forecast (referred as *Streamflow* in Figure 4.5) and an update of surface or deep soil moisture (referred as *Wat. State* in), which will be used as input for the next ANN model timestep, as output variables (that is exactly the forecast chain schematized Figure 4.5). Finally, the ANN model using both streamflow and surface soil moisture as the watershed state variables

(4-QSMP) is an extension of the scheme explained above; however in this case, both outputs (i.e., the streamflow forecast and the updated surface soil moisture) are new inputs to the next ANN model timestep.




Figure 4.5 – Schematic representation of the forecast chain used (example for forecasts one and two days in advance and exactly represented 2-SMP and 3-dSMP with update of watershed state variable at each time step). The tilde represents outputs of the ANN model. The index represents the forecast horizon day, with 0 the day of forecasting.

Spatial distribution of inputs

To examine how the spatial distribution of input data affects the ANN model performance, we ran the ANN model with either global, fully distributed, or single pixel-based input data. For the global dataset, we averaged each of the four hydrometeorological observations (i.e., the ANN input variables) across all RHHUs. Regardless of the watershed, there is the same number of inputs as the number of variables of each combination, that means 3 for 1-QP, 2-SMP, and 3-dSMP and 4 for 4-QSMP (see column called Average, Table 4.4). This reduces the complexity of the input data but loses the spatial detail. For the fully distributed dataset, we first defined a regular grid ($28 \times 28 \text{ km}^2$), in which 158 grid cells covered the Susquehanna and 28 grid cells covered the Androscoggin watershed, and then assigned each grid cell the average value of each of the four hydrometeorological observations of the overlapping RHHUs. We defined the size of the grid cells to be close to the spatial resolution of passive microwave satellites such as Soil Moisture and Ocean Salinity (SMOS) and Soil Moisture Active and Passive (SMAP), developed by the European Space Agency and the National Aeronautics and Space Administration, respectively. We did not run the ANN model in which the spatial distribution of the input data was the RHHUs because of the large number of RHHUs in both watersheds would significantly increase the complexity of the model and, therefore, the computer resources required to run it. Due to the same constraints, we decided only to assess the spatially distributed input data (i.e.,

regular grid configuration) for the Androscoggin watershed, resulting in a number of inputs equal to 84 (3 inputs over 28 grid cells) for the combinations 1-QP, 2-SMP, and 3-dSMP and 112 (4 inputs over 28 grid cells) for 4-QSMP (see column called Regular Grid, Table 4.4). Moreover, because information from all grid cells may cause some redundancy in the model inputs, we further examined the ANN model performance for the Androscoggin watershed when input data were at the single-pixel scale. To do so, we successively ran the ANN model using each of the 28 grid cells as inputs and compared the model performance to the ANN model where the inputs were averaged across all 28 grid cells. To determine if some grid cells contain more useful information than others for the ANN model, we compared model performance across each grid cell. Only one combination of watershed state variables (3-SMP, see Table 4.3) was used to assess the effect of the three spatial distributions of inputs. We chose to use surface soil moisture as the watershed state input variable because soil moisture is a spatialized input. Indeed, there are several satellite products that offer soil moisture observations in the first centimeters of soil such as Sentinel-1, and *SMOS*. By only changing spatial discretization, we ensure that there is no other influence on the ANN forecast model.

Table 4.4 – Number of inputs for the ANN model depending on the combination of variables and the spatial distribution. With a regular grid, information is only given for the Androscoggin watershed (An.).

<i>No. and Name</i>	<i>Average</i>	<i>Regular Grid</i>
<i>1—SMP</i>		
<i>2—dSMP</i>	3	84 (An.)
<i>3—QP</i>		
<i>4—QSMP</i>	4	112 (An.)

Evaluation criteria

To evaluate streamflow forecasts across the different combinations of hydrometeorological observations (i.e., input variables) and spatial distribution of inputs to the ANN model, we calculated the Nash–Sutcliffe efficiency (NSE). NSE is a hydrologic-oriented metric that quantifies the goodness of fit between observed and simulated hydrographs, where an NSE of 1 is equivalent to a perfect forecast and a value of 0 means that the model has the same predictive skill as taking the average value of observed streamflow. Positive NSE values mean the forecast model is better than climatology, and negative NSE values mean the forecast value is worse than climatology. NSE is particularly sensitive to extremely high flow values.

4.5. Results

4.5.1. Preliminary analysis: definition of the number of neurons in the hidden layer

To determine the optimal number of neurons in the hidden layer of the ANN model, we compared NSE values from models with up to 12 neurons in the hidden layer for both watersheds (Figure 4.6). In brief, we aggregated the NSE results across the 1 to 7-day forecast horizon and for the 16 different years used in cross-validation from the ANN model in which surface soil moisture was the input watershed state variable (2-SMP, Table 4.3). Results are the NSE values for the two watersheds (Androscoggin and Susquehanna in Figure 4.6 a and b, respectively) with a distinction between training (blue boxplots) and validation (red boxplots). The optimal number of neurons in the hidden layer should maximize model robustness, that is the difference in NSE values between training and validation steps should be minimized in addition to minimizing the dispersion of NSE values, defined as the difference between the 5th and the 95th percentiles (represented by tight boxplots in Figure 4.6).

For the training step, model performance for both watersheds increased with the number of neurons in the hidden layer, with large improvements across 1 to 4 neurons (see blue boxplots in Figure 4.6). Independent of the number of neurons, dispersion of NSE values for the training step for the Androscoggin watershed was constant (see blue boxplots in Figure 4.6a). In contrast,

dispersion for the training step was more variable for the Susquehanna watershed (see blue boxplots in Figure 4.6b). There was a large increase in the dispersion from 1 to 2 nodes in the hidden layer, followed by a decrease and a stabilization from 3 to 9, and finally an increase from 10 to 12. For the validation step, model performance from the Androscoggin watershed initially improved as the number of neurons increased from 1 to 7 (median NSE increased from 0.65 to 0.8 in training and 0.65 to 0.7 in validation), followed by a slow decrease in performance from 7 to 12 neurons (see red boxplots in 6a). For the Susquehanna watershed, model performance of the validation step initially decreased as the number of neurons increased from 1 to 2 neurons (median NSE decreased from 0.425 to 0.25), followed by an improvement and stabilization from 3 to 10 neurons (median NSE approximately 0.3) before performance declined again (see red boxplots in Figure 4.6b). While the dispersion in the validation step was larger than the training step, dispersion in the validation step is quite similar for both watersheds.

Taken together, the robustness of the ANN model was similar regardless of the number of neurons in the hidden layer. In general, the ANN model was more robust for the Androscoggin watershed than for the Susquehanna watershed (i.e., the differences between the median values in training and in validation are smaller for the Androscoggin watershed). The difference in the training and validation results is minimized for both watersheds when a single neuron is in the hidden layer for the two watersheds. However, the dispersion is lower when more neurons are used, in particular for the training step. We concluded that six neurons in the hidden layer is a good compromise to have a robust ANN model for both watersheds. This amount was selected for the ANN structure for the remainder of this work.

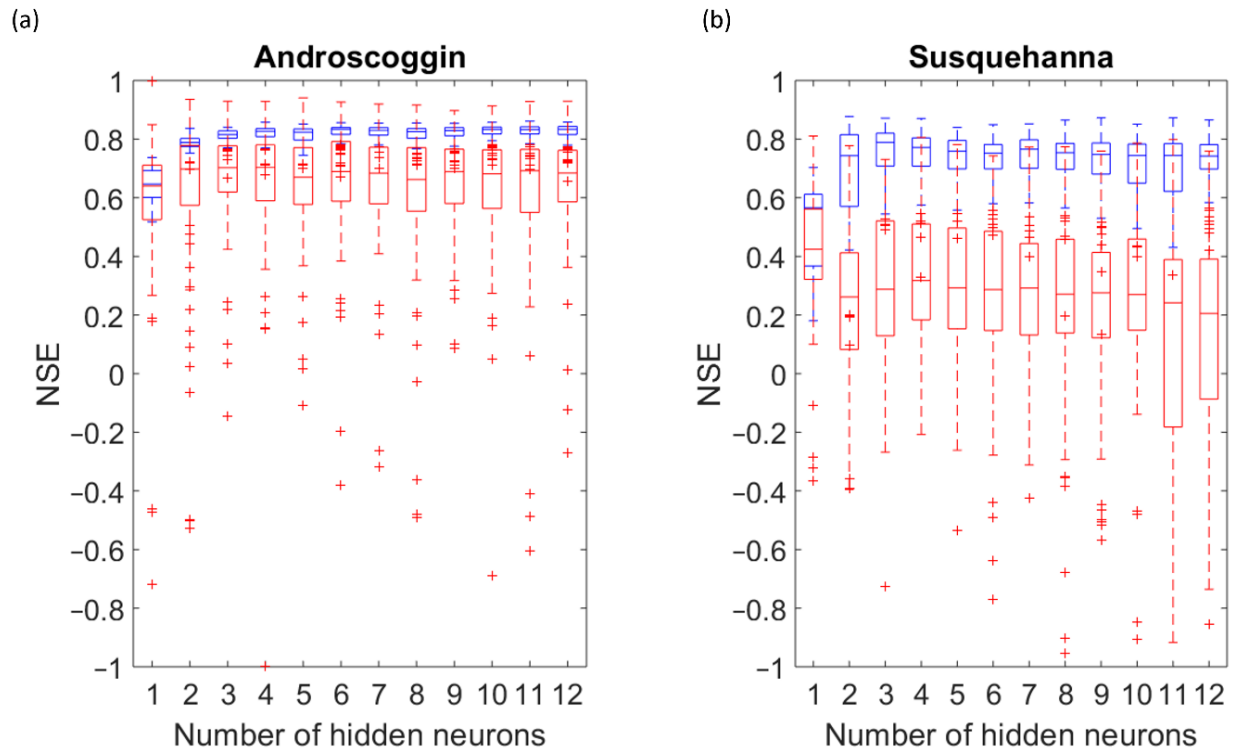


Figure 4.6 – Evaluation of the number of neurons in the hidden layer for (a) the Androscoggin and (b) the Susquehanna watersheds. Blue boxplots are relative to the training step, while red are for the validation step. Each boxplot is plotted with the 16 summers used in the cross-validation process.

4.5.2. Forecast evaluation according to horizon forecast and inputs

We found that the ANN forecast model performance differed across the different combinations of inputs. Model performance was more consistent during the training period but was more variable across the 16 summers successively used as validation period. Therefore, we decided to focus analyses on two specific years of validation, 2009 and 2010—defined as a wet and dry summer respectively. To validate the ANN model for each of these two summers, it was successively trained with the 15 remaining summers (2000 to 2008 + 2010 to 2015, and 2000 to 2009 + 2011 to 2015, with 2009 and 2010 in validation, respectively).

Using antecedent streamflow as the watershed state variable for the model input (1-QP, see red lines in Figure 4.7 to Figure 4.12) the ANN forecast model in validation was highly accurate up to 3 days for the Androscoggin watershed for both wet and dry years. For the 1-day forecast,

streamflow was almost perfectly forecasted ($NSE > 0.85$ in both training and validation steps) and both high and low flows were well estimated (Figure 4.9 and Figure 4.11). Tables 4.5 and 4.6 shows NSE values of 0.928 and 0.884 when summer 2009 was used in validation, and 0.924 and 0.928 when summer 2010 was used in validation, for training and validation steps respectively. For both wet and dry years, streamflow was well predicted for the entire hydrograph for a 1-day forecast (see Figure 4.10 and Figure 4.12, respectively). The accuracy of the ANN forecast model declines beyond the 2-day forecast ahead, also referred to as $D + 2$, with a decrease in NSE of around 0.2 between $D + 1$ and $D + 7$ for the more accurate years (2000, 2003, 2005, 2007, 2012, and 2015). In $D + 3$, $D + 5$, and $D + 7$, streamflow forecasts deteriorated, in particular for high flows. The timing of peak flows was still well forecasted, but high flows were underestimated and small floods were overestimated—exemplified by September and October 2009 (see Figure 4.9) and summer 2010 (see Figure 4.11). This suggests that from $D + 4$ to $D + 7$, the forecast model puts too much weight on precipitation, resulting in overestimating the forecast flow. For summer 2010, the forecast became noisy starting three days in advance. The ANN forecast model had more difficulties forecasting streamflow during a dry summer as compared to a wet one; the decrease in NSE was greater for summer 2010 (from 0.928 to 0.122, 1- to 7-day forecasts, respectively) in comparison with summer 2009 (from 0.884 to 0.458, 1- to 7-day forecasts, respectively) (Table 4.5 and Table 4.6).

While the general trends were the same for both watersheds, the forecast was less accurate for the Susquehanna watershed when the ANN watershed state variable was antecedent streamflow. Model performance in the training step for $D + 1$ for the Susquehanna watershed was very similar to the Androscoggin watershed, but had slightly smaller NSE values (0.784 for summer 2009 and 0.828 for summer 2010). Similar to the Androscoggin watershed, there was a decrease in model accuracy across the 7-day window forecast in both training and validation, but for the Susquehanna watershed, NSE values were negative for forecasts beyond $D + 3$ in validation for both dry and wet summers (Table 4.5 and Table 4.6). The ANN model was less robust, in other words less homogeneous from year to year, for the Susquehanna watershed compared to the Androscoggin watershed for the 16 years used for the comparison, and overall the NSE values were smaller for the Susquehanna watershed.

In contrast with the ANN forecast model with antecedent streamflow as the watershed state variable, the forecast accuracy improved with an increasing forecast horizon when surface soil moisture was the watershed state variable used as the input to the ANN model (2-SMP, see blue lines in Figure 4.7 - Figure 4.12). For the first 2 days of the forecast horizon, the accuracy of the model was lower than when antecedent streamflow was used to describe the watershed hydrological state. Relative to this last combination of inputs, for the entire window from $D + 1$ to $D + 7$, the forecast gradually improved using surface soil moisture as the watershed state variable, mainly for high flows. For the summer 2009 validation, the model underestimates the higher flows (i.e., June, July, and end of October) and overestimates the mid-flows (i.e., September and beginning of October) until $D + 3$ but the high flow forecasts improve for $D + 5$ to $D + 7$. For the summer 2010 validation, there was also an improvement of the forecasts as the forecast horizon increases. NSE values were largest at $D + 1$ and $D + 5$ compared to $D + 1$ and $D + 7$, although there was an overall improvement from $D + 1$ to $D + 7$. This behavior was consistent across both watersheds, with a maximum NSE of 0.818 for $D + 3$ in validation for the Androscoggin watershed in 2009 and 0.555 for $D + 5$ in validation for the Susquehanna watershed in 2010. Finally, forecasts were better for summer 2009 than for summer 2010, which was also observed when using streamflow and precipitation as inputs to the ANN model.

Using deep soil moisture as the watershed state variable as the input the ANN forecast followed the same overall trend as when surface soil moisture was the watershed state variable; model performance improved as the forecast horizon increased (3-dSMP, see cyan lines in Figure 4.7 - Figure 4.12). However, the NSEs were lower (see Figure 4.7 and Figure 4.8) and the hydrographs were noisier (see Figure 4.9 and Figure 4.11 for Androscoggin and Figure 4.10 and Figure 4.12 for Susquehanna) when using deep soil moisture as the watershed state variable. Moreover, the ANN model was less robust when using deep soil moisture, in particular for the Susquehanna watershed. While using deep soil moisture, NSE was negative for all but one forecast horizon, see Table 4.5 for the Susquehanna watershed. Relative to the Susquehanna watershed, for the Androscoggin watershed, results were much accurate for the two summers analyzed, with a large improvement of the forecast from $D + 1$ to $D + 7$ in the validation step (NSE values of 0.489 to 0.824 for summer 2009 and from -5.375 to 0.628, with a maximum of 0.782 at $D + 3$, for summer 2010). The large negative NSE value at $D + 1$ for the Androscoggin

watershed in validation for summer 2010 cannot be easily explained, as subsequent NSE values across the forecast horizons were relatively close to each other. The difference between $D + 1$ and $D + 2$ was large, with a NSE value negative at $D + 1$ and positive at $D + 2$ for the worst summers in validation (2000, 2001, 2003, 2004, 2007, 2010, 2013, and 2015). For the Susquehanna watershed, the conclusions are similar, and the ANN model has lower NSE values beyond $D + 1$. In accordance with forecasts when antecedent streamflow and surface soil moisture were used as the watershed state input variables, streamflow was better forecasted for wet years than for dry years in validation for both watersheds (Figure 4.9 - Figure 4.12).

When streamflow and surface soil moisture was used in combination as ANN model inputs (4-QSMP, green lines of Figure 4.7 - Figure 4.12), NSE values were high in the first days of the forecast horizon and then decreased as the forecast horizon increased; however, this decline in performance was less pronounced compared to only using streamflow alone to describe the watershed state. This combination of inputs effectively is taking advantage of the strengths of both the variables used to describe the watershed state, that is streamflow offers better performance during the first forecast days ($D + 1$ to $D + 3$), while surface soil moisture improves the forecast at later forecast horizons ($D + 4$ to $D + 7$). In other words, the ANN model used the information from soil moisture to improve its forecast accuracy when compared to the forecast only using streamflow alone. Nevertheless, the trend in model performance for a few years more closely resembles model performance when using surface soil moisture alone to describe the watershed state (e.g., 2004 and 2014 for Androscoggin, and 2001 and 2011 for Susquehanna); NSE decreased between $D + 1$ and $D + 3$ and then improved beyond day 3. The ANN model performance using both streamflow and surface soil moisture differed between the two watersheds and between wet and dry summers (Table 4.5 and Table 4.6). For the Androscoggin watershed, the ANN was robust and had high NSE values for both the training and validation steps for 2009 (minimum NSE value was 0.783 at $D + 7$ in validation and maximum NSE value was 0.930 at $D + 1$ in training, see Table 4.5); moreover, the forecasted hydrograph closely resembled the observed hydrography during the entire summer season in 2009 (cyan line in Figure 4.9). In contrast, the ANN was less robust and had lower NSE values for the Susquehanna watershed; the NSE values in validation were either below or close to 0 beyond $D + 2$ and the

simulated hydrographs were noisy and differed significantly from observed hydrographs—peak flow events were both missed or amplified (cyan line in Figure 4.10 and Figure 4.12).

Table 4.5 – Nash–Sutcliffe efficiency (NSE) values for Susquehanna and Androscoggin for summer 2009, a relatively wet year, as validation period.

Watershed	Susquehanna				Androscoggin				
	Forecast Horizon	D + 1	D + 3	D + 5	D + 7	D + 1	D + 3	D + 5	D + 7
1-QP	train.	0.784	0.298	0.192	0.086	0.928	0.835	0.707	0.818
	valid.	0.696	-0.057	-0.328	-0.116	0.884	0.803	0.827	0.458
2-SMP	train.	0.716	0.767	0.765	0.812	0.792	0.837	0.843	0.769
	valid.	0.080	0.318	0.274	0.205	0.501	0.818	0.816	0.796
3-dSMP	train.	0.415	0.523	0.669	0.685	0.699	0.847	0.842	0.833
	valid.	-1.321	-0.369	0.175	-0.603	0.489	0.803	0.852	0.824
4-QSMP	train.	0.835	0.486	0.768	0.747	0.930	0.887	0.883	0.867
	valid.	0.567	-2.163	0.135	-0.215	0.873	0.834	0.844	0.783

Table 4.6 – NSE values for Susquehanna and Androscoggin for summer 2010, a relatively dry year as validation period.

Watershed	Susquehanna				Androscoggin				
	Forecast Horizon	D + 1	D + 3	D + 5	D + 7	D + 1	D + 3	D + 5	D + 7
1-QP	train.	0.828	0.550	0.195	0.132	0.924	0.846	0.829	0.810
	valid.	0.355	0.123	-0.114	-0.061	0.928	0.650	0.295	0.122
2-SMP	train.	0.723	0.791	0.849	0.541	0.814	0.833	0.824	0.767
	valid.	-1.914	0.207	0.555	0.344	-0.380	0.574	0.531	0.436
3-dSMP	train.	0.556	0.643	0.586	0.595	0.790	0.784	0.844	0.837
	valid.	0.828	0.550	0.195	0.132	0.924	0.846	0.829	0.810
4-QSMP	train.	0.355	0.123	-0.114	-0.061	0.928	0.650	0.295	0.122
	valid.	0.723	0.791	0.849	0.541	0.814	0.833	0.824	0.767

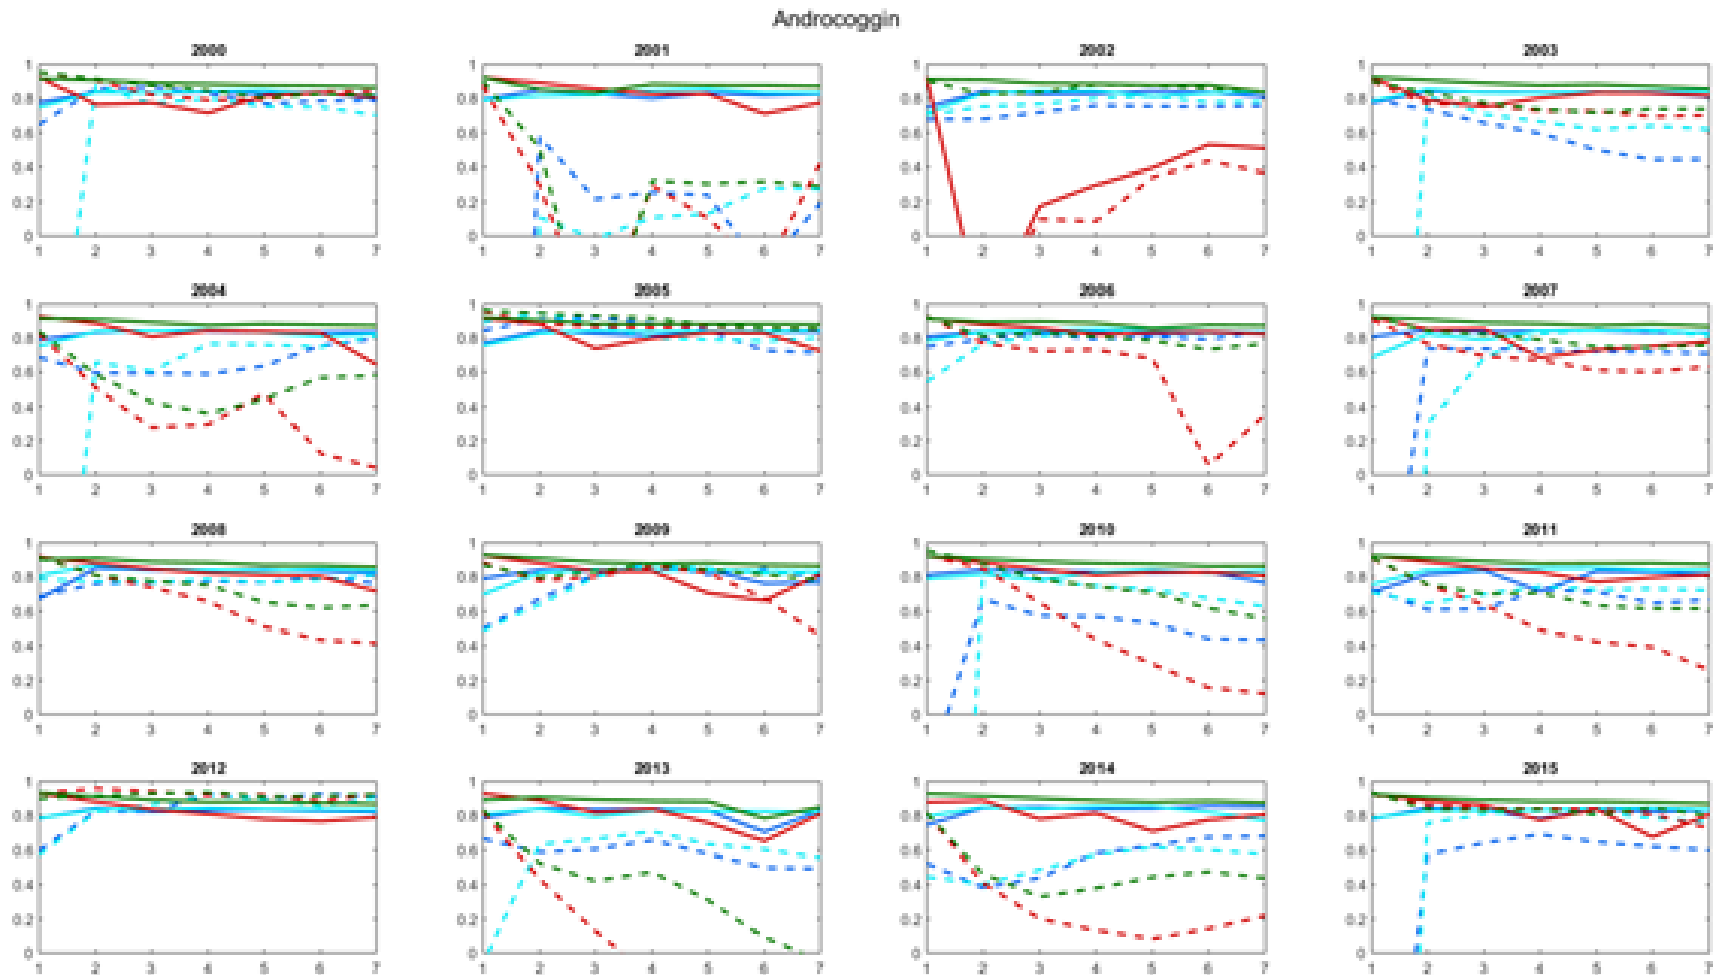


Figure 4.7 – Evolution of NSE across the 7-day forecast window for the Androscoggin watershed. The training step is in full line, while leave-one-out validation is in dotted line. QP results are represented in red, SMP in blue, dSMP in cyan, and QSMP in green. Each subplot corresponds to a specific step of our cross-validation approach with the year used in validation in sub-title.

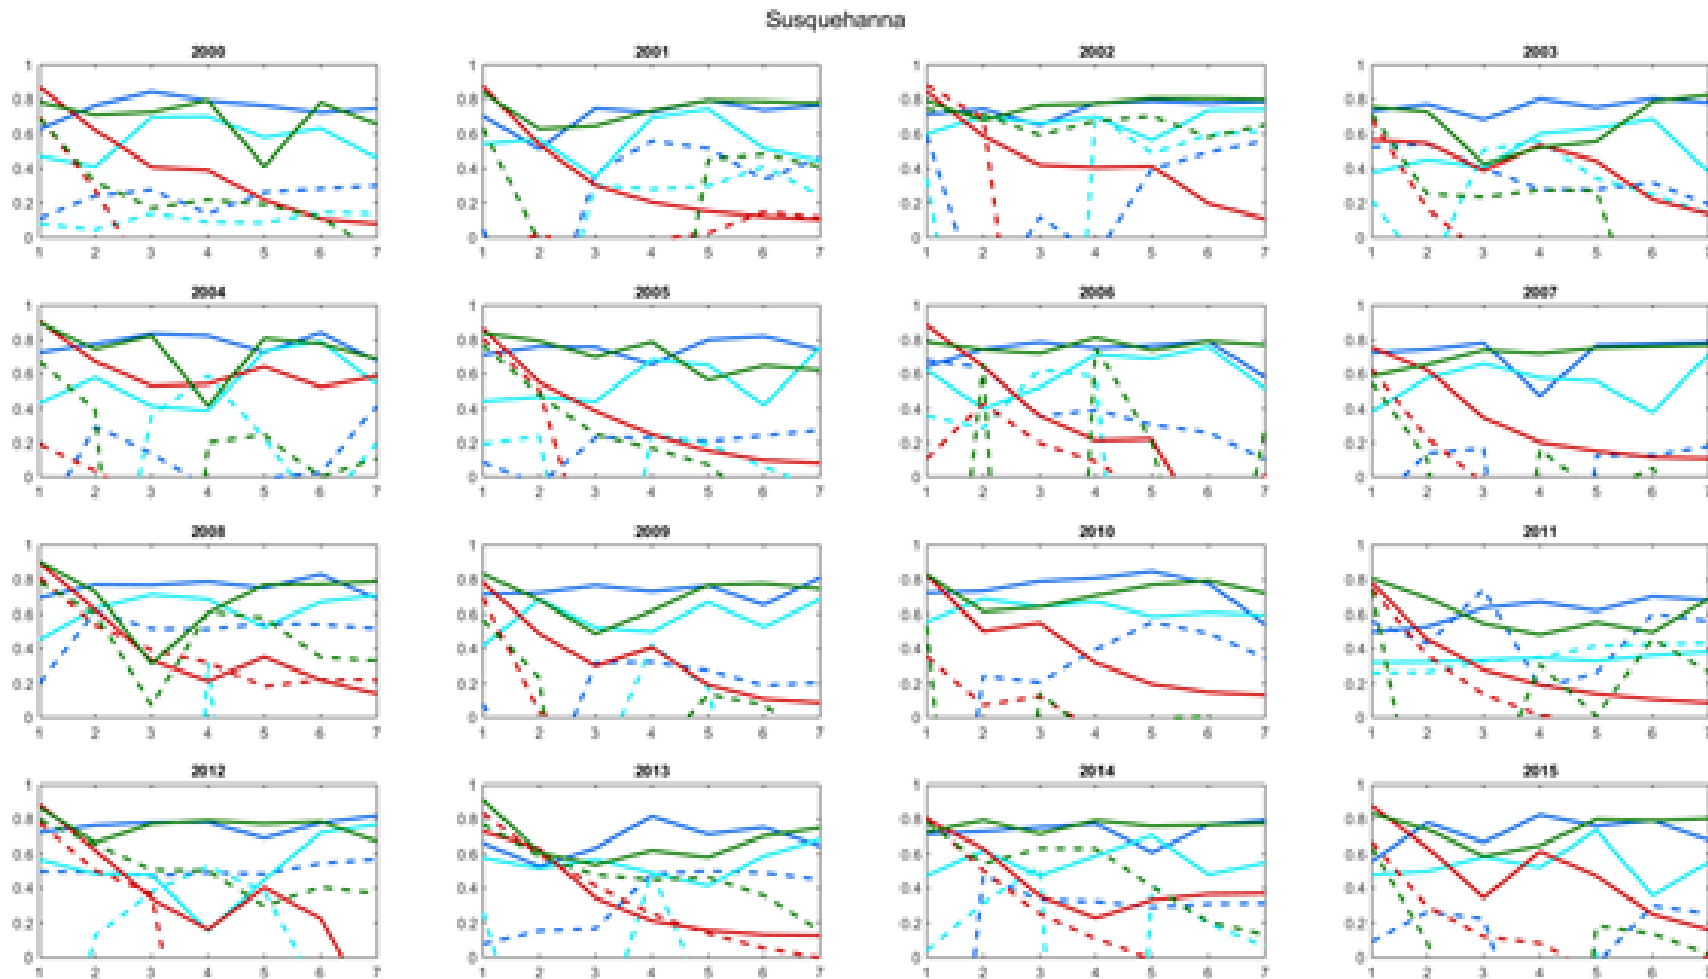


Figure 4.8 – Evolution of NSE across the 7-day forecast window for the Susquehanna watershed. The training step is in full line, while leave-one-out validation is in dotted line. QP results are represented in red, SMP in blue, dSMP in cyan, and QSMP in green. Each subplot corresponds to a specific step of our cross-validation approach with the year used in validation in sub-title.

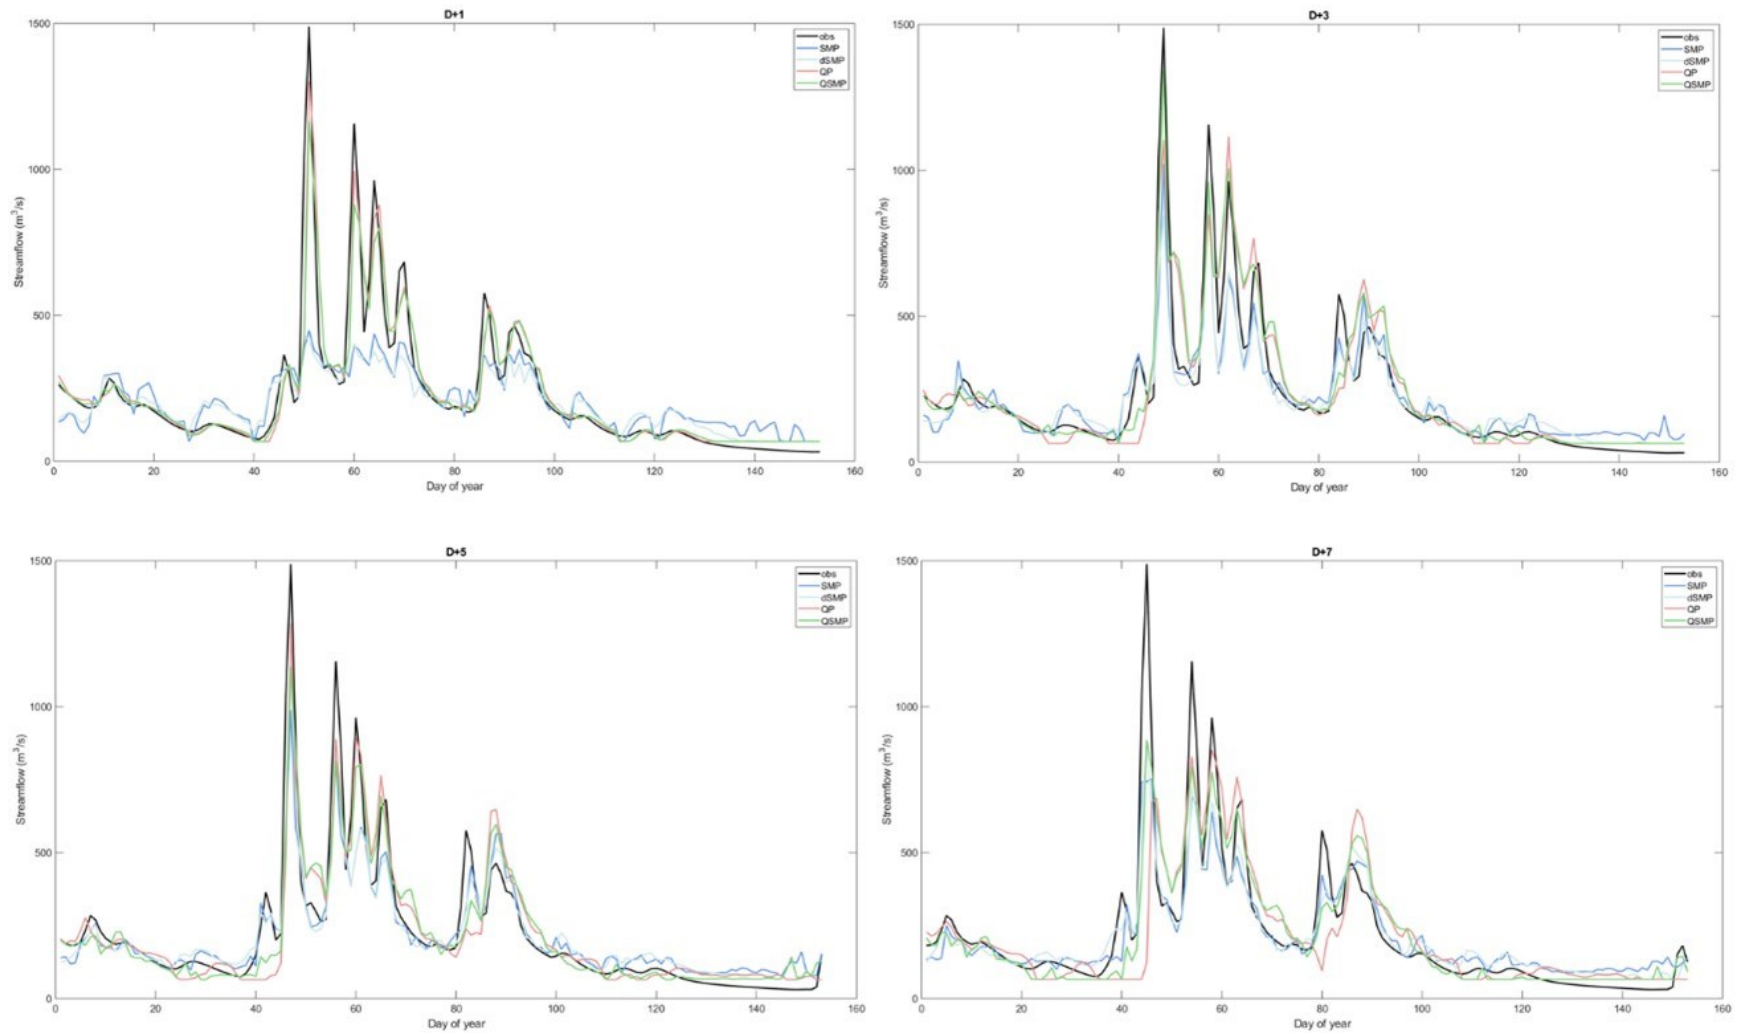


Figure 4.9 – Hydrographs for the Androscoggin watershed for summer 2009 (validation period) (a) 1, (b) 3, (c) 5 and (d) 7 days in advance.

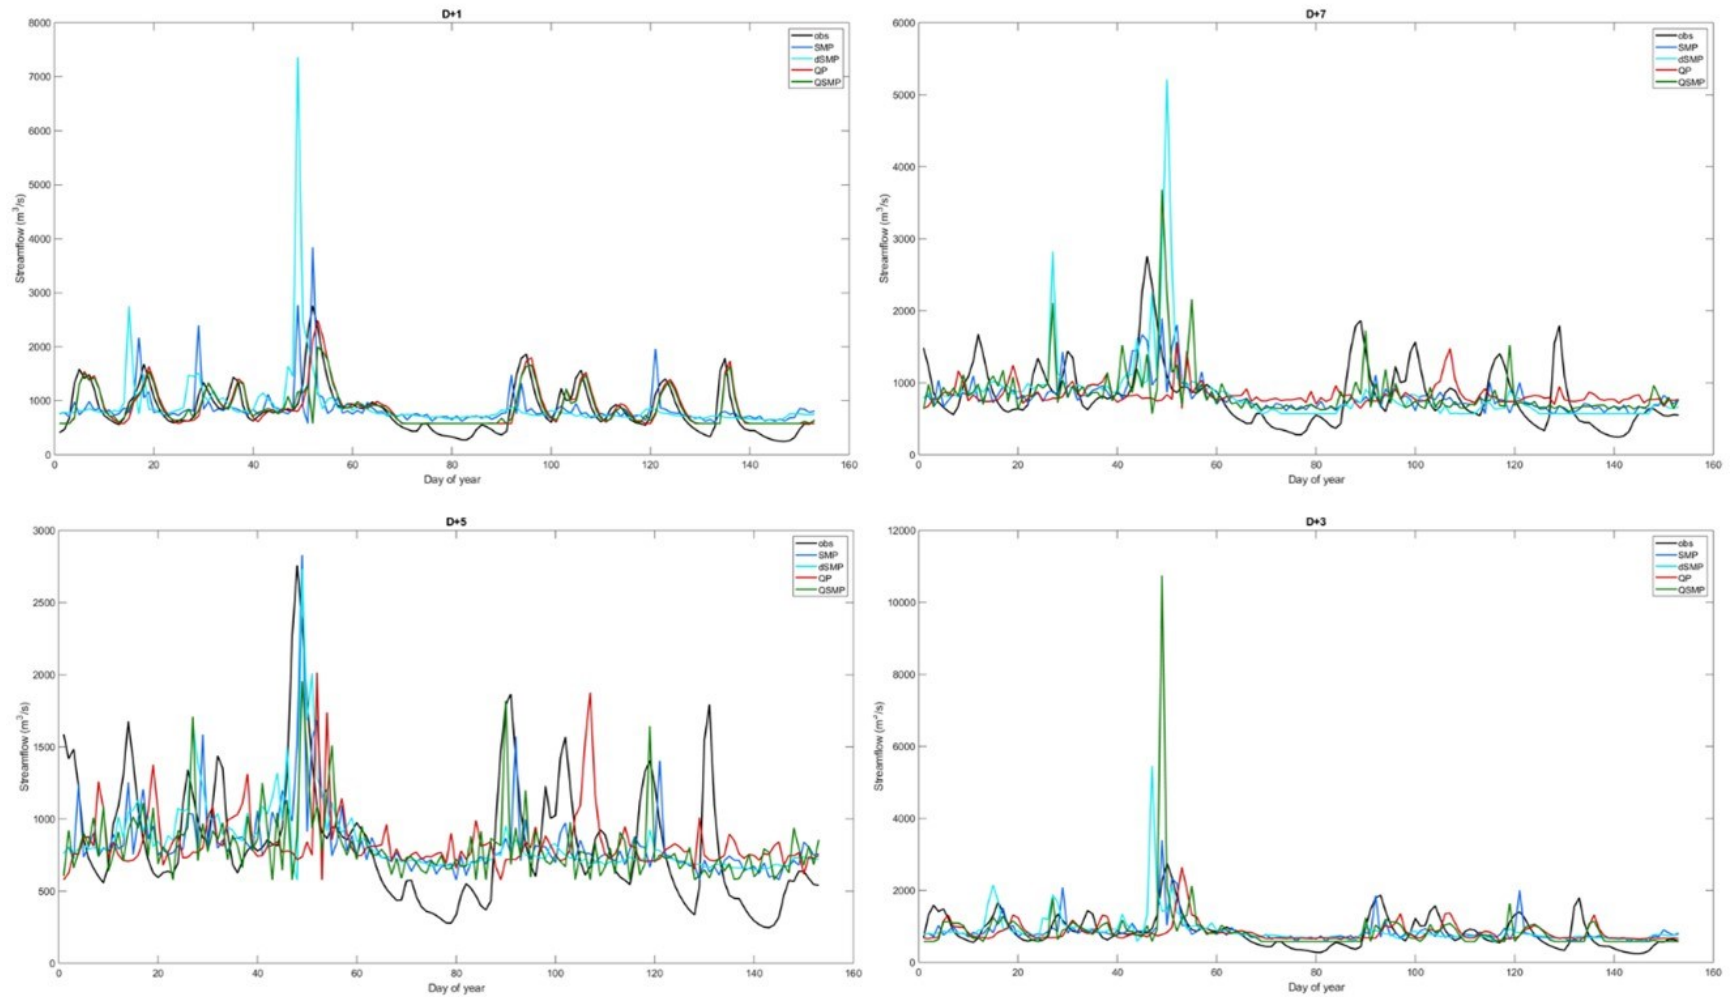


Figure 4.10 – Hydrographs for the Susquehanna watershed for summer 2009 (validation period) (a) 1, (b) 3, (c) 5 and (d) 7 days in advance.

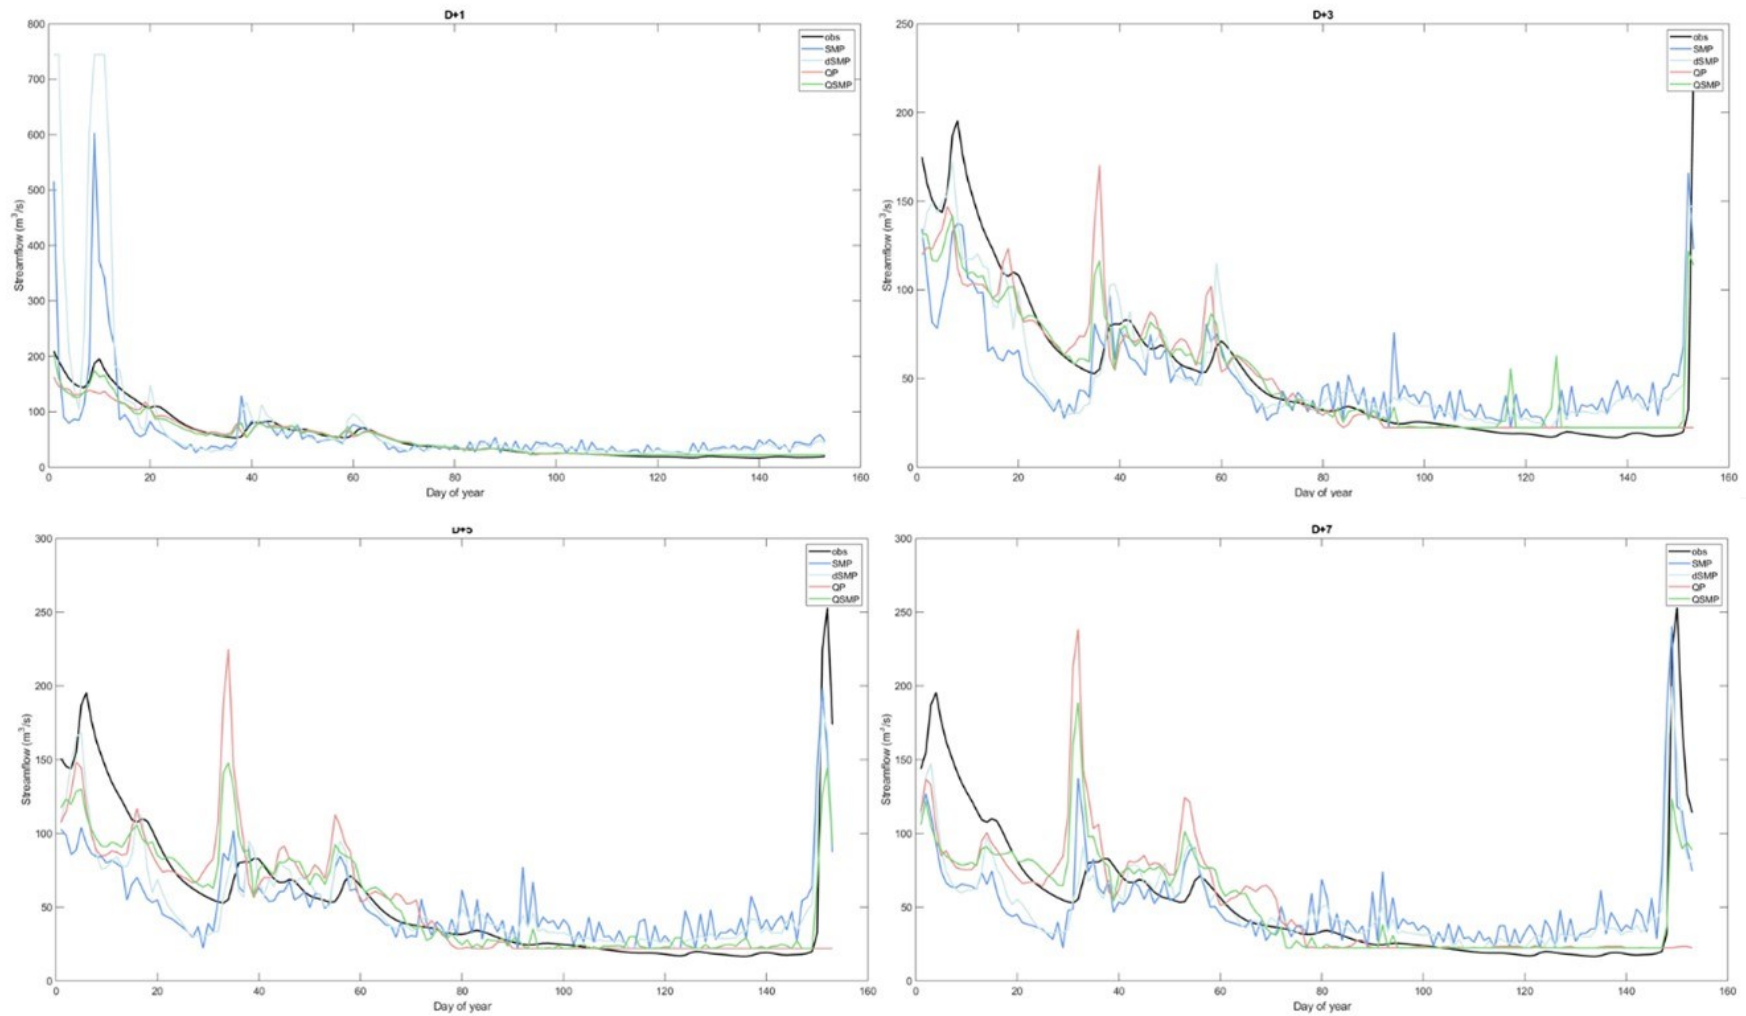


Figure 4.11 – Hydrographs for the Androscoggin watershed for summer 2010 (validation period) (a) 1, (b) 3, (c) 5 and (d) 7 days in advance.

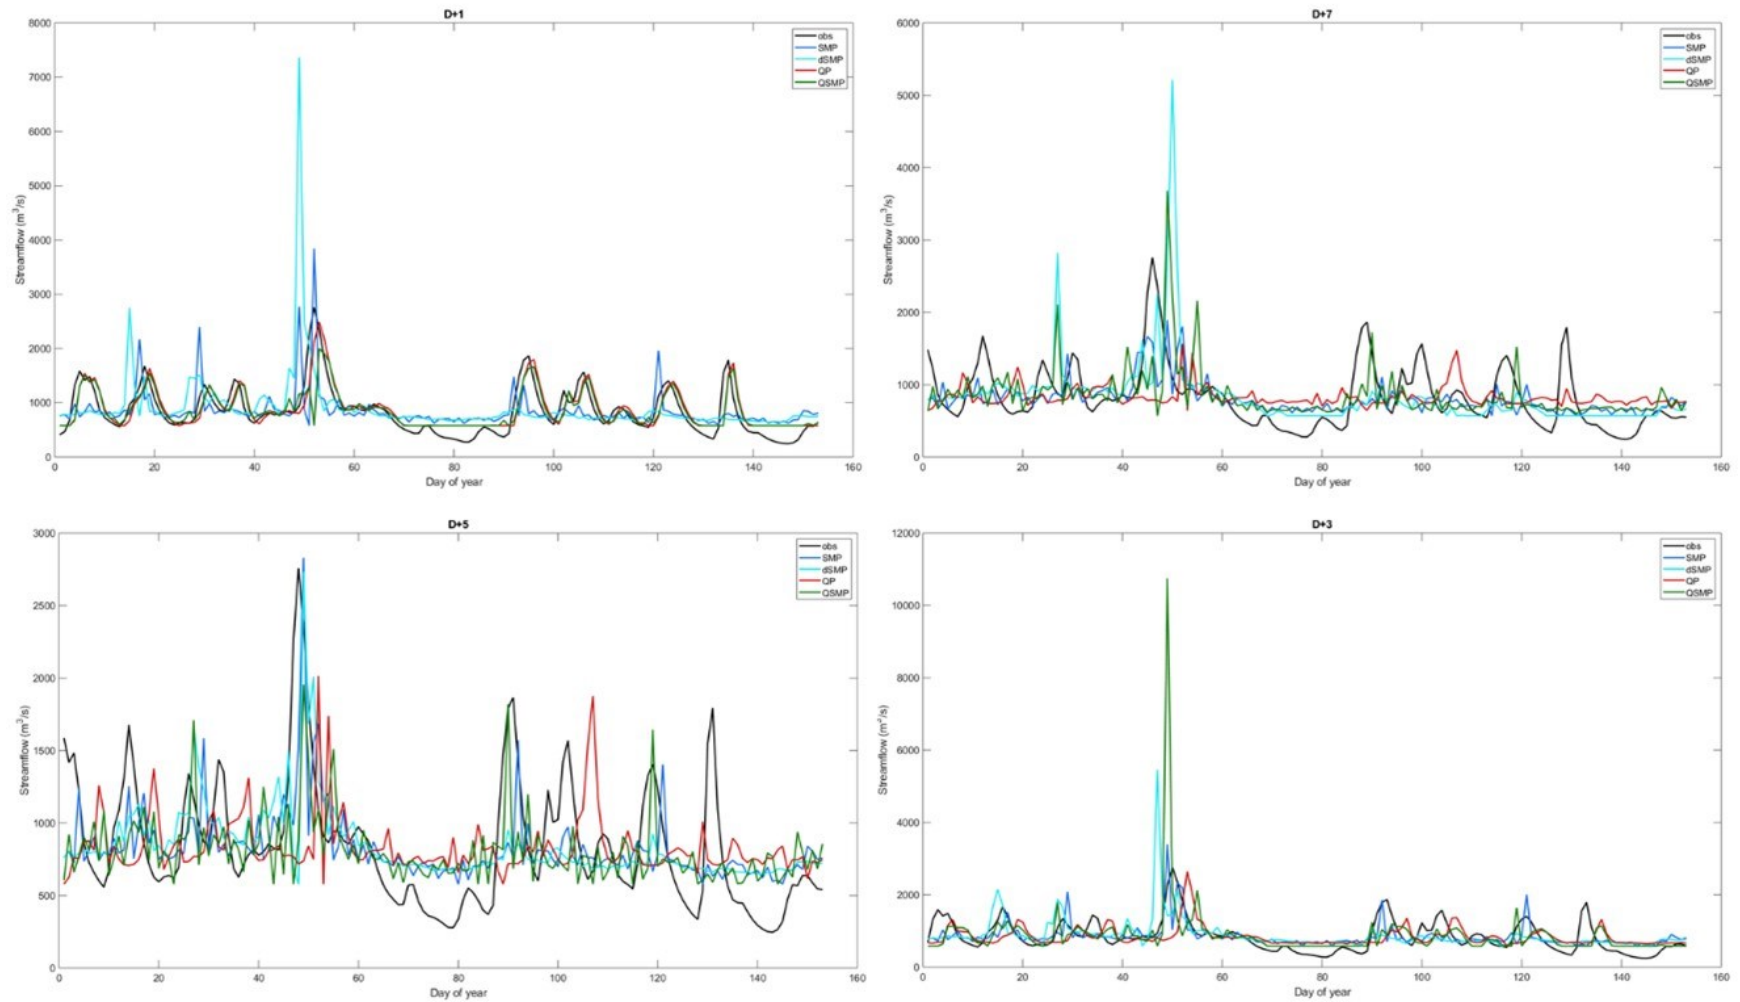


Figure 4.12 – Hydrographs for the Susquehanna watershed for summer 2010 (validation period) (a) 1, (b) 3, (c) 5 and (d) 7 days in advance.

4.5.3. Spatial discretization of inputs

Three main trends in model performance across the three spatial distribution ANN models were observed. First, the ANN model performance in training and validation was similar for both the global and fully distributed models, while the performance of single pixel-based models differed (Figure 4.13). We found that year-to-year dispersion, represented by the difference between the 75th and 25th percentiles (i.e., the height of the boxplots), varied both across the forecast horizon and between the three spatial distributions (Figure 4.13). In training, dispersion was small for both the global and the fully distributed model (average dispersion < 0.1 across the 7-day window). In contrast, dispersion in training across the single pixel-based models was much larger and was almost constant across of the forecast horizon, with an average value of 0.2. However, regardless of the spatial discretization, in validation the dispersion was much larger than in training, and at the minimum dispersion was less than 0.2 at $D + 2$ and at the maximum dispersion was approximately 0.4 at $D + 7$. In validation, the dispersion across the single pixel-based models was smallest on day 2 (0.3) and largest on day 1 (0.55). Next, there was always a difference between the median value of NSE of the training and validation periods regardless of the spatial discretization of inputs. While the difference in NSE fluctuates with no defined trend for both global and local models, the difference increased with the forecast horizon for the fully distributed model. Using the global model (Figure 4.13a) and single pixel-based models (Figure 4.13c), the gap between the median NSE in training and validation is about 0.2 on average across the 1- to 7-day forecasts. However, the difference in NSE for the distributed model increased from 0.15 at $D + 1$ and $D + 2$ to 0.3 at $D + 6$ and $D + 7$ (Figure 4.13b). Moreover, the forecast performance in the training step of all 28 single-pixel models were, in general, less accurate across the 7-day forecast window than the two other spatial configurations—as demonstrated by the 75th percentile NSE values of the single pixel-based models all being below the 25th percentile values of the global and the fully distributed models (Figure 4.13). While forecast performance in validation decreased across the forecast horizon for all spatial discretizations, some single-pixel models outperformed the other distributed models (see overlapping boxplots in Figure 4.13). This was especially evident when comparing the fully distributed and single pixel-based models for $D + 5$ to $D + 7$ (Figure 4.13b, c, red boxplots cover the same range of values).

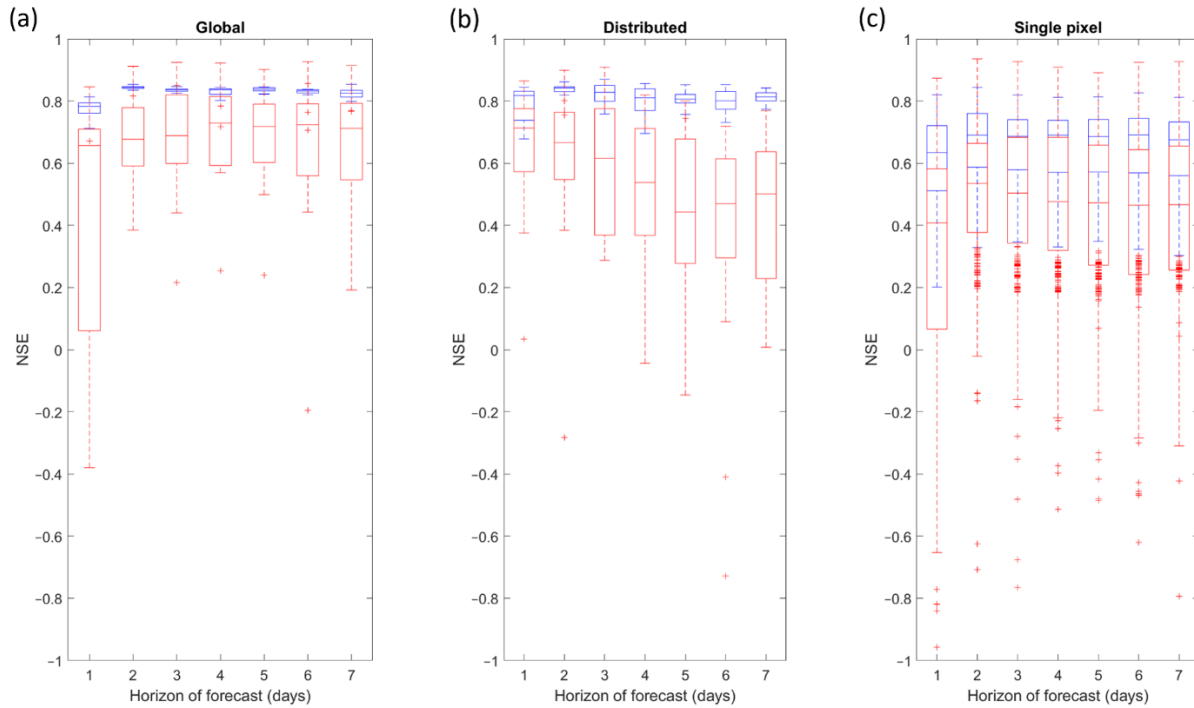


Figure 4.13 – For the Androscoggin watershed, the evolution of the NSE across the 7-day forecast window for 3 types of input spatialization: (a) global (i.e., grid average), (b) distributed (i.e., full-grid), and (c) single pixel (i.e., each of the 28 grid points individually). Each boxplot represents the dispersion across the 16 years used in cross-validation, blue is training, red is validation.

While the global and fully distributed ANN models overall offer equivalent performances across the 7-day horizon for both training and validation steps (Figure 4.13), the relative performance between the two spatial discretizations varied with training and validation years. For example, we found the fully distributed model to perform best (the dotted line in Figure 4.14) in 2009, which was a dry year (training years: 2000–2008 and 2010–2015), but we found the global model to perform best (the solid line in Figure 4.15) in 2012 (training years: 2000–2011 and 2013–2015), which was a wet year. For both of these spatial distributions, the NSE curves for the training step closely resembled each other and they were approximately constant across the forecast horizon (NSE values around 0.8), while for the validation step NSE increased across the forecast horizon for the two summers detailed. More specifically, the global model’s NSE curve was essentially constant in 2009 (the full line in Figure 4.14) with a NSE very close to 0.8 for the entire forecast window, but in 2012 the NSE increases from 0.5 at $D + 1$ to 0.7 at $D + 7$ (the full line in Figure 4.15). For the fully distributed model, NSE improved across the forecast

horizon similarly for the two selected years (the dotted line in Figure 4.14 and Figure 4.15), from approximately 0.5 to 0.8 respectively at $D + 1$ and $D + 7$ in 2009 and from 0.6 to approximately 0.9 respectively at $D + 1$ and $D + 7$ in 2012. Year 2009, which was a wet year (high base flow and frequent peaks) takes advantage of information averaged over the entire watershed, while the fully distributed model offered the best performance in 2012, which was a dry year. However, additional years of observations with contrasting hydrological behaviour before drawing more definitive conclusions. As for the single-pixel models, NSE values in training were almost constant across the 7 days of forecast for the year 2009 (the colored lines in Figure 4.14), with values varying between 0.6 and 0.8 depending on the pixel used to develop the model, but in 2012 the evolution of NSE differed between pixels (the colored lines in Figure 4.15). For approximately half of the pixels, we found a clear improvement of the model up to $D + 2$ followed by a stabilization of model performance with NSE values between 0.6 and 0.7. The other half of the pixels either had a constant performance across the 7-day window forecast, with NSE values between 0.6 and 0.8, or deteriorated up to $D + 3$ before stabilizing. However, the differences between single pixels were greater in the validation step; there was a large dispersion for $D + 1$ and $D + 2$ with NSE values below zero for 8 and 6 of the 28 pixels analyzed, respectively for years 2009 and 2012. In general across the different pixels, single-pixel models' performance in the validation step stabilized from $D + 3$ to $D + 7$, with NSE values hovering between 0.3 to 0.8 for the majority of pixels analyzed (26 for 2009 and 25 for 2012). We found that no single-pixel model performed better than either the global or the distributed model across the entire 7-day forecasting window. Finally, it is not clear which approach is better between the global and the fully distributed models.




Figure 4.14 – NSE evolution for the Androscoggin watershed in 2009. (a) Training, (b) Validation. Colored lines for each pixel, dotted line for the distributed model, and full line for the global one.




Figure 4.15 – NSE evolution for Androscoggin watershed in 2012. (a) Training, (b) Validation. Colored lines for each pixel, dotted line for the distributed model, and full line for the global one.

4.6. Discussion

Here, we introduce an ANN model framework for short-term hydrological forecast, studying the role of inputs, both identity and spatial representation, on model performance. We implemented the ANN model in a virtual environment representing the Androscoggin and Susquehanna watersheds in the northeastern United States and over a 1- to 7-day forecast window. We structured the ANN model with a single hidden layer and found the optimal number of neurons in it to be six.

Our comparison of the four different combinations of inputs, using a global spatial distribution, to the ANN model highlights the importance of soil moisture for streamflow forecast. While the ANN model performed better up to a 3-day forecast using streamflow for the antecedent day as the input, the model performance using surface soil moisture as input was found to perform better after 4 days. Moreover, model performance using these two different inputs had opposing trends across the 7-day forecast window; model performance improved across the forecast window with both surface and deep soil moisture as the input but decreased with antecedent streamflow as the input. We attribute the improved performance when surface soil moisture is used as the model input to the ‘memory’ effect—in brief, soil moisture captures watershed lag time, therefore improving performance at the longer-term horizon (from 4 to 7 days ahead). The time it takes for water to infiltrate to deeper soil layers may explain why we found slightly lower performance using deep soil moisture as opposed to surface soil moisture as the model input—the model output using deep soil moisture was very noisy, which was likely driven by the forecasted hydrographs being too sensitive to precipitation. The ANN model using both surface soil moisture and antecedent streamflow as inputs gave the best forecasts across the 7-day window. These findings apply to both the Androscoggin and Susquehanna watersheds, although the ANN model performs better (higher NSE) on the Androscoggin watershed compared to the Susquehanna watershed. Furthermore, three spatial distributions of inputs are compared for the Androscoggin watershed: global, fully distributed, and single pixel-based. We found that global and fully distributed models outperformed the single pixel-based models, regardless of the pixel used to train and validate the model. Model performance overall was very close between global and fully distributed models for both the training and validation steps.

4.6.1. Selection of inputs for hydrological forecasting

This study demonstrates the importance of having input variables that describe the watershed state, as well as current and forecasted precipitation. While we only examined the combination of a few watershed state variables, we found that having multiple watershed state variables as inputs optimized the performance of the ANN model across the 7-day forecast window. In this study, the number of input variables examined was relatively small; however, combinations with other variables have been explored, such as the antecedent precipitation index (API), normalized API, and P-ET (where P is precipitation and ET is evapotranspiration). Results with those derived variables were not conclusive; the information given as inputs to the ANN model was either adding noise in the model—resulting in a drop of NSE values—or resulted in similar performance as the ANN model with the simpler input variables presented here.

Coupling streamflow with surface soil moisture resulted in the most accurate model, as the strength of each variable complemented each other; streamflow was the most important variable for the streamflow forecast over the first 3 days, while surface soil moisture was important for days later in the forecast horizon (i.e., days 4–7). We argue that soil moisture plays the role of a ‘memory’ variable. This ‘memory’ effect is explained by the concept of watershed lag time, defined as the time at which a watershed responds to a runoff-producing rain event, and is tightly related to the time of concentration of the watershed. A number of equations have been proposed to calculate the watershed time lag and, or time of concentration, several of which include a runoff coefficient that increases or decreases the time lag as it increases or decreases respectively (e.g., the curve number in the National Resources Conservation Service’s equation). In other words, the more the watershed has the capacity to infiltrate water, the slower is its response to a given rainfall. Conversely, the more the watershed has the capacity to generate surface runoff, the faster its response to the same rainfall event. Such behavior agrees with the results of our study, as soil moisture is related to infiltration capacity.

We found surface soil moisture to provide more useful information to the ANN model compared to deep soil moisture, although the difference between the two is not large, and using one or the other as the input variable does not significantly affect model robustness. We attribute the difference to the low NSE values at D + 1 when deep soil moisture is the input variable (Table 4.5 and Table 4.6, Figure 4.7 and Figure 4.8). This is most probably related to the time required

for deeper soil moisture to react to infiltration compared to surface soil moisture. As expected, the ANN model forecasts with deep soil moisture improve across the 7-day window forecast likely owing to the fact that at later time horizons water has had time to infiltrate and reach deeper soil layers. Different physiographic characteristics (i.e., land cover) are associated with different soil properties and therefore, infiltration rates (Morbidelli et al., 2018) and soil water holding capacities (Martínez-Fernández et al., 2021). We found the ANN model forecasts using deep soil moisture performed better for the Androscoggin watershed compared to the Susquehanna watershed and argue this is likely due to their difference in their surface area and land cover, as defined in HYDROTEL. The Androscoggin watershed is both smaller in area and more homogeneous in land cover compared to the Susquehanna watershed (eight times smaller; 83.5% vs. 59% forested area, respectively), potentially explaining the increase in year-to-year consistency of the results (Figure 4.7 and Figure 4.8).

While our ANN forecasts only slightly improved using surface soil moisture in comparison to deep soil moisture as model inputs, the biggest benefit to using surface soil moisture to train future ANN models for streamflow forecasts is that it can be quantified using remote sensing. Currently, active and microwave sensors onboard satellites, such as the Sentinel-1 (active) and the (SMOS) (passive), offer the possibility to measure soil moisture in the first centimeters of the soil (Gao et al., 2017; Kerr et al., 2012), however the ability to quantify soil moisture is limited to areas where vegetation does not significantly interfere with the microwave signal. It is well established that the root zone layer of the soil has an important role in the vertical and horizontal flows of water (Brocca et al., 2012; Wanders et al., 2014). While different techniques exist for interpolating near-surface soil moisture to deeper layers (Baldwin et al., 2017; Massari et al., 2015), if near-surface and subsurface soil moisture are correlated well, it is more convenient to directly use the initial value retrieved by the satellite. However, several studies using field data and modelling have shown deviations from linear correlations between near-surface and root zone (i.e., deeper soil layers) soil moisture, referred to as decoupling, and suggest that decoupling is driven by vegetation (Wilson et al., 2003) and soil moisture conditions (Carranza et al., 2018). The similar performance of our ANN forecast model using surface and deep soil moisture as inputs suggests that the soil layers within our studied watersheds are not decoupled and we stress this result may not be ubiquitous across all watersheds, particularly

where strong decoupling occurs. It is possible that this finding is the result of the hydrological model—vertical soil water dynamics were simulated by BV3C within HYDROTEL (Figure 4.3)—used to ‘construct’ the surface and deep soil layer soil moisture ‘observations’ (i.e., soil layers within the watersheds are decoupled but the hydrological model used was unable to accurately quantify the dynamics). Other models that offer a finer discretization of the soil column, such as MIKE-SHE (Singh et Frevert, 2006), may yield different results by more accurately capturing the decoupling effect. Additional research using satellite-derived soil moisture alone or in combination with ground soil moisture measurements will help overcome limitations associated with virtual environments and further our knowledge about the importance of surface versus deep soil moisture in ANN streamflow forecasting.

4.6.2. Spatial distribution of inputs

There is a trade-off between model complexity and, therefore, computational demand, and model adaptability when using spatially distributed versus global ANN models—spatially distributed models are more complex but are more adaptable because the weights and biases, inherent to the internal structure of the ANN, can be defined differently for each discrete spatial entity (i.e., grid points). We found that model performance was similar using either a global or fully distributed representation of inputs (i.e., surface soil moisture). This is particularly true for periods of high streamflow—modelled hydrographs, using the best combination of inputs at the global scale, are closer in validation to observed streamflow for wet summers (Figure 4.9 and Figure 4.11) than for dry summers (Figure 4.10 and Figure 4.12)—which are important to forecast in order to protect people and reduce damage to infrastructure.

Based on our results, we claim that there is an added value in using distributed surface soil moisture in ANN models, either as an explicit representation of soil moisture variability in a fully distributed model, or as a representative average soil moisture at the watershed scale in a global model. This in turn illustrates the potential of such models when coupled to satellite-based remote-sensing products. Current (e.g., Sentinel-1, Radarsat Constellation mission, SMAP, and SMOS) and future (e.g., NiSAR) spaceborne missions provide or will provide, soil moisture information at the watershed scale that could be implemented as inputs to ANN models.

However, depending on the size of the watershed and on the satellite products used, a spatially distributed model can require large computational resources. While we show that the fully distributed ANN model gives better results than single pixel-based models (Figure 4.13Figure 4.15), we think a compromise can be developed in which a selection of pixels are used as inputs instead of the whole grid. This selection could be based on land cover, retaining only those pixels that cover areas where satellite-derived soil moisture measurements are more reliable as inputs to the ANN model. This is equivalent to data time series from ‘virtual soil moisture stations’, similar to the concept of ‘virtual limnometric stations’ applied to satellite altimetry to obtain surface water body elevation (Roux et al., 2010). To this extent, we argue that there should be a focus on using spatially ‘oriented’ distributed models in the future.

4.6.3. Comparison with physically based models

Traditionally, hydrological modelling has focused on physically based and conceptual models. For at least two decades there has been a change in the way to think about hydrological modelling, with an increase in interest and publications surrounding the application of data-driven models (Chang et Guo, 2020; Faizollahzadeh ardabili et al., 2019; Yaseen et al., 2015). In order to forecast streamflow, an ANN model does not rely on physically based equations or conceptual approaches to describe hydrological processes, such as infiltration and runoff, but instead uses a “black-box” approach to describe relationships between hydrometeorological input variables, such as precipitation and soil moisture, and resulting streamflow. During the training step, in which the best black-box model is established, an ANN model in essence “learns” these physical principles (Kratzert et al., 2018).

We show that using previous streamflow in combination with surface and deep soil moisture improves the ANN model performance compared to using either individually. We interpret this as the ANN model learning the physical laws and principles and understanding the connections between the inputs and streamflow. (Shen et Lawson, 2021) state that “a handful of applications have sought to combine data-driven models with physics [and] to demonstrate that when physics are included in ML models, models tend to perform better than pure ML models when extrapolating to instances unseen in the training database” (Shen et Lawson (2021), p. 292). We agree that the potential of data-driven models, including ANN models, are not currently being fully exploited and that traditional models can be used to improve data-driven models for

hydrological applications. To date, there have been a few examples of integrating traditional and data-driven models that can be found in the literature, such as the estimation of root-zone soil moisture from different soil profiles (Tian et al., 2020), meteorological forcings based on data-driven models (Kornelsen et Coulibaly, 2013), and the delineation of groundwater potential zones by an ANN model (Tamiru et Wagari, 2021). Numerous challenges remain unsolved in hydrology but integrating the two types of model may lead to interesting improvements (T. Xu et Liang, 2021).

4.7. Conclusions

A number of research avenues should be explored to improve the application of ANN models to streamflow forecasts. Real observations, either ground observations or remotely sensed, and forecasted variables could be used as model inputs. Meteorological station observations, reanalyses, and forecasts are freely accessible from different weather services, such as the European Center for Medium-Range Weather Forecast (ECMWF) in Europe and USGS in the USA. Moreover, streamflow observations are also widely available, for example from USGS across the USA and the DEHA in the province of Québec, Canada. Most relevant to our findings, satellite observations could be used as model inputs; satellite missions such as SMOS and SMAP have offered soil moisture data with a spatial resolution of 25 km² and 36 km², respectively, since 2010 for SMOS and 2015 for SMAP and continue to collect data (their spatial coverage includes the watersheds studied in this paper). Active microwave satellite missions such as the Sentinel-1A and 1B, as well as the Radarsat Constellation Mission, are also data sources to consider. Using remote-sensing information with ANN approaches for hydrological modelling and/or forecasting is one of the main current and future challenges (Abdollahipour et al., 2020).

Given that a fully distributed approach to the spatial distribution of inputs is likely computer-intensive, alternative spatial discretization approaches should be examined; for example, grouping pixels based on land use, land cover, and, or topography. This idea is not novel and a similar approach has been implemented, with success, in traditional hydrological modelling through the concept of ‘homogeneous response unit’ (HRU); for example, HYDROTEL (Fortin et al., 2001) and SWAT (Arnold et al., 1998). This approach to spatial discretization should

reduce the risk of duplicate information in ANN model inputs, likely resulting in a more robust model that is less prone to overfitting. This approach could be examined with real data, as suggested above, or in a virtual environment, as in this current study. Transfer learning should be explored if the ANN model is to be developed across a large selection of watersheds. Transfer learning saves time and reduces the complexity of the model and the risk of overtraining and overparameterization.

Our ANN model forecasts applied to the streamflow at a single location; however, ANN models with several streamflow outputs (i.e., streamflow at multiple locations) should be explored. Instead of developing a distinct hydrological model for the natural inflows of each reservoir having its sub-watershed, the entire watershed is taken into consideration with one streamflow output for each river location with a reservoir. This application of ANN model forecasts would be particularly relevant for hydropower companies that manage several reservoirs within a watershed. Within the literature, there are examples of ANN-based models for hydrological forecasting with more complex internal structure, in comparison to the ANN models implemented here, that are a part of the deep learning group. The long short-term memory model is especially relevant for large watersheds with regular time series values available. Moreover, convolutional models have a high potential to exploit images in general, and remotely sensed images of Earth. Researchers should consider convolutional models with attention to hydrological application in streamflow forecast but also for flood detection.

CHAPITRE 5 MATÉRIEL SUPPLÉMENTAIRE EN ENVIRONNEMENT VIRTUEL

5.1. Matériel complémentaire à l'article

5.1.1. Sélection de la période d'apprentissage

Les résultats présentés dans cette thèse sont issus d'expériences fonctionnant sur le principe de la validation croisée quand on est en environnement virtuel. Chaque année est successivement isolée pour servir de période de validation tandis que toutes les autres servent de période d'apprentissage.

Une analyse sur le BV Androscoggin a été faite pour déterminer le rôle des années utilisées en apprentissage selon le régime hydrologique de l'année en validation. Les seize étés utilisés ont ainsi été répartis de manière subjective d'un point de vue hydrologique entre été sec et été humide. La subjectivité vient du fait que la définition de régime hydrologique sec ou humide se fait en fonction des années à disposition et pas en fonction de la comparaison avec le régime hydrologique moyen du BV à l'étude. On compare ainsi les seize années à disposition à partir des hyétogrammes et des hydrogrammes. Les années avec le moins de précipitation et avec les étiages estivaux les plus prononcés sont qualifiés de sèches ; au contraire, celles avec le plus de précipitation et des étiages modérés à faibles et avec des débits plus élevés sont qualifiées d'humide. En effet, on cherche seulement ici à catégoriser les années pour évaluer l'influence d'un apprentissage sur des années particulières. Cette sélection, bien que peu formelle suffit dans ce cadre. De plus, avec les années à disposition, on observe une répartition équitable entre étés secs et humides, avec huit étés dans chaque catégorie. Pour le BV Androscoggin, c'est de cette manière que 2009 est défini comme année humide et 2010 comme année sèche. Pour chacune des quinze années disponibles en apprentissage, trois échantillons sont créés : un avec seulement les années du même régime hydrologique que l'année de validation, un avec seulement les années du régime hydrologique opposé à l'année de validation et un avec toutes les années confondues sans tenir compte du régime hydrologique. En prenant un peu d'avance sur les résultats de l'analyse faite, on annonce dès à présent que les expériences des CHAPITRE

4 et 0, ainsi que celles des autres sections du présent chapitre sont toutes menées avec ce dernier échantillon qui prend en compte toutes les années indifféremment de leur régime hydrologique.

Pour chacun des trois échantillons d'apprentissage, on dispose d'un résultat en validation. Sans surprise le modèle performe mieux et est plus fiable pour un apprentissage du même type que la validation : l'écart entre les critères d'évaluation en apprentissage et en validation est minimum. L'intérêt principal d'une telle expérience est de déterminer l'information perdue par l'utilisation d'un échantillon d'un régime hydrologique opposé et surtout de mesurer l'écart avec l'échantillon qui prend toutes les années en compte.

En effet, en mode prévisionnel réel, il n'est pas pertinent de faire une distinction de ce type car le régime hydrologique général du BV pour la saison à venir n'est pas connu lorsque le modèle de prévision tourne tout au long de la saison²⁰. La comparaison entre le modèle de RNA ayant appris sur les années du même régime hydrologique que l'année de validation et le modèle de RNA ayant appris sur toutes les années sert principalement à évaluer si le modèle de RNA est capable d'extraire l'information nécessaire d'un long apprentissage et donc, comme mentionné plus haut, d'évaluer la robustesse et la capacité de généralisation du RNA.

Quels que soient les intrants utilisés, les observations faites sont les mêmes (Figure 5.1 et Figure 5.2). Cependant, d'après les résultats du Chapitre 4 (qui seront également confirmés plus loin dans ce chapitre), le modèle de RNA a plus de facilité à prévoir les forts débits et donc la qualité des prévisions, en apprentissage comme en validation, est meilleure pour les années humides que pour les années sèches. On remarque ainsi qu'en validation, les courbes bleue, cyan et jaune présentent les moins bons résultats (voir le RMSE sur la Figure 5.1 et la Figure 5.2). Les associations les plus appropriées, c'est-à-dire un apprentissage et une validation de même régime hydrologique (sec ou humide), montrent que le modèle est alors très fiable avec des résultats très proches entre apprentissage et validation (voir le NSE sur la Figure 5.1 et la Figure 5.2).

²⁰ À moins de faire de la prévision à moyen ou long terme dans un premier temps, de se baser sur ce résultat pour déterminer l'échantillon d'apprentissage à utiliser pour faire l'apprentissage du modèle pour la prévision à court terme. Mais toute ceci relève d'une autre question.

Enfin, les résultats pour le modèle de RNA apprenant sur toutes les années sont satisfaisants, d'un niveau comparable à un modèle avec apprentissage du même régime hydrologique. Cela est particulièrement marqué pour les horizons les plus lointains pour lesquels les scores des métriques sont équivalents. Dans le cas de la configuration d'intrants QP avec 2010 en validation, c'est un peu moins évident (chute du NSE à 0 à J+3 avant de remonter à 0,3 à J+7, Figure 5.2, courbe jaune pointillée) qu'avec la configuration HUP (Figure 5.2, courbe jaune pointillée). Malgré tout, ce résultat reste relativement bon pour avancer que le modèle de RNA a une bonne capacité à déceler dans l'échantillon d'apprentissage le comportement hydrologique de l'année à valider, et donc dispose d'un bon pouvoir de généralisation.

Une dernière observation comparant les trois types d'apprentissage permet de voir que le RNA se comporte de manière similaire sur l'ensemble de la fenêtre de prévision. En effet, la tendance sur les 7 jours de prévision est la même quelle que soit la période d'apprentissage utilisée et la configuration d'intrants retenue, soit une diminution du NSE et une augmentation du RMSE avec l'horizon prévisionnel ; seul le niveau de performance varie. Les écarts peuvent toutefois varier ; c'est notamment le cas avec la configuration QP en validation, pour laquelle le NSE passe de 0,8 à J+1 à une valeur négative à J+7 pour un apprentissage sur les étés humides et validation sur 2010. Il est en effet observé que quel que soit l'échantillon d'apprentissage, la validation faite sur l'été 2010 avec la configuration QP est médiocre à partir de J+3. Le modèle de RNA développé offre des tendances similaires en sortie et est donc en mesure de capter les principaux effets des différents intrants testés. Plus précisément, au-delà de ces tendances partagées, la qualité de la prévision change selon les intrants, avec notamment un RNA nettement supérieur avec la configuration d'intrants HUP que la configuration QP.




Figure 5.1 – Évolution du RMSE (gauche) et du NSE (droite) selon l'horizon de prévision en apprentissage (traits pleins) et en validation (traits pointillés) pour la configuration HUP avec l'année 2009 ou 2010 en validation et les années sèches (respectivement rose et bleu), humides (respectivement rouge et cyan) ou toutes (respectivement vert et jaune) en apprentissage




Figure 5.2 - Évolution du RMSE (gauche) et du NSE (droite) selon l'horizon de prévision en apprentissage (traits pleins) et en validation (traits pointillés) pour la configuration Q avec l'année 2009 ou 2010 en validation et les années sèches (respectivement rose et bleu), humides (respectivement rouge et cyan) ou toutes (respectivement vert et jaune) en apprentissage

5.1.2. Modèle singulier pour le BV Androscoggin

Cette sous-section présente des éléments supplémentaires qui font suite aux résultats de l'article présenté au Chapitre 4. Il s'agit d'analyses complémentaires au modèle singulier (*single-pixel based*).

La Figure 5.3 montre la grille utilisée pour couvrir le BV Androscoggin et l'indice des cellules associées. Cette grille, d'une résolution de $28 \times 28 \text{ km}^2$ (soit $0,25^\circ \times 0,25^\circ$) est inspirée de la résolution spatiale des produits d'humidité du sol des satellites SMOS et SMAP. On ne considère ici que les cellules qui couvrent au moins partiellement une portion du BV; il y a finalement vingt-huit cellules qui sont retenues. Le modèle de RNA tourne autant de fois qu'il y a de cellules, prenant à chaque fois les valeurs issues d'une cellule en particulier comme intrants. Cette approche permet d'observer si certaines cellules apportent de l'information plus pertinente que d'autres et donc de comprendre si certaines caractéristiques liées à ces cellules représentent finalement mieux le BV. Dans l'interprétation des résultats, cette approche peut s'assimiler à une approche de modélisation d'ensemble, chaque cellule constituant un membre. Il est évident que l'ensemble auquel on fait référence ici n'est pas créé dans le concept classique de prévision d'ensemble²¹. Le parallèle proposé vient d'une incertitude liée à l'état du BV : chaque cellule dispose d'une valeur d'humidité du sol qu'on considère représentative de l'humidité du sol sur l'ensemble du BV. Ainsi, chaque modèle singulier fournit une prévision qui lui est propre. On essaye alors de comprendre si ces valeurs d'humidité du sol prises indépendamment les unes des autres permettent de fournir des sorties de modèle de qualité et, si oui, où elles se situent par rapport aux sorties des modèles global et spatialisé. Avec le parallèle proposé, on se permet de parler de dispersion et on pourrait aussi se permettre d'utiliser une métrique comme le *Continuous Rank Probability Score* pour évaluer la performance de la prévision liée à l'incertitude associée à l'état hydrique du bassin versant.

²¹ En prévision d'ensemble, chaque membre est associé à une perturbation des données d'entrée qui permet *in fine* de représenter l'incertitude d'un élément de la modélisation sur les résultats du modèle. Par exemple, l'incertitude introduite peut être associée à la prévision météorologique, à l'état du BV (humidité du sol, stock de neige) ou encore à la structure du modèle hydrologique.




Figure 5.3 - Indice des cellules pour le BV Androscoggin

Avec l'utilisation de la configuration d'intrants HUP, on se rappelle que certains modèles singuliers font mieux que le modèle global ou le modèle spatialisé, mais jamais sur l'ensemble de la fenêtre de prévision (Figure 4.14 et Figure 4.15, Chapitre 4). Le Tableau 5.1 montre les sept meilleures cellules (soit les 25 % les meilleures) pour chaque horizon, en apprentissage et en validation pour les deux années de validation sélectionnées : 2009 (année humide) et 2012 (année sèche). On remarque tout d'abord qu'il y a un certain manque de robustesse des modèles singuliers car les meilleures cellules en apprentissage ne sont que rarement les meilleures cellules en validation. Ces propos sont toutefois à modérer par la forte similarité des résultats observés en apprentissage. En effet, les écarts d'un modèle singulier à l'autre sont très faibles pour cette période (Figure 4.14 et Figure 4.15, Chapitre 4). De plus, les cellules qui permettent au modèle d'être le plus performant en termes de NSE ne sont pas nécessairement les mêmes d'une année de validation à l'autre.

C'est pour les horizons de prévision les plus lointains qu'il y a une certaine consistance du NSE. Les meilleures cellules changent d'un horizon à l'autre entre J+1 et J+3, mais on observe une régularité à partir de J+3, avec par exemple la cellule 1 en 2009 qui occupe la première place de J+3 à J+6 et la cinquième à J+7. En 2012, c'est la cellule 26 qui a des performances remarquables : troisième place à J+2, deuxième place à J+3 et première place ensuite (Tableau 5.1).

En termes de localisation des cellules sur le territoire, il ne ressort pas de zones particulières du BV qui permettent une meilleure prévision du débit à l'exutoire. Cela s'observe par les indices des sept meilleures cellules, dispersés sur l'ensemble du BV. Cela se vérifie en particulier pour la validation. En revanche, en apprentissage, un zonage semble ressortir, avec pour 2009, la zone amont du BV qui est favorable à un bon NSE et, pour 2012, la zone aval.

Tableau 5.1 – Sept meilleurs indices (par ordre croissant du meilleur au 7^e meilleur) du modèle singulier présentant les meilleurs NSE pour chaque horizon de prévision en apprentissage et en validation selon l'utilisation de l'été 2009 ou 2012 comme échantillon de validation, avec utilisation de la configuration HUP

	Vali 2009		Vali 2012	
	Appr	Vali	Appr	Vali
J+1	16-19-9-18-5-13-14	26-23-10-7-8-24-16	25-28-24-17-19-23-20	20-22-19-6-17-3-12
J+2	2-13-20-1-3-12-19	10-26-27-17-14-11-23	25-17-24-23-20-28-26	22-6-26-24-23-27-13
J+3	2-1-4-12-3-13-28	1-17-14-26-27-13-23	24-25-19-23-18-28-22	6-26-22-13-19-7-28
J+4	3-1-12-4-2-9-10	1-14-23-27-17-26-7	25-27-23-28-21-3-17	26-19-13-22-28-7-6
J+5	3-2-19-4-1-5-11	1-17-27-23-16-14-7	24-19-26-22-27-28-21	26-28-19-23-6-10-17
J+6	1-2-4-3-19-18-21	1-17-27-23-14-16-26	24-27-18-22-21-28-25	26-19-28-12-10-17-23
J+7	4-2-3-20-5-7-6	14-17-27-23-1-26-3	24-18-28-19-22-21-17	26-19-28-10-6-7-9

L'analyse des hydrogrammes (Figure 5.4 et Figure 5.5) révèle une tendance générale des modèles singuliers à sous-estimer le débit. Cette tendance, déjà observée avec le modèle spatialisé (courbe bleue), est plus prononcée notamment pour les pics de crue. Ceci se vérifie pour les sept horizons de prévision. La dispersion des modèles singuliers est plus importante en période de crue. Il est évident que certains modèles ne prévoient simplement pas l'ampleur de

la crue. Cela pourrait être due à des données d'humidité du sol locales qui ne reflètent pas ce qu'il se passe sur l'ensemble du BV. Les faibles débits parfois simulés par des modèles singuliers en période de crue pourraient être dus à un retard ou un avancement du début ou de la fin de la crue. Le fait d'intégrer l'ensemble des points de grille avec le modèle spatialisé (courbe bleue, Figure 5.4 et Figure 5.5) permet de limiter ces effets locaux. En effet, sur chaque horizon de prévision pris indépendamment, le modèle spatialisé fait mieux que les trois quarts des modèles singuliers (symbolisé par le tracé noir qui couvre tous les résultats entre les quantiles 25 et 75).

Enfin, on remarque que les évolutions du NSE et du RMSE suivent sensiblement le même profil, à savoir une amélioration des métriques avec l'horizon de prévision (Figure 5.4 et Figure 5.5). Pour les modèles singuliers, cela se lit avec les extrémités des boîtes à moustaches qui soulignent les meilleures performances même si ce n'est pas toujours avec la même cellule. On remarque ainsi que les meilleurs modèles singuliers sont équivalents au modèle spatialisé. Cette observation est particulièrement vraie en validation (courbes rouges). Les écarts en apprentissage sont plus grands (courbes bleues). On observe notamment que le nombre de modèles singuliers qui performant mieux que le modèle spatialisé est plus important ; cette observation est surtout visible avec le NSE. La tendance de la médiane des modèles singuliers suit celle du modèle spatialisé. Pour l'année 2009, en validation, il y a une amélioration du NSE entre J+1 et J+4, passant de 0,6 à presque 0,8 pour le modèle spatialisé et de 0,45 à 0,6 pour la médiane des modèles singuliers. Il y a ensuite une baisse du NSE jusqu'à J+7 pour le modèle spatialisé, atteignant 0,65, alors que la médiane des modèles singuliers reste constante sur les derniers horizons. En 2012, la tendance est la même avec le modèle spatialisé, qui performe au mieux à J+3, avec un passage du NSE de 0,65 à 0,85 entre J+1 et J+3, avant de revenir au niveau de J+1 à J+7. La médiane des modèles singuliers croît entre J+1 et J+3, passant de 0,3 à 0,7, et restant à ce niveau-là jusqu'à J+7. Les résultats entre les deux années montrent que 2012, considérée comme une année sèche, est plus difficile à prévoir. Les deux métriques présentent des valeurs qui traduisent des modèles moins performants en 2012. Ainsi, les modèles singuliers sont moins robustes lorsque validés sur une année sèche.

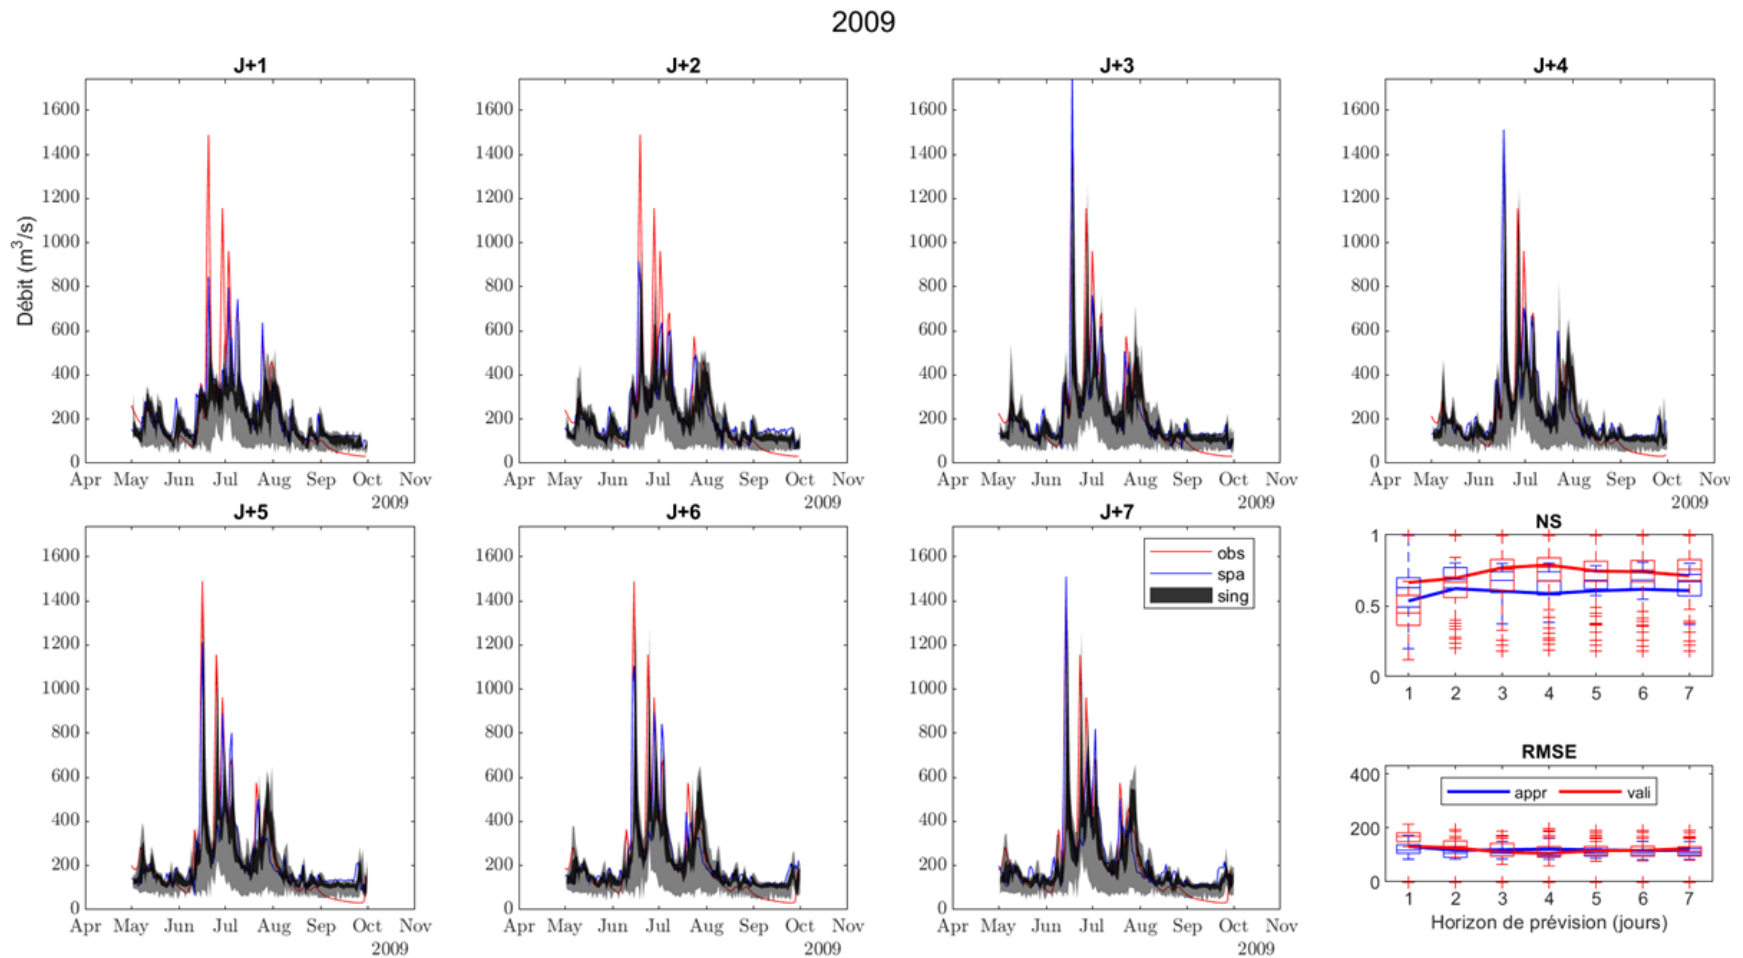


Figure 5.4 - Hydrogrammes pour l'année 2009 en validation de 1 à 7 jours à l'avance avec superposition de l'observation (rouge), la sortie du modèle spatialisé (bleu) et les sorties des modèles singuliers (gris). La dernière sous-figure montre le NSE et le RMSE en apprentissage (appr, en bleu) et la validation (vali, en rouge) sur la fenêtre de prévision de 7 jours avec les lignes pour le modèle spatialisé et les boîtes à moustache pour les modèles singuliers.

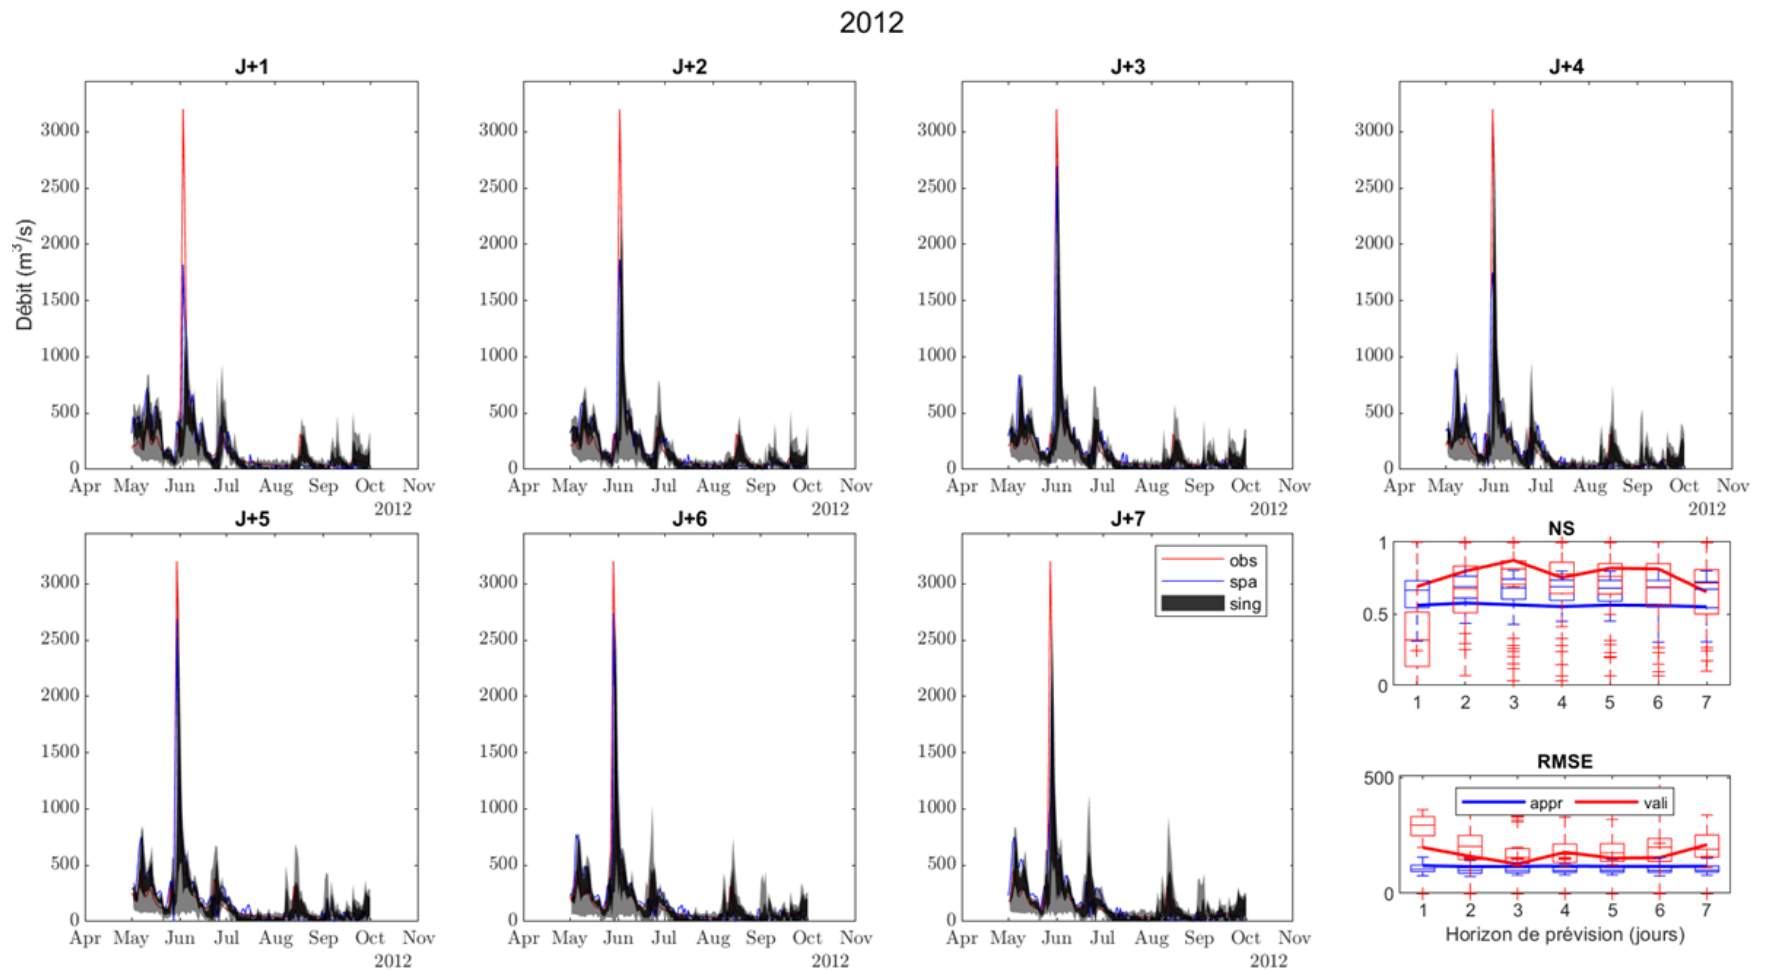


Figure 5.5 - Hydrogrammes pour l'année 2012 en validation de 1 à 7 jours à l'avance avec superposition de l'observation (rouge), la sortie du modèle spatialisé (bleu) et les sorties des modèles singuliers (gris). La dernière sous-figure montre le NSE et le RMSE en apprentissage (appr, en bleu) et la validation (val, en rouge) sur la fenêtre de prévision de 7 jours avec les lignes pour le modèle spatialisé et les boîtes à moustache pour les modèles singuliers.

5.1.3. Comparaison entre modèle spatialisé et modèle global

Dans le Chapitre 4, les illustrations pour la comparaison des types de spatialisation couvrent deux années singulières, à savoir 2009 et 2010 choisies respectivement comme exemples d'étés humide et sec. On souhaite ici généraliser ces résultats afin d'assurer le lecteur que les conclusions avancées se vérifient sur l'ensemble du jeu de données à disposition (seize années).

La principale conclusion lorsqu'on compare le modèle global (issu d'une moyenne sur tout le BV) avec le modèle spatialisé est que les résultats sont très proches et qu'il n'y a pas de différence clairement établie entre les deux (Figure 5.6a). Cette observation reste valide sur l'ensemble des seize années utilisées en validation croisée. Les écarts sont très faibles entre les deux modèles, avec une différence de la médiane du NSE d'environ 0,02 en apprentissage (Figure 5.6a) et de 0,05 en validation (Figure 5.6b). Même si, en apprentissage, le modèle global est toujours légèrement en dessous du modèle spatialisé (médiane, 25^e et 75^e percentiles), cette tendance s'inverse en validation. Cela est notamment révélateur d'une meilleure robustesse des modèles globaux avec un 25^e percentile du NSE ne descendant jamais sous 0,5 et un 75^e percentile du NSE n'excédant pas 0,8 en apprentissage comme en validation pour les sept horizons de prévision. Les modèles spatialisés, quant à eux, passent d'un écart de 0,2 entre le plus bas 25^e percentile (0,58 à J+1) et le plus haut 75^e percentile (0,78 à J+2 et J+3) en apprentissage à un écart de 0,4 en validation (plus bas 25^e percentile à 0,35 à J+7 et plus haut 75^e percentile à 0,75 à J+1 et J+2). Enfin, il n'y a que pour J+7 que les dispersions sont significativement différentes, avec deux tendances opposées : une dispersion plus faible pour le modèle spatialisé en apprentissage (0,2 entre les percentiles 25 et 75 pour le modèle global contre 0,1 pour le modèle spatialisé) et une dispersion plus grande en validation (toujours 0,2 pour le modèle global et 0,4 pour le modèle spatialisé). À part le modèle spatialisé à J+7, les dispersions entre apprentissage et validation restent constantes pour les deux types de spatialisation des intrants.

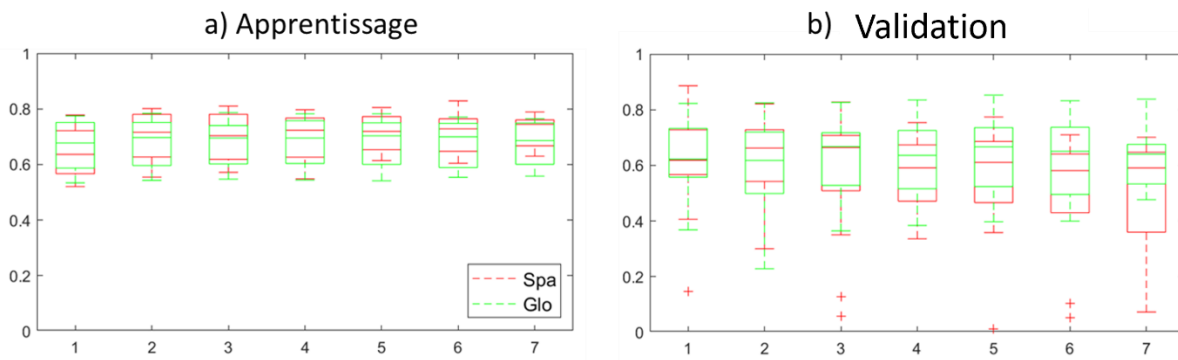


Figure 5.6 – NSE en a) apprentissage et b) validation après avoir considéré l'ensemble des 16 étés comme période de validation via une validation croisée, pour le modèle spatialisé (rouge) et le modèle global (vert) pour le BV Androscoggin.

5.2. Configuration d'intrants sur les quatre BV à l'étude

Avant de définir et de détailler les configurations d'intrants explorées, il est important de rappeler les sorties au modèle de prévision. Ce travail de thèse vise à faire de la prévision hydrologique à court terme à un pas de temps journalier ; ici, c'est le débit qui est la variable cible. Plus précisément, le débit à l'exutoire du BV.

Avec la discrétisation spatiale accessible grâce au modèle HYDROTEL, le débit sur n'importe quel tronçon du BV est disponible, à la fois le débit amont que le débit aval. Cependant, un cadre est établi afin de se rapprocher d'un système de prévision réel, pour lequel le débit n'est prévu qu'à l'exutoire ou du moins à un site cible du BV. Ainsi, le présent cadre vise à construire le système de prévision basé sur un modèle de RNA en gardant à l'esprit la façon d'opérer en « vrai », c'est la raison pour laquelle seul le débit à l'exutoire est pris en compte en tant que variable de sortie du modèle de RNA. D'un point de vue structurel, un RNA permet de fournir une prévision de débit sur différents tronçons du BV à l'étude. La modélisation par des approches d'apprentissage automatique offre à l'utilisateur de modéliser le débit en sortie sur tous les points d'intérêts du BV tant que les données sont à disposition dans les échantillons d'apprentissage et de validation. Ainsi, selon l'application qui est faite du modèle de prévision hydrologique développé, cela peut représenter un réel avantage d'implémenter un modèle d'apprentissage automatique plutôt qu'un modèle hydrologique traditionnel.

Les combinaisons testées ont été nombreuses et, comme indiqué plus haut, une seule règle régit les essais : la présence minimale d'une variable météorologique et d'une variable d'état.

Les essais menés se décomposent en différentes phases selon l'information qui est intégrée. Ainsi, se retrouvent des essais sur la précipitation, la température, les variables dérivées de la précipitation, l'humidité du sol, le débit. Le modèle hydrologique développé fait de la prévision à court terme et à travers les lectures faites, il est décidé qu'aucune variable climatique ne sera intégrée comme intrant. Par variable climatique, on fait ici référence à une variable qui fournit une tendance sur un temps long et/ou sur une vaste région. On les distingue des variables météorologiques utilisées dans cette thèse qui, elles, ont des variabilités spatiale et temporelle beaucoup plus importantes. Parmi les variables climatiques les plus communes et ayant un impact sur les régions à l'étude, on peut citer entre autres l'oscillation d'El Nino, l'oscillation nord Atlantique, l'oscillation de Madden-Julian.

On peut regrouper les configurations testées (Tableau 5.2) par groupe selon la classification arbitraire mais malgré tout utile :

- configurations 1 à 4 : rôle de la précipitation, de la température et de l'évapotranspiration potentielle avec le débit comme variable d'état ;
- configurations 5 à 10 : rôle de l'humidité du sol en surface ou en profondeur comme variables d'état, et ;
- configurations 11 à 17 : rôle de la précipitation selon la façon dont cette variable est intégrée dans le modèle : précipitation (11), API (12, 14 et 16) ou API_{mod} (13, 15 et 17).

Tableau 5.2 – Configurations d'intrants testées. Les indices 0 et 1 correspondent au pas de temps présent et au jours suivant

Configu- ration	Variables météo	Variables d'état	Configu- ration	Variables météo	Variables d'état
1	P ₀ , P ₁	Q ₀	10	P ₀ , P ₁ , ETP ₀	Q ₀ , Hupro ₀
2	P ₀ , P ₁ , T ₀ , T ₁	Q ₀	11	P ₀ , P ₁ , T ₀	Q ₀
3	P ₀ , P ₁ , T ₀ , T ₁ , ETP ₀	Q ₀	12	API ₀ , T ₀ , T ₁	Q ₀
4	P ₀ , P ₁ , ETP ₀	Q ₀	13	API _{mod} ₀ , T ₀ , T ₁	Q ₀
5	P ₀ , P ₁ , T ₀ , T ₁	Q ₀ , Hu ₀	14	API ₀	Q ₀
6	P ₀ , P ₁ , T ₀ , T ₁	Q ₀ , Hupro ₀	15	API _{mod} ₀	Q ₀
7	P ₀ , P ₁	Q ₀ , Hu ₀	16	API ₀ , T ₀ , T ₁	Q ₀ , Hu ₀
8	P ₀ , P ₁	Q ₀ , Hupro ₀	17	API _{mod} ₀ , T ₀ , T ₁	Q ₀ , Hu ₀
9	P ₀ , P ₁ , ETP ₀	Q ₀ , Hu ₀			

L'utilisation de nouvelles variables en plus de celles utilisées dans les configurations du Chapitre 4 n'est pas concluante (Figure 5.7 et Figure 5.8). L'intégration de l'API ou de l'API_{mod} ne permet pas d'apporter de plus-value au RNA et semble même au contraire le défavoriser. L'interprétation possible à apporter à ce comportement vient du lissage temporel intégré dans le calcul de ces deux indices. L'API et l'API_{mod} ajoutent de l'information sur une fenêtre temporelle déterminée en fonction des caractéristiques de chaque BV, ici autour de sept jours pour l'API et, de par sa définition, jusqu'à environ vingt jours de manière significative au maximum pour l'API_{mod}. Cette définition même de ces indices lisse donc en partie l'information fournie par une nouvelle journée de précipitation. Ainsi, l'utilisation de l'API et de l'API_{mod} n'est pas préconisée dans ce type d'approche. Au lieu de faire appel à de tels indices qui intègrent une composante temporelle, on pourrait plutôt penser changer la structure interne du RNA et développer un modèle LSTM. Avec ce type d'approche, l'évolution des événements hydrologiques seraient directement intégrée dans la structure interne du modèle. Le

modèle pourrait alors apprendre avec plus de succès à utiliser ces séquences temporelles pour en extraire l'information la plus utile.

L'autre variable qui ne rencontre pas de succès est l'ETP. L'intégration d'une telle variable dégrade même grandement les scores, que ce soit en apprentissage ou en validation. Le RNA n'arrive donc simplement pas à utiliser l'information issue de cette variable. Il ne l'ignore même pas, auquel cas les scores seraient identiques à une configuration d'intrants identiques sans l'ETP. Des essais avec une variable représentant la précipitation moins l'évapotranspiration ne sont pas concluants. En effet, celle-ci renseigne sur le changement de teneur en eau dans le sol sur un horizon de temps, donc sur le changement d'humidité du sol et pas sur une valeur représentative de la teneur en eau dans le sol. Le constat est le même, avec la même tendance, à savoir une chute des performances du modèle de prévision sur les sept jours de prévision.

En conclusion, on relève que les meilleures combinaisons sont celles qui intègrent plusieurs variables météorologiques et plusieurs variables d'état. Sur les quatre BV à l'étude, la meilleure configuration d'intrants est celle qui utilise la précipitation, la température moyenne au pas de temps présent et à venir, ainsi que le débit et l'humidité du sol au pas de temps présent.

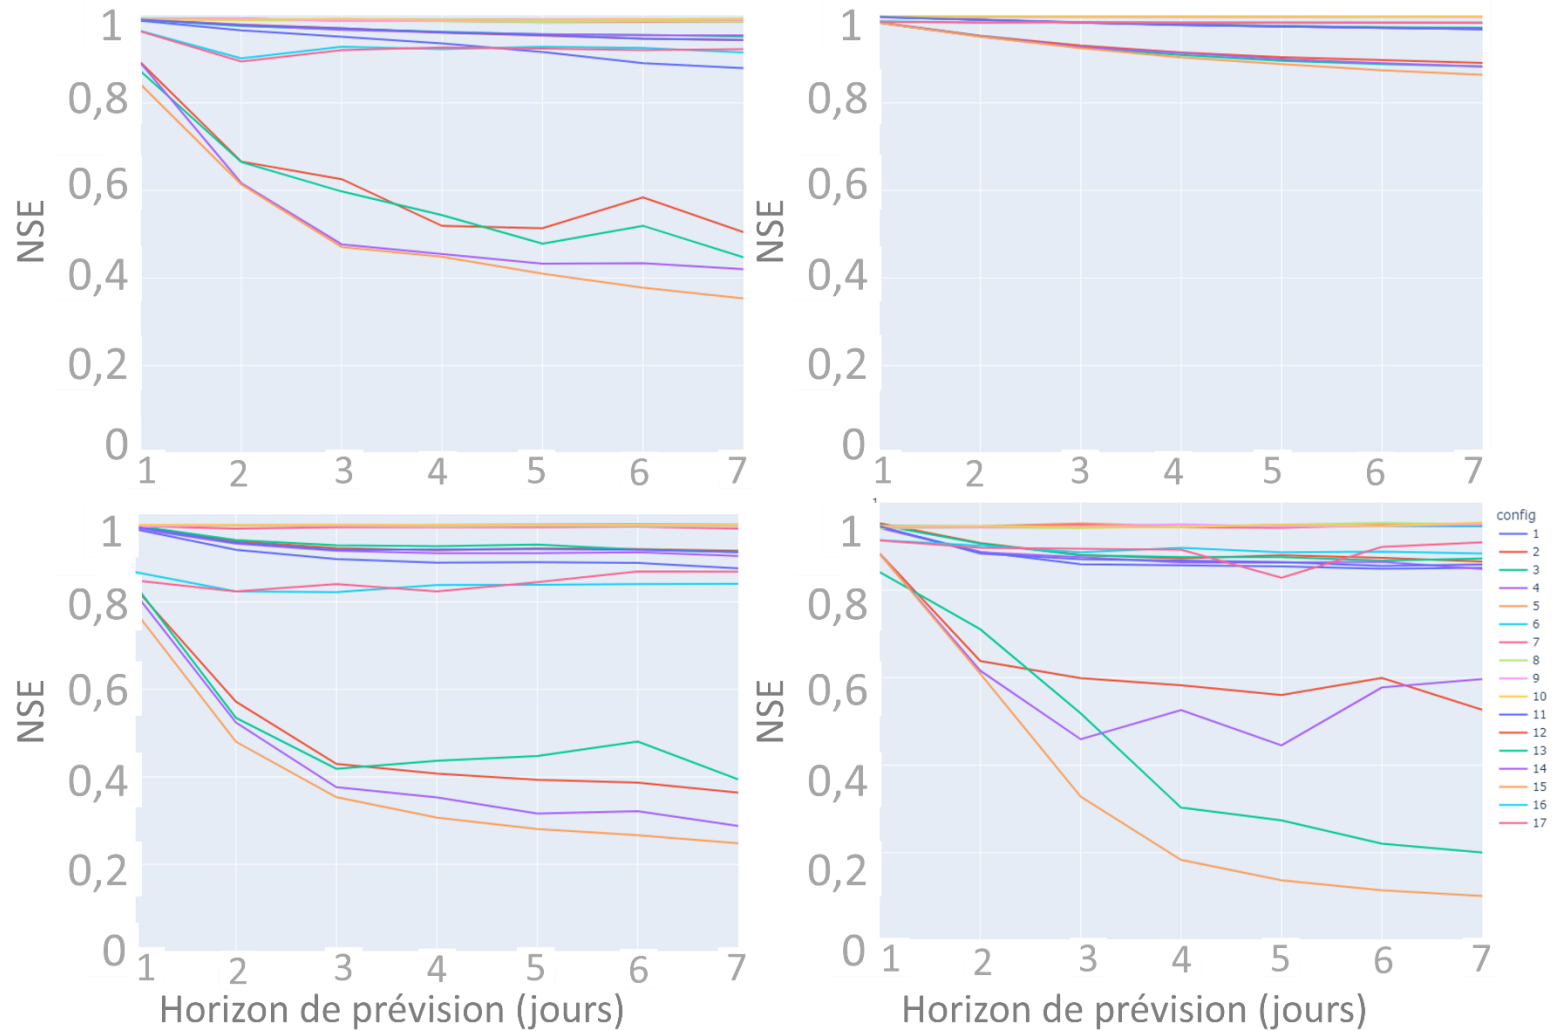


Figure 5.7 – Évolution du NSE selon l'horizon de prévision sur la période d'apprentissage lorsque 2009 est la période de validation pour 17 configurations d'intrants pour les BV a) Au Saumon, b) Magog, c) Androscoggin et d) Susquehanna.

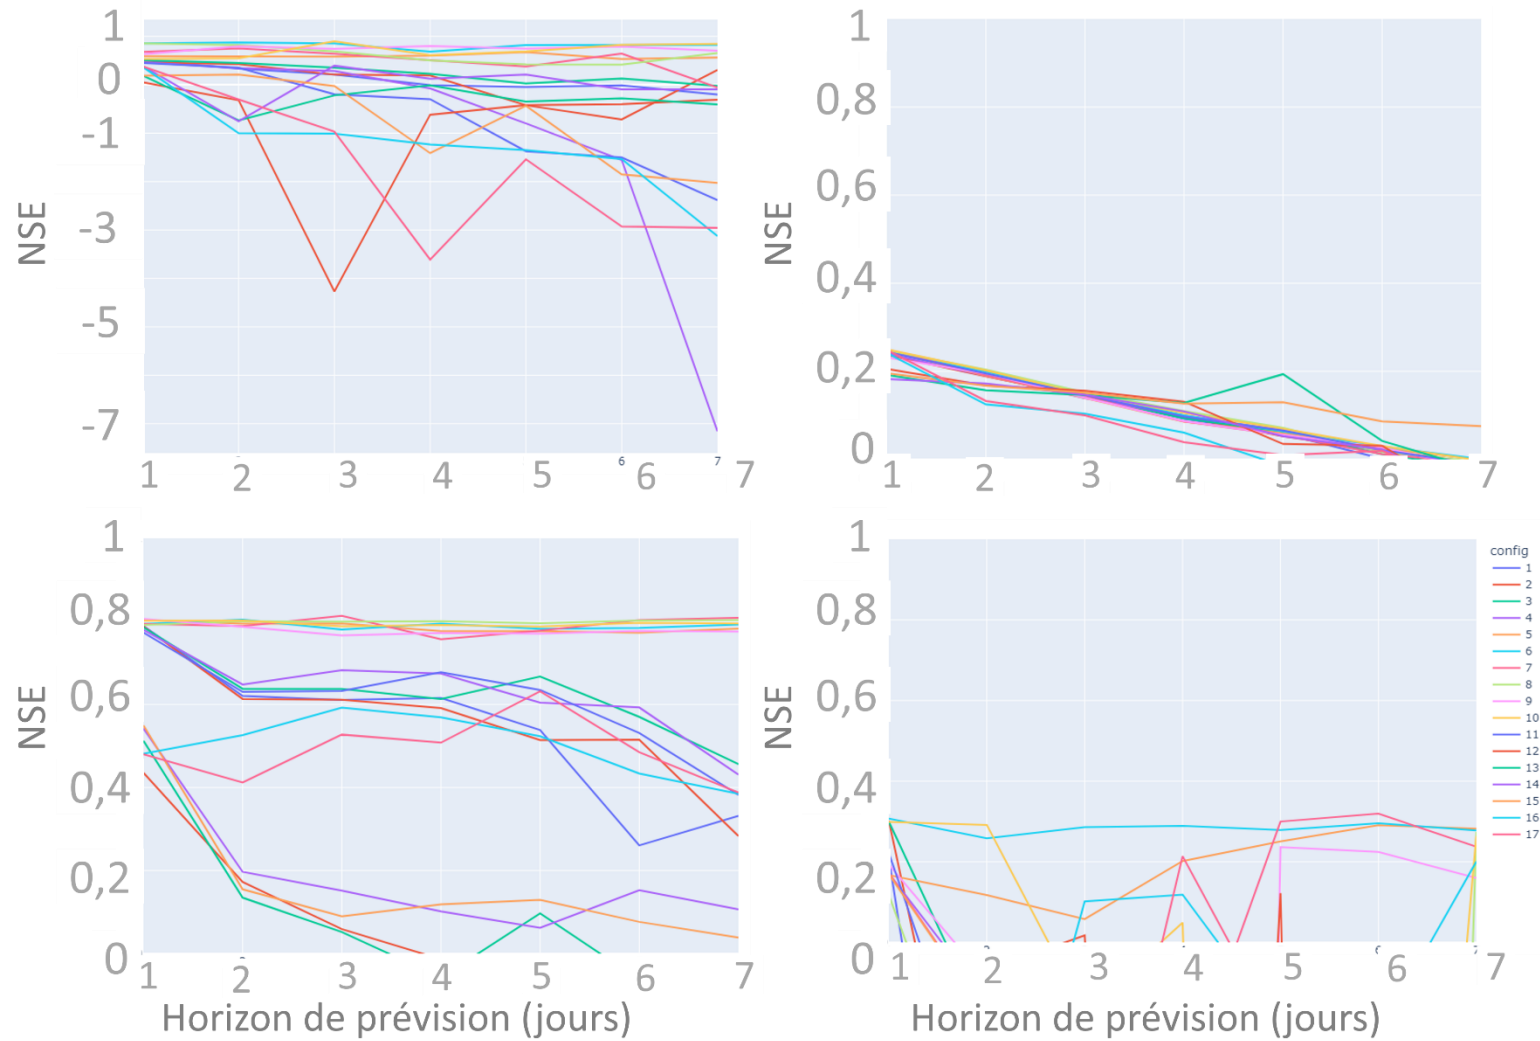


Figure 5.8 – Évolution du NSE selon l'horizon de prévision sur la période de validation (2009) pour 17 configurations d'intrants pour les BV a) Au Saumon, b) Magog, c) Androscoggin et d) Susquehanna.

5.3. Rôle de la spatialisation pour le BV Au Saumon

Une étude un peu plus poussée sur la spatialisation des intrants a été menée sur le BV Au Saumon. Au total, ce sont trois types de spatialisation qui sont prises en compte : global, semi-spatialisé et spatialisé. Le modèle global et le modèle spatialisé se caractérisent de la même manière que dans le Chapitre 4. Le modèle semi-spatialisé prend en compte chaque UHRH comme unité individuelle ; une valeur pour chaque UHRH de chaque variable utilisée en entrée du RNA est prise en compte comme intrant au modèle.

L'analyse du NSE en validation entre les trois spatialisations montrent des résultats très proches entre les modèles global et spatialisé (Figure 5.9). Le modèle semi-spatialisé fournit des résultats qui ne sont pas mauvais mais qui restent néanmoins moins bons que les deux autres. Le NSE médian du modèle spatialisé se situe entre 0,5 et 0,6, alors qu'il est entre 0,7 et 0,8 pour les modèles global et spatialisé. Cela montre donc qu'une discrétisation trop fine du BV, ici avec deux cent cinq UHRH, pénalise le RNA par rapport à un modèle global ou à une discrétisation plus grossière, comme la représentation spatialisée basée sur six pixels. Cela n'est pas sans rappeler la notion de zone d'élément représentative (REA, *Representative Element Area*) développée par Wood et al. (1988) et reprise et complétée ensuite par Blöschl et al. (1995). Une REA se définit comme la plus petite zone d'un territoire sur laquelle une mesure sera représentative de l'ensemble du territoire. Leurs recherches menées avec le modèle à base physique TOPMODEL montrent en particulier que la topographie est une variable clef pour déterminer la taille d'une REA, alors que la durée d'un épisode précipitant est secondaire. De plus, l'approche par REA est applicable à tout BV. Par rapport au travail fait dans cette thèse, il serait prometteur d'utiliser le concept de REA pour discrétiser le BV et définir un RNA semi-spatialisé de qualité. En effet, une discrétisation trop fine basée sur les UHRH comme celle fournie par HYDROTEL semble pouvoir pénaliser le RNA. De prime abord, la définition des UHRH pourrait s'approcher du concept de REA. Cependant, l'insuccès rencontré lors de la modélisation par RNA avec une discrétisation du territoire dessinée par HYDROTEL rejoint probablement les doutes et limites évoqués par Fan et Bras (1995) à propos des REA. Ils soulignent en effet que la définition de REA n'est pas aussi robuste que présentée dans les articles de référence (dont en particulier Wood et al. (1988)), notamment à cause d'une absence

de correspondance avec la réalité dont une forte dépendance aux types d'événements précipitants qui affectent le territoire²².

En revanche, quelle que soit la spatialisation utilisée, le comportement selon la combinaison d'intrants retenus n'est pas très différent. Quelle que soit la spatialisation retenue, les résultats obtenus précédemment sont validés : l'intégration du débit en complément de l'humidité du sol comme intrant au modèle permet au modèle de RNA de faire de meilleures prévisions. L'écart de NSE est d'environ 0,05 entre les deux combinaisons d'intrants (Figure 5.10).

En regardant les résultats sur chaque année de validation individuellement et avec l'évolution selon l'horizon de prévision, cela fait ressortir des comportements particuliers. Tout d'abord, l'intégration du débit comme intrant au RNA améliore toujours les prévisions (lignes pleines au-dessus des lignes pointillées, Figure 5.10). Seules les années 2009 et 2012 présentent un comportement contraire. 2012 et 2001 sont les deux années de validation pour lesquelles le RNA ne performe pas bien (NSE négatif à tous les horizons) pour les six essais effectués. À part les deux années citées, le NSE est tout le temps supérieur à 0,4, avec pour le modèle global huit années sur douze avec un NSE supérieur à 0,8. Comme sur le BV Androscoggin (Chapitre 4) et sur les quatre BV de manière générale (section précédente du présent chapitre), une amélioration du NSE est visible avec l'utilisation seule de l'humidité du sol comme variable d'état pour certaines années de validation (lignes pointillées, Figure 5.10). Cet effet de mémoire est particulièrement visible en 2005 et 2010 pour les modèles global (rouge) et spatialisé (bleu). En revanche, cette tendance n'est jamais observée pour le modèle semi-spatialisé (vert) ; cela semble être lié au trop grand nombre d'informations qui brouillent le RNA développé.²³

Par ailleurs, l'évolution avec l'horizon de prévision est plus sujette à changement selon l'année de validation concernée mais globalement une diminution du NSE est visible entre J+1 et J+7. Cela se vérifie pour les trois spatialisations et les deux combinaisons d'intrants considérées. Il

²² Cette remarque semble d'ailleurs aller à l'encontre d'un des résultats de l'article de base (Wood et al., 1988) dans lequel les auteurs avancent que le rôle d'un événement précipitant est limité pour définir les REA.

²³ On pourrait ici envisager de faire une nouvelle paramétrisation du RNA pour tenter d'améliorer les prévisions avec un modèle semi-spatialisé. En effet, le grand nombre d'intrants pourrait pénaliser le modèle tel qu'il a été développé initialement.

est d'ailleurs important de noter que l'évolution est très similaire pour les trois spatialisations avec des écarts qui restent constants sur les sept jours de prévision.

Au-delà des années pour lesquelles les résultats sont mauvais (2001 et 2012), quelques anomalies sont observées, comme des oscillations du NSE avec l'horizon de prévision, en particulier pour le modèle semi-spatialisé avec utilisation du débit comme intrant au modèle (ligne verte pleine, Figure 5.10). Les années 2007 et 2009 illustrent très bien cette situation avec une tendance qui change à chaque horizon : alternance entre amélioration et diminution du NSE sur les sept jours de prévision. Cette inconstance dans les prévisions avec l'horizon de prévision n'est pas bien expliquée, i.e. les raisons qui amènent à cette tendance ne sont pas évidentes. Pour tenter de mieux comprendre cet aspect, la métrique de mesure de la constance de la prévision pourrait être calculée. Celle-ci est développée par Pappenberger et al. (2011) et permet de définir si un système de prévision fournit des résultats de qualité relativement similaire sur l'ensemble de la fenêtre de prévision (dans le cas de cette thèse, sur sept jours donc). L'application de cette métrique sur les prévisions faites ici pourrait fournir des éléments de réponse pour comprendre les différences entre les années de validation.




Figure 5.9 – Boîtes à moustache du NSE en validation construites sur les sept horizons de prévision et les quatorze années de la validation croisée pour les trois spatialisations et les deux combinaisons d'intrants testés. glo faisant référence au modèle global, spat au spatialisé et semispat au semi-spatialisé. HU et QHU font références à la variable d'état utilisée, l'humidité du sol seule ou combinée avec le débit.

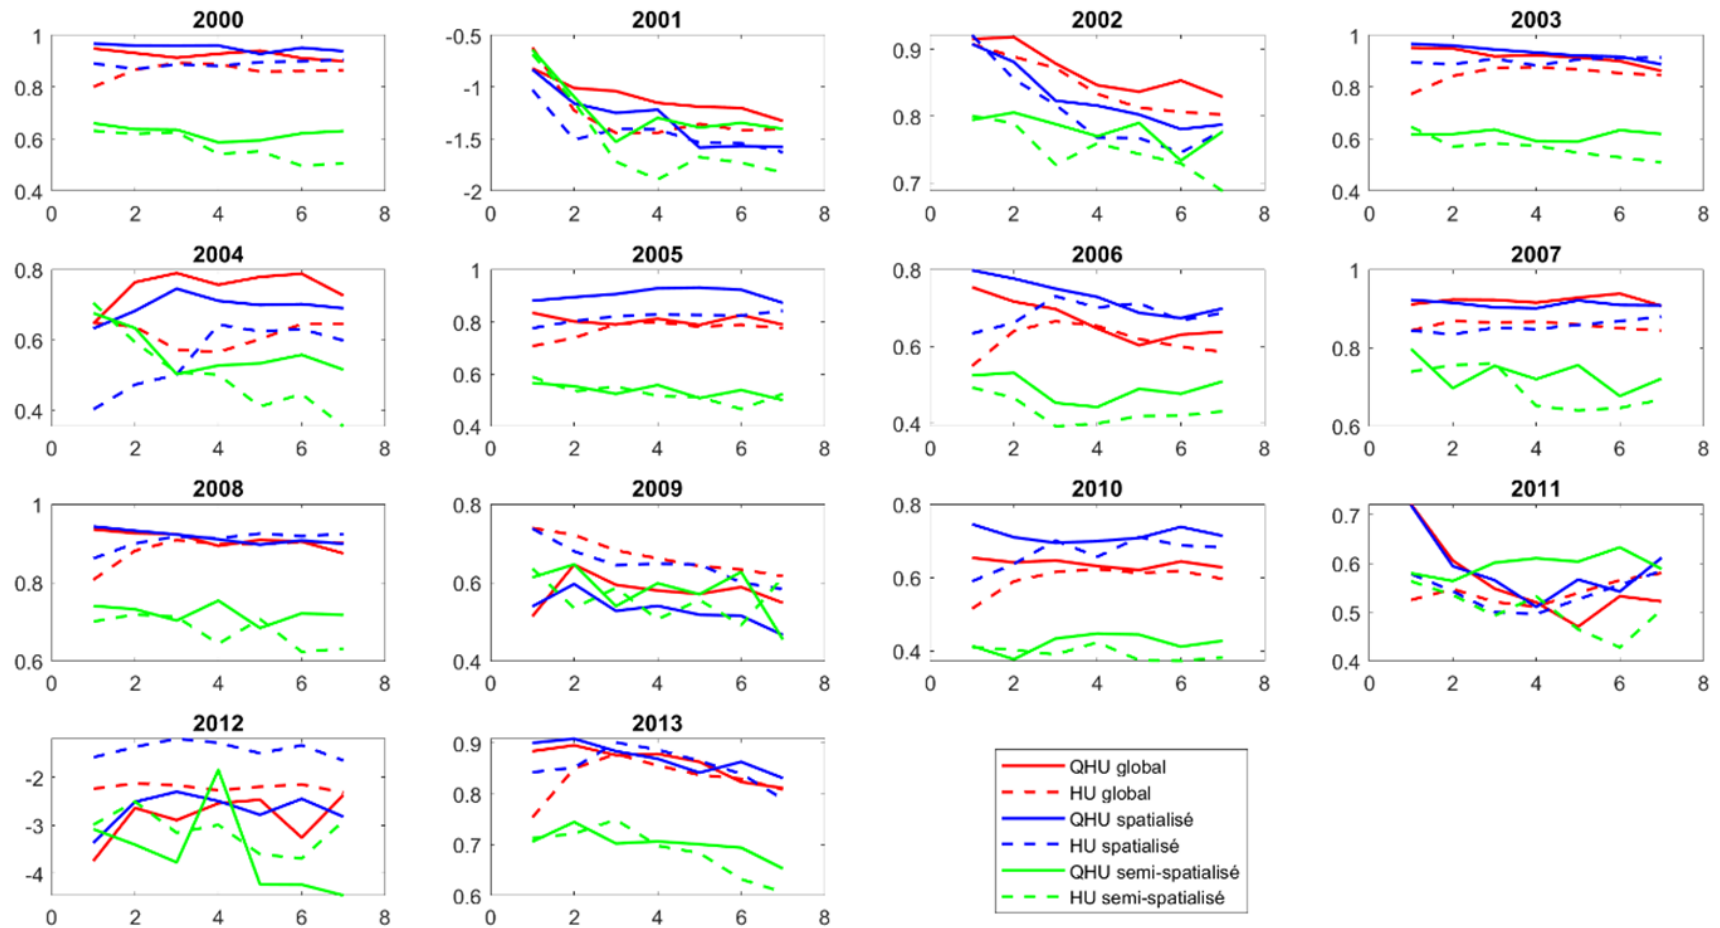


Figure 5.10 – Évolution du NSE en validation sur les sept horizons de prévision pour chaque année de validation (correspondant à une sous-figure) et pour les trois spatialisations et les deux combinaisons d'intrants testés.

Les hydrogrammes complètent l'analyse faite sur le NSE avec une vision plus précise des écarts entre le modèle semi-spatialisé (vert) et les modèles global (rouge) et spatialisé (bleu, Figure 5.11). Le choix est fait de comparer les hydrogrammes seulement pour la configuration d'intrants utilisant à la fois le débit et l'humidité du sol en surface comme variables d'état. Le pic de crue de grande ampleur de fin octobre 2003 est manqué par le modèle semi-spatialisé, qui sous-estime de moitié l'ampleur de la crue tant à J+1 (a) qu'à J+7 (b). De plus, la forte disparité entre les valeurs d'humidité du sol, précipitation et température (due au grand nombre d'UHRH) fait sur-réagir le modèle avec des pics de crue en réponse à chaque événement précipitant tout au long de l'été. Les modèles global et semi-spatialisé sont bien meilleurs dans la gestion de ces événements mineurs. En 2009 (c et d), le modèle semi-spatialisé fait jeu égal avec les deux autres spatialisations. Ce comportement, déjà observé avec le NSE (Figure 5.10), se confirme ici. Les pics de début et de fin d'été sont mieux prévus (proche de l'observé contre surestimation pour les deux autres), mais le modèle semi-spatialisé est ensuite pénalisé par le nombre important de pics de crue secondaires prévus.

Les hydrogrammes sur les treize années de validation successivement utilisées permettent de conforter ces observations et analyses. Les modèles global et spatialisé ont des performances équivalentes. En revanche, le modèle semi-spatialisé, avec sa fine discrétisation spatiale, est pénalisé et fournit des prévisions moins bonnes que ces deux modèles. Ces analyses montrent donc qu'une décomposition du territoire en différents sous-bassins ne nuit pas aux bons résultats du modèle de RNA, pour autant que la division ne soit pas trop fine, en accord avec le concept de REA évoqué plus haut. L'utilisation de données d'observation au sol ou par télédétection pourrait ainsi être envisagé de manière légitime dans un environnement réel. Cependant, avec les analyses en environnement virtuel de cette dernière section, un réseau de mesures au sol trop dense ou une image satellitaire avec une résolution spatiale très fine pourrait nuire au modèle. Dans le cadre du Chapitre 6 et de l'analyse du comportement du modèle de RNA en environnement réel, on prendra donc garde à la densité du réseau de sondes de mesure de l'humidité au sol et de la résolution spatiale des réanalyses modèle utilisées pour les variables météorologiques.

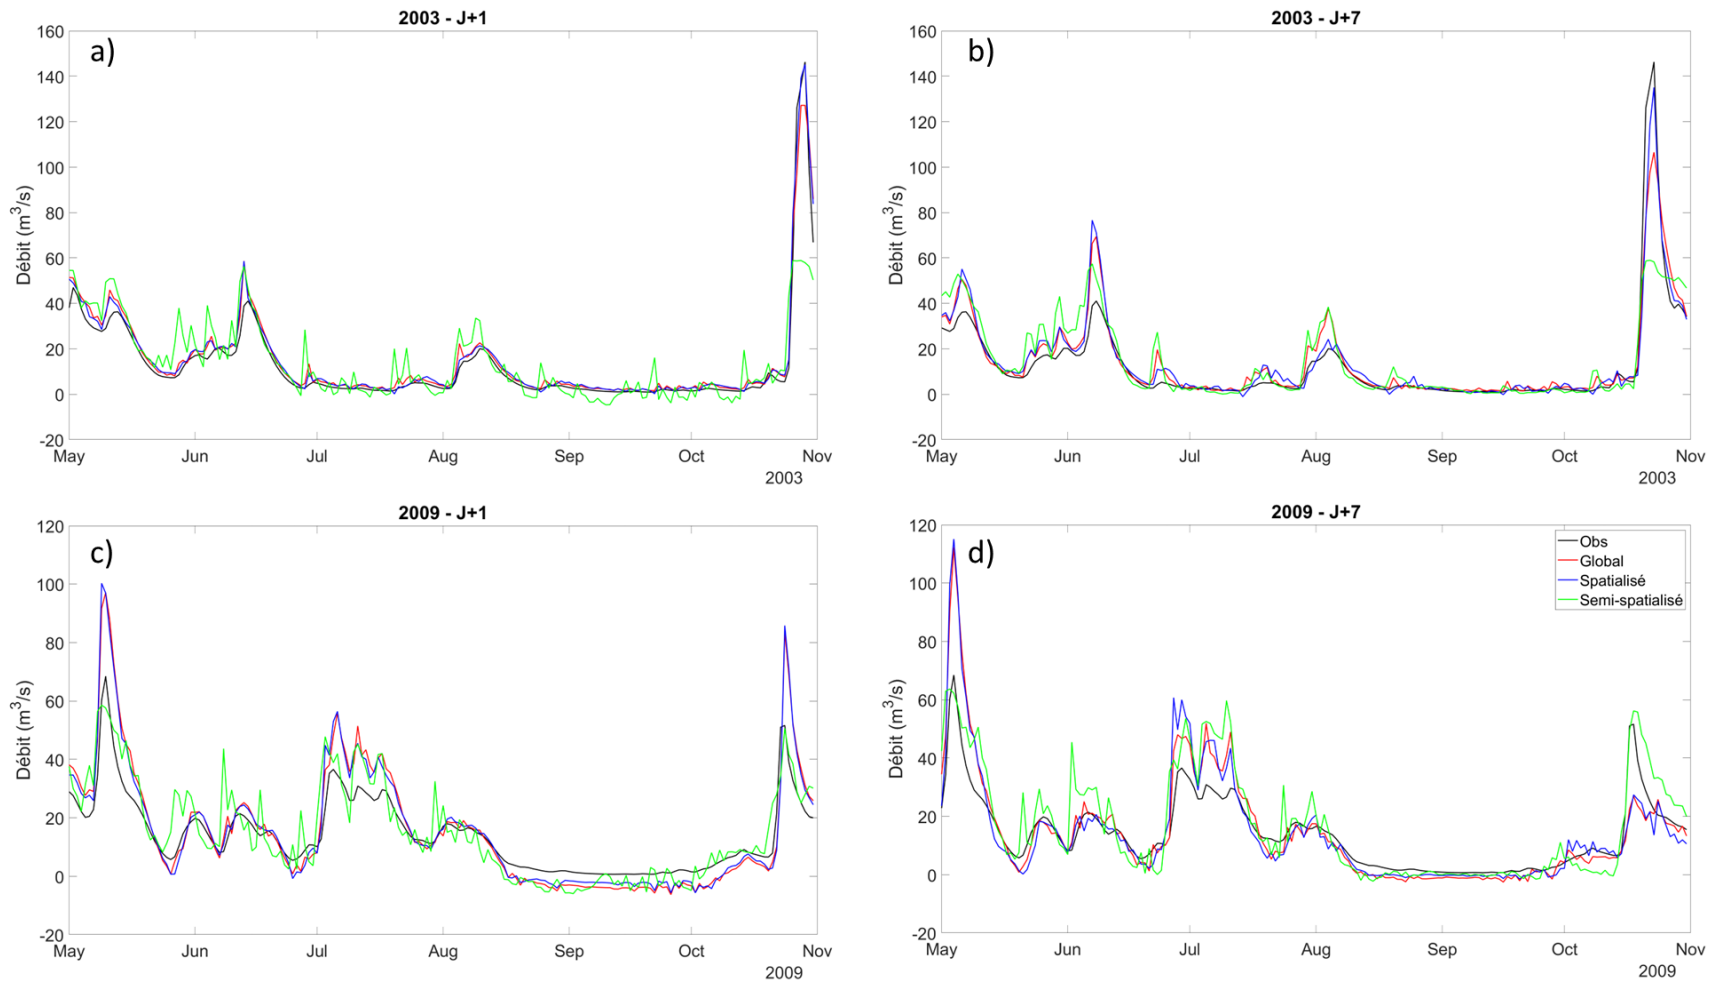


Figure 5.11 – Hydrogrammes en validation pour les années 2003 à J+1 (a) et J+7 (b) et 2009 à J+1 (c) et J+7 (d) avec la configuration d'intrants utilisant débit et humidité du sol comme variables d'état.

5.4. Sommaire

Ce chapitre visait à compléter le chapitre 4 et à fournir des éléments d'analyse supplémentaires en environnement virtuel. La première section s'articule autour de trois axes en ajoutant des analyses sur des points du chapitre 4. Premièrement, une étude du rôle de la période d'apprentissage sur la qualité des prévisions en validation est menée. On montre ici que le modèle de RNA bénéficie d'un apprentissage sur des années hydrologiques du même type (sèche ou humide) que les années de validation. De plus, il est également montré que l'incorporation de toutes les années disponibles en apprentissage ne pénalise pas démesurément le modèle en validation. Les années en apprentissage associées à un régime hydrologique opposé à celui des années en validation ne sont pas rédhibitoire à une bonne robustesse du RNA.

Ensuite, l'analyse du modèle singulier, succinctement faite dans le chapitre 4, est ici complétée en regardant plus en détails le rôle de chaque cellule. En particulier, on détaille l'évolution de la qualité des prévisions pour chaque cellule en fonction de l'horizon de prévision. Ces résultats sont comparés à ceux des modèles global et spatialisé. On observe que certaines cellules fournissent de meilleures prévisions que les deux modèles de référence ; cela se vérifie seulement pour des horizons de prévision particuliers et aucune cellule ne les surpasse sur l'ensemble de la fenêtre de prévision. Cette analyse est faite sur les années 2009 et 2012 prises chacune individuellement en validation. La comparaison entre modèle global et modèle spatialisé a été complétée avec une validation croisée en prenant successivement les seize années du jeu de données de base en validation. Cela a permis de conforter les résultats obtenus dans le chapitre 4, montrant que les résultats sont très similaires et qu'il ne ressort pas de réel avantage à privilégier l'utilisation de l'une des deux spatialisations.

Le chapitre 4 est développé sur les cas d'études des BV Androscoggin et Susquehanna en environnement virtuel. Le chapitre 6, quant à lui, fera la démonstration du passage entre environnements virtuel et réel pour les BV Au Saumon et Magog. Les deux derniers axes de ce chapitre 5 ont donc pour objectif de faire le lien entre les chapitres 4 et 6. On évalue tout d'abord différentes combinaisons d'intrants pour les quatre BV. Au-delà des différences sur la qualité des prévisions, en apprentissage comme en validation, on retient surtout les tendances similaires pour les quatre sites d'étude. La meilleure configuration d'intrants est celle qui utilise le débit

et l'humidité du sol en surface comme variables d'état et les précipitations et températures comme variables météorologiques. Enfin, la dernière analyse porte sur la comparaison de trois discrétisations spatiales des intrants au RNA pour le BV Au Saumon : global, semi-spatialisé et spatialisé. Les modèles global et spatialisé ont des performances proches supérieures à celles du modèle semi-spatialisé. Ce dernier est construit sur la base des deux cent cinq UHRH définis par HYDROTEL. La finesse de cette résolution spatiale, et donc le grand nombre d'intrants, pénalise fortement le RNA par rapport aux deux autres testés. Le concept de REA pour discrétiser le territoire pour définir le modèle semi-spatialisé pourrait donc être une alternative prometteuse.

CHAPITRE 6 DE L'ENVIRONNEMENT VIRTUEL À L'ENVIRONNEMENT RÉEL

6.1. Éléments méthodologiques

6.1.1. Présentation des données d'observation *in situ*

Comme présenté dans le Chapitre 3, les données d'observation d'humidité du sol dans les BV des rivières Au Saumon et Magog couvrent des sites parfois différents sur des périodes de temps différentes sur les quatre années de mesure. 2018 étant l'année de lancement de la campagne de mesure, le choix des sites n'a pas toujours été concluant ; environ un tiers (cinq sur quatorze) indique un sol saturé pendant toute la campagne. Elles présentent des valeurs bien plus hautes que les autres années et surtout sans aucune réactivité particulière aux événements précipitants ou aux épisodes de plus forte chaleur. Le signal ne montre pas de réactions aux différents événements précipitants ou de sécheresse.

D'un point de vue hydrométéorologique, l'année 2019 a de très fortes précipitations fin octobre avec des crues rapides dans les cours d'eau de l'Estrie. L'été 2020 est plutôt sec avec un étiage estival marqué. En 2021, l'été est très sec avec un déficit global d'eau sur la région et des débits très bas durant de longues semaines, synonymes d'un étiage long et sévère. D'après les résultats des chapitres 4 et 5, le modèle de RNA en environnement virtuel fournit des prévisions de meilleure qualité pour des étés hydrologiques qualifiés d'humide que pour ceux qualifiés de sec.

BV Au Saumon

Le débit mesuré à la station 030282 sur les quatre étés pour lesquels on dispose de données *in situ* d'humidité du sol sont très variables (Figure 6.2). 2018 et 2019 sont relativement dans la norme avec des pics de crues réguliers mais des volumes limités. On manquera toutefois le pic de crue du 1^{er} novembre 2019 qui avait fait des ravages en Estrie et en particulier dans les deux BV à l'étude. 2020 et 2021 sont très secs, avec des étiages très sévères (débits qui ne dépassent pas les 25 m³/s en 2021). 2021 est une année très particulière car les pics de crue de l'automne

sont très faibles, illustrant un BV en déficit d'eau et donc un ruissellement plus faible que les autres années à cette saison.

Dans cette recherche, on compare le modèle de RNA selon l'utilisation des mesures en surface (cinq premiers cm) ou des mesures en profondeur (20 cm). Seuls les sites en milieu ouvert disposent de sondes en profondeur et les sites sont instrumentés avec des sondes en profondeur uniquement à partir de 2019. Le nombre de données d'humidité du sol en profondeur est donc limité. De plus, on rappelle que les résultats en environnement virtuel sont moins bons avec l'humidité du sol en profondeur que celle en surface mais restent satisfaisants. Une première analyse est faite en comparant la corrélation entre humidité du sol en surface et humidité du sol en profondeur. On distingue les trois années pour lesquelles on dispose de mesures terrain en profondeur (2019, 2020 et 2021). Les sites de mesure changeant d'une année à l'autre, on est amené à prendre différents UHRH en considération pour entraîner le RNA et donc aussi pour la validation en environnement réel. Ainsi, pour les trois années, on peut calculer la corrélation moyenne sur tous les sites en environnement réel ou UHRH en environnement virtuel (Tableau 6.1). Les calculs en environnement réel révèlent des corrélations moyennes annuelles plus élevées qu'en environnement adapté (Tableau 6.1). Cela peut alors signifier un lien plus fort dans les mesures *in situ* que dans la modélisation du profil vertical d'humidité du sol par HYDROTEL. Les résultats en apprentissage sont plus bas qu'en validation car la période est plus longue (dix-huit années en apprentissage, soit 2000 à 2017 – voir Chapitre 3, contre une en validation), amenant ainsi une diversité plus grande des profils verticaux d'humidité du sol venant d'HYDROTEL. Des conditions particulières certaines années peuvent favoriser une forte corrélation entre les deux profondeurs. Parmi celles-ci, l'année 2021 est particulière car soumise à de forts étiages. Ainsi, on peut légitimement s'attendre à ce que l'évaporation affecte bien plus la couche de surface que la couche intermédiaire (où on mesure l'humidité à 20 cm). Cela est d'autant plus vrai pour les sites avec le moins de végétation. C'est un phénomène appelé *decoupling effect* documenté (Capehart et Carlson, 1997).

Tableau 6.1 – Corrélation moyenne entre données d’humidité du sol en surface et en profondeur selon l’année de validation pour les BV Au Saumon et Magog en apprentissage et validation en environnement adapté et en validation en environnement réel.

	Année de validation	2019	2020	2021
Au Saumon	Apprentissage Adapté	0,813	0,791	0,760
	Validation Réel	0,886	0,882	0,762
	Validation Adapté	0,826	0,833	0,844
Magog	Apprentissage Adapté	0,752	0,653	0,662
	Validation Réel	0,870	0,905	0,718
	Validation Adapté	0,786	0,448	0,787

Les valeurs d’humidité du sol en surface simulées par HYDROTEL sont comparées avec celles observées en faisant une association entre la localisation de chaque station et l’UHRH correspondant. La Figure 6.1 illustre ces différences absolues pour chaque station sur les quatre années d’instrumentation du BV Au Saumon (2018 à 2021) pour les valeurs d’humidité du sol en surface. On note que, au sein d’une même année, la dispersion varie selon les couples sondes-UHRH. Cela signifie que les simulations d’humidité du sol fournies par HYDROTEL présentent une grande variabilité de correspondance avec les observations *in situ*. Ces différences dans les dispersions sont plus marquées pour 2018 et 2020, deux étés pour lesquels les périodes de mesure ont été plus courtes. D’une année à l’autre, on peut observer une variabilité venant des valeurs aberrantes, soit de quelques journées durant l’été pour lesquelles les simulations d’HYDROTEL sont très éloignées des observations *in situ*.

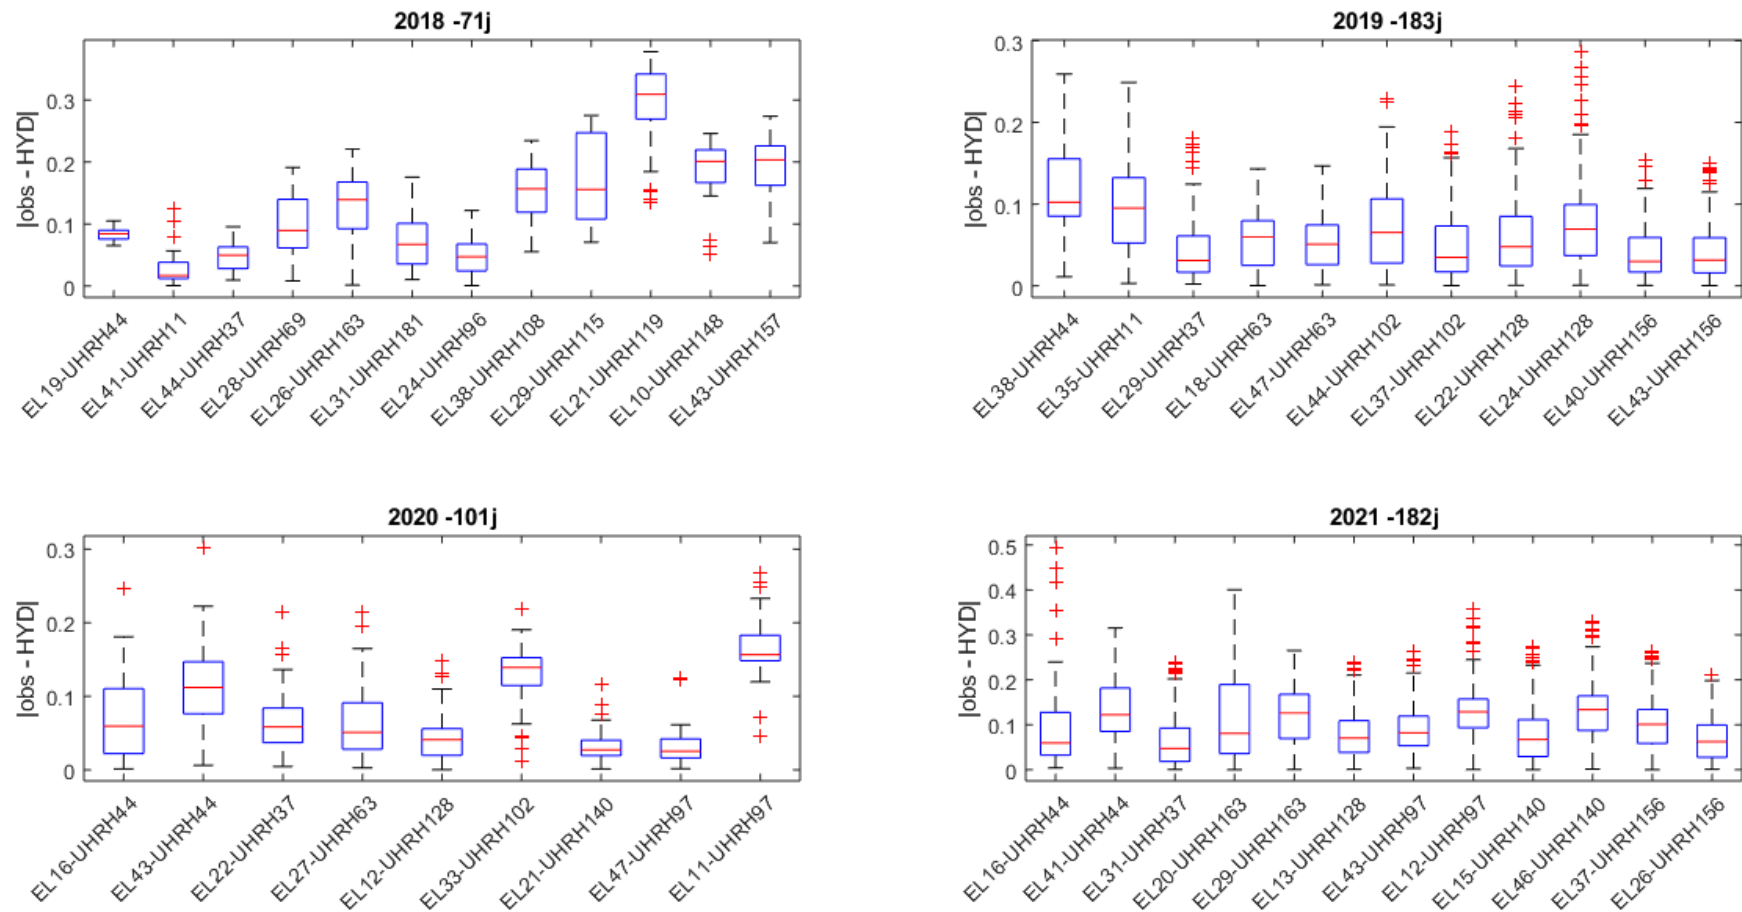


Figure 6.1 – Différence absolue entre les données d'humidité du sol observées in situ et simulées par HYDROTEL par année d'instrumentation (2018 à 2021) pour le BV Au Saumon, avec les numéros des stations et d'UHRH correspondants. Le nombre de jours pour lesquels on dispose de données d'observations est indiqué à titre indicatif en titre de chaque sous-figure.

La distribution des sondes d'humidité du sol sur le BV Au Saumon est relativement homogène dans l'espace et dans le temps, c'est-à-dire que sur les quatre années de mesure, on dispose de mesures dans des zones très différentes du BV et plusieurs sites sont les mêmes d'une année sur l'autre. La répartition selon l'occupation du sol est également équilibrée entre milieux ouverts et milieux forestiers.

Parmi les quatre campagnes de mesure, les données de débit observé sont interrompues pour plusieurs jours en 2019 et 2021 (Figure 6.2). En 2019, les données sont manquantes entre les 12 et 29 juillet inclus ; en 2021, c'est la période du 07 au 20 mai inclus qui manque. Lorsque le débit n'est pas utilisé comme intrant au modèle, le RNA est en mesure de fournir une prévision du débit pour ces dates-là. En revanche, ce n'est pas le cas lorsque le débit est pris comme intrant. En effet, le modèle de RNA ne peut pas tourner si un des intrants présente des valeurs manquantes ; aucune substitution de ces valeurs-là n'est faite par le RNA. Aucun remplacement n'ayant été fait en amont, les périodes avec absence de données de débit observé sont retirées. Ainsi, les périodes avec débit manquant sont simplement retirées du jeu de données pour les essais utilisant le débit comme variable d'état en intrant au modèle, soit les essais 3, 4, 7, 8, 11 et 12. La description de ces essais est présentée à la section 6.1.2 et ceux-ci sont résumés dans le Tableau 6.2.




Figure 6.2 - Débit moyen journalier à la station Au Saumon pour les années 2018 – 2022 avec superposition des précipitations moyennes journalières issues des réanalyses ERA5-land. En rouge, les périodes pour lesquelles on dispose d’observations in situ d’humidité du sol.

BV Magog

La série temporelle de débit utilisée pour le BV Magog est une reconstruction à partir des données des stations des rivières Clyde et Black, respectivement les stations USGS 04296500 et 0529600. Ces deux rivières ont une confluence commune au sud du lac Memphrémagog au niveau du pont de la route 5 à Newport (VT). Les débits sont reconstruits pour tenir compte de l'aire drainée entre la localisation exacte des stations et la confluence des rivières. L'aire drainée additionnelle est fournie via l'utilisation d'un modèle numérique d'élévation et en appliquant un traitement avec l'outil d'accumulation de flux sur un logiciel de traitement de données géospatiales, dans le cas présent ArcMAP. La rivière Barton dispose également d'une station (USGS 04296280), mais n'est pas incluse dans cette reconstruction car elle ne dispose de mesures qu'à partir du 16 juillet 2010, contre le 1^{er} janvier 1975 pour les deux autres stations. L'aire totale drainée par les rivières Clyde et Black telle que prise après reconstruction couvre 717 km², soit 36 % des 1979 km² du BV de la rivière Magog. L'aire drainée est située dans la partie aval du BV, uniquement aux États-Unis (Figure 6.4).

Le profil hydrologique est similaire à celui du BV Au Saumon avec des étés 2018 et 2019 relativement dans les normales, une fin d'automne 2019 avec un événement extrême et les étés 2020 et 2021 associés à des étiages sévères (Figure 6.5).

Les sondes d'humidité du sol installées sur le BV de la rivière Magog sont toutes situées dans la partie canadienne, principalement sur les bords est et nord du lac Memphrémagog. À la vue de la taille du BV et de son occupation du sol relativement homogène, on fait l'hypothèse que les phénomènes hydrologiques du BV Magog sont régis de manière suffisamment proche sur l'entièreté du territoire pour qu'un ensemble de mesures dans un sous-bassin soit représentatif du reste du BV. De plus, on respecte toujours une installation dans des milieux ouverts et dans des milieux forestiers pour conserver une représentation de l'hétérogénéité dans l'évolution de la teneur en eau dans le sol selon les milieux. Bien qu'aucune des stations d'humidité du sol *in situ* ne soient situées dans l'aire drainée de la station hydrométrique fictive pour laquelle les débits ont été reconstruits comme détaillés précédemment, on émet l'hypothèse que les données d'humidité du sol mesurées restent pertinentes à utiliser. Cette hypothèse repose sur le fait qu'à l'échelle du territoire drainée et du territoire couvert par les mesures *in situ*, la climatologie est

la même et la physiographie également. Ainsi, on s'attend à ce qu'un événement précipitant ait des répercussions identiques sur les deux zones.

Comme pour le BV Au Saumon, lorsque les données d'humidité du sol en profondeur servent d'intrant au RNA, seules trois années sont utilisées en validation : 2019, 2020 et 2021. De plus, les mesures en profondeur en sont disponibles que pour les sites en milieu ouvert. La corrélation entre mesures en surface et mesures en profondeur est ici aussi forte (Tableau 6.1).

Enfin, si on souhaite dresser un bilan commun aux deux BV, on peut dire que les mesures d'humidité du sol en surface et celles en profondeur sont fortement corrélées (Tableau 6.1). Des écarts dans la corrélation moyenne sont observés entre les deux BV, avec notamment des différences plus importantes en environnement adapté qu'en environnement réel. Pour les deux BV, la tendance d'une année de validation à l'autre est identique, à savoir une tendance générale (mais pas exclusive) à avoir une corrélation moyenne plus forte avec 2019 comme année de validation que 2020, elle-même plus forte que 2021. Ce qui s'explique par les nombreuses similitudes entre les deux BV d'un point de vue physiographique dont en particulier l'occupation du sol mais aussi d'un point de vue hydro-climatique. Ils sont soumis aux mêmes phénomènes météorologiques synoptiques et seuls les phénomènes locaux tels que les orages sont spécifiques à l'un ou à l'autre.

Comme pour le BV Au Saumon, la Figure 6.3 illustre la différence entre l'humidité du sol simulée par HYDROTEL et celle observée *in situ*. L'analyse est très similaire entre les deux BV. Pour le BV Magog aussi, on observe une variabilité intra-annuelle entre stations plus grande qu'une variabilité interannuelle.

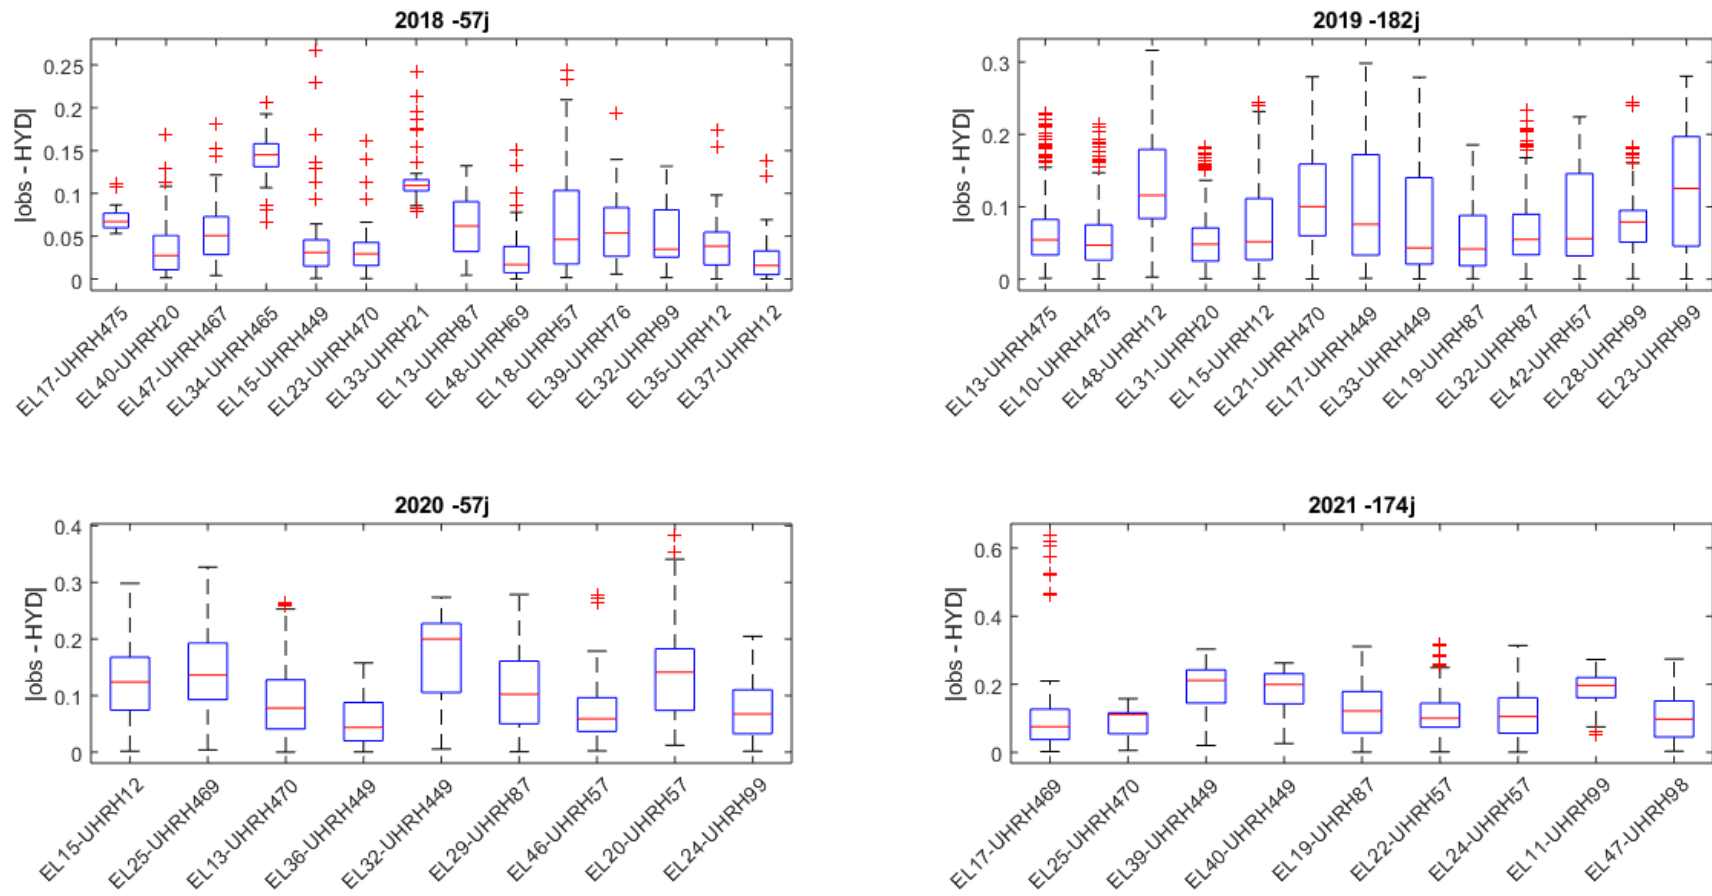


Figure 6.3 – Différence absolue entre les données d'humidité du sol observées in situ et simulées par HYDROTEL par année d'instrumentation (2018 à 2021) pour le BV Magog, avec les numéros des stations et d'UHRH correspondants. Le nombre de jours pour lesquels on dispose de données d'observations est indiqué à titre indicatif en titre de chaque sous-figure.

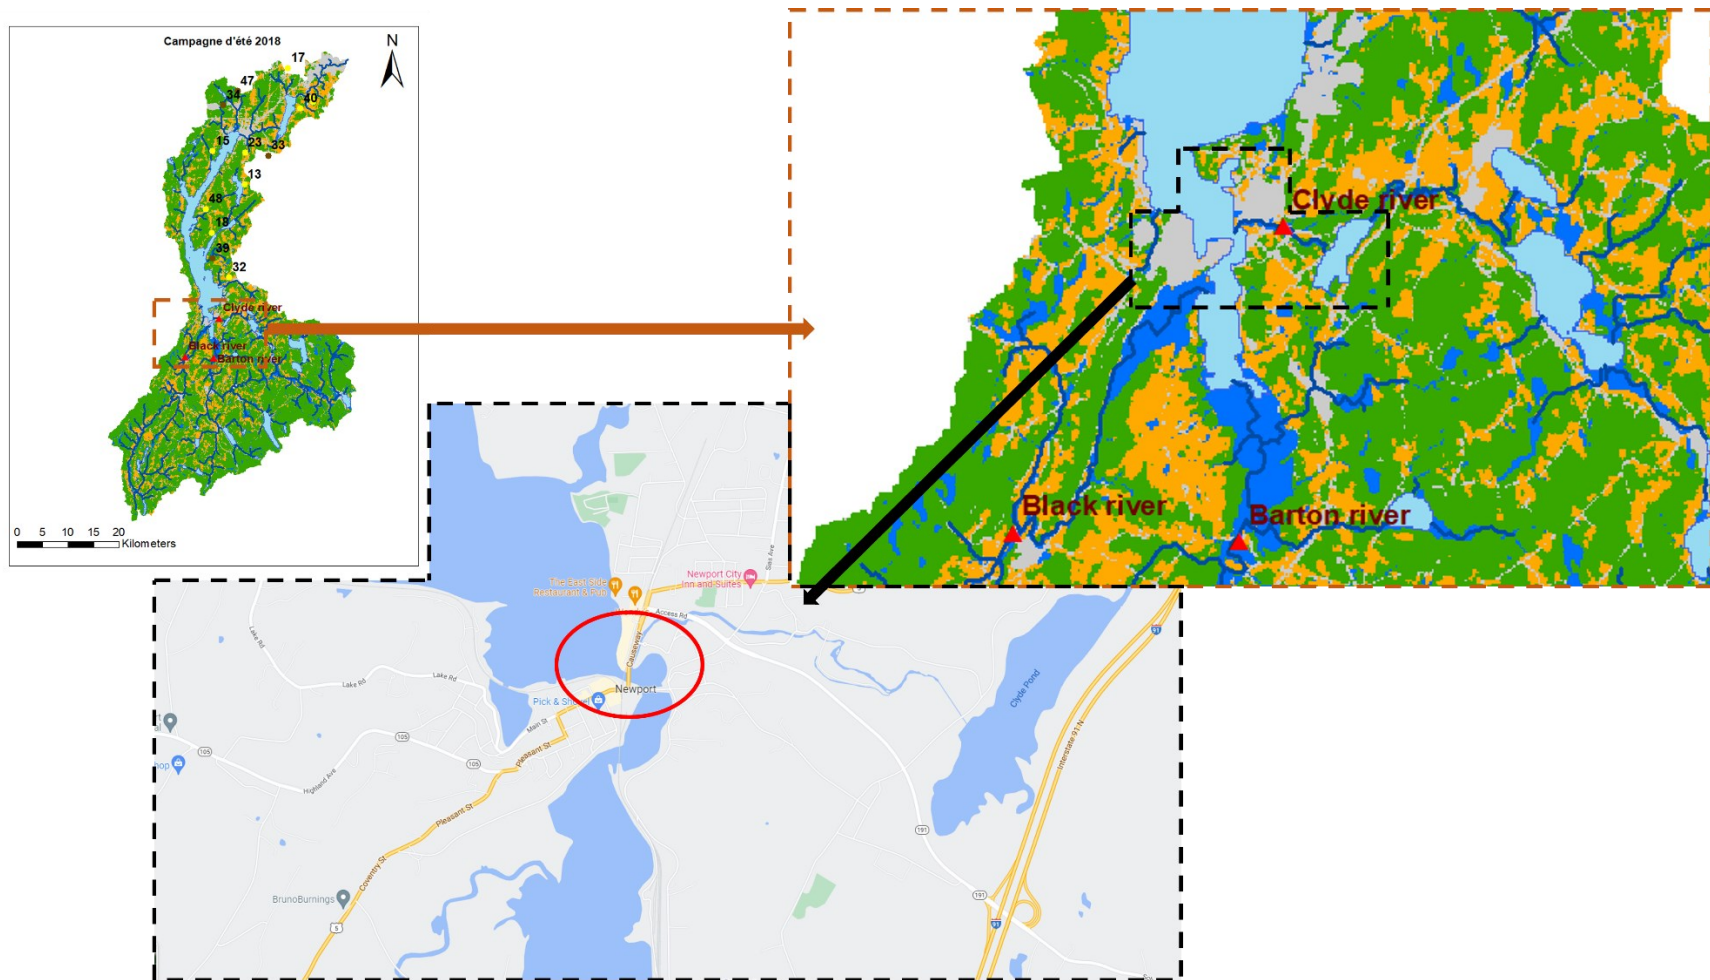


Figure 6.4 - Localisation de la station fictive après confluence des rivières Clyde et Black.




Figure 6.5 - Débit moyen journalier reconstruit au pont de la route 5 à Newport (VT) pour les années 2018 – 2022 avec superposition des précipitations moyennes journalières issues des réanalyses ERA5-land. En rouge, les périodes pour lesquelles on dispose d'observations in situ d'humidité du sol.

6.1.2. Modèles testés

Huit combinaisons d'intrants sont prises en compte, ainsi que deux approches différentes lorsque l'humidité du sol en surface est utilisée. Au total, douze modèles sont donc testés pour chacun des BV Au Saumon et Magog, conformément au Tableau 6.2. Huit sont liés à l'utilisation de l'humidité du sol en surface (1 à 8) et quatre à l'humidité du sol en profondeur (9 à 12). Lors de l'utilisation de l'humidité du sol en surface, on distingue deux approches pour extrapoler dans le temps les mesures sur tous les sites instrumentés d'un BV : l'approche par moyenne (1 à 4) et celle par la méthode des plus proches voisins (5 à 8).

Tableau 6.2 – Caractérisation des essais effectués. P = précipitation, Tn = température minimale, Tx = température maximale, Hu_{surf} = humidité du sol en surface, Q = débit, Hu_{prof} = humidité du sol en surface en profondeur.

Appellation de l'essai	Variables météorologiques	Variables d'état	Méthode de correction des données manquantes
1	P, Tn, Tx	Hu _{surf}	Moyenne
2	P	Hu _{surf}	
3	P, Tn, Tx	Hu _{surf} , Q	
4	P	Hu _{surf} , Q	
5	P, Tn, Tx	Hu _{surf}	Plus proche voisin (ppv)
6	P	Hu _{surf}	
7	P, Tn, Tx	Hu _{surf} , Q	
8	P	Hu _{surf} , Q	
9	P, Tn, Tx	Hu _{prof}	Moyenne
10	P	Hu _{prof}	
11	P, Tn, Tx	Hu _{prof} , Q	
12	P	Hu _{prof} , Q	

De plus, les séries temporelles de mesures d'humidité du sol n'ont pas nécessairement toute la même longueur. Cela vient des dates d'installation ou de retrait qui peuvent varier selon les années et la localisation sur le BV. Il y a pu y avoir des bris durant la saison (fils débranchés ou mal branchés, rupture de câbles par des rongeurs), des autorisations d'accès et d'installation par les propriétaires des sites qui arrivent plus tard dans la saison ou le matériel qui n'est pas encore entièrement prêt lors de la première installation (manque de batteries). Bref, autant de raisons qui, pour le traitement des données récoltées, amènent à mettre en place une méthode d'extrapolation des données dans le temps de manière à les bien les intégrer aux RNA. Cette méthode est maintenant décrite.

Les mesures d'humidité du sol sont faites au pas de temps horaire. Dans le cadre de cette recherche, on utilise un pas de temps journalier en appliquant une moyenne sur 24h, en considérant une journée de mesure allant de minuit le jour J à minuit le jour J+1. En dehors des cas particuliers cités dans le paragraphe précédent, seules la première et la dernière journée de mesure ne font pas 24h. Il est tout de même décidé de conserver cette méthode de moyenne sur les heures de mesure disponible. On estime en effet (très) faible le risque d'avoir un événement extrême manqué sur ces quelques heures et donc d'avoir deux valeurs d'humidité du sol journalière faussées. Toutefois, concernant les différences entre stations, on cherche à avoir un maximum de stations couvrant la même période. Ainsi, on complète les séries des stations qui commencent plus tard ou finissent plus tôt. Deux méthodes sont choisies pour faire cet ajustement :

- la moyenne de toutes les stations installées sur le BV, méthode appelée moyenne,
- la moyenne des quatre stations les plus proches, méthode appelée ppv pour plus proches voisins.

Dans le cadre de la méthode ppv, l'occupation du sol (milieu ouvert ou forestier) n'est pas prise en compte pour déterminer les stations voisines à utiliser ; seule la distance compte. Cette approximation comporte certains défauts car l'occupation du sol peut avoir une influence notable sur l'humidité du sol mesurée. Cependant, vu le nombre de stations présentes sur chaque BV et leur répartition sur le territoire, l'hypothèse faite ici repose sur le fait que la différence entre station sera plus importante selon leur localisation sur le territoire que selon l'occupation du sol. Le choix de prendre quatre stations est un compromis jugé acceptable par rapport au

nombre total de stations dont on dispose dans cette recherche. Au maximum, il y a quatorze stations installées à l'été 2018 sur le BV Au Saumon et au minimum neuf sur les BV Au Saumon et Magog, respectivement en 2020 et 2021. Prendre trop peu de stations reviendrait à faire un remplacement sans intégrer de variations issues de la dispersion entre stations et en prendre trop rapprocherait trop de la moyenne de toutes les stations. En effet, il est fréquent que plus d'une station ait des données manquantes, en particulier en début et en fin de saison de mesure. Ainsi, il est nécessaire de procéder à une correction avec un nombre limité de données.

Dans le cas où c'est l'humidité du sol en profondeur qui est utilisée, seule la moyenne est utilisée comme méthode de correction. En effet, les mesures en profondeur (20 cm) sont faites seulement en milieux ouverts, ce qui limite donc le nombre de sites pour lesquels on dispose de ces données. On ne dispose donc pas d'un panel de sondes en profondeur suffisamment grand pour appliquer la méthode de correction ppv.

Par ailleurs, l'humidité du sol n'a pas été mesurée en profondeur pour le premier été, 2018. On dispose donc seulement de trois années pour expérimenter le modèle de RNA en environnement réel avec les données d'observation d'humidité du sol en profondeur.

La chaîne de prévision est la même que celle utilisée en environnement virtuel (Figure 3.17). Pour une prévision faite le jour J à un horizon J+1, on utilise les variables météo à J+1 et les variables d'état à J.

6.2. Résultats

6.2.1. Comparaisons du NSE

Les Figure 6.6 à Figure 6.9 montrent l'évolution du NSE avec l'horizon de prévision pour les BV Au Saumon et Magog pour les douze configurations d'intrants du Tableau 6.2. Les résultats sont distingués selon les trois échantillons utilisés : apprentissage en environnement adapté et validations en environnements adapté et réel. La Figure 6.6 et la Figure 6.8 traitent les essais avec seulement l'humidité du sol comme variable d'état (1, 2, 5, 6, 9, 10), alors que la Figure 6.7 et la Figure 6.9 ceux avec l'utilisation conjointe de l'humidité du sol et du débit (essais 3, 4, 7, 8, 11 et 12). Les essais 1 à 8 utilisent l'humidité du sol en surface comme intrant, les essais 9

à 12 l'humidité du sol en profondeur. Sur les quatre figures, le choix est fait de se limiter à un intervalle de NSE compris entre -0,5 et 1 pour la visualisation ; cela implique que les résultats de modèle les moins bons (en dessous de -0,5) ne sont pas visibles sur les Figure 6.6 à Figure 6.9. Cela permet de comparer de façon plus aisée entre les figures et les sous-figures, ainsi que de ne pas perdre en détail pour les intervalles les plus intéressants, qui sont ceux au-dessus de 0. En effet, on n'est pas intéressé par la valeur exacte du NSE dès lors que celui-ci est négatif.

On rappelle que dans ce chapitre on dispose d'un modèle semi-spatialisé avec une discrétisation spatiale dictée par la localisation des sondes d'humidité du sol et par la grille des réanalyses ERA5-land pour les variables de température et précipitation. De plus, l'environnement dit réel ne concerne qu'une validation. L'apprentissage et une validation sont faits en environnement adapté. Dans ce dernier cas, il est important de noter que les essais 1 à 4 sont équivalents aux essais 5 à 8 (Tableau 6.2).

Apprentissage

La première observation concerne les résultats en apprentissage, avec des NSE très constants selon l'horizon de prévision et avec des valeurs très proches entre les essais et les années de validation selon lesquelles l'apprentissage a été fait pour les deux BV. La période d'apprentissage est la même (2000-2017), mais le nombre d'intrants d'humidité du sol varie d'une année sur l'autre ; ce ne sont donc pas forcément les mêmes UHRH qui sont pris en compte d'une année à l'autre. Les différences observées entre essais et années sont principalement liées aux valeurs de NSE ; les tendances, quant à elles, restent les mêmes sans distinctions significatives.

Les résultats sur le BV Au Saumon sont meilleurs que pour le BV Magog, avec un seul NSE qui descend sous les 0,5 pour la configuration, la 10 avec l'humidité du sol en profondeur et le débit comme variables d'état (Figure 6.7). Pour le BV Magog, l'apport du débit comme intrant au modèle de RNA révèle un gain notable du NSE, d'environ 0,5, passant d'environ 0,2 sur les quatre années pour les configurations 1, 2, 5, 6, 9 et 10 à 0,7 voire 0,8 pour les autres configurations (Figure 6.6 à Figure 6.9).

Aussi, pour les deux BV, les différences de NSE selon l'utilisation de l'humidité du sol en surface ou celle en profondeur ne sont pas significatives sur les périodes d'entraînement (lignes pointillées superposées aux lignes pleines, Figure 6.6). Il n'y a que l'apprentissage fait pour une validation sur l'année 2019 sur le BV Au Saumon qui montre un écart plus grand pour les configurations 10 et 12, avec respectivement une perte de 0,3 et 0,2 de NSE par rapport aux configurations équivalentes avec l'humidité du sol en surface, les 2 et 4 (Figure 6.6 et Figure 6.7).

Enfin, on rappelle que les RNA ont été entraînés en employant l'information sur l'humidité du sol en provenance des UHRH où se trouvent les sondes d'humidité du sol. D'une année à l'autre, les emplacements des sites instrumentés ont parfois changé ; les UHRH utilisés en apprentissage ont donc eux aussi variés. Ceci explique pourquoi on a un apprentissage en environnement adapté pour chacune des années de validation (2018 à 2021) et pourquoi les résultats de NSE varient.

Validation – environnement réel

La tendance sur sept jours est toute autre en validation en environnement réel avec une amélioration du NSE entre un et sept jours. On n'observe pas de tendance commune pour un BV sur les quatre années de validation testées. En effet, les résultats diffèrent d'une année sur l'autre et selon les configurations. En revanche, les valeurs de NSE sont quasiment toujours meilleures pour le BV Au Saumon que pour le BV Magog, sans distinction de l'année de validation ou de la configuration d'intrants (Figure 6.6 et Figure 6.7 pour Au Saumon contre Figure 6.8 et Figure 6.9 pour Magog).

Les configurations d'intrants montrent une certaine consistance entre les deux BV pour une même année, c'est-à-dire que les résultats varient similairement d'une année à l'autre pour les deux BV. L'année 2018 (première ligne, colonne de droite) présente des résultats qui s'améliorent fortement avec l'horizon de prévision, pour atteindre jusqu'à au moins 0,8 sur les deux BV pour au moins une configuration. Cependant, les valeurs de NSE sur les premiers horizons et pour certaines configurations sont négatives, donc traduisent de très mauvaises

performances. Les configurations qui offrent les meilleurs résultats sont les 1, 3, 5 et 7 pour les deux BV (respectivement en bleu et vert sur la Figure 6.6 et la Figure 6.8).

Pour l'année 2019 (deuxième ligne, colonne de droite), la première avec des données d'humidité du sol en profondeur, on observe ainsi de très bons résultats, avec un NSE qui n'est jamais négatif mais avec toujours au moins une configuration dont le NSE est supérieur à 0,5 sur les sept jours de prévision. 2019 est une année avec une plus grande dispersion entre les configurations d'intrants. Sur la fenêtre complète de prévision, la tendance n'est pas toujours la même dépendamment de la configuration d'intrants. Pour le BV Au Saumon (Figure 6.6 et Figure 6.7), il est notable que l'utilisation de l'humidité du sol en surface profite mieux au RNA que celle de l'humidité du sol en profondeur (traits pleins contre traits pointillés). À J+1 et J+2, le NSE est du même ordre de grandeur (autour de 0,50). Alors qu'il reste constant avec l'humidité du sol en profondeur, il croît jusqu'à atteindre 0,8 avec l'humidité du sol en surface. Les configurations utilisant la méthode de correction de la moyenne ont les meilleurs résultats (lignes rouge et bleu) que celles basées sur la méthode ppv (lignes verte et cyan). Ces dernières suivent d'ailleurs la même tendance que le modèle avec l'humidité du sol en profondeur comme intrant. Pour le BV Magog (Figure 6.8 et Figure 6.9), les tendances sont opposées, avec des résultats qui sont bons avec l'utilisation de l'humidité du sol en profondeur (lignes pointillées) ou avec l'approche ppv (lignes verte et cyan) : le NSE atteint des valeurs de 0,8 sur l'ensemble de la fenêtre de prévision avec les configurations 7 et 11. Cette inversion des tendances selon la profondeur de l'humidité du sol pourrait s'expliquer par la localisation des sondes sur le BV Magog, en dehors de la zone drainée par la station hydrométrique sur laquelle on fait la prévision. L'humidité du sol en profondeur serait alors un meilleur marqueur régional et moins sensible aux variations locales.

L'année 2020 (troisième ligne, colonne de droite) marque une rupture pour le BV Au Saumon (Figure 6.6 et Figure 6.7) pour lequel le NSE ne dépasse jamais 0,5. Pour le BV Magog (Figure 6.8 et Figure 6.9), les configurations 1, 2, 7 et 8 ont des valeurs supérieures à 0,5, avec même les configurations 1 et 2 qui ont une NSE autour de 0,8 pour les sept jours de prévision. Sur le BV Au Saumon, le NSE ne varie quasiment pas entre J+1 et J+7 et reste compris entre 0 et 0,5. Pour cette année de validation et en particulier pour le BV Magog, l'humidité du sol en profondeur comme intrant offre des résultats moins bons que l'humidité du sol en surface.

Enfin, pour l'année 2021 (quatrième ligne, colonne de droite), les observations sont très semblables à celle de l'année 2020 pour le BV Au Saumon (Figure 6.6 et Figure 6.7). Le NSE ne varie quasiment pas sur les sept jours de prévision et reste compris entre 0 et 0,5. Par contre, contrairement à 2020, il n'y a pas de différences significatives entre les douze configurations testées. Pour le BV Magog (Figure 6.8 et Figure 6.9), seules quatre configurations d'intrants offrent des résultats prometteurs, car positifs ; il s'agit des configurations 1 à 4, soit celles qui utilisent la méthode de correction par la moyenne. Les configurations 3 et 4, bien que présentant une tendance à la baisse entre J+1 (0,85) et J+7 (0,5), offrent les meilleures garanties pour la BV Magog en 2021.

Ainsi, de manière générale, on remarque finalement que les configurations d'intrants qui offrent les meilleurs résultats sur les deux BV et sur les quatre années sont celles qui associent l'humidité du sol et le débit comme variables d'état, avec l'utilisation de l'approche par moyenne pour combler les observations d'humidité du sol manquantes.

Validation – environnement adapté

Les résultats en validation en environnement adapté montrent, quant à eux, la capacité du modèle de RNA à prévoir le débit lorsqu'il est dans les meilleures conditions, i.e. avec les mêmes sources de données qu'en apprentissage. Pour le BV Au Saumon (Figure 6.6 et Figure 6.7), les résultats sont très similaires entre les années 2018 et 2019, avec un NSE qui reste constant sur les sept jours de prévision. Les meilleurs résultats sont obtenus sur ces deux années pour la configuration d'intrants 3. En 2020, les résultats se dégradent fortement, avec un NSE qui est rarement positif, alors que la performance en apprentissage ne se détériore pas. Il ne l'est sur l'ensemble de la fenêtre de prévision que pour les configurations 4, 11 et 12, mais ne dépassant jamais une valeur de 0,2. Cela est clairement dû à une difficulté du RNA à prévoir les faibles débits observés cet été-là, plutôt qu'à un modèle mal conçu à la base, car l'apprentissage était de qualité similaire aux autres années. En 2021, c'est encore pire, avec aucune configuration qui offre un NSE positif, malgré une performance en apprentissage équivalente à celles des autres années. Les six mois sur lesquels le RNA tourne sont très secs et il apparaît

donc que l'humidité du sol générée par HYDROTEL ne permet pas de prévoir ces faibles débits. Elle pénalise même le modèle lorsque le débit est utilisé comme co-variable d'état.

Pour le BV Magog (Figure 6.8 et Figure 6.9), cette difficulté à prévoir les faibles débits sur une période allongée est pire, car dès l'année 2020, aucune configuration d'intrants ne permet au modèle de fournir une prévision associée à un NSE positif. Un tel résultat n'est pas surprenant, compte tenu que la performance en apprentissage est mauvaise (NSE entre 0 et 0,2), et ce, pour toutes les années considérées. En 2018, le NSE des configurations qui utilisent le débit et l'humidité du sol en surface comme variables d'état (Figure 6.8, configurations 3, 4) décroît avec l'horizon de prévision passant de presque 0,9 à J+1 à 0,5 à J+7. En 2019, il reste constant autour de 0,6. Sur ces deux années, il est intéressant de relever que les configurations qui ne prennent pas en compte le débit comme variable d'état ont des résultats beaucoup moins bons (Figure 6.8, configurations 1, 2). La tendance sur la fenêtre de prévision est la même mais le NSE est compris entre 0 et 0,5.

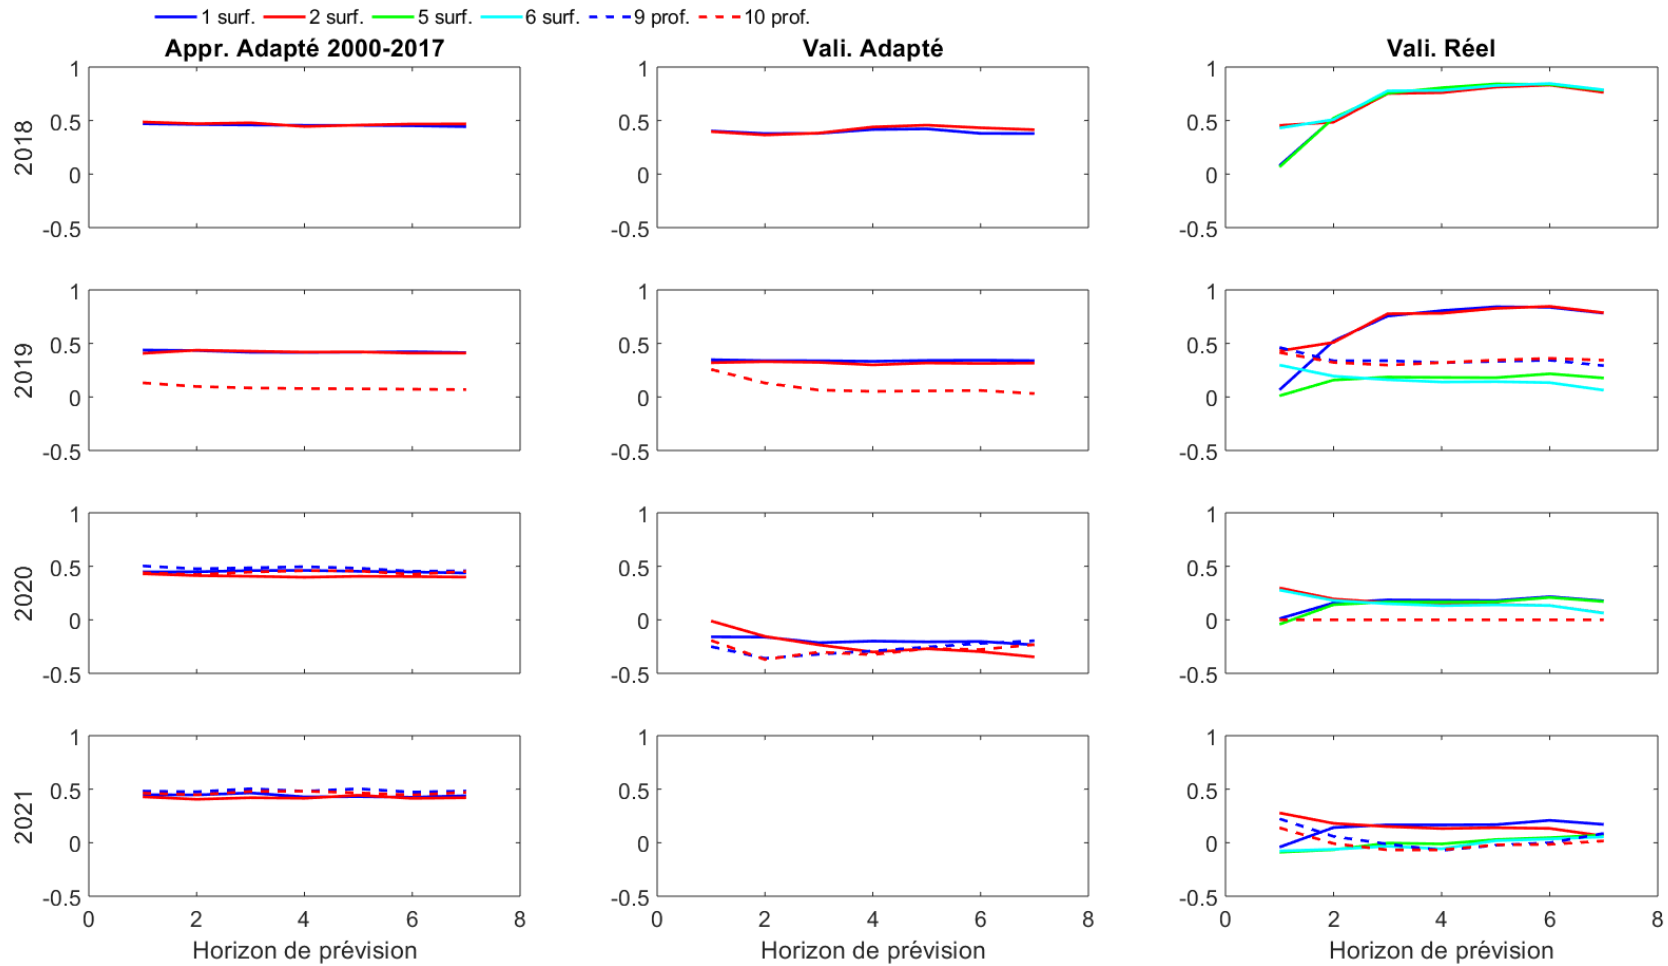


Figure 6.6 – Évolution du NSE avec l’horizon de prévision en apprentissage (colonne de gauche), validation en environnement virtuel (colonne centrale) et validation en environnement réel (colonne de droite) pour le BV Au Saumon sur les années 2018 à 2021 pour six configurations différentes ne faisant pas intervenir le débit comme intrant au modèle (scénarios 1, 2, 5 et 6 avec l’humidité du sol en surface (traits pleins) et 9 et 10 en profondeur (traits pointillés)).

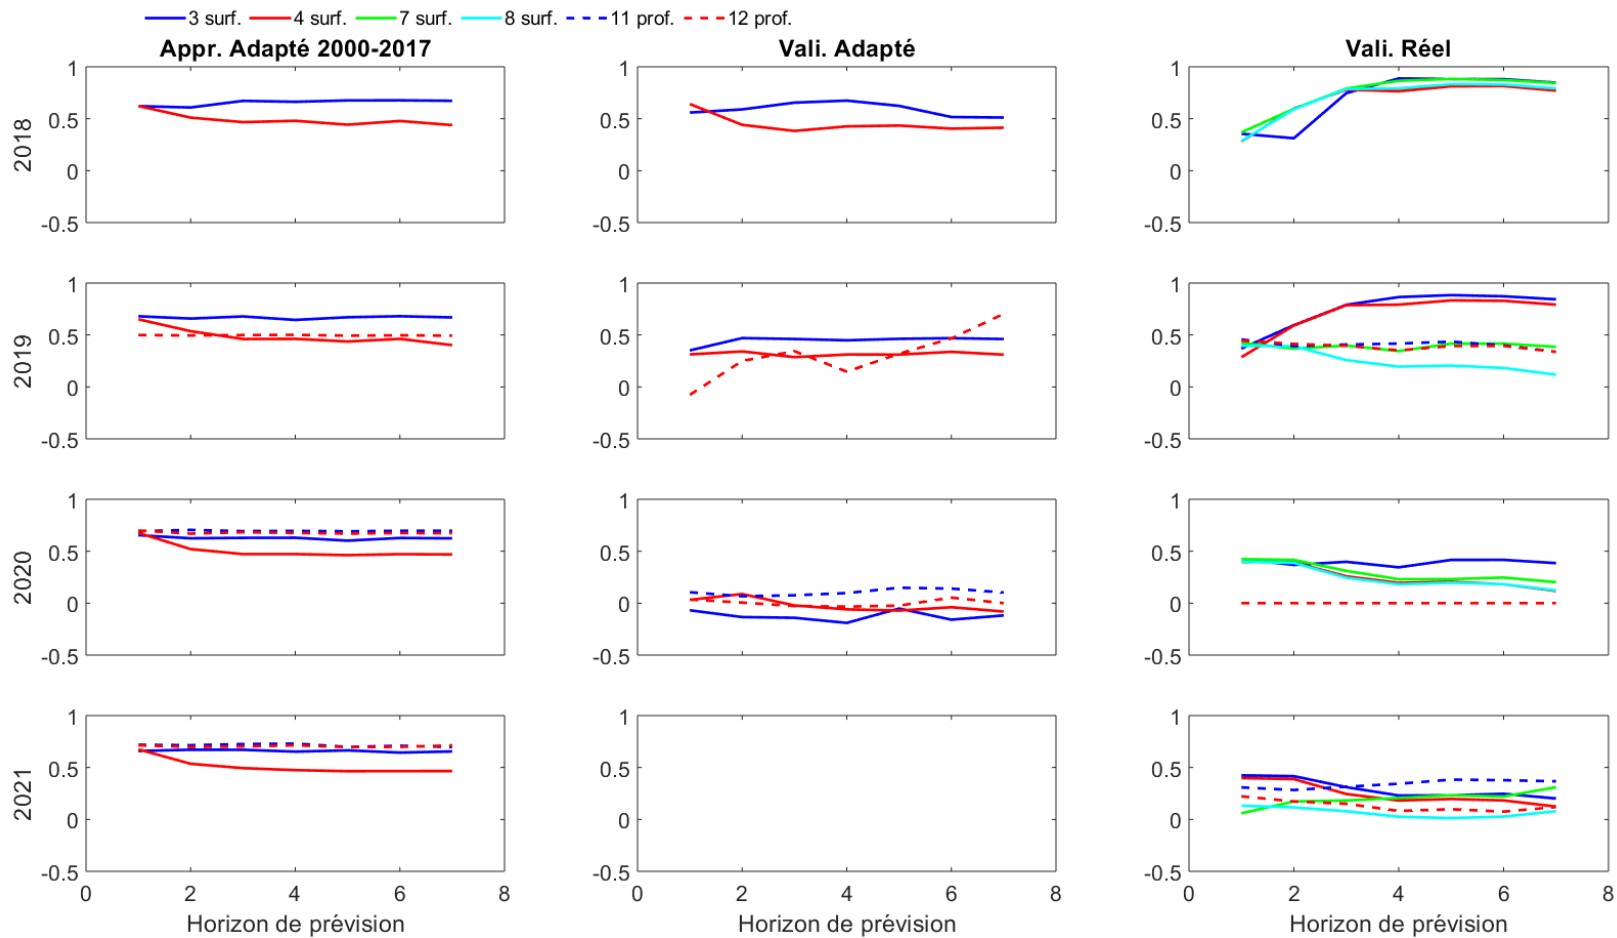


Figure 6.7 – Évolution du NSE avec l’horizon de prévision en apprentissage (colonne de gauche), validation en environnement virtuel (colonne centrale) et validation en environnement réel (colonne de droite) pour le BV Au Saumon sur les années 2018 à 2021 pour six configurations différentes faisant intervenir le débit comme intrant au modèle (scénarios 3, 4, 7 et 8 avec l’humidité du sol en surface (traits pleins) et 11 et 12 en profondeur (traits pointillés)).




Figure 6.8 – Évolution du NSE avec l’horizon de prévision en apprentissage (colonne de gauche), validation en environnement virtuel (colonne centrale) et validation en environnement réel (colonne de droite) pour le BV Magog sur les années 2018 à 2021 pour six configurations différentes ne faisant pas intervenir le débit comme intrant au modèle (scénarios 1, 2, 5 et 6 avec l’humidité du sol en surface (traits pleins) et 9 et 10 en profondeur (traits pointillés)).




Figure 6.9 – Évolution du NSE avec l’horizon de prévision en apprentissage (colonne de gauche), validation en environnement virtuel (colonne centrale) et validation en environnement réel (colonne de droite) pour le BV Magog sur les années 2018 à 2021 pour six configurations différentes faisant intervenir le débit comme intrant au modèle (scénarios 3, 4, 7 et 8 avec l’humidité du sol en surface (traits pleins) et 11 et 12 en profondeur (traits pointillés)).

6.2.2. Analyse des hydrogrammes de validation en environnement réel

Au Saumon

Les hydrogrammes du BV de la rivière Au Saumon pour les scénarios 1 à 8 avec l'humidité du sol en surface décrits dans le Tableau 6.2 sont présentés à la Figure 6.10 et à la Figure 6.11 et pour les scénarios 9 à 12 avec l'humidité du sol en profondeur à la Figure 6.12. L'étude des hydrogrammes pour le BV Au Saumon en validation sur les étés 2018 à 2021 permet d'analyser plus précisément les résultats et de comprendre les forces et faiblesses observées avec les tendances de NSE.

La campagne de mesure de l'été 2018 est courte et tardive. Les précipitations sont fréquentes mais pas toujours abondantes. Avec le modèle de RNA développé, on observe une réactivité prononcée à l'exutoire du BV à ces différents événements précipitants qui est bien visible sur les hydrogrammes (Figure 6.10 et Figure 6.11, haut). Dès J+1, les prévisions du RNA pour tous les essais sont de bonne qualité, avec une bonne réactivité à chacun des événements précipitants. Un gain est visible à J+7, avec en particulier de meilleures montées et descentes de crues et donc une meilleure prévision du pic de crue dans son ensemble. La dispersion entre les essais est également réduite à J+7 comparé à J+1. En revanche, le RNA prévoit toujours une réactivité trop forte de la rivière par rapport à la réalité. En effet, le faible pic de début octobre est constamment surestimé (par tous les essais et à tous les horizons). La même observation est faite sur le faible pic de crue de fin octobre. Ainsi, il semblerait que le RNA donne trop de poids aux précipitations de moindre intensité et/ou que les données d'humidité du sol réagissent plus que la rivière. L'apport du débit et de l'humidité du sol en surface comme intrant au RNA (essais 3, 4, 7 et 8) semble aider le modèle à améliorer la qualité des prévisions et en particulier à réduire l'intensité des faibles pics de crue évoqués, comparativement l'incorporation de la seule humidité du sol au modèle. Ce sont ces quatre essais qui présentent les meilleurs résultats avec les prévisions les plus proches des observations. Il est intéressant de rappeler qu'en analysant le NSE, les essais les plus performants sont les 1, 3, 5 et 7. On note donc une légère variation entre ce qu'on peut observer avec les métriques et les hydrogrammes.

L'été 2019 est assez proche de l'été 2018 en termes de comportement hydrologique, avec des pics de crues courts et modérés en début et fin de saison et une période d'étiage compensée par

de réguliers faibles apports en eau, en particulier avec les événements précipitants associés à des orages. En 2019, la campagne de mesure étant plus longue, on a la possibilité de tester le modèle de RNA sur une saison estivale complète. Comme pour 2018, l'essai 3 fournit les meilleures prévisions. Cela est en accord avec les analyses faites sur le NSE. Étant donné la longueur de la période où des prévisions sont émises (six mois), le nombre de pics de crue est plus grand qu'en 2018, donc les modèles associés à chaque essai sont potentiellement plus pénalisés à cause de la forte réactivité observée du RNA aux événements précipitants de faible intensité ou au contraire plus à même de montrer leurs forces. Ainsi, on observe un peu plus de dispersion entre les essais sur l'ensemble des pics de crue, principalement en termes d'intensité (Figure 6.10 et Figure 6.11). De nouveau, le RNA réagit trop aux précipitations, prévoyant des pics de crue finalement non observés. C'est le cas en particulier en fin d'été et début d'automne (pics de crue prévus sur la seconde moitié d'août et tout le mois de septembre). Cela peut s'expliquer par le fait que les variables d'état ne représentent pas suffisamment bien ce qu'il se passe dans le BV. En effet, en début d'été (mai et juin), le BV n'est, généralement, pas en déficit hydrique car la crue printanière vient de passer avec de fortes précipitations et surtout la fonte du manteau neigeux. Les sols se sont gorgés d'eau et le ruissellement a pu être important. Même en période de fortes chaleurs précoces²⁴, le temps qui s'écoule après la crue printanière n'est pas suffisamment long pour assécher l'ensemble du BV. Ainsi, durant les événements précipitants du début de l'été, le ruissellement reste suffisant pour alimenter les cours d'eau. Les variations du débit de la rivière suivent donc de près les aléas précipitants. En revanche, en fin août et septembre, les événements précipitants arrosent un territoire en situation plus ou moins sévère de stress hydrique²⁵, une situation qui ne favorise pas un ruissellement conséquent en surface. Ainsi, l'eau qui tombe sur la période allant de mi-août à fin septembre est susceptible de ne pas fournir de réponse visible en rivière, car cette eau est alors en plus grande partie absorbée par le sol pour recharger les différents réservoirs de sol. Ainsi, l'information issue de l'humidité du sol en surface, qu'elle soit couplée ou non avec le débit, ne permet pas de bien prévoir le débit

²⁴ Comme ce fut le cas en mai 2020 avec une première canicule la dernière semaine de mai. Malheureusement, aucune sonde n'était installée à ces dates-là, donc cet événement-là ne sera pas traité dans cette recherche et ne sera pas malheureusement évoqué dans le paragraphe suivant consacré à l'été 2020.

²⁵ Attention, il n'est pas dit ici que tous les étés entraînent des périodes de stress hydrique, mais il s'agit de noter que les situations les plus sévères d'étiage se retrouvent au cœur de l'été, lorsque les températures sont les plus élevées et les pluies les moins fréquentes, favorisant entre autres une forte évapotranspiration.





pour les configurations hydro-climatiques détaillées. Bien qu'on s'attende à ce que le modèle de RNA soit en mesure de s'adapter à ces non-linéarités, l'origine des données d'humidité du sol selon les périodes d'apprentissage ou de validation pourrait aussi partiellement expliquer ce raté. En effet, les données d'humidité du sol en apprentissage sont fictives, issues d'HYDROTEL, alors que ce sont de vraies données d'observation *in situ* en validation.

Comme 2018, la période de mesure pour 2020 est courte, avec seulement trois mois de mesure et donc seulement une demi-saison à prévoir. La qualité des prévisions reste relativement constante et bonne sur l'ensemble de la fenêtre de prévision. Le problème évoqué et détaillé précédemment pour 2019 en fin d'été est très visible ici. En effet, plusieurs pics de crue non observés sont prévus par le RNA, début août, fin août et fin septembre. En termes de bonne performance, le modèle arrive à bien prévoir le plus gros pic de crue de la période étudiée, un épisode de crue qui s'étale sur trois semaines durant le mois d'octobre. La qualité de la prévision varie cependant selon les essais, avec de nouveau l'essai 3 qui performe le mieux, notamment sur l'écart des valeurs de débit par rapport aux observations. Les crues et décrues sont bien prévues par tous les essais, sans anticipation ni retard notable. En analysant le NSE, il était plus difficile de faire ressortir un essai par rapport à un autre, au moins pour le BV Au Saumon.

Enfin, en 2021, quel que soit l'essai considéré, aucune sortie de modèle ne permet une bonne représentation sur l'ensemble de la saison. Ainsi, durant la longue période d'étiage, qui couvre les mois de juin, juillet et août, le RNA prévoit des pics de crue en réaction aux événements précipitants, alors qu'aucun de ces pics n'est en réalité observé à la station hydrométrique. Comme pour 2020, cela vient du fait que la variable d'état d'humidité du sol ne permet pas de bien représenter ce qu'il se passe sur le BV. De plus, le modèle de RNA a mal interprété/utilisé une donnée d'humidité du sol issue d'observations *in situ* en validation sachant que l'apprentissage s'est fait sur des données simulées par HYDROTEL. De plus, l'ajout du débit comme intrant au modèle permet seulement de limiter les intensités des pics de crue prévus, i.e. le RNA prévoit quand même un pic de crue. Les résultats n'étant pas très satisfaisants, il est important de s'appuyer sur l'analyse des hydrogrammes ; les valeurs de NSE n'apportent pas suffisamment d'information pour l'année 2021.

Les résultats avec l'humidité du sol en profondeur sont très similaires à ceux obtenus avec celle en surface (Figure 6.12). Les différences entre essais montrent les mêmes tendances, à savoir

que l'essai 11 (équivalent des essais 3 et 7, seule la profondeur de l'humidité du sol varie) est celui qui fournit les résultats les plus satisfaisants. La principale différence, et pas des moindres, vient de l'application du modèle avec les essais 9 et 10. Dans ces conditions-là, l'absence du débit comme intrant plombe complètement le RNA, avec des plateaux et un manque total de plusieurs événements. Il n'y a pas de représentation des pics de crue, que ce soit en début ou en fin de saison. Cela se vérifie à la fois à J+1 et à J+7. Pour les étés 2020 et 2021, ces écarts sont moins flagrants mais restent visibles, en particulier en fin de saison. Paradoxalement, cela permet au modèle une meilleure représentation du pic de crue à la mi-octobre en 2020. Le RNA ne fournit malheureusement pas de réelle réponse à un événement en particulier, mais le plateau qu'il prévoit à cette période de l'année atteint une valeur relativement égale à celle du débit de pointe de cet événement.










Figure 6.10 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2018 à 2021 pour le BV Au Saumon avec l’humidité du sol en surface pour les configurations 1 à 4 qui utilisent l’approche d’extrapolation moyenne (couleurs) et le débit observé (noir).






Figure 6.11 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2018 à 2021 pour le BV Au Saumon avec l’humidité du sol en surface pour les configurations 5 à 8 qui utilisent l’approche d’extrapolation ppv (couleurs) et le débit observé (noir).

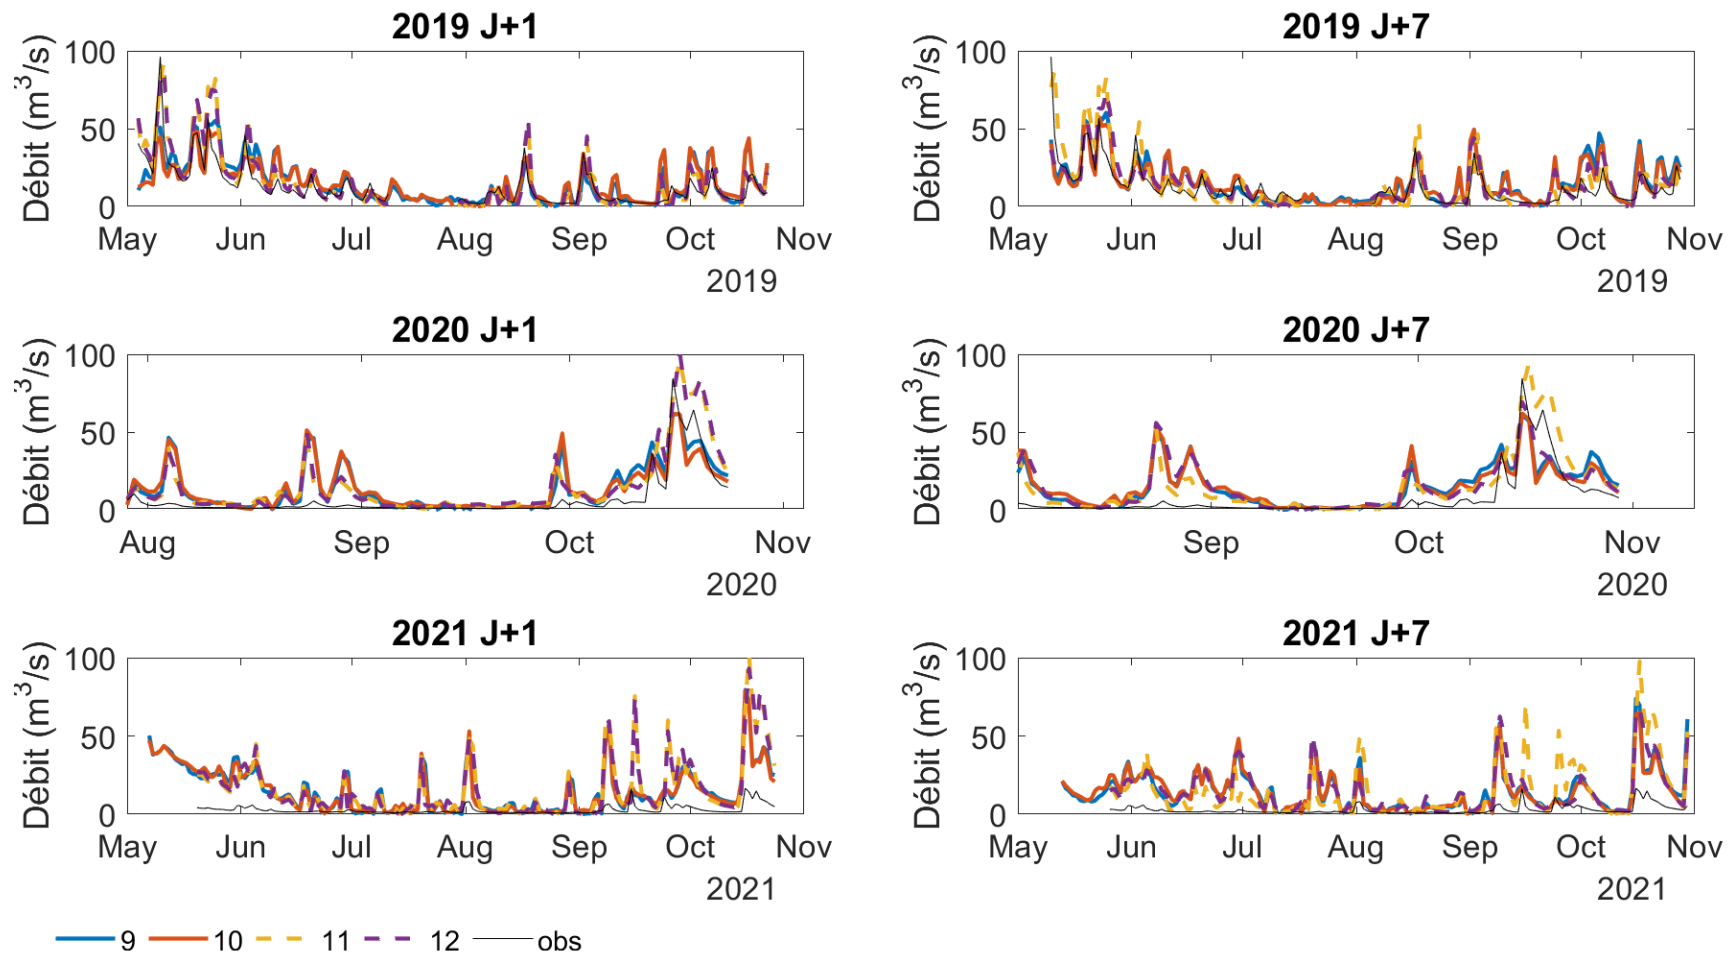


Figure 6.12 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2019 à 2021 pour le BV Au Saumon avec l'humidité du sol en profondeur pour les configurations 9 à 12 qui utilisent l'approche d'extrapolation moyenne (couleurs) et le débit observé (noir).

Magog

Les hydrogrammes du BV de la rivière Magog pour les scénarios 1 à 8 décrits dans le Tableau 6.2 sont présentés de la Figure 6.13 à la Figure 6.15. La Figure 6.13 et la Figure 6.14 montrent les hydrogrammes simulés par le RNA lorsque l'humidité du sol en surface est utilisée seule ou en combinaison avec les débits comme intrants au modèle. La Figure 6.15 montre les résultats lorsque l'humidité du sol en profondeur est employée comme intrant. L'étude des hydrogrammes pour le BV Magog en validation sur les étés 2018 à 2021 permet d'analyser plus précisément les résultats et de comprendre les forces et faiblesses observées avec les tendances de NSE. De manière générale en observant les hydrogrammes de la Figure 6.13 et de la Figure 6.15 et avec les commentaires émis dans la sous-section précédente, les résultats pour le BV Magog sont moins bons que pour le BV Au Saumon.

En 2018, on note une nette amélioration entre J+1 et J+7, avec les débits prévus par le RNA qui sont constamment surestimés à J+1 et la présence de pics de crue prévus bien supérieurs à ce qui est observé. De plus, ces pics de crue prévus sont en retard et la période de décrue est bien trop longue. En revanche, à J+7, les sorties de RNA surestiment toujours le débit, mais sans proposer de forts pics de crue non observés. Un seul événement s'empire, c'est celui de la dernière semaine d'octobre, avec les prévisions de débit qui proposent une forte crue à J+7 qui était pourtant modérée à J+1. Il est intéressant de relever les différences entre essais, avec les essais 1, 2, 5 et 6 qui proposent moins de pics de crue et qui offrent donc des prévisions de meilleures qualités, bien que toujours surestimée. Au contraire, les essais 3, 4, 7 et 8 prévoient les pics de crue non observés. Ce comportement est inexplicable car les derniers essais mentionnés sont ceux qui utilisent le débit comme intrant au modèle. On s'attend donc à avoir un modèle qui s'approcherait plus de la réalité. On voit ici que c'est totalement l'inverse et que cette utilisation du débit comme intrant semble au contraire perturber le RNA.

Pour l'été 2019, la tendance sur la fenêtre de prévision de sept jours est la même que pour 2018, à savoir une amélioration des prévisions avec l'horizon de prévision. Il demeure que les prévisions pour l'été 2019 ne sont satisfaisantes que pour deux essais, les numéros 3 et 7 (utilisant le débit et l'humidité du sol comme variables d'état et les températures minimale et maximale ainsi que les précipitations comme variables météo). Les prévisions issues du RNA avec la configuration de l'essai 3 ou celle de l'essai 7 offrent une prévision qui donne un poids





très fort au débit. Ce comportement s'observe avec le décalage temporel d'une journée qu'il y a entre le débit prévu et le débit réellement observé, la sortie de modèle étant en retard. Une amélioration est visible avec l'horizon de prévision, notamment en début de saison avec un alignement temporel très bon pour les différents pics de crue des mois de mai et de juin à J+7. En revanche, pour le pic de crue de fin septembre (le plus important) puis ceux secondaires d'octobre, on note un retard dans la prévision qui demeure sur l'ensemble de la fenêtre de prévision. Bien que proches, les résultats selon l'utilisation de l'essai 3 ou de l'essai 7 présentent des différences. Cela revient donc à dire que la manière dont est extrapolée l'humidité du sol à l'échelle du bassin joue un rôle dans la modélisation, tout comme pour les modèles traditionnels. Dans le cas de l'essai 7, on observe la disparition des pics de crue avec l'horizon de prévision. À J+1, les prévisions sont très similaires entre les deux essais considérés. Par contre, dès J+2, l'essai 7 ne prévoit plus les pics de crue (à J+2, atténuation du pic de crue de la 2^e semaine de mai), allant jusqu'à une absence de prévision complète du pic de crue principale de la dernière semaine de septembre à J+7. Concernant les autres essais (1, 2, 4, 5, 6 et 8), les résultats ne sont jamais satisfaisants, et ce, quel que soit l'horizon de prévision et quelle que soit la période de la saison : pics du début d'été non observés, étiage estival surestimé, pics de fin d'été et d'automne quasiment inexistant. D'une part, cela permet d'avancer que l'utilisation conjointe de l'humidité du sol avec le débit est vraiment nécessaire. D'autre part, l'utilisation seule de la précipitation sans la température n'est pas pertinente. Ces deux derniers arguments pourraient être liés au fait que les stations de mesure d'humidité du sol ne sont pas dans l'aire drainée par la station fictive pour laquelle on cherche à prévoir le débit. En d'autres mots, l'hypothèse avancée signifie que la dynamique d'humidité du sol mesurée à l'extérieur du BV diffère de celle à l'intérieur du BV, ou au moins à l'intérieur de l'aire drainée par la station hydrométrique de référence. Les essais 2 et 6, qui ne font intervenir que la précipitation et l'humidité du sol, ne sont jamais en mesure de prévoir une quelconque variation du débit lorsque le débit est le plus élevé (début et fin de saison). En effet, on observe des sorties de modèle constantes, comme s'il y avait saturation de la sortie du modèle de RNA. Ce comportement inattendu n'est pas totalement élucidé. Comme évoqué antérieurement, cela pourrait être relié avec la différence de localisation entre les stations de mesure d'humidité du sol et l'aire drainée par la station hydrométrique fictive. En revanche, l'absence de la prise en compte de la température ne semble pas pouvoir expliquer à elle seule l'obtention d'un plateau. Les essais 1 et 5, qui pourtant

n'incluent que les températures minimale et maximale comme intrants, ne présentent pas de plateau aussi prononcé en début et fin d'été. Il y a toujours la présence de légères variations plurijournalières. Le rôle de l'évapotranspiration, indirectement pris en compte par les précipitation et température, n'est pas clair. Alors même qu'elle dégradait les résultats en environnement virtuel (voir la section 5.2), son intégration comme intrant au RNA pourrait être une piste d'amélioration afin de gommer les défauts liés à l'intégration de la précipitation seule.

Les résultats pour l'année 2020 suivent le même profil d'amélioration sur la fenêtre de sept jours. Cependant, les scores restent insatisfaisants en termes de qualité des prévisions. Chaque essai réagit plutôt bien aux périodes de faibles débits puis aux périodes de crue. Pour ces dernières situations, il y a toujours ou une surestimation du débit prévu ou un retard dans la montée de crue. Ce retard dans le pic de crue peut être de trois ou quatre jours pour les essais 3, 4, 7 et 8 à J+1 pour le pic de début août, voire d'environ une semaine pour les essais 4 et 8 pour le pic de crue de fin septembre à J+7. Les essais 2, 3 et 6 ont les améliorations de la prévision les plus satisfaisantes sur la période de faibles débits entre J+1 et J+7. En effet, bien qu'il y ait toujours une surestimation du débit prévu par rapport au débit observé, le signal de sortie est bien plus lisse à J+7. Le RNA semble donc s'affranchir du poids de la précipitation au fur et à mesure que l'horizon de prévision grandit. En revanche, sur le mois d'octobre, durant lequel les débits croissent, aucun essai ne s'améliore avec l'horizon de prévision, seul l'essai 3 ne se dégrade pas en restant constant dans la surestimation des deux pics de crue à prévoir.

Les prévisions sur l'été 2021 s'améliorent également avec l'horizon de prévision. C'est très visible sur les hydrogrammes, quel que soit l'essai considéré. Les surestimations des pics de crue sont atténuées, parfois allant jusqu'à une disparition de la prévision de ces pics. Cette dernière observation est problématique même si l'été et l'automne 2021 sont très secs et donc les pics de crue observés très peu à risque pour l'environnement, ses occupants et leurs activités. La prévision du long étiage estival surestime les débits sur les sept jours de la fenêtre de prévision, avec toutefois une diminution de l'écart entre débits observé et prévu à J+7 par rapport à J+1. Enfin l'essai 3 est vraiment le seul à prévoir une évolution du débit prévu sur toute la saison qui suit l'évolution observée. Bien que les débits en périodes de crue soient largement surestimés, on observe une nette différence entre périodes d'étiage et périodes de crue pour cet essai.

En comparant les résultats selon la profondeur de la mesure d'humidité du sol utilisée en intrant du RNA pour le BV de la rivière Magog, le constat est le même que pour celui de la rivière Au Saumon. Les tendances sur les années et selon les essais sont les mêmes qu'avec l'utilisation de l'humidité du sol en surface. On retrouve de nouveau l'essai 3 qui fournit les meilleures prévisions. Des sorties de modèles de valeurs constantes (visuellement, on voit des plateaux sur les hydrogrammes) sont toujours présentes avec les essais 1 et 2. Mais, pour le BV Magog, il est important de noter que c'était un défaut déjà observé avec l'humidité du sol en surface.



— 1 — 2 - - 3 - - 4 — obs

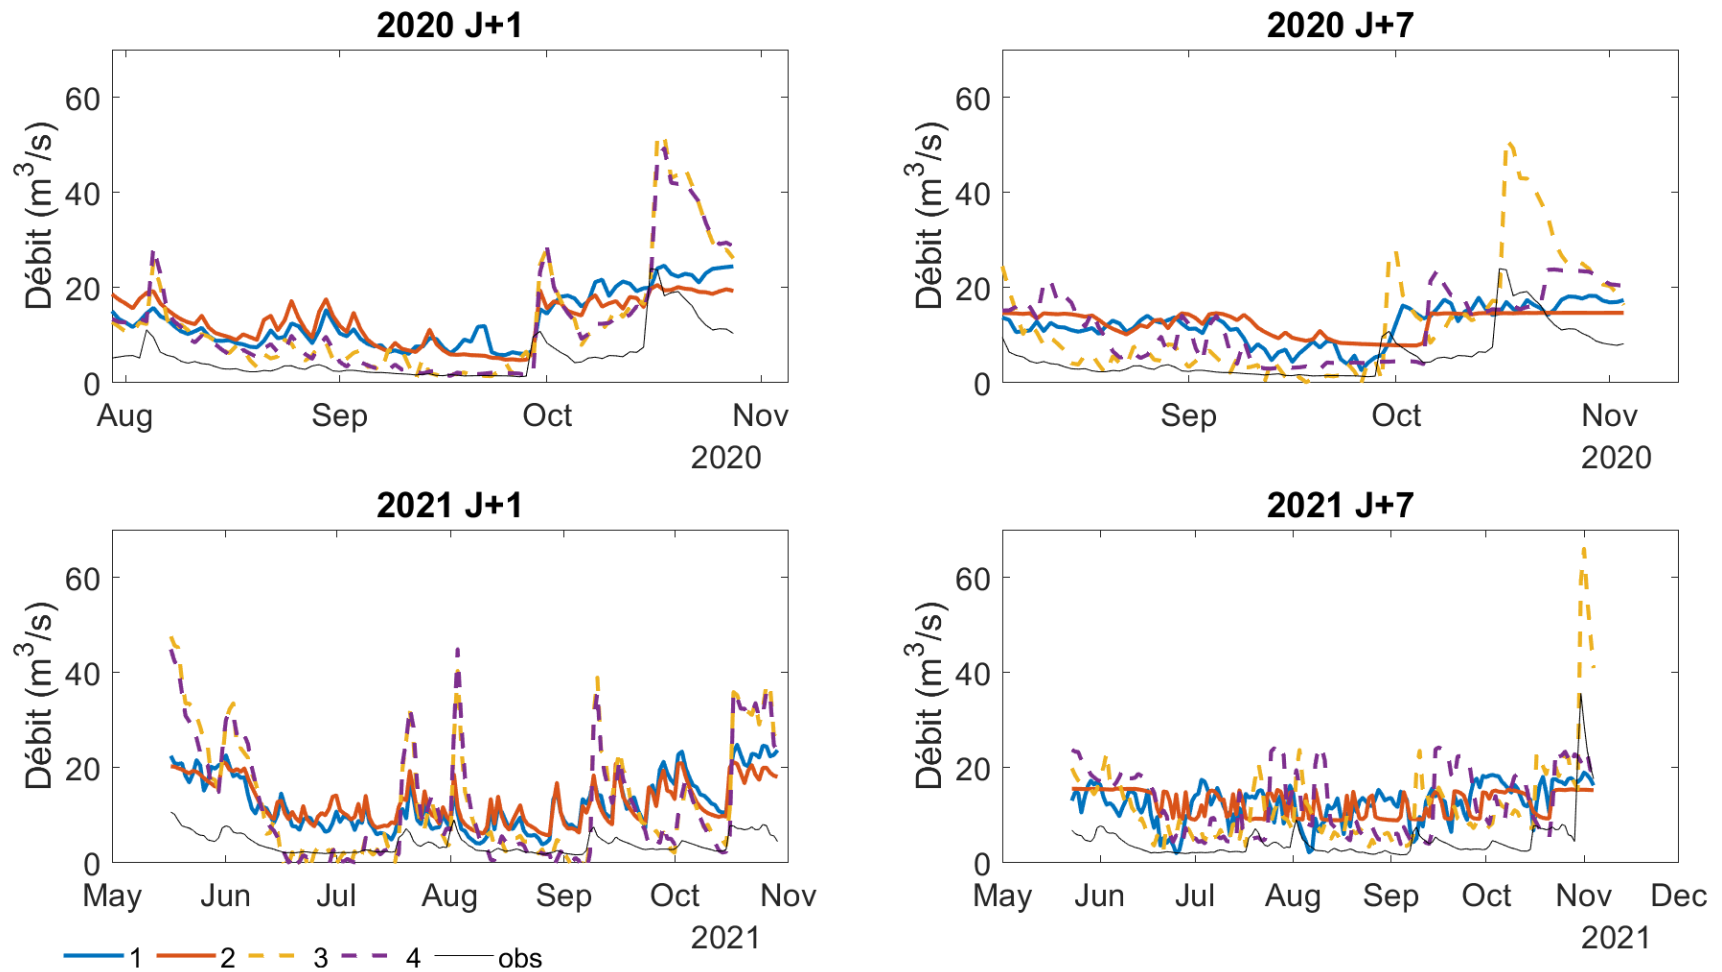




Figure 6.13 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2018 à 2021 pour le BV Magog avec l'humidité du sol en surface pour les configurations 1 à 4 qui utilisent l'approche d'extrapolation moyenne (couleurs) et le débit observé (noir).


2018 J+1




2018 J+7



2019 J+1



2019 J+7



— 5 — 6 — 7 — 8 — obs

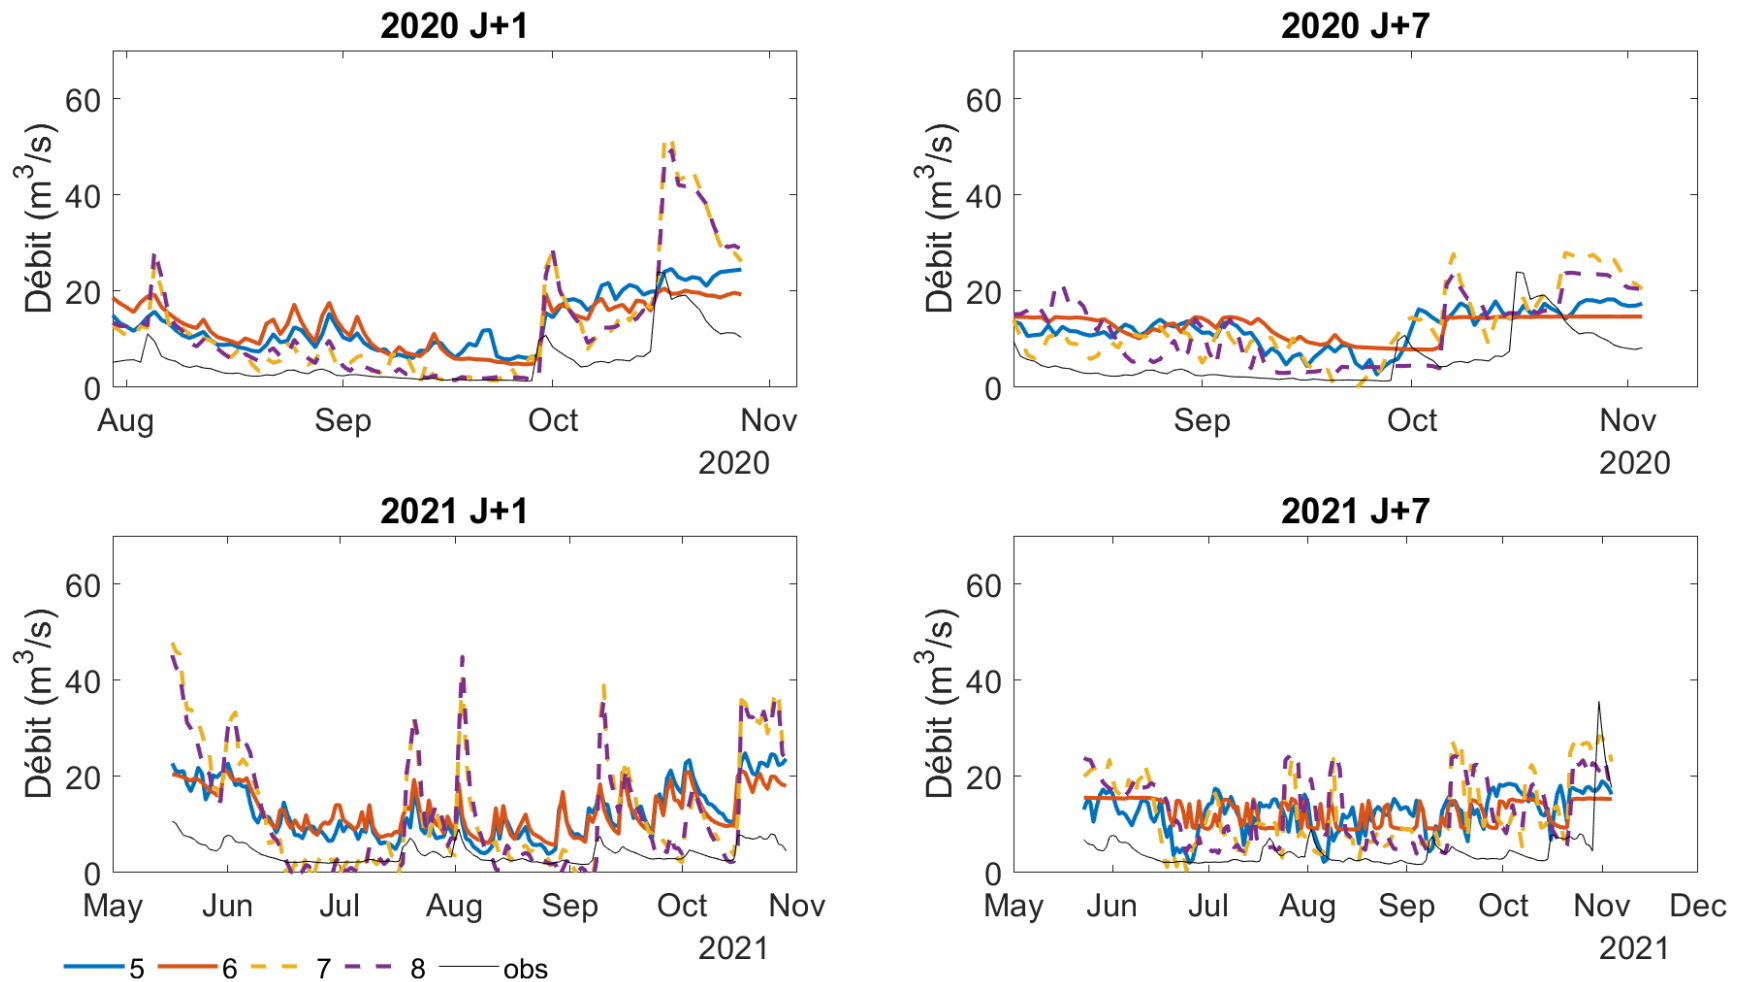


Figure 6.14 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2018 à 2021 pour le BV Magog avec l'humidité du sol en surface pour les configurations 5 à 8 qui utilisent l'approche d'extrapolation ppv (couleurs) et le débit observé (noir).

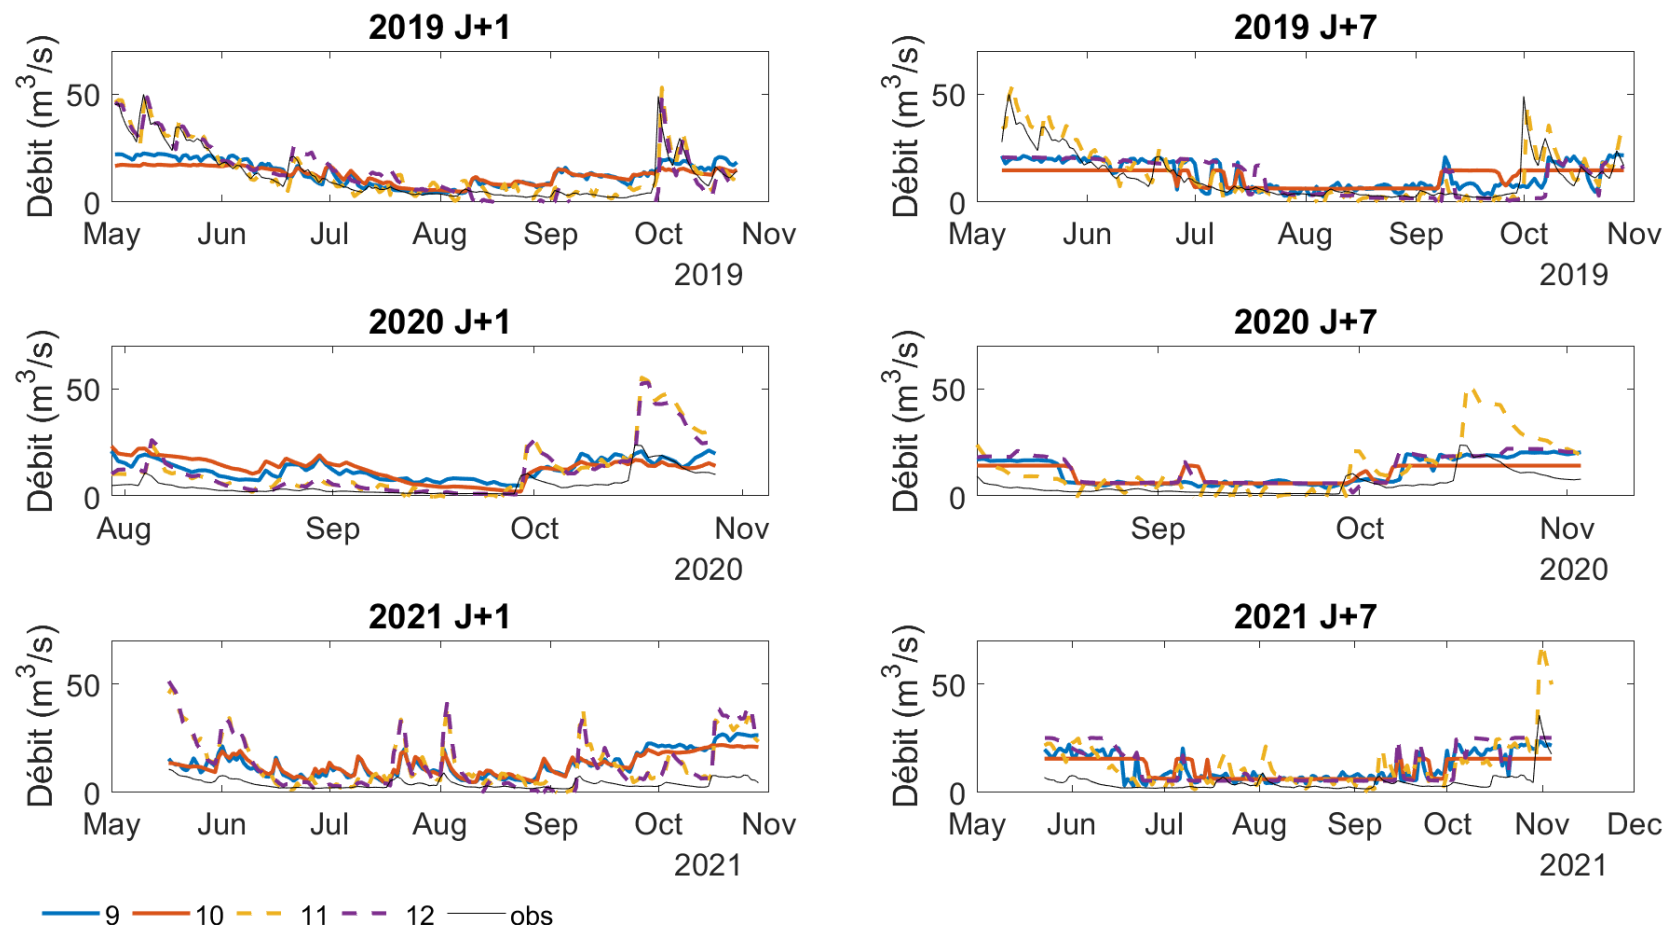


Figure 6.15 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement réel sur 2019 à 2021 pour le BV Magog avec l’humidité du sol en profondeur pour les configurations 9 à 12 qui utilisent l’approche d’extrapolation moyenne (couleurs) et le débit observé (noir).





6.2.3. Analyse des hydrogrammes de validation en environnement adapté

La Figure 6.16 et la Figure 6.17 présentent les résultats du RNA pour le BV Au Saumon, respectivement pour les essais 1 à 4 (humidité du sol en surface) et 9 à 12 (humidité du sol en profondeur). La Figure 6.18 et la Figure 6.19 fournissent les mêmes informations pour le BV Magog. Les essais 5 à 8 ne sont pas analysés, car ils sont en tout point identiques à ceux des essais 1 à 4, puisqu'il n'est pas question ici d'inclure des mesures réelles d'humidité en surface. En environnement adapté, les différences entre les deux BV sont très frappantes. Il semble donc que la relation soit plus forte dans HYDROTEL entre le débit et l'humidité du sol du territoire drainé, donc qu'il y ait plus de différences selon les UHRH dans la simulation de l'humidité du sol, en surface ou en profondeur. La corrélation entre humidités du sol en surface et en profondeur est bien moins importante pour le BV Magog en utilisant les données issues d'HYDROTEL, alors qu'elle est du même ordre de grandeur pour Au Saumon (Tableau 6.1). Les résultats sur le BV Magog ne sont pas satisfaisants, mais ils s'améliorent tous, ou presque, avec l'horizon de prévision, et ce pour les quatre années utilisées en validation. Cette différence de résultats entre les deux BV en validation avec HYDROTEL est difficile à expliquer totalement. Une des pistes de réflexion vient de la particularité des années de validation sélectionnées par rapport à la période d'apprentissage, spécialement pour 2020 et 2021. Pour le BV Magog, on se rappelle que les UHRH utilisés pour extraire l'humidité du sol sont situés en dehors de la zone drainée par la station. Ainsi, dans HYDROTEL, la relation entre humidité du sol d'un sous-bassin et débit à l'exutoire d'un autre sous-bassin est peut-être mal établie, contrairement au BV Au Saumon pour lequel la zone drainée par la station de débit contient les UHRH dont est extraite l'humidité du sol.

Pour le BV Au Saumon, le débit prévu est souvent surestimé, mais il l'est de moins en moins avec l'horizon de prévision qui croît. La prévision des étiages est toujours problématique, avec notamment en 2021 une réactivité constante aux précipitations. Il est important de relever que certains pics de crue au milieu de l'été ne sont prévus que par certains essais. Cependant, il n'y a pas un essai qui prévoit l'étiage aussi long.

Pour le BV Magog, les résultats sont bien moins bons et il arrive même qu'ils se dégradent avec l'horizon de prévision, c'est notamment le cas en 2018. En 2019, avec les essais 3 et 4, le RNA corrige son décalage temporel entre débit d'entrée et débit de sortie, i.e. il intègre bien

l'information issue de l'humidité du sol et plus seulement le débit du pas de temps précédent. Les différences entre essais sont plus marquées pour le BV Magog. Cela peut s'expliquer par le choix des UHRH utilisés pour extraire l'humidité du sol. En apprentissage, le choix des UHRH à considérer pour extraire l'humidité du sol utilisé comme intrant au RNA est directement dicté par la localisation des sondes sur le terrain. Les choix des sites d'instrumentation se sont faits sur la base d'un équilibre entre milieux ouvert et fermé et pour assurer une relative homogénéité dans la couverture spatiale. Ainsi, une sélection *a priori* des sites à instrumenter pourrait être faite en tenant compte du type de sol par exemple. Il faudrait cependant toujours passer outre les limites pratiques d'un travail de terrain en milieu réel où il est nécessaire d'obtenir les accords des propriétaires des sites, pas impossible mais plus incertain. En 2020 et 2021, on note de nouveau de mauvaises prévisions de la période d'étiage avec, encore, une surestimation du débit prévu. En 2021, il est toutefois satisfaisant de voir que, même si le débit est constamment surestimé, le RNA réagit toujours bien aux précipitations ayant amené à un pic de crue observé.



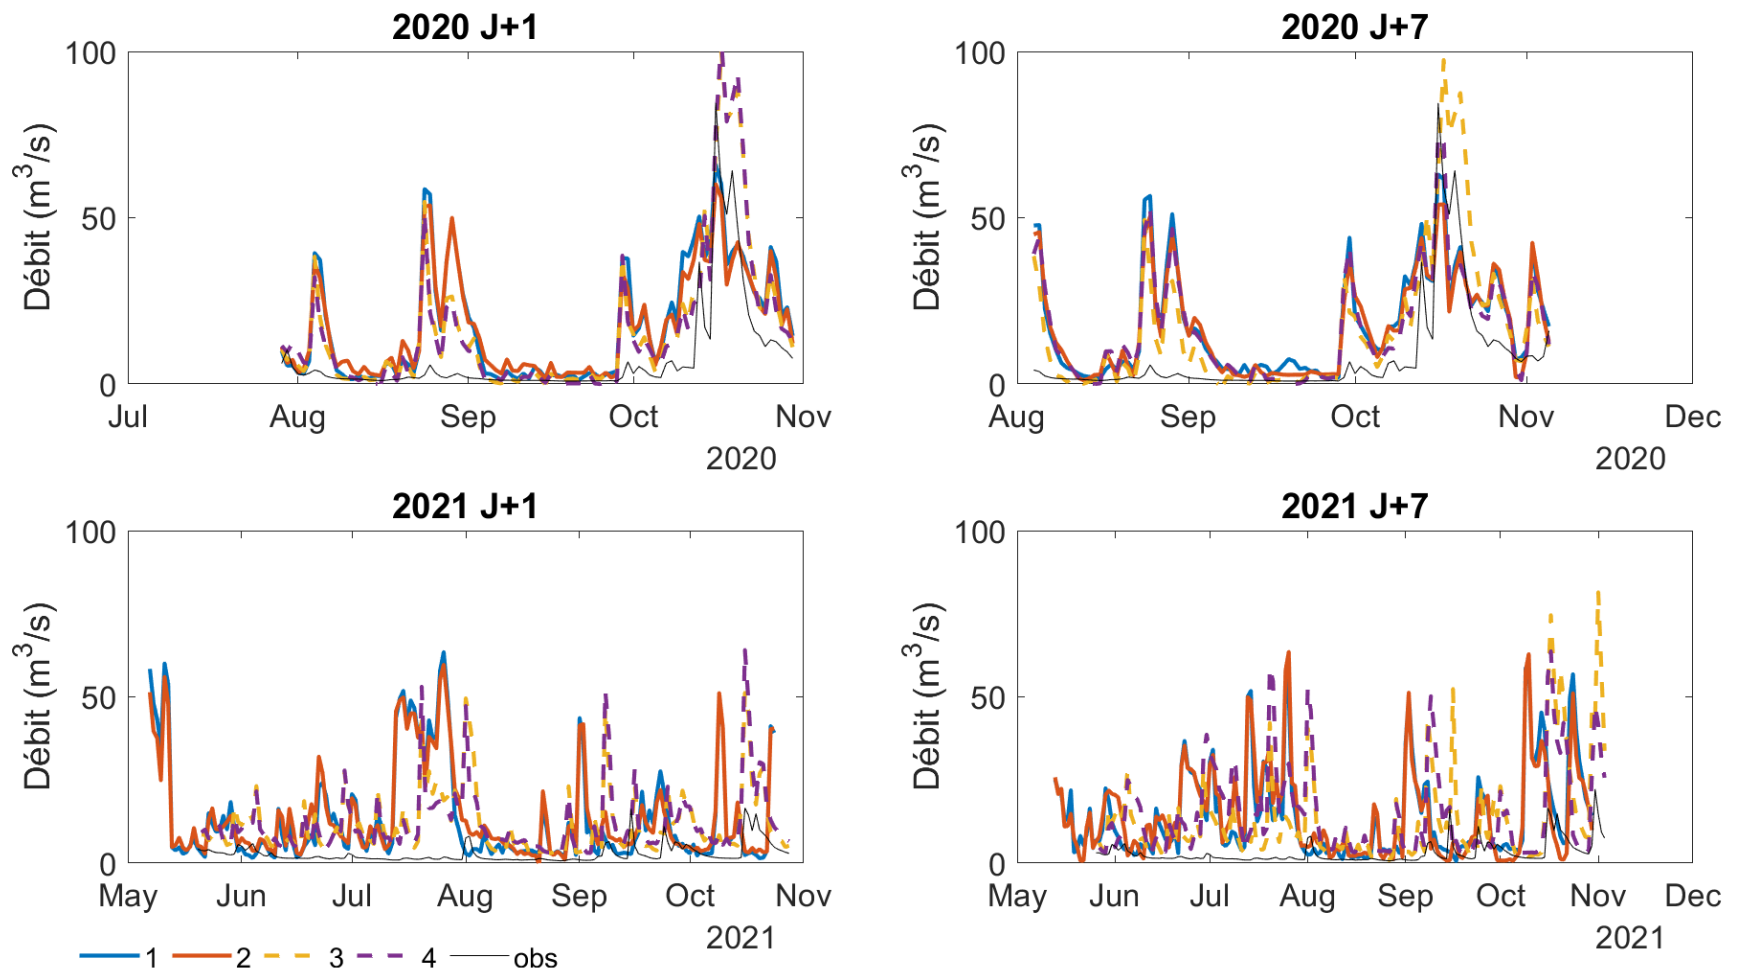


Figure 6.16 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement adapté sur 2018 à 2021 pour le BV Au Saumon avec l’humidité du sol en surface pour les configurations 1 à 4 (couleurs) et le débit observé (noir).






Figure 6.17 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement adapté sur 2018 à 2021 pour le BV Au Saumon avec l'humidité du sol en profondeur pour les configurations 9 à 12 (couleurs) et le débit observé (noir).


2018 J+1




2018 J+7



2019 J+1



2019 J+7



— 1 — 2 — 3 — 4 — obs

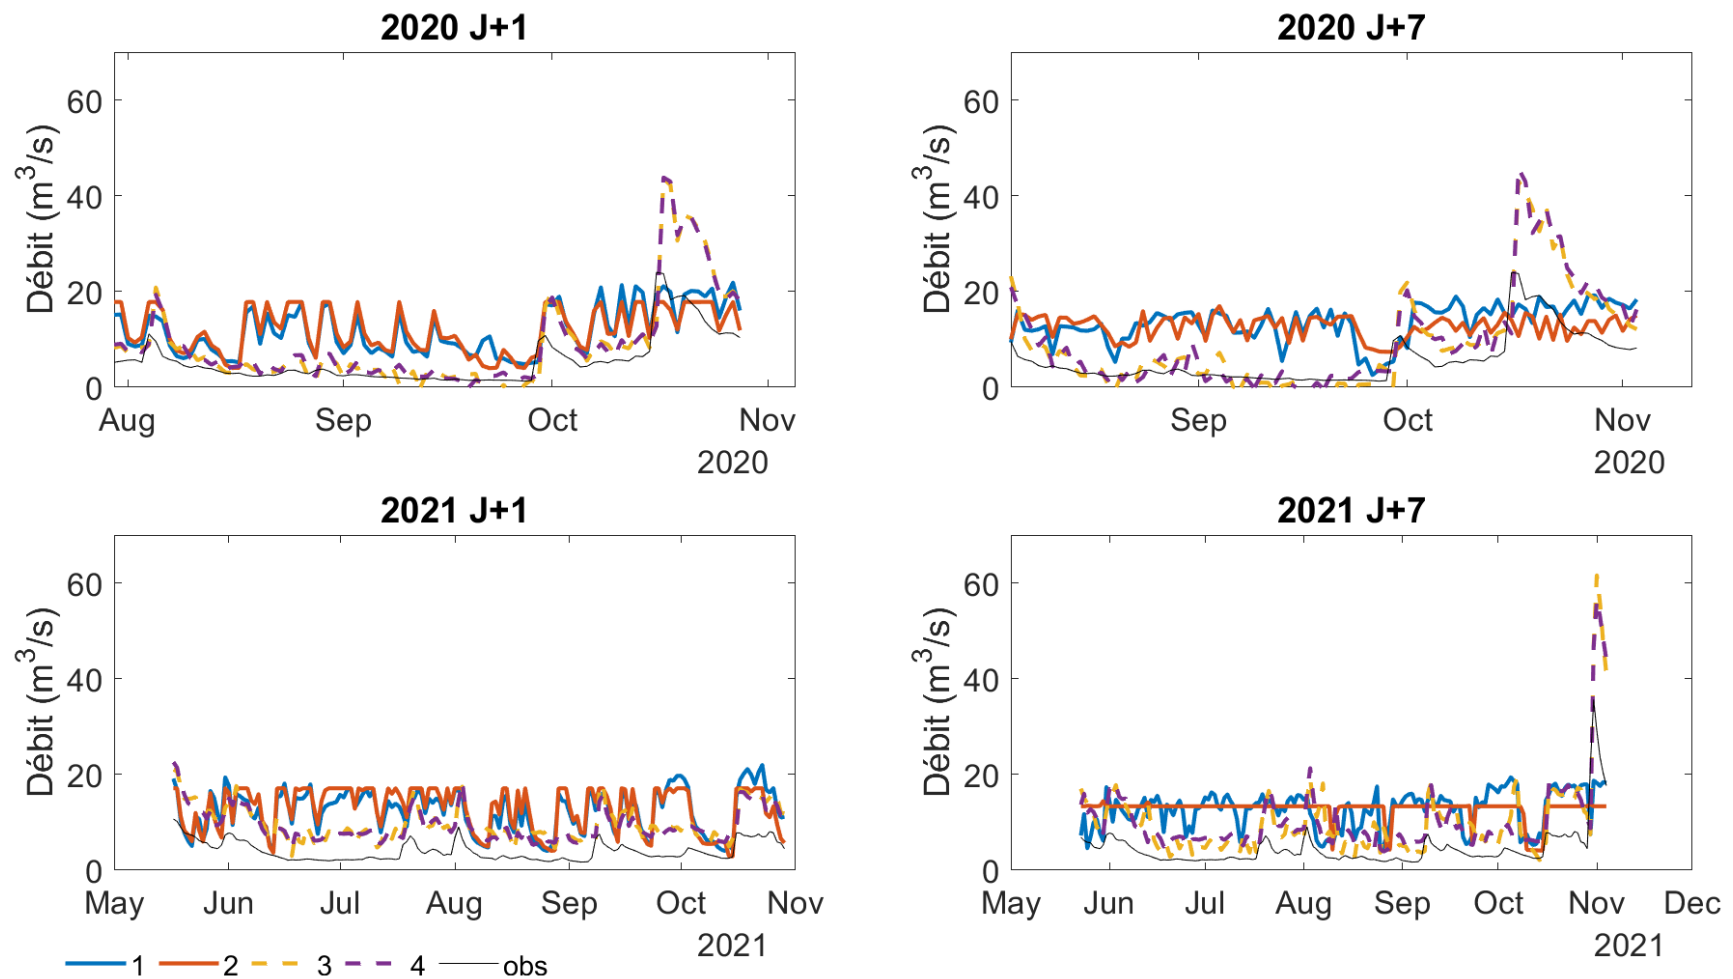


Figure 6.18 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement adapté sur 2018 à 2021 pour le BV Magog avec l'humidité du sol en surface pour les configurations 1 à 4 (couleurs) et le débit observé (noir).

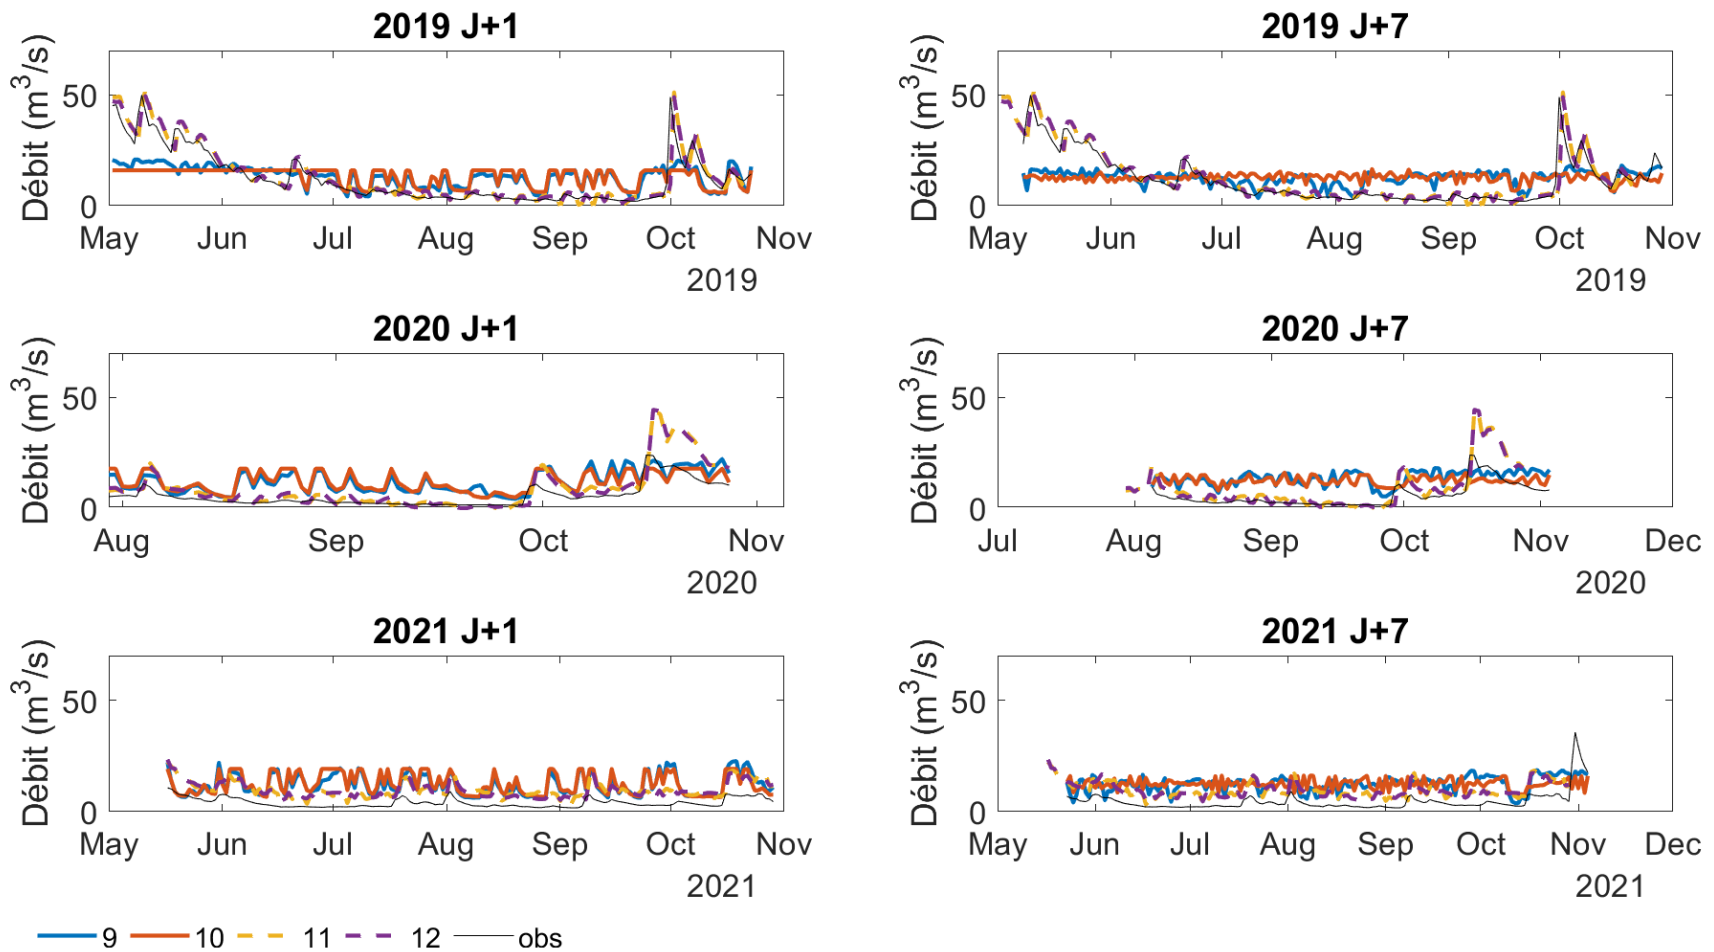


Figure 6.19 – Hydrogrammes à J+1 (gauche) et J+7 (droite) en validation en environnement adapté sur 2018 à 2021 pour le BV Magog avec l’humidité du sol en profondeur pour les configurations 9 à 12 (couleurs) et le débit observé (noir).

6.3. Discussion

6.3.1. Selon l'année

Les observations faites dans ce chapitre à propos des différences selon les années à prévoir en validation en environnement réel montrent des similitudes avec les résultats obtenus en environnement adapté. Cette constance dans les résultats obtenus entre environnements adapté et réel est satisfaisante, car elle met en avant que le modèle RNA a un pouvoir de généralisation satisfaisant. Bien sûr, on ne cache pas qu'il y a une perte de qualité des prévisions, mais les tendances globales demeurent identiques.

En environnement réel, le modèle de RNA conserve sa difficulté à prévoir les périodes d'étiage, qu'ils soient sévères ou non. Les débits sont constamment surestimés et l'intégration des variables d'état sélectionnées comme intrants au modèle ne semble pas pertinente pour la prévision des étiages. En effet, le débit prévu est toujours soumis à une réactivité forte aux précipitations, sans égard à l'état du BV et donc à la capacité d'infiltration et à la capacité de ruissellement du sol à un instant donné de la saison. La littérature dispose d'éléments sur le sujet, montrant en particulier le besoin de développer des modèles spécifiques pour les périodes d'étiage (Horn et Schumann, 2018) : le comportement hydrologique d'un BV durant cette période est différent par rapport à d'autres périodes de l'année hydrologique. Ainsi, prévoir convenablement ce type d'événement hydrologique dans un modèle général comme on le fait ne pourra pas mener à des résultats aussi bons que des modèles développés spécifiquement pour la prévision en période d'étiage. Des indices sont développés pour tenter d'intégrer au mieux les particularités du BV lors de périodes d'étiage, comme l'indice de Palmer (Alley, 1984), l'indice de sécheresse effective (Byun et Wilhite, 1999), l'indice standardisé de précipitation et d'évapotranspiration (Vicente-Serrano et al., 2010), l'indice d'étiage (Nalbantis et Tsakiris, 2009) ou, développé plus récemment, l'indice de sécheresse intégré (Shah et Mishra, 2020). Cette sélection d'indice met de l'avant le nombre important d'indices potentiels auxquels on peut faire appel. Foulon et al. (2018) en proposent même une comparaison de trois d'entre eux afin de mieux comprendre les indices les plus appropriés pour la prévision des faibles débits et en particulier dans un contexte de changements climatiques.

En considérant l'ensemble de la saison estivale, le modèle de RNA développé en environnement adapté mais utilisé en environnement réel perçoit les variations naturelles du débit. Bien qu'il surestime presque toujours le débit prévu par rapport au débit observé, on note une réduction de l'amplitude des montées et descentes de crue qui sont – très souvent – prévues au bon moment, illustrant ainsi la capacité du RNA à déceler les pics les plus importants. Ce comportement est à modérer par la sur-réactivité du RNA à beaucoup d'événements précipitants. Ainsi, les hydrogrammes issus des sorties du RNA montrent des oscillations régulières associées aux précipitations sans modération selon le vrai état du BV. Le fait que le modèle de RNA ait appris avec des données d'humidité du sol de l'environnement adapté et soit validé avec des données de l'environnement réel peut directement impacter les résultats du modèle. Un biais initial entre les deux sources des données d'humidité du sol engendrerait un biais en sortie sur les données de débit fournies par le RNA. On note toutefois une amélioration avec l'horizon de prévision, et ce pour les quatre années de prévision successivement utilisées en validation. Ainsi, il semble que l'effet de mémoire de l'humidité du sol soit plus important et favorable avec un certain délai.

Les meilleurs résultats sont obtenus pour l'été 2018 et les pires pour l'été 2021. Au moins deux raisons peuvent être trouvées à cela. La période de l'été 2018 sur laquelle la campagne de mesure d'humidité du sol est courte et ne couvre que la fin de l'été. Le RNA est plus à son avantage, car c'est une période de l'année où les étiages sont finis ou courts quand il y en a encore. Les pics de crue se succèdent en réponse aux différents événements précipitants que subissent les BV. Le modèle doit ajuster les valeurs de débit à prévoir mais le comportement global est très bon sur les deux BV. Déjà amplement commenté, l'été 2021 est un été très sec avec un étiage sévère et prolongé. On a déjà évoqué les difficultés du RNA à modéliser et donc prévoir les étiages et 2021 en est une très bonne illustration. Le modèle réagit à tous les événements précipitants sans distinction. Le modèle de RNA développé n'est donc pas pertinent pour prévoir seulement des faibles débits, amenant à des étiages, que ceux-ci soient sévères ou pas. Toutefois, on peut modérer ces propos car une limite du modèle vient du faible nombre de données disponibles et donc d'un apprentissage du modèle plus compliqué pour affirmer de manière stricte que les étiages ne peuvent pas être prévu avec le modèle de RNA développé avec les

intrants utilisés. Il est légitime d'espérer que les résultats puissent être améliorés avec des séries de données plus longues.

6.3.2. Selon l'essai pour les configurations avec l'humidité du sol

Les différences observées entre les essais ont parfois été soumises à des cas particuliers dus par exemple au BV à l'étude ou à l'année de validation utilisée. Toutefois, certains comportements demeurent les mêmes pour tous les essais et les quatre années de validation. En effet, les résultats montrent que le choix des variables d'état joue un rôle plus important que le choix des variables météorologiques, comme c'est le cas en environnement virtuel (rappel de la section 5.2). L'intégration des températures minimale et maximale ne joue pas un rôle majeur mais il apparaît que leur intégration aide le modèle sur l'ensemble de la saison. Comme c'est intégré pour les modèles déterministes traditionnels, la combinaison entre la précipitation et la température renferme une information plus complète en lien avec les différents processus hydrologiques dans la genèse des débits. Cette similitude entre le fonctionnement des deux modèles (déterministes et RNA) met en exergue la modélisation indirecte des relations non-linéaires des processus hydrologiques par le RNA à partir seulement des intrants et sorties du modèle fournies en apprentissage.

L'utilisation du débit comme variable d'état en plus de l'humidité du sol exerce une influence plus marquée. Ce sont en effet les essais 3, 4, 7 et 8 qui présentent les meilleurs résultats. Les hydrogrammes prévus sont plus proches de l'observation en termes de valeurs mais aussi concernant les montées et descentes de crue. Les pics de crue, bien que toujours surestimés, sont atténués avec l'ajout du débit au pas de temps précédent comme intrant au modèle. Cette plus-value du débit est plus marquée en environnement réel qu'en environnement adapté, avec même une pondération trop importante dans certains cas (BV Magog, été 2019, essais 3 et 4, Figure 6.13 ; essais 7 et 8, Figure 6.14 pour lesquels le RNA semble proposer comme valeur de débit le débit observé le jour de la prévision. C'est un comportement qu'on retrouve également avec l'humidité du sol en profondeur (toujours pour les essais 11 et 12, Figure 6.15)

La combinaison entre débit et humidité du sol en surface offre les meilleurs résultats et en particulier lorsque températures et précipitations sont utilisées comme intrants météorologiques.

L'usage couplé de l'humidité du sol et du débit permet justement d'atténuer partiellement la simple reproduction du débit observé quelques jours plus tard. Cependant, on note une très forte réactivité du RNA aux précipitations. L'humidité du sol en surface étant également très réactive aux précipitations, il semblerait que le RNA ait une fâcheuse tendance à prévoir un pic de crue à chaque événement précipitant. On voit que les mesures *in situ* d'humidité du sol en profondeur ne permettent pas de résoudre ce problème, notamment à cause de la forte corrélation entre les mesures d'humidité du sol en surface et en profondeur. Ces derniers propos méritent toutefois d'être confrontés à une autre explication issue de la méthode de modélisation retenue. Compte tenu du faible nombre d'années d'observations d'humidité du sol *in situ*, on a privilégié l'utilisation de ces données-là en période de validation. L'apprentissage s'est quant à lui fait avec des données simulées par HYDROTEL. Or, le calage d'HYDROTEL a été réalisé sans une prise en compte des observations d'humidité du sol. Il se pourrait alors qu'un biais soit présent entre les humidités du sol simulées par le modèle et celles observées sur le terrain. Un tel biais, si avéré, pourrait être à l'origine d'un « défaut » du modèle de RNA. Sans remettre en cause son apprentissage ni sa validation, il s'agirait alors ici de voir qu'un écart entre les deux sources de données se répercute ensuite en sortie et donc sur les métriques évaluatrices des performances du RNA. Cette dernière remarque est appuyée par les illustrations des différences entre simulations HYDROTEL et observations *in situ* de la Figure 6.1 et de la Figure 6.3, respectivement pour les BV Au Saumon et Magog. Elle est aussi appuyée par le fait que les profondeurs des couches de surface et intermédiaires d'HYDROTEL (Tableau 3.4) ne correspondent pas forcément à celles utilisées lors de l'instrumentation des BV.

On se rappelle par ailleurs qu'en environnement virtuel, les prévisions de débit avec l'humidité du sol en profondeur présentaient des résultats satisfaisants mais moins bons que l'humidité du sol en surface. Les résultats obtenus ici sont très similaires quel que soit la profondeur de la mesure de l'humidité du sol. Cela peut venir des sites de mesure ou de la profondeur retenue. On se serait attendu à une réactivité moins forte aux précipitations avec l'humidité du sol en profondeur car le réservoir de sol de la couche intermédiaire est moins sensible aux précipitations que la couche de surface qui réagit très fortement aux précipitations et aux fortes températures entraînant une forte évaporation.

On étudie maintenant plus en détails les résultats pour les essais 3 et 11 sur les trois années pour lesquelles l'humidité du sol en profondeur est disponible (2019, 2020 et 2021) avec tous les résultats en validation (i.e. humidités du sol en surface et en profondeur en environnements réel et adapté). Pour les deux BV, les résultats sont assez similaires. Cela peut venir de la forte ressemblance entre les profils d'humidité du sol en surface et en profondeur avec des réactions aux événements précipitants assez similaires. Cela pourrait venir du choix des sites agricoles sur lesquels les sondes en profondeur ont été installées. Également, un nombre plus grand de stations de mesure en profondeur *in situ* pourrait apporter plus de variabilité dans la représentation du BV et ainsi aider à mieux prévoir le débit. On pourrait penser à instrumenter les sites forestiers de sondes à 20 cm de profondeur. Ce type d'instrumentation permettrait de comparer dans des conditions strictement identiques les performances du RNA selon la profondeur de la mesure, sans prise en compte du nombre de stations et l'occupation du sol à laquelle elles sont liées. On veillerait toutefois à ne pas trop densifier le réseau de mesures pour ne pas tomber dans un modèle moins bon comme illustré en section 5.3 pour le BV Au Saumon en environnement virtuel. On avait alors introduit la notion de REA, qui pourrait sans aucun doute être utile pour déterminer le nombre de sites à instrumenter, ainsi que leur localisation.

Par rapport aux résultats en environnement adapté, la différence des sorties de modèle selon la profondeur de l'humidité du sol utilisée en intrant est beaucoup plus faible. La forte sensibilité du débit issu du modèle de RNA aux variations d'humidité du sol en profondeur est atténuée avec l'utilisation de données *in situ*. Cela peut s'expliquer par les moins grandes différences d'évolution entre les deux profondeurs pour les mesures *in situ* que pour les valeurs fournies par HYDROTEL. Le modèle conceptuel dont on se sert, à travers le schéma BV3C, propose une variation quasi-permanente de l'humidité du sol selon le profil vertical et donc des profils bien distincts. En revanche, les observations *in situ* n'offrent que peu de différences de profil selon la profondeur et cela pénalise fortement le RNA pour proposer des résultats différents selon la profondeur des sondes d'humidité du sol.

Enfin, pour les essais utilisant l'humidité du sol en surface, deux méthodes d'extrapolation des séries temporelles ont été comparées pour les données d'observation d'humidité du sol, utilisées en validation. Il convient ici d'apporter des éléments de réflexion au fait que les modèles de RNA avec la méthode de la moyenne (essais 1 à 4, Tableau 6.2) performant mieux que ceux

avec la méthode ppv (essais 5 à 8, Tableau 6.2). La méthode ppv est plus objective que la moyenne car elle tient compte de la distance et donc pourrait mieux percevoir certaines évolutions à une échelle très locale. Cependant, il faut prendre garde que cette méthode d'extrapolation n'est pas à base physique et ne tient pas compte des caractéristiques physiographiques du BV à l'étude. Elle ne permet donc pas forcément de représenter adéquatement les variations spatiales de l'humidité du sol à l'échelle régionale. En utilisant cette méthode, l'enjeu repose avant tout sur la densité du réseau d'observation utilisé : plus il est dense, plus cette approche sera pertinente à utiliser même si elle n'intègre aucune information physiographique. Une dizaine de sites de mesure sont utilisés pour les quatre années de validation considérées. Il est courant d'avoir deux sondes de mesure très proches en distance mais dans deux milieux différents (forêt ou aire ouverte) qui ont toutes deux les mêmes périodes manquantes à compléter (car installées sur les sites rattachés à un même propriétaire). Ainsi, une correction sur deux sondes issues d'un site double avec une installation tardive en début de saison ou un retrait anticipé en fin de saison peut perturber l'hétérogénéité naturelle qu'on était venu chercher en utilisant ces données. Ces deux sondes, étant très proches, vont très probablement avoir comme voisins les plus proches les quatre mêmes sondes. En apprentissage, la variation simulée par HYDROTEL ne se retrouve plus en validation et pénalise alors le RNA. Cela s'explique par le fait qu'HYDROTEL simule une variation d'humidité du sol sur une approche physique, illustrée par le découpage du territoire en UHRH. L'avantage de l'utilisation de la moyenne est qu'on ne favorise pas ou ne pénalise pas un milieu par rapport à un autre. C'est ce qui peut alors expliquer les meilleurs résultats obtenus avec l'approche par moyenne que par ppv.

Une approche plus objective tenant compte des types de sol, de leur utilisation et leur altitude par exemple pourrait aider à mieux corriger les données manquantes. De plus, le nombre restreint de station sur le BV limite l'utilisation des approches proposées. On pourrait légitimement proposer une approche par ppv pour des BV de plus grandes superficies avec un réseau d'observation dense ; dans ce cas, les différences spatiales pourraient être mieux perçues, plus ou moins indifféremment du type du site d'installation.

6.3.3. Selon le BV

La première observation qui surgit en comparant les deux BV à l'étude porte sur la différence de qualité des résultats en validation alors même que les similitudes étaient nombreuses en apprentissage et en environnement virtuel. Il est vrai que les tendances d'ensemble sont les mêmes et ceci est rassurant. En effet, on note une amélioration des prévisions avec l'horizon de prévision pour les deux BV pour une forte majorité des cas étudiés en validation. Il est également vrai que le comportement selon l'essai retenu est le même. Il est toujours exact que les difficultés à prévoir les étiages et les bonnes aptitudes à prévoir les pics de crue s'observent sur le BV Au Saumon tout comme sur le BV Magog. Cependant, la qualité des prévisions est indubitablement moins bonne pour le bassin transfrontalier. Plusieurs pistes peuvent être avancées pour en donner les raisons.

Il convient de rappeler (une fois de plus) la différence de couverture spatiale des sondes d'humidité du sol par rapport à l'aire drainée des stations hydrométriques utilisées. La station hydrométrique installée sur le BV Au Saumon couvre environ 75 % du territoire. La répartition des stations de mesure d'humidité du sol est homogène sur le territoire. On peut donc s'attendre à voir une assez bonne représentation du profil d'humidité du sol sur la partie drainée par la station de débit utilisée. Pour le BV Magog, la configuration est totalement différente, mais cela reste toutefois intéressant et pertinent de tester et d'observer le comportement du modèle de RNA. La station hydrométrique reconstruite ne draine qu'un tiers de la totalité du BV dans sa partie amont. Les sondes d'humidité du sol sont toutes installées dans la partie avale, une région extérieure au territoire drainé. On a fait l'hypothèse que les caractéristiques du BV sont suffisamment homogènes pour que des mesures prises en dehors de la zone drainée apportent toujours de l'information pertinente. Compte tenu des résultats obtenus et des hydrogrammes de sortie du RNA, cette hypothèse semble s'avérer faible. Pour expliquer nos résultats, on mise davantage sur la faiblesse de cette hypothèse plutôt que sur le dysfonctionnement des sondes installées sur le BV Magog car la qualité des mesures d'humidité du sol semble être équivalente entre les deux BV avec une réactivité normale aux précipitations. De plus, l'aire drainée sur le BV Magog par la station hydrométrique fictive considérée est d'environ 700 km², soit équivalente à celle drainée par la station hydrométrique du BV Au Saumon. Le nombre de sondes d'humidité du sol installées est du même ordre de grandeur chaque année également. Le

rapport entre le nombre de stations pour la mesure de l'humidité du sol, leur répartition sur le territoire et la taille du bassin drainé par les stations hydrométriques ne semblent donc pas être un argument expliquant les différences de résultats observées entre les deux BV.

6.4. Sommaire

Ce chapitre visait à transférer le modèle de RNA développé sur les BV Au Saumon et Magog de l'environnement virtuel à l'environnement réel, via le passage par un environnement qualifié d'adapté. L'approche utilisée a été dictée par la disponibilité des données d'observation *in situ* d'humidité du sol sur les quatre années d'instrumentation des BV (2018-2021). Les données d'humidité du sol issues des mesures *in situ* sont utilisées en validation seulement. En apprentissage, on se sert des données fournies par HYDROTEL sur les UHRH correspondant à la localisation des sites de mesure. Les données météorologiques sont issues de réanalyses ERA5-Land. Les données de débit sont des observations issues d'une station hydrométrique pour le BV Au Saumon et d'une reconstruction de deux stations hydrométriques en amont du lac Memphrémagog pour le BV Magog.

De manière générale, les résultats montrent de plus grandes différences en validation selon les années prises en compte, avec de grosses difficultés pour les étiages sévères (2020 et 2021) et de meilleures prévisions pour les années « normales » (2018 et 2019). Une comparaison en validation entre environnements adapté et réel a été menée et a abouti à des résultats proches. Cela révèle à la fois de la qualité des données mesurées *in situ* sur les aires sélectionnées de chaque BV et de la bonne représentation par le modèle HYDROTEL des écoulements et autres phénomènes hydrologiques, aboutissant à une estimation de l'humidité du sol proche de la réalité.

Par ailleurs, la comparaison entre différentes configurations d'intrants a mené à des conclusions similaires aux chapitres précédents, à savoir que l'utilisation conjointe du débit avec l'humidité du sol fournit les meilleures prévisions. Selon la profondeur des mesures d'humidité du sol, peu de différences sont observées, bien que le RNA construit avec des mesures d'humidité du sol en surface produise sensiblement les meilleurs résultats. Cela vient de la forte corrélation qu'il y a entre les deux types de mesure.

Enfin, la comparaison entre les deux BV révèle l'avantage de couvrir l'aire drainée par la station de débit pour laquelle on fait la prévision (Au Saumon) et non une zone en amont à la station (Magog). Sur les quatre étés étudiés, les résultats sont globalement meilleurs pour le BV Au Saumon. Ainsi, ce chapitre met en exergue les qualités et défauts du modèle de RNA développé

et entraîné en environnement adapté lorsqu'il est ensuite validé avec des données d'observation *in situ*. Il permet de faire un lien tangible entre le développement d'une méthode sur banc d'essai et une première approche appliquée avec des données similaires à celles utilisées en opérationnel par les prévisionnistes.

CHAPITRE 7 CONCLUSION

7.1. Résumés des travaux réalisés

Ce projet de recherche a mis en place un modèle de prévision hydrologique à court terme à partir d'une structure de RNA en environnement virtuel. Les résultats ont permis de discriminer les apports de différents intrants au modèle et le rôle de la spatialisation de ces intrants pour les BV des rivières Androscoggin, Susquehanna, Au Saumon et Magog. De plus, une évaluation du modèle avec des données d'observation *in situ* d'humidité du sol a été faite sur les deux derniers BV cités. Seul l'été a été pris en compte, avec comme objectif une prévision du débit à l'exutoire du BV ou au niveau de la station hydrométrique présente sur le BV. L'horizon de prévision court terme est défini comme allant de un à sept jours à l'avance.

L'apport de différentes variables comme intrant au RNA a d'abord été étudié en environnement virtuel. L'environnement virtuel a été ici défini comme un banc d'essai dans lequel est utilisé un modèle hydrologique conceptuel dans une première phase pour générer des séries de données complètes et homogènes. Celles-ci servent d'intrants au RNA dans un second temps et permettent de faire un nombre d'essais moins limité avec des « vraies données ». Sur la base de chaque UHRH, le modèle HYDROTEL a servi à générer les variables utilisées ensuite comme intrants au modèle de RNA. La comparaison s'est faite sur les quatre BV à l'étude à l'aide d'un modèle global. Les essais ont porté tant sur différentes variables météorologiques que sur différentes variables d'état. Les tests sur les variables météorologiques ont mis de l'avant la plus-value des précipitations et des températures par rapport à d'autres variables telles que l'évapotranspiration ou l'API classique ou modifiée. Concernant les variables d'état, les tendances sur la fenêtre de prévision de sept jours sont différentes et il est intéressant de les comparer selon l'intégration d'une seule variable d'état ou de deux à la fois. En effet, l'humidité du sol, qu'elle soit de surface ou de profondeur, améliore les résultats de prévision avec l'horizon de prévision. Il y a donc un effet de mémoire qui entre en jeu dans la chaîne de prévision. Les résultats avec l'humidité du sol en profondeur restent satisfaisants, mais sont toutefois moins bons que ceux avec l'humidité du sol en surface. L'utilisation du débit au pas de temps précédent est associée à un niveau de performance qui décroît entre J+1 et J+7. En revanche, coupler humidité du sol en surface et débit au pas de temps précédent permet de

combiner les meilleurs effets des deux variables d'état et de gommer, au moins partiellement, les défauts de chacune. Ainsi, les résultats montrent une variation bien moins importante selon l'horizon de prévision, avec le débit du pas de temps précédent qui est bien intégré sur les premiers horizons puis l'effet de mémoire de l'humidité du sol qui joue un rôle significatif pour les horizons les plus lointains. La configuration d'intrants qui fournit les meilleurs résultats prend en compte les précipitations, les températures minimale et maximale (ou moyenne), l'humidité du sol en surface et le débit au pas de temps précédent. Ces observations sont vérifiées pour les quatre BV de façon plus ou moins nette selon les années. On distingue par ailleurs une meilleure capacité du modèle hydrologique à prévoir les années qualifiées d'humides comparées aux années dites sèches. Le modèle de RNA développé en environnement virtuel surestime presque toujours les périodes d'étiage, quel que soit le BV, alors qu'il prévoit très bien les différents pics de crue, que ce soit en termes de volume, de débit de pointe ou de dates de début de crue et de fin de décrue.

Le second objectif mené en environnement virtuel visait à comparer le rôle de la spatialisation des intrants sur la qualité de la prévision. Considérant la configuration d'intrants avec l'humidité du sol comme seule variable d'état, ainsi que les précipitations et les températures minimale et maximale comme variables météorologiques, quatre spatialisations sont testées : globale, semi-spatialisé (construit sur la base des UHRH), spatialisée (construit sur la base de pixels de 28x28 km²) et singulière (utilisant un seul pixel à la fois). Le modèle a été mis à l'épreuve sur le BV de la rivière Androscoggin et dans une moindre mesure sur ceux des rivières Au Saumon et Magog. Le BV de la rivière Susquehanna n'est pas intégré à cette partie de la recherche à cause de ses dimensions et des ressources de calcul qui auraient été nécessaires pour faire tourner le modèle spatialisé. Les résultats montrent un avantage clair des modèles global et spatialisé par rapport aux différents modèles singuliers, bien que certains modèles singuliers dépassent occasionnellement ces deux modèles, sur certains horizons de prévision. Par conséquent, cela montre que les informations issues d'une région particulière du BV ne permettent pas de fournir de l'information de qualité sur l'ensemble du BV. Cependant, il ne ressort pas de réelle plus-value du modèle global par rapport au modèle spatialisé et vice-versa. Tant en apprentissage qu'en validation, les deux types de spatialisation fournissent des résultats équivalents. Il ne ressort pas de performance accrue d'une des spatialisations par rapport à l'autre selon le régime

hydrologique dominant. À propos du modèle semi-spatialisé, exploité sur le BV Au Saumon et pour lequel le débit a été ajouté comme variable d'état en plus de l'humidité du sol en surface, on relève que la forte densité d'unités hydrologiques a très probablement pénalisé le modèle par rapport aux modèles global et spatialisé. Sans que les résultats du modèle semi-spatialisé soit désastreux, ils ne sont pas du niveau du global et du spatialisé.

Finalement, la troisième et dernière partie de cette thèse s'est déroulée en environnement réel, dans lequel seuls les BV des rivières Au Saumon et Magog ont été étudiés. On a alors adapté la spatialisation du modèle de RNA à un modèle semi-spatialisé. L'apprentissage du RNA s'appuie sur dix-huit années (2000-2017) en utilisant les données d'humidité du sol issues d'HYDROTEL. La validation a été effectuée indépendamment sur les quatre étés pour lesquels on dispose de mesures terrain (2018-2021). Sur le BV Au Saumon, les observations d'humidité du sol couvrent l'ensemble du territoire avec une station hydrométrique qui draine environ 70 % du territoire (soit environ 700 km²). Sur le BV transfrontalier Magog, le débit utilisé est un débit reconstruit à partir de deux stations hydrométriques qui drainent un territoire couvrant environ 700 km² dans sa partie amont, aux États-Unis. Les stations d'observation d'humidité du sol sont installées en aval de la station hydrométrique fictive, dans sa partie canadienne. Sur les deux BV, les sondes sont installées à la fois en milieu forestier et en milieu ouvert. La mesure est réalisée en surface (5 cm) pour les milieux forestiers et en surface et en profondeur (20 cm) pour les milieux ouverts. Différentes configurations d'intrants sont aussi testées. Le nombre de variables s'en trouve ici réduit par rapport aux essais effectués précédemment en environnement virtuel, car on a considéré seulement les variables les plus : humidité du sol, débit, précipitations et températures. Huit combinaisons différentes sont testées. Les sondes ont pu être installées et retirées à des dates différentes. Deux méthodes d'extrapolation des séries temporelles ont été considérées : la moyenne de toutes les stations disponibles et la moyenne des quatre plus proches voisins (ppv). Pour les données d'humidité du sol en profondeur, seule la moyenne a été prise en compte, car dans ce cas-ci le panel de données n'était pas suffisant pour qu'il soit vraiment approprié d'utiliser la méthode ppv. Les débits simulés par le RNA sont meilleurs pour le BV de la rivière Au Saumon que pour celui de la rivière Magog. Les tendances observées en termes d'évolution du NSE avec l'horizon de prévision ou sur les profils des hydrogrammes étant similaires pour les deux BV pour les différentes configurations d'intrants, elles ont été jugées

satisfaisantes. En environnement réel, la différence de performance du RNA selon l'utilisation de l'humidité du sol en surface ou en profondeur n'est pas aussi claire que pour le RNA entièrement développé et validé en environnement adapté, ce qui pourrait s'expliquer par la forte corrélation existante entre les deux types de mesure. La meilleure configuration d'intrants en environnement réel – températures minimale et maximale, précipitations, humidité du sol en surface et débit – se retrouve être la même qu'en environnement adapté. La meilleure méthode d'extrapolation est la moyenne, bien que les différences soient faibles avec celle des plus proches voisins. En termes de qualité de prévision selon les années, les résultats dépendent fortement de la période de la saison et du régime hydrologique particulier en cours. Ne disposant d'observations qu'à partir du mois d'août, l'été 2018 est difficile à évaluer, mais les résultats obtenus sur les soixante-quinze jours dont on dispose, ont une prévision satisfaisante du débit sur l'ensemble de la fenêtre de prévision. Les résultats sur 2019 sont du même niveau de satisfaction qu'en 2018. En 2020 et 2021, les étés sont secs et le RNA a de grandes difficultés à fournir une prévision de qualité similaire aux deux autres étés. La période d'étiage étant relativement courte en 2020, le RNA continue à fournir des prévisions de qualité sur l'ensemble de la saison pour le BV Au Saumon. En revanche en 2021, l'été étant très sec pendant de longues semaines, le RNA surestime régulièrement le débit et réagit trop fortement à tous les événements précipitants. L'état du BV est mal perçu et mal intégré dans le modèle. Le défaut majeur du modèle de prévision développé en environnement adapté et testé en environnement réel est sa sur-réactivité aux précipitations. Les différences, parfois importantes comme en 2020, entre les deux BV laissent penser que l'installation de sondes sur un sous-bassin qui n'est pas dans la partie drainée de la station où l'on prévoit le débit serait en cause. Enfin, une observation significative a mis en lumière la qualité des données d'observation *in situ* qui concurrencent le modèle validé en environnement adapté.

7.2. Contributions originales

Cette thèse participe à l'élaboration de nouveaux modèles de prévision à destination de la communauté scientifique rattachée tant en recherche académique qu'en industrie.

Tout d'abord, ce travail de recherche apporte une contribution d'ordre théorique. L'étude de la spatialisation des intrants pour un modèle de RNA en prévision hydrologique n'étant pas documentée, cette recherche en propose donc une première évaluation. La méthode développée puis testée a une portée large, car elle peut être répliquée sur des BV de différentes tailles et pour d'autres saisons, voire sur l'année complète. La comparaison entre discrétisations globale, semi-spatialisée et spatialisée a permis de fournir des tendances spécifiques pour la prévision hydrologique par RNA. En particulier, on peut rappeler les résultats proches obtenus avec une discrétisation globale et une discrétisation spatialisée. Les résultats issus d'une discrétisation semi-spatialisée, certes moins bons, restent encourageants. Cette thèse offre une première comparaison entre trois discrétisations des intrants pour un même BV avec des conditions de modélisation similaire (notamment, même source des intrants).

Par ailleurs, le développement des expériences en environnement virtuel contrôlé met de l'avant le champ expérimental de cette recherche, donnant accès à un grand nombre d'essais de modélisation. Le contrôle dont dispose le modélisateur lui permet dans un second temps de confronter son modèle à des conditions dites d'environnement réel, correspondantes à des conditions plus proches de l'opérationnel. On se place donc dans deux environnements de modélisation avec des sources d'intrants différentes. On met ici de l'avant la force du RNA de valider ses performances sur des données réelles à partir d'un apprentissage fait sur des données virtuelles. De plus, les campagnes de mesure d'humidité du sol réalisées donnent accès à une couverture spatiale et temporelle acceptable par rapport à la taille des BV à l'étude. En d'autres mots, nonobstant le niveau de satisfaction émanant des résultats obtenus, le cadre de modélisation en environnement réel permet de confronter le modèle de RNA à un nombre représentatif d'intrants issus de mesures *in situ*.

Enfin, la mise en place d'une chaîne originale de prévision sur sept jours concourt à une dimension pratique de cette contribution. Chaque horizon de prévision est associé à un modèle de RNA indépendant et chaque horizon est lié au suivant par des sorties et intrants communs. À travers ce processus en chaîne, chaque RNA est indépendant car il apprend spécifiquement à partir de données associées à une certaine erreur (liée soit aux observations pour le modèle à $J+1$, soit à l'incertitude liée à une prévision au-delà de $J+1$). De plus, faire de la prévision hydrologique à court terme implique d'incorporer les conditions initiales sur l'état du BV. Les

forces et faiblesses de l'utilisation des variables d'état d'humidité du sol (en surface et en profondeur) et de débit, conjointement ou non, ont pu être établies. Cela constitue une avancée dans la compréhension de la structure d'un modèle de RNA pour la prévision hydrologique. Cette approche, comme les précédentes, a pour objectif ultime d'offrir aux prévisionnistes de nouveaux outils et des éléments de compréhension des modèles de RNA en prévision hydrologique. Cette thèse propose une méthode de mise en place et d'évaluation d'un modèle de prévision hydrologique à court terme qui peut être reprise, confrontée et améliorée dans d'autres cadres d'étude par d'autres équipes de recherche.

7.3. Perspectives de recherche et travaux futurs

Cette thèse a donné satisfaction concernant plusieurs aspects. Toutefois, de manière assez naturelle, plusieurs travaux de recherche restent encore à mener et les pistes de recherche existantes s'avèrent multiples. Cela s'avère être encourageant, car révélateur du dynamisme du domaine dans lequel ces pistes s'inscrivent. Il a été choisi de n'en sélectionner que quatre, celles considérées comme les plus prometteuses, mais surtout celles parmi les plus directes à mener d'après les résultats obtenus.

Premièrement, la structure même du modèle de prévision développé pourrait être confrontée à d'autres structure voire être modifiée. L'approche par RNA a été sélectionnée, car plus simple et prometteuse pour les objectifs de cette thèse. Des modifications pourraient être élaborées à partir de cette structure de base (c'est d'ailleurs tout l'avantage d'avoir élaboré la méthodologie sur une structure simple). Avant tout, elle pourrait être comparée avec d'autres approches prometteuses récemment investiguées dans la littérature. Par exemple, les modèles récurrents ou LSTM sont tous deux déjà utilisés dans de nombreuses études et permettent d'intégrer directement à travers les intrants une séquence de temps (Kratzert et al., 2018). En particulier dans le cas d'un modèle LSTM, les intrants sont construits sur la base de séquences, il n'est donc plus nécessaire d'introduire plusieurs fois la même variable à des pas de temps différents comme cela a été fait dans cette thèse. Plusieurs études montrent ainsi le potentiel de ce type d'approche, surtout pour des applications à moyen ou long terme. Avec l'approche proposée dans cette thèse pour de la prévision à court terme, il s'agirait alors de comprendre de quelle

manière un LSTM intègre bien les conditions initiales du BV, information primordiale pour de courtes échéances. Kratzert et al. (2018) proposent un LSTM pour faire une prévision sur un vaste ensemble de BV, mettant alors en place le principe de transfert d'apprentissage. L'autre grand changement structurel concerne la possibilité d'intégrer des images comme intrants, à l'aide d'une approche par CNN. L'intérêt majeur d'un CNN est la possibilité d'utiliser une image satellitaire comme seul intrant sans avoir besoin d'en décomposer l'information. Le modèle de prévision peut directement être construit à partir d'un CNN avec une série d'images satellitaires. Le CNN peut aussi être utilisé pour faire un prétraitement des données afin de définir des intrants pour un RNA plus classique. Par exemple, Wang et al. (2018) développent un CNN pour déterminer la part du territoire qui est couverte de neige. Cela peut servir à construire un intrant à un modèle de prévision hydrologique. L'enjeu serait de nouveau de penser comment intégrer les conditions initiales du BV au CNN car, bien que la littérature soit prometteuse, les applications à court terme ne sont pas les plus nombreuses. Enfin, il est possible de coupler LSTM et CNN en un seul modèle. Cela permet de traiter une série temporelle d'images ou une vidéo par exemple (Rajabi et Estebarsari, 2019). Quelle que soit le type de structure retenue, il conviendrait toujours de la confronter au RNA développé dans cette thèse, afin de faire ressortir les forces et faiblesses de chacune et d'évaluer les gains et les pertes d'utiliser une approche plus « complexe » par rapport à un « simple » RNA.

Comme évoqué dans le paragraphe précédent, le transfert d'apprentissage est une autre avenue d'intérêt. Cette thèse a pris en compte quatre puis deux BV. Le modèle de RNA développé sur un BV aurait pu être validé sur les trois autres BV afin d'évaluer le pouvoir de généralisation et également de se rapprocher de la problématique de la prévision hydrologique pour les BV non jaugés. À l'image de la recherche, déjà citée, menée par Kratzert et al. (2018), plusieurs regroupements de BV pourraient être envisagés. De manière générale, la prévision de BV non jaugés est bien documentée et continue d'être alimentée (Arsenault et Brissette, 2014 ; Razavi et Coulibaly, 2013). Des exemples peuvent également être trouvés avec l'utilisation de RNA (Besaw et al., 2010 ; Campos et Pedrollo, 2021). On pourrait donc légitimement mettre en place une approche de transfert d'apprentissage en environnement virtuel sur les quatre BV sélectionnés, mais aussi sur les BV des rivières Magog et Au Saumon en environnement réel à partir des données d'observation *in situ* d'humidité du sol.

La troisième piste proposée porte sur la saisonnalité, la prévision événementielle et la sélection des intrants au modèle. Cette thèse s'est concentrée sur la saison estivale entière et, en particulier avec l'exemple de l'été 2021, les résultats en période d'étiage sont les moins satisfaisants. La prévision des étiages est une sous-discipline à part entière, on encourage ainsi les scientifiques à utiliser la méthodologie développée avec des intrants spécifiques pour ces périodes de faibles débits. Certains indices dédiés à la description de l'état du BV ont été fournis dans la section 6.3.1 et pourraient dans un premier temps être utilisés comme intrants au modèle. Dans le même ordre d'idée, la prévision en période hivernale ou printanière pourrait être intégrée. Il s'agirait alors de développer un modèle spécifique pour la prévision de la crue printanière par exemple, ou alors un modèle de prévision annuelle avec des intrants spécifiques à certains phénomènes particuliers (indices de sécheresse en été, indices sur la couverture neigeuse au printemps par exemple). Enfin, la prévision d'événements hydrologiques en tant qu'objets pourrait faire l'objet d'une étude à part entière. Elle pourrait s'appuyer sur certains résultats de cette thèse, comme ceux concernant la spatialisation des intrants. Chaque événement pourrait être considéré indépendamment et défini à partir d'une signature hydrologique : types de montée et descente de crue, forme de l'hydrogramme événementiel à définir à partir d'une fonction de probabilité (Chebana et al., 2012 ; McMillan et al., 2017 ; Ternynck et al., 2016).

Enfin, la dernière avenue de recherche qu'on souhaite présenter porte sur l'utilisation de données de télédétection. En environnement virtuel, on a proposé un modèle spatialisé inspiré des résolutions des produits satellitaires SMAP et SMOS. Une autre expérience aurait pu être menée en dégradant la qualité des données de manière à simuler la qualité de vraies données satellitaires. Cette dégradation aurait pu être faite en introduisant un bruit aléatoire aux séries temporelles utilisées pour chaque pixel. En environnement réel, les données satellitaires issues des satellites SMAP (depuis 2015) et SMOS (depuis 2010) pourraient être envisagées pour disposer de données d'humidité du sol. De même, les missions Sentinel-1A et 1B (depuis 2014) et de la constellation Radarsat (depuis 2020) sont des sources non négligeables de produits satellitaires en micro-ondes actives. Les séries d'images disponibles couvrent plusieurs années pour les missions les plus anciennes et surtout couvrent les BV à l'étude dans cette thèse et plus généralement les BV des régions les plus peuplées du Canada ou tous les BV des États-Unis, hors Alaska. L'intégration de ces données satellitaires pourrait être faite après traitement dans

un modèle de RNA classique comme celui développé dans cette thèse, mais aussi dans un CNN. Finalement, une autre source de données d'entrée au modèle de prévision vient des observations *in situ* mises à disposition par l'USGS aux États-Unis ou par les gouvernements fédéral et provinciaux au Canada, ainsi que des prévisions météorologiques disponibles comme celles issues du CEPMMT, d'Environnement Canada ou d'autres centres météorologiques nationaux.

Hormis ces quatre pistes pour lesquelles des éléments additionnels sont fournis, cette thèse pourrait être complétée par le développement d'un système de prévision d'ensemble, par l'évaluation de l'impact économique de ce type de prévision par RNA (Boucher et al., 2012) ou encore par la mise en place d'un module d'assimilation de données pour renforcer davantage le modèle de RNA (Bergeron, 2017).

ANNEXE

A1 Suppléments du chapitre 2

Tableau A1.1 - Avantages et inconvénients des différents capteurs pour la télédétection de l'humidité du sol.

Types de mesure	Avantages	Inconvénients	Sources de bruits
Micro-ondes actives	Indépendant des conditions atmosphériques Résolution spatiale fine	Étape de calibration	Rugosité du sol Couverture végétale Pente du sol
Micro-ondes passives	Indépendant des conditions atmosphériques Pénétration dans la végétation moyenne	Résolution spatiale peu fine (~10 km) Peut être influencé par les interférences des ondes radio	Rugosité du sol Couverture végétale Température du sol
Réflectance	Haute résolution spatiale Bonnes compréhensions physiques	Limité par la couverture nuageuse Sensible uniquement à une fine couche de surface et à la matière organique du sol	Couverture végétale Topographie Minéraux Rugosité du sol Angle solaire Matière organique
Inra-rouge thermique	Haute résolution spatiale Bonnes compréhensions physiques	Fréquence d'observation limitée par la couverture nuageuse	Conditions météorologiques locales Couverture végétale Topographie

Tableau A1.2 – Options des méthodes disponibles dans HYDROTEL pour l'interpolation des données météorologiques.

Polygone de Thiessen	Gradient vertical de température (°C/100m)
Moyenne pondérée des 3 stations les plus proches	Gradient vertical de précipitation (mm/100m) Température de passage pluie – neige (°C)

Tableau A1.3 – Méthode disponible dans HYDROTEL pour l'évolution du couvert nival.

Méthode mixte degrés jours – bilan énergétique	Taux de fonte (mm/jour) Seuil (°C) et taux (mm/jour.°C) de fonte pour les forêts de conifères, feuillus et milieux découverts Coefficient de tassement Densité maximale de la neige (kg/m ³) Seuil d'albédo
------------------------------------------------	-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Tableau A1.4 – Options des méthodes disponibles dans HYDROTEL pour l'évapotranspiration

Hydro-Québec	Coefficient multiplicatif d'optimisation
Thornthwaite	Indice thermique Facteur de déphasage
Linacre	Température des mois les plus froid et chaud (°C) Albédo Coefficient multiplicatif d'optimisation
Penman	Hauteur de mesure (m) et vitesse du vent (m/s) Hauteur de la végétation (m) Relation résistance aérodynamique Coefficient multiplicatif d'optimisation
Penman-Monteith	Hauteur de mesure (2m) et vitesse du vent (m/s) Hauteur de mesure de l'humidité (2m) Hauteur de la végétation (m) Résistance stomatale (s/m) Coefficient multiplicatif d'optimisation
Priestley-Taylor	Coefficient de proportionnalité alpha Coefficient multiplicatif d'optimisation

Tableau A1.5 – Équations et pas de temps associés pour les méthodes de calcul de l'évapotranspiration dans HYDROTEL.

Méthode	Équation	Pas de temps
Thornwaite (1948)	$ETP = \frac{16.2}{30.4} \cdot L_j \cdot \frac{10T^\alpha}{I}$	Mensuel
Penman-Monteith (1965)	$ETP = \left(\frac{\Delta \cdot R_n + E_a}{\Delta + \gamma} \right) \cdot \frac{1}{L_e}$	Journalier
Priestley et Taylor (1972)	$ETP = \varepsilon \cdot \left(\frac{\Delta \cdot R_n}{\Delta + \gamma} \right) \cdot \frac{1}{L_e}$	Journalier
Linacre (1977)	$ETP = \left[\frac{24.41 \cdot (0.75 - A) T_{mer}}{100 - L_m} + (T - T_{wm}) \right] \cdot \left(\frac{\Delta}{\Delta + \gamma} \right)$	Journalier
Hydro-Québec	$ETP = 0.0029718 \cdot (T_x - T_n) \cdot e^{0.0342 \cdot (T_x - T_n) + 1.216}$	Journalier

Tableau A1.6 – Noms et unité des paramètres utilisés dans les différentes options de calcul de l'évapotranspiration dans HYDROTEL.

Paramètre	Définition
L_j	Facteur de déphasage (jours)
T	Température moyenne journalière (°C)
I	Indice thermique (°C)
α	Coefficient déterminé à partir de l'indice thermique I
Δ	Pente de la tension de vapeur saturante de l'air
R_n	Relation solaire nette à l'endroit où se produit l'ETP ($J \cdot m^{-2} \cdot j^{-1}$)
E_a	Pouvoir évaporant de l'air ($J \cdot mb \cdot m^{-2} \cdot K^{-1} \cdot j^{-1}$)

γ	Constante psychométrique (mb.K ⁻¹)
L_e	Chaleur latente de vaporisation de l'eau (J.kg ⁻¹)
ϵ	Coefficient de proportionnalité
A	Albédo de chacune des classes d'occupation du territoire
T_{mer}	Température de l'air moyenne journalière ramenée au niveau de la mer (°C)
T_{wm}	Température du point de rosée moyenne journalière (°C)
L_m	Latitude moyenne du BV
T_x	Température maximale journalière (°C)
T_n	Température minimale journalière (°C)

Tableau A1.7 – Méthode disponible dans HYDROTEL pour le bilan vertical

Bilan Vertical à 3 Couches (BV3C)	<p>Épaisseurs des 3 couches de sol (m)</p> <p>Humidité relative initiale dans les 3 couches</p> <p>Coefficient d'extinction</p> <p>Coefficient de récession (m/h)</p> <p>Coefficient multiplicatif de l'assèchement</p> <p>Variation maximale de l'humidité relative</p>
CEQUEAU	<p>Seuil minimal de ruissellement sur surface imperméable</p> <p>Niveau d'eau maximal dans le sol et dans la nappe</p> <p>Seuil de vidange dans le sol et dans les milieux aquatiques</p>

Tableau A1.7 – Méthode disponible dans HYDROTEL pour le ruissellement.

Onde cinématique	Coefficient de Manning pour les milieux forestiers, aquatiques et autres
------------------	--------------------------------------------------------------------------

Tableau A1.8 – Méthode disponible dans HYDROTEL pour le laminage,

Onde cinématique	Coefficient d'optimisation de rugosité et de largeur de rivières
------------------	------------------------------------------------------------------

A2 Suppléments du chapitre 5

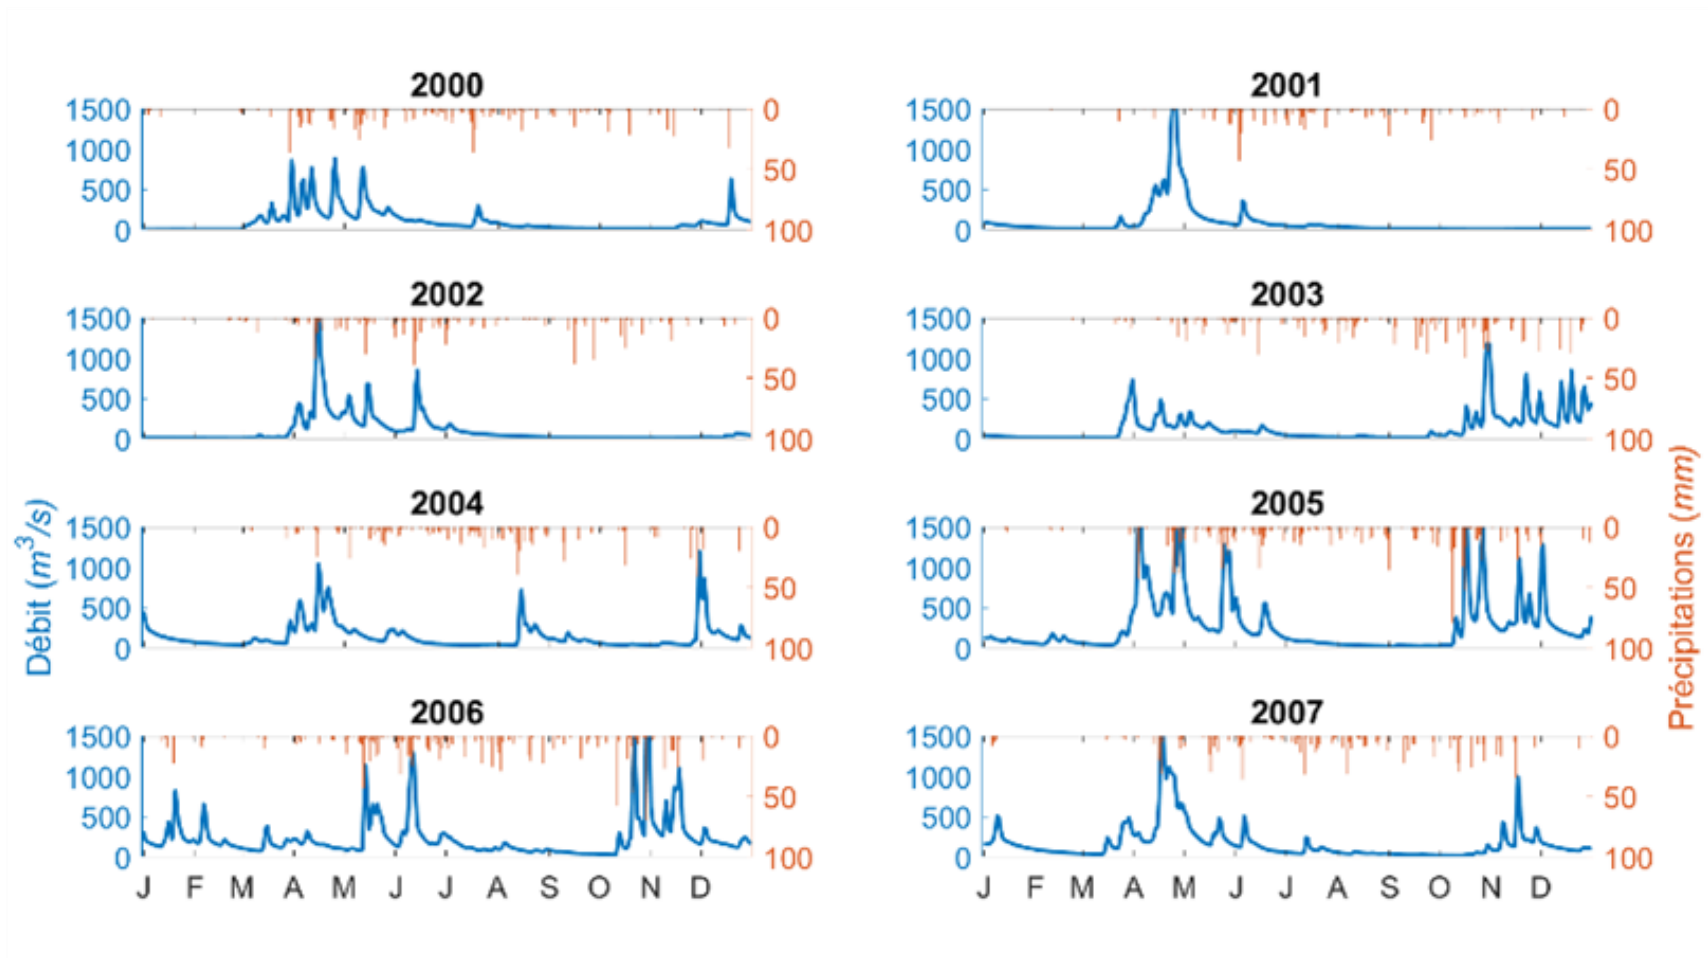


Figure A2.1 – Hydrogrammes et hyétogrammes annuels pour le BV Androscoggin à l'exutoire du BV (simulation HYDROTEL) pour les années 2000 à 2007.

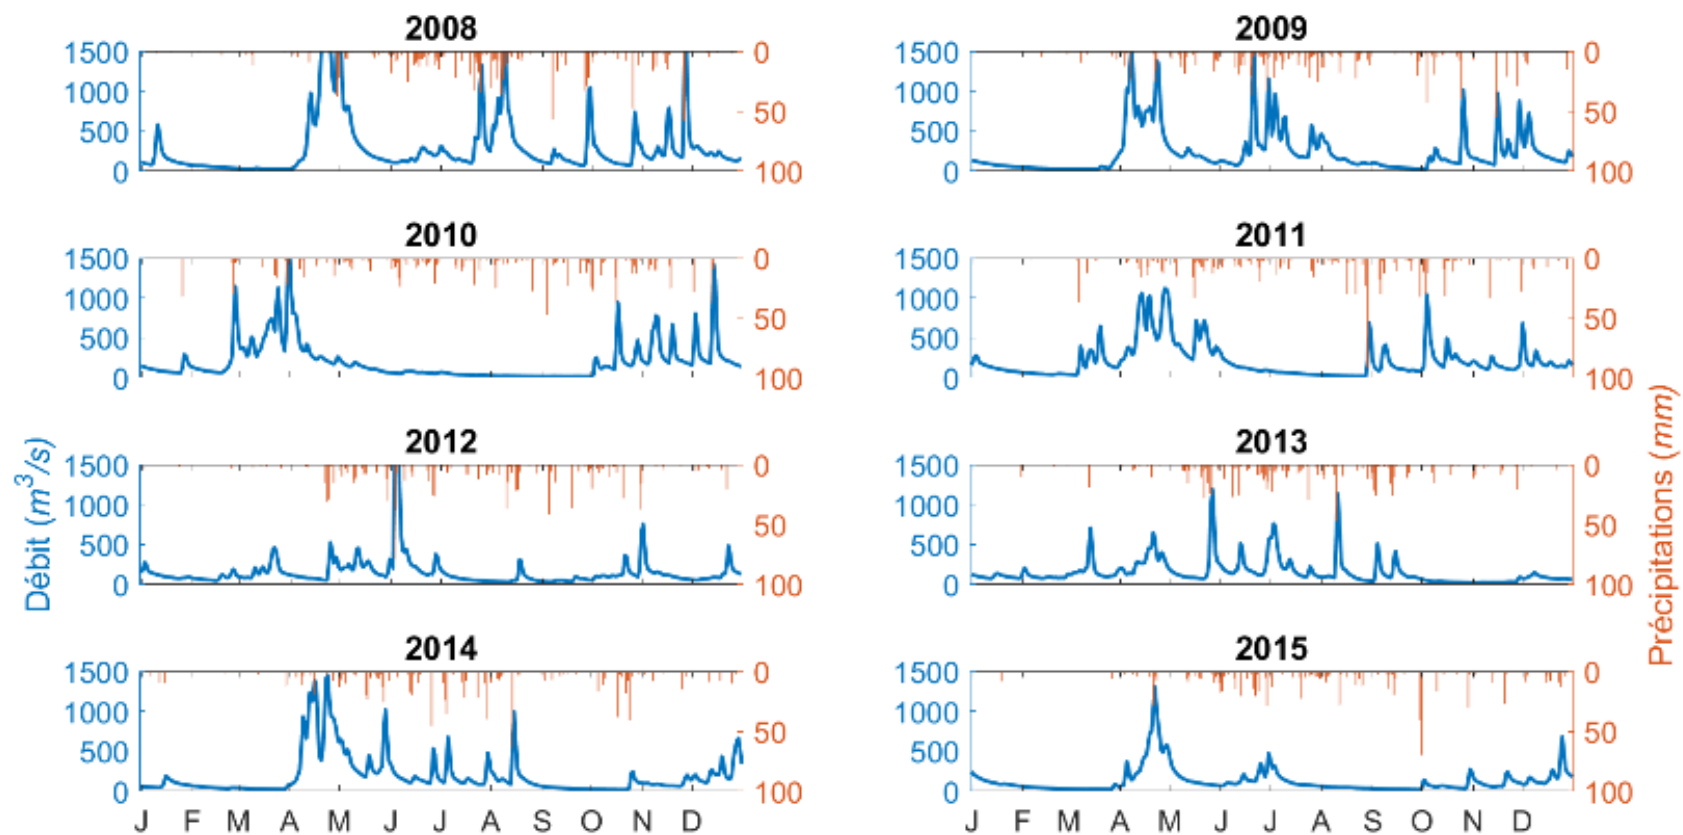






















Figure A2.2 – Hydrogrammes et hyétogrammes annuels pour le BV Androscoggin à l'exutoire du BV (simulation HYDROTEL) pour les années 2008 à 2015.











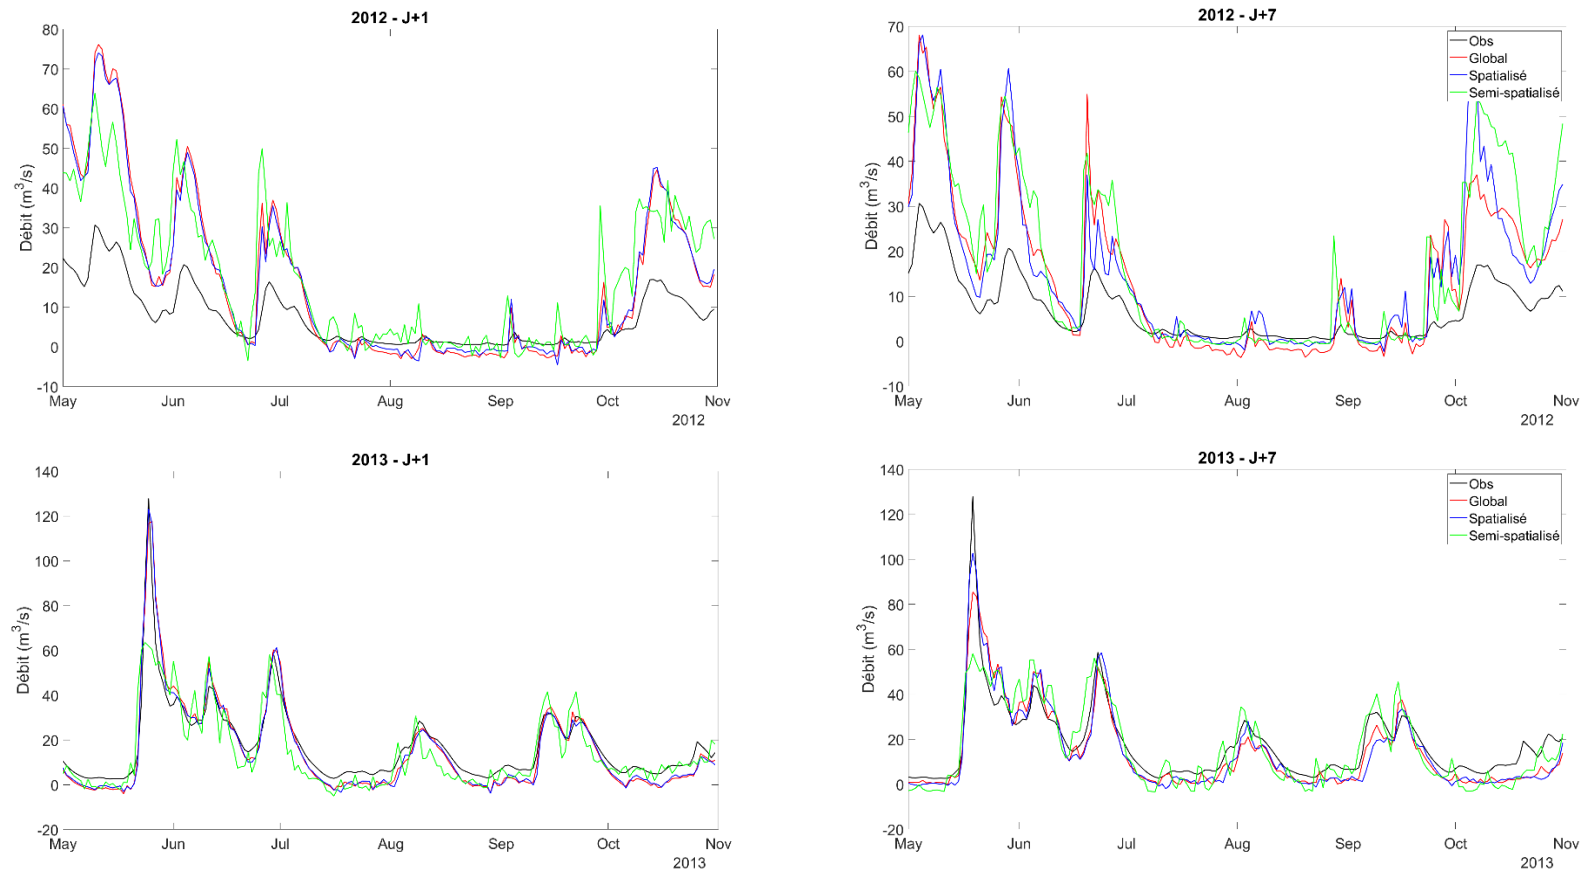


Figure A2. 3 – Hydrogrammes en validation pour les années 2000 à 2013 (excluant 2003 et 2009) à J+1 (panneau de gauche) et J+7 (panneau de droite) avec la configuration d'intrants utilisant débit et humidité du sol comme variables d'état.

A3 Suppléments du chapitre 6

En 2020 et 2021, les sites d'installation des sondes d'humidité du sol *in situ* n'ont pas changé sur le BV Au Saumon. Ainsi, il est possible de comparer les mesures en milieux ouvert et forestier sur ces deux étés-là. Les sondes EL9911 et EL9947 installées en 2020 respectivement en forêt et en prairie sont les équivalents des sondes EL 9912 et EL9946.

On compare également les simulations HYDROTEL avec ces observations *in situ*.

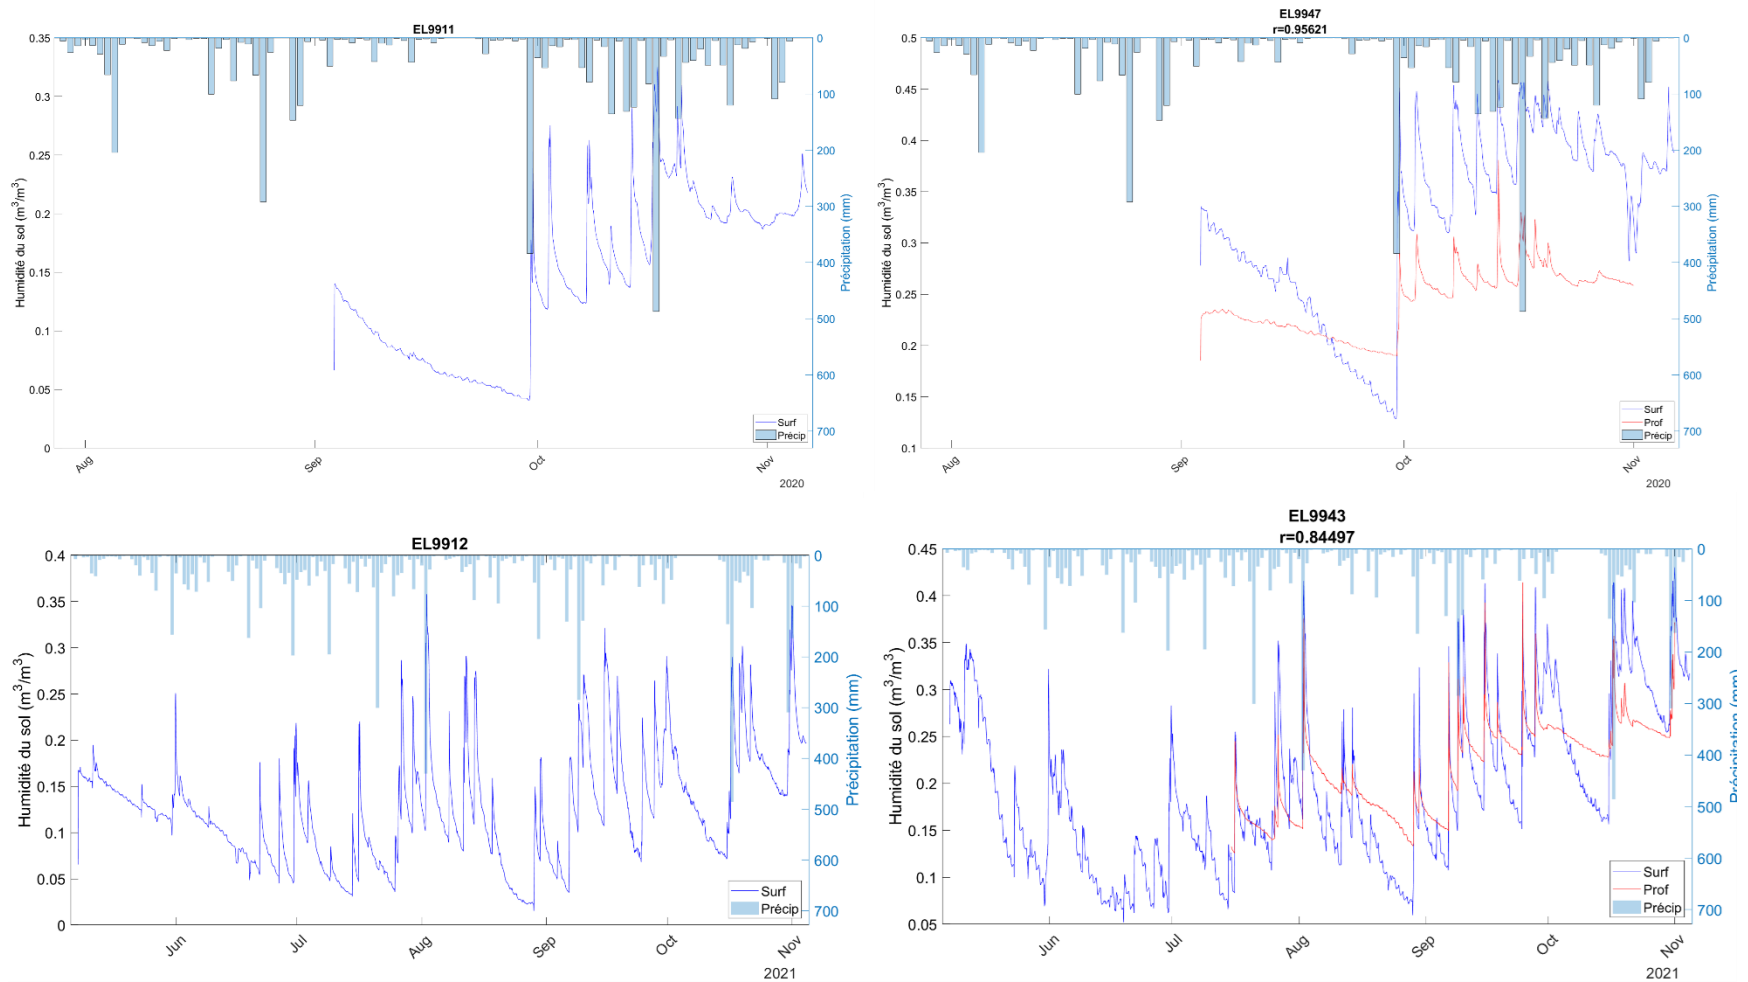


Figure A3. 4 – Profils d’humidité du sol pour quatre sondes installées en 2020 (haut) et 2021 (bas) en milieux forestier (gauche) et ouvert (droite), avec superposition des précipitations et des mesures in situ en surface (bleu) et en profondeur (rouge).

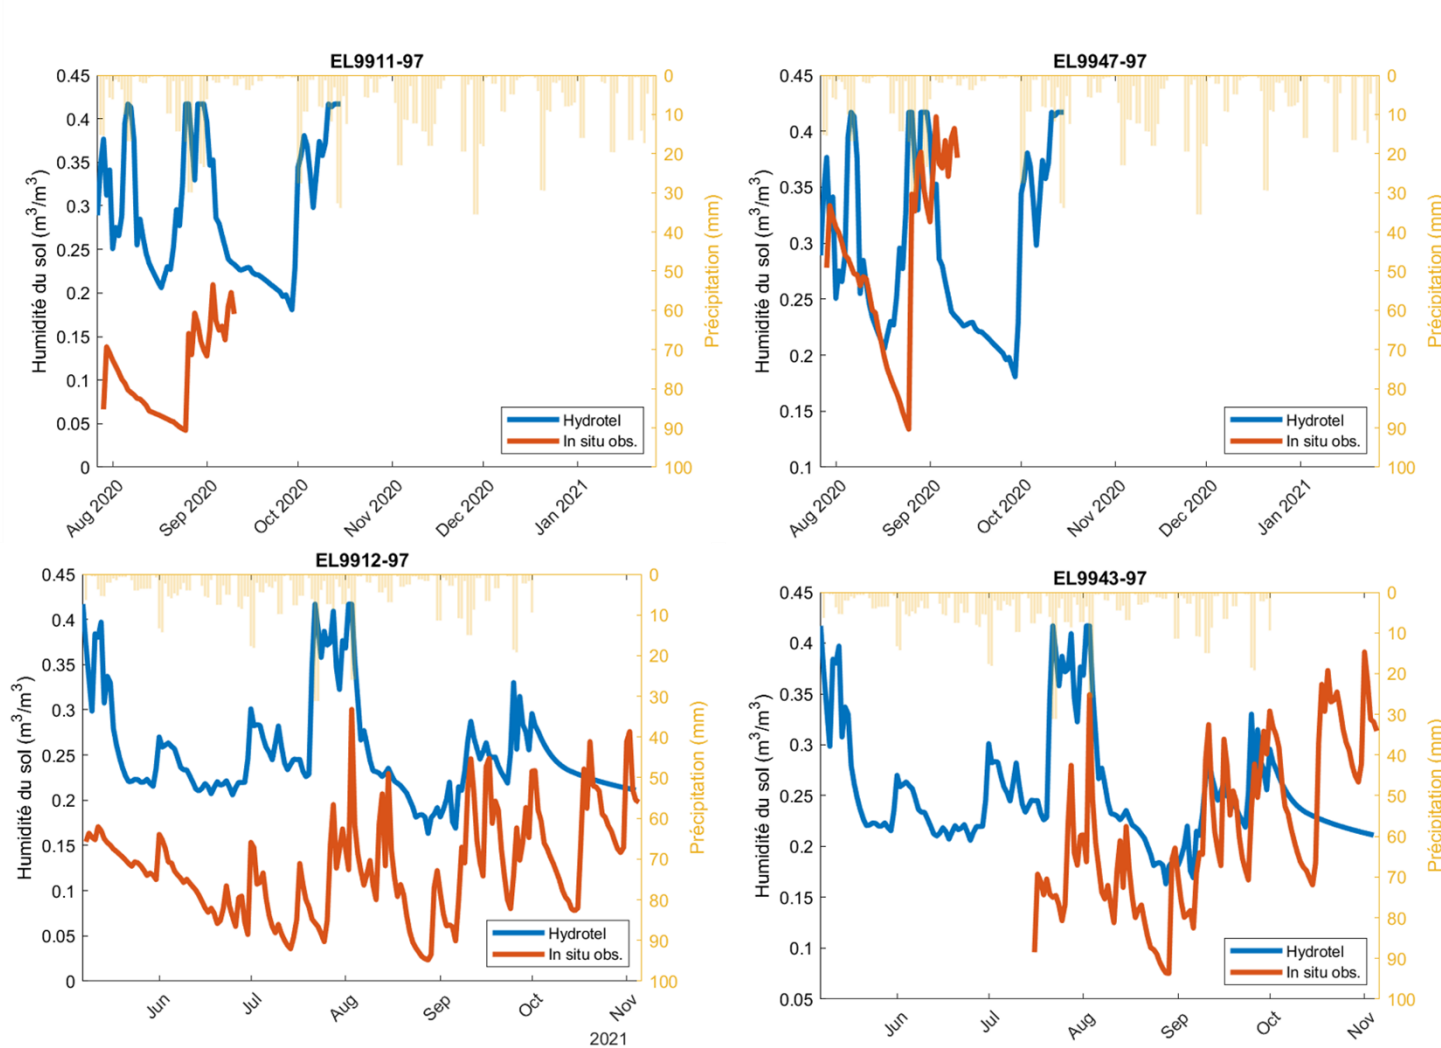


Figure A3.5 – Profils d'humidité du sol en surface issues des observations in situ (rouge) et issues des simulations HYDROTEL (bleue) pour quatre sondes installées en 2020 (en haut) et 2021 (en bas) avec superposition des précipitations.

LISTE DES RÉFÉRENCES

- Abaza, M., Anctil, F., Fortin, V., & Turcotte, R. (2014). Sequential streamflow assimilation for short-term hydrological ensemble forecasting. *Journal of Hydrology*, 519, 2692-2706. <https://doi.org/10.1016/j.jhydrol.2014.08.038>
- Abdollahipour, A., Ahmadi, H., & Aminnejad, B. (2020). Evaluating the hydrological utility of satellite-based rainfall products using neural network models over the Ghare Ghieh River basin, Iran. *Journal of Water and Climate Change*, jwc2020050. <https://doi.org/10.2166/wcc.2020.050>
- Abrahart, R. J., Anctil, F., Coulibaly, P., Dawson, C. W., Mount, N. J., See, L. M., Shamseldin, A. Y., Solomatine, D. P., Toth, E., & Wilby, R. L. (2012). Two decades of anarchy? Emerging themes and outstanding challenges for neural network river forecasting. *Progress in Physical Geography*, 36(4), 480-513. <https://doi.org/10.1177/0309133312444943>
- Ali, S., & Shahbaz, M. (2020). Streamflow forecasting by modeling the rainfall–streamflow relationship using artificial neural networks. *Modeling Earth Systems and Environment*, 6(3), 1645-1656. <https://doi.org/10.1007/s40808-020-00780-3>
- Alley, W. M. (1984). The Palmer Drought Severity Index : Limitations and Assumptions. *Journal of Climate and Applied Meteorology*, 23, 1100-1109.
- Anctil, F., Michel, C., Perrin, C., & Andréassian, V. (2004). A soil moisture index as an auxiliary ANN input for stream flow forecasting. *Journal of Hydrology*, 286(1-4), 155-167. <https://doi.org/10.1016/j.jhydrol.2003.09.006>
- Anctil, F., & Tape, D. G. (2004). An exploration of artificial neural network rainfall-runoff forecasting combined with wavelet decomposition. *Journal of Environmental Engineering and Science*, 3(Supplement 1), S121-S128. <https://doi.org/10.1139/s03-071>

-
- Annys, S., Ghebreyohannes, T., & Nyssen, J. (2020). Impact of Hydropower Dam Operation and Management on Downstream Hydrogeomorphology in Semi-Arid Environments (Tekeze, Northern Ethiopia). *Water*, 12(8), 2237. <https://doi.org/10.3390/w12082237>
- Arnold, J. G., Srinivasan, R., Muttiah, R. S., & Williams, J. R. (1998). Large area hydrologic modeling and assessment. Part I: Model development. *Journal of the American Water Resources Association*, 34(1), 73-89. <https://doi.org/10.1111/j.1752-1688.1998.tb05961.x>
- Arsenault, R., Brissette, F., Martel, J.-L., Troin, M., Lévesque, G., Davidson-Chaput, J., Gonzalez, M. C., Ameli, A., & Poulin, A. (2020). A comprehensive, multisource database for hydrometeorological modeling of 14,425 North American watersheds. *Scientific Data*, 7(1), 243. <https://doi.org/10.1038/s41597-020-00583-2>
- Arsenault, R., & Brissette, F. P. (2014). Continuous streamflow prediction in ungauged basins: The effects of equifinality and parameter set selection on uncertainty in regionalization approaches. *Water Resources Research*, 50(7), 6135-6153. <https://doi.org/10.1002/2013WR014898>
- Babaeian, E., Sadeghi, M., Jones, S. B., Montzka, C., Vereecken, H., & Tuller, M. (2019). Ground, Proximal, and Satellite Remote Sensing of Soil Moisture. *Reviews of Geophysics*, 57(2), 530-616. <https://doi.org/10.1029/2018RG000618>
- Baldwin, D., Manfreda, S., Keller, K., & Smithwick, E. A. H. (2017). Predicting root zone soil moisture with soil properties and satellite near-surface moisture data across the conterminous United States. *Journal of Hydrology*, 546, 393-404. <https://doi.org/10.1016/j.jhydrol.2017.01.020>
- Basist, A., Grody, N. C., Peterson, T. C., & Williams, C. N. (1998). Using the Special Sensor Microwave/Imager to Monitor Land Surface Temperatures, Wetness, and Snow Cover. *Journal of Applied Meteorology*, 37(9), 888-911. [https://doi.org/10.1175/1520-0450\(1998\)037<0888:UTSSMI>2.0.CO;2](https://doi.org/10.1175/1520-0450(1998)037<0888:UTSSMI>2.0.CO;2)

- Bathurst. (1995). Environmental River Flow Hydraulics. Dans *Guidebook of Applied Fluvial Geomorphology for River Engineering and Management* (Nottingham University (UK) Department of Geography, p. 33).
- Bazile, R., Boucher, M.-A., Perreault, L., & Leconte, R. (2017). Verification of ECMWF System 4 for seasonal hydrological forecasting in a northern climate. *Hydrology and Earth System Sciences*, 21(11), 5747-5762. <https://doi.org/10.5194/hess-21-5747-2017>
- Belvederesi, C., Dominic, J. A., Hassan, Q. K., Gupta, A., & Achari, G. (2020). Short-Term River Flow Forecasting Framework and Its Application in Cold Climatic Regions. *Water*, 12(11), 3049. <https://doi.org/10.3390/w12113049>
- Bergeron, J. (2017). *L'assimilation de données multivariées par filtre de Kalman d'ensemble pour la prévision hydrologique* [Mémoire de thèse]. Université de Sherbrooke.
- Bergmeir, C., Hyndman, R. J., & Koo, B. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics & Data Analysis*, 120, 70-83. <https://doi.org/10.1016/j.csda.2017.11.003>
- Berthet, L., Andreassian, V., Perrin, C., & Javelle, P. (2009). How crucial is it to account for the antecedent moisture conditions in flood forecasting? Comparison of event-based and continuous approaches on 178 catchments. *Hydrol. Earth Syst. Sci.*, 13. <https://doi.org/10.5194/hess-13-819-2009>
- Besaw, L. E., Rizzo, D. M., Bierman, P. R., & Hackett, W. R. (2010). Advances in ungauged streamflow prediction using artificial neural networks. *Journal of Hydrology*, 386(1-4), 27-37. <https://doi.org/10.1016/j.jhydrol.2010.02.037>
- Beven, K. J., & Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology / Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological Sciences Bulletin*, 24(1), 43-69. <https://doi.org/10.1080/02626667909491834>

-
- Beven, K. J., Kirkby, M. J., Freer, J. E., & Lamb, R. (2021). A history of TOPMODEL. *Hydrology and Earth System Sciences*, 25(2), 527-549. <https://doi.org/10.5194/hess-25-527-2021>
- Bhandari, S., Thakur, B., Kalra, A., Miller, W. P., Lakshmi, V., & Pathak, P. (2019). Streamflow Forecasting Using Singular Value Decomposition and Support Vector Machine for the Upper Rio Grande River Basin. *JAWRA Journal of the American Water Resources Association*, 55(3), 680-699. <https://doi.org/10.1111/1752-1688.12733>
- Bindlish, R., Crow, W. T., & Jackson, T. J. (2009). Role of Passive Microwave Remote Sensing in Improving Flood Forecasts. *IEEE Geoscience and Remote Sensing Letters*, 6(1), 112-116. <https://doi.org/10.1109/LGRS.2008.2002754>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Blöschl, G., Grayson, R. B., & Sivapalan, M. (1995). On the representative elementary area (REA) concept and its utility for distributed rainfall-runoff modelling. *Hydrological Processes*, 9(3-4), 313-330. <https://doi.org/10.1002/hyp.3360090307>
- Bogena, H., Huisman, J., Schilling, B., Weuthen, A., & Vereecken, H. (2017). Effective Calibration of Low-Cost Soil Water Content Sensors. *Sensors*, 17(12), 208. <https://doi.org/10.3390/s17010208>
- Boucher, M.-A., Tremblay, D., Delorme, L., Perreault, L., & Anctil, F. (2012). Hydro-economic assessment of hydrological forecasting systems. *Journal of Hydrology*, 416-417, 133-144. <https://doi.org/10.1016/j.jhydrol.2011.11.042>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Brocca, L., Ciabatta, L., Massari, C., Camici, S., & Tarpanelli, A. (2017). Soil Moisture for Hydrological Applications: Open Questions and New Opportunities. *Water*, 9(2), 140. <https://doi.org/10.3390/w9020140>

- Brocca, L., Moramarco, T., Melone, F., Wagner, W., Hasenauer, S., & Hahn, S. (2012). Assimilation of Surface- and Root-Zone ASCAT Soil Moisture Products Into Rainfall–Runoff Modeling. *IEEE Transactions on Geoscience and Remote Sensing*, 50(7), 2542-2555. <https://doi.org/10.1109/TGRS.2011.2177468>
- Buizza, R., Milleer, M., & Palmer, T. N. (2007). Stochastic representation of model uncertainties in the ECMWF ensemble prediction system. *Quarterly Journal of the Royal Meteorological Society*, 125(560), 2887-2908. <https://doi.org/10.1002/qj.49712556006>
- Byun, H.-R., & Wilhite, D. A. (1999). Objective Quantification of Drought Severity and Duration. *Journal of Climate*, 12(9), 2747-2756. [https://doi.org/10.1175/1520-0442\(1999\)012<2747:OQODSA>2.0.CO;2](https://doi.org/10.1175/1520-0442(1999)012<2747:OQODSA>2.0.CO;2)
- Cai, H. (2010). *Flood forecasting on the Humber river using an artificial neural network approach* [Mémoire de maîtrise]. Memorial University of Newfoundland.
- Cai-hong Hu, Ze-ning Wu, Ji-jun Wang, & Lina Liu. (2011). Application of the Support Vector Machine on precipitation-runoff modelling in Fenhe River. *2011 International Symposium on Water Resource and Environmental Protection*, 1099-1103. <https://doi.org/10.1109/ISWREP.2011.5893206>
- Camacho Olmedo, M. T., Paegelow, M., Mas, J.-F., & Escobar, F. (Éds.). (2018). *Geomatic Approaches for Modeling Land Change Scenarios*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-60801-3>
- Campos, J. A., & Pedrollo, O. C. (2021). A regional ANN-based model to estimate suspended sediment concentrations in ungauged heterogeneous basins. *Hydrological Sciences Journal*, 66(7), 1222-1232. <https://doi.org/10.1080/02626667.2021.1918695>
- Capehart, W. J., & Carlson, T. N. (1997). Decoupling of surface and near-surface soil water content : A remote sensing perspective. *Water Resources Research*, 33(6), 1383-1395. <https://doi.org/10.1029/97WR00617>

-
- Carranza, C. D. U., van der Ploeg, M. J., & Torfs, P. J. J. F. (2018). Using lagged dependence to identify (de)coupled surface and subsurface soil moisture values. *Hydrology and Earth System Sciences*, 22(4), 2255-2267. <https://doi.org/10.5194/hess-22-2255-2018>
- Cenci, L., Laiolo, P., Gabellani, S., Campo, L., Silvestro, F., Delogu, F., Boni, G., & Rudari, R. (2016). Assimilation of H-SAF Soil Moisture Products for Flash Flood Early Warning Systems. Case Study : Mediterranean Catchments. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(12), 5634-5646. <https://doi.org/10.1109/JSTARS.2016.2598475>
- Chang, F.-J., & Guo, S. (2020). Advances in Hydrologic Forecasts and Water Resources Management. *Water*, 12(6), 1819. <https://doi.org/10.3390/w12061819>
- Chebana, F., Dabo-Niang, S., & Ouarda, T. B. M. J. (2012). Exploratory functional flood frequency analysis and outlier detection : Functional frequency analysis. *Water Resources Research*, 48(4). <https://doi.org/10.1029/2011WR011040>
- Chen, C., Hui, Q., Xie, W., Wan, S., Zhou, Y., & Pei, Q. (2021). Convolutional Neural Networks for forecasting flood process in Internet-of-Things enabled smart city. *Computer Networks*, 186, 107744. <https://doi.org/10.1016/j.comnet.2020.107744>
- Chen, L., Hao, T., Qiao, G., Lu, P., & Li, R. (2019). Using Multi-Years MODIS LST Data to Monitor the Ground Surface Freezing and Thawing Conditions on the Qinghai-Tibet Plateau. *2019 10th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp)*, 1-4. <https://doi.org/10.1109/Multi-Temp.2019.8866955>
- Clark, M. P., Wilby, R. L., Gutmann, E. D., Vano, J. A., Gangopadhyay, S., Wood, A. W., Fowler, H. J., Prudhomme, C., Arnold, J. R., & Brekke, L. D. (2016). Characterizing Uncertainty of the Hydrologic Impacts of Climate Change. *Current Climate Change Reports*, 2(2), 55-64. <https://doi.org/10.1007/s40641-016-0034-x>

- Cloke, H. L., & Pappenberger, F. (2009). Ensemble flood forecasting : A review. *Journal of Hydrology*, 375(3-4), 613-626. <https://doi.org/10.1016/j.jhydrol.2009.06.005>
- Coron, L., Thirel, G., Delaigue, O., Perrin, C., & Andréassian, V. (2017). The suite of lumped GR hydrological models in an R package. *Environmental Modelling & Software*, 94, 166-171. <https://doi.org/10.1016/j.envsoft.2017.05.002>
- Coulibaly, P., Anctil, F., & Bobée, B. (2001). Multivariate Reservoir Inflow Forecasting Using Temporal Neural Networks. *Journal of Hydrologic Engineering*, 6(5), 367-376. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2001\)6:5\(367\)](https://doi.org/10.1061/(ASCE)1084-0699(2001)6:5(367))
- Das, K., & Paul, P. K. (2015). Present status of soil moisture estimation by microwave remote sensing. *Cogent Geoscience*, 1(1). <https://doi.org/10.1080/23312041.2015.1084669>
- Dawson, C. W., Abrahart, R. J., Shamseldin, A. Y., & Wilby, R. L. (2006). Flood estimation at ungauged sites using artificial neural networks. *Journal of Hydrology*, 319(1-4), 391-409. <https://doi.org/10.1016/j.jhydrol.2005.07.032>
- Dawson, C. W., & Wilby, R. L. (2001). *Hydrological modelling using artificial neural networks*. 29. <https://doi.org/10.1177/030913330102500104>
- Demirel, M. C., Venancio, A., & Kahya, E. (2009). Flow forecast by SWAT model and ANN in Pracana basin, Portugal. *Advances in Engineering Software*, 40(7), 467-473. <https://doi.org/10.1016/j.advengsoft.2008.08.002>
- Devi, G. K., Ganasri, B. P., & Dwarakish, G. S. (2015). A Review on Hydrological Models. *Aquatic Procedia*, 4, 1001-1007. <https://doi.org/10.1016/j.aqpro.2015.02.126>
- Dietterich, T. G. (2000). *An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees : Bagging, Boosting, and Randomization*. 19. <https://doi.org/10.1023/A:1007607513941>

-
- Dtissibe, F. Y., Ari, A. A. A., Titouna, C., Thiare, O., & Gueroui, A. M. (2020). Flood forecasting based on an artificial neural network scheme. *Natural Hazards*, 104(2), 1211-1237. <https://doi.org/10.1007/s11069-020-04211-5>
- Faizollahzadeh ardabili, S., Mosavi, A., Dehghani, M., & R. Várkonyi-Kóczy, A. (2019). *Deep Learning and Machine Learning in Hydrological Processes, Climate Change and Earth Systems : A Systematic Review* [Preprint]. Mathematics & computer science. <https://doi.org/10.20944/preprints201908.0166.v1>
- Fan, Y., & Bras, R. L. (1995). On the concept of a representative elementary area in catchment runoff. *Hydrological Processes*, 9(7), 821-832. <https://doi.org/10.1002/hyp.3360090708>
- Fleming, S. W., Bourdin, D. R., Campbell, D., Stull, R. B., & Gardner, T. (2015). Development and Operational Testing of a Super-Ensemble Artificial Intelligence Flood-Forecast Model for a Pacific Northwest River. *JAWRA Journal of the American Water Resources Association*, 51(2), 502-512. <https://doi.org/10.1111/jawr.12259>
- Fleming, S. W., & Goodbody, A. G. (2019). A Machine Learning Metasystem for Robust Probabilistic Nonlinear Regression-Based Forecasting of Seasonal Water Availability in the US West. *IEEE Access*, 7, 119943-119964. <https://doi.org/10.1109/ACCESS.2019.2936989>
- Fortin, J. P., Moussa, R., Bocquillon, C., & Villeneuve, J. P. (1995). Hydrotel, un modèle hydrologique distribué pouvant bénéficier des données fournies par la télédétection et les systèmes d'information géographique. *Revue des sciences de l'eau*, 8(1), 97. <https://doi.org/10.7202/705215ar>
- Fortin, J.-P., Turcotte, R., Massicotte, S., Moussa, R., Fitzback, J., & Villeneuve, J.-P. (2001). Distributed Watershed Model Compatible with Remote Sensing and GIS Data. I: Description of Model. *Journal of Hydrologic Engineering*, 6(2), 91-99. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2001\)6:2\(91\)](https://doi.org/10.1061/(ASCE)1084-0699(2001)6:2(91))
- Fortin, V. (2000). *Le modèle météo-apport HSAMI: historique, théorie et application*. 68.

- Foulon, É., Rousseau, A. N., & Gagnon, P. (2018). Development of a methodology to assess future trends in low flows at the watershed scale using solely climate data. *Journal of Hydrology*, 557, 774-790. <https://doi.org/10.1016/j.jhydrol.2017.12.064>
- Gao, Q., Zribi, M., Escorihuela, M., & Baghdadi, N. (2017). Synergetic Use of Sentinel-1 and Sentinel-2 Data for Soil Moisture Mapping at 100 m Resolution. *Sensors*, 17(9), 1966. <https://doi.org/10.3390/s17091966>
- Gong, Y., Zhang, Y., Lan, S., & Wang, H. (2016). A Comparative Study of Artificial Neural Networks, Support Vector Machines and Adaptive Neuro Fuzzy Inference System for Forecasting Groundwater Levels near Lake Okeechobee, Florida. *Water Resources Management*, 30(1), 375-391. <https://doi.org/10.1007/s11269-015-1167-8>
- Habib, E., Cruz-Neira, C., Ma, Y., & Williams, D. (2010). Development Of A Virtual Hydrologic Observatory For Integration Of Field Observations And Model Simulations Into Engineering Hydrology Courses. *2010 Annual Conference & Exposition Proceedings*, 15.410.1-15.410.13. <https://doi.org/10.18260/1-2--16342>
- Haguma, D., & Leconte, R. (2018). Long-Term Planning of Water Systems in the Context of Climate Non-Stationarity with Deterministic and Stochastic Optimization. *Water Resources Management*, 32(5), 1725-1739. <https://doi.org/10.1007/s11269-017-1900-6>
- Hecht, J. S., Lacombe, G., Arias, M. E., Dang, T. D., & Piman, T. (2019). Hydropower dams of the Mekong River basin: A review of their hydrological impacts. *Journal of Hydrology*, 568, 285-300. <https://doi.org/10.1016/j.jhydrol.2018.10.045>
- Heggen, R. J. (2001). Normalized Antecedent Precipitation Index. *Journal of Hydrologic Engineering*, 6(5), 377-381. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2001\)6:5\(377\)](https://doi.org/10.1061/(ASCE)1084-0699(2001)6:5(377))
- Hingray, B., Picouet, C., & Musy, A. (2009). *hydrologie. Une science pour l'ingénieur* (PPUR presses polytechniques, Vol. 2).

-
- Horn, G., & Schumann, A. (2018). *Utilisation of meteorological and hydrological drought monitoring as base for operational low flow forecasting*. 1.
- Huang, X., Li, Y., Tian, Z., Ye, Q., Ke, Q., Fan, D., Mao, G., Chen, A., & Liu, J. (2021). Evaluation of short-term streamflow prediction methods in Urban river basins. *Physics and Chemistry of the Earth, Parts A/B/C*, 123, 103027. <https://doi.org/10.1016/j.pce.2021.103027>
- Huffman, G. J., Bolvin, D. T., Nelkin, E. J., Wolff, D. B., Adler, R. F., Gu, G., Hong, Y., Bowman, K. P., & Stocker, E. F. (2007). The TRMM Multisatellite Precipitation Analysis (TMPA) : Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. *Journal of Hydrometeorology*, 8(1), 38-55. <https://doi.org/10.1175/JHM560.1>
- IPCC. (2022). *Climate Change 2022. Impacts, Adaptation and Vulnerability. Summary for Policymakers*.
- Ishwaran, H. (2015). The effect of splitting on random forests. *Machine Learning*, 99(1), 75-118. <https://doi.org/10.1007/s10994-014-5451-2>
- Jagtap, A. D., Kawaguchi, K., & Karniadakis, G. E. (2020). Adaptive activation functions accelerate convergence in deep and physics-informed neural networks. *Journal of Computational Physics*, 404, 109136. <https://doi.org/10.1016/j.jcp.2019.109136>
- Jain, S. K., Das, A., & Srivastava, D. K. (1999). Application of ANN for Reservoir Inflow Prediction and Operation. *Journal of Water Resources Planning and Management*, 125(5), 263-271. [https://doi.org/10.1061/\(ASCE\)0733-9496\(1999\)125:5\(263\)](https://doi.org/10.1061/(ASCE)0733-9496(1999)125:5(263))
- Jain, S. K., Mani, P., Jain, S. K., Prakash, P., Singh, V. P., Tullos, D., Kumar, S., Agarwal, S. P., & Dimri, A. P. (2018). A Brief review of flood forecasting techniques and their applications. *International Journal of River Basin Management*, 16(3), 329-344. <https://doi.org/10.1080/15715124.2017.1411920>
- Javelle, P., Payrastre, O., Boudevillain, B., Bourgin, F., Bouttier, F., Caumont, O., Charpentier-Noyer, M., Ducrocq, V., Fleury, A., Garambois, P.-A., Gaume, E., Hocini, N., Janet, B., Jay-Allemand, M., Lague, D., Lovat, A., Moncoulon, D., Naulin, J.-P., Nicolle, P., ... Terti, G. (2021). Flash flood

- impacts nowcasting within the PICS project (2018-2022): End-users involvement and first results. *Science and Practice for an Uncertain Future*, null-null. <https://doi.org/10.3311/FloodRisk2020.17.3>
- Kam Ho, T. (1998). *Nearest neighbors in random subspaces*. 9.
- Karsoliya, S. (2012). Approximating Number of Hidden layer neurons in Multiple Hidden Layer BPNN Architecture. *International Journal of Engineering Trends and Technology*, 4.
- Kayri, M. (2016). Predictive Abilities of Bayesian Regularization and Levenberg–Marquardt Algorithms in Artificial Neural Networks : A Comparative Empirical Study on Social Data. *Mathematical and Computational Applications*, 21(2), 20. <https://doi.org/10.3390/mca21020020>
- Kerr, Y. H., Waldteufel, P., Richaume, P., Wigneron, J. P., Ferrazzoli, P., Mahmoodi, A., Al Bitar, A., Cabot, F., Gruhier, C., Juglea, S. E., Leroux, D., Mialon, A., & Delwart, S. (2012). The SMOS Soil Moisture Retrieval Algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5), 1384-1403. <https://doi.org/10.1109/TGRS.2012.2184548>
- Kingston, D. G., McGregor, G. R., Hannah, D. M., & Lawler, D. M. (2006). River flow teleconnections across the northern North Atlantic region. *Geophysical Research Letters*, 33(14). <https://doi.org/10.1029/2006GL026574>
- Kisi, O., Shiri, J., & Nikoofar, B. (2012). Forecasting daily lake levels using artificial intelligence approaches. *Computers & Geosciences*, 41, 169-180. <https://doi.org/10.1016/j.cageo.2011.08.027>
- Kneale, P., See, L., & Smith, A. (2001). *Towards defining evaluation measures for neural network forecasting models*. Academia.
- Kohler, M. A., & Linsley, R. K. (1951). Predicting the runoff from storm rainfall. *Weather Bureau Research Papers*, 34, 12.

-
- Kornelsen, K. C., & Coulibaly, P. (2013). Advances in soil moisture retrieval from synthetic aperture radar and hydrological applications. *Journal of Hydrology*, 476, 460-489. <https://doi.org/10.1016/j.jhydrol.2012.10.044>
- Kourgialas, N. N., Dokou, Z., & Karatzas, G. P. (2015). Statistical analysis and ANN modeling for predicting hydrological extremes under climate change scenarios: The example of a small Mediterranean agro-watershed. *Journal of Environmental Management*, 154, 86-101. <https://doi.org/10.1016/j.jenvman.2015.02.034>
- Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). Rainfall-Runoff modelling using Long-Short-Term-Memory (LSTM) networks. *Hydrology and Earth System Sciences Discussions*, 1-26. <https://doi.org/10.5194/hess-2018-247>
- Kustas, W. P., French, A. N., Hatfield, J. L., Jackson, T. J., Moran, M. S., Rango, A., Ritchie, J. C., & Schmugge, T. J. (2003). Remote Sensing Research in Hydrometeorology. *Photogrammetric Engineering & Remote Sensing*, 69(6), 631-646. <https://doi.org/10.14358/PERS.69.6.631>
- Lefaivre, D., Hamdi, S., & Morse, B. (2009). Statistical Analysis of the 30-Day Water Level Forecasts in the St. Lawrence River. *Marine Geodesy*, 32(1), 30-41. <https://doi.org/10.1080/01490410802661971>
- Lettvin, J. Y., Maturana, H. R., McCulloch, W. S., & Pitts, W. H. (1968). *What the frog's eye tells the frog's brain*. 14.
- Li, Y., Ryu, D., Western, A. W., & Wang, Q. J. (2013). Assimilation of stream discharge for flood forecasting: The benefits of accounting for routing time lags: discharge assimilation for flood forecasting. *Water Resources Research*, 49(4), 1887-1900. <https://doi.org/10.1002/wrcr.20169>
- Liaw, A., & Wiener, M. (2002). *Classification and Regression by randomForest*. 2, 6.
- Lin, J.-Y., Cheng, C.-T., & Chau, K.-W. (2006). Using support vector machines for long-term discharge prediction. *Hydrological Sciences Journal*, 51(4), 599-612. <https://doi.org/10.1623/hysj.51.4.599>
- Liu, Y., Starzyk, J. A., & Zhu, Z. (2007). *Optimizing number of hidden neurons in neural networks*. 6.

- Loritz, R., Hrachowitz, M., Neuper, M., & Zehe, E. (2021). The role and value of distributed precipitation data in hydrological models. *Hydrology and Earth System Sciences*, 25(1), 147-167. <https://doi.org/10.5194/hess-25-147-2021>
- Lovat, A., Vincendon, B., & Ducrocq, V. (2020). *Hydrometeorological evaluation of two nowcasting systems for Mediterranean heavy precipitation events with operational considerations* [Preprint]. Hydrometeorology/Modelling approaches. <https://doi.org/10.5194/hess-2020-629>
- Marcil, G.-K., Trudel, M., & Leconte, R. (2016). Using Remotely Sensed MODIS Snow Product for the Management of Reservoirs in a Mountainous Canadian Watershed. *Water Resources Management*, 30(8), 2735-2747. <https://doi.org/10.1007/s11269-016-1319-5>
- Martínez-Fernández, J., González-Zamora, A., & Almendra-Martín, L. (2021). Soil moisture memory and soil properties: An analysis with the stored precipitation fraction. *Journal of Hydrology*, 593, 125622. <https://doi.org/10.1016/j.jhydrol.2020.125622>
- Massari, C., Brocca, L., Tarpanelli, A., & Moramarco, T. (2015). Data Assimilation of Satellite Soil Moisture into Rainfall-Runoff Modelling : A Complex Recipe? *Remote Sensing*, 7(9), 11403-11433. <https://doi.org/10.3390/rs70911403>
- McMillan, H., Westerberg, I., & Branger, F. (2017). Five guidelines for selecting hydrological signatures. *Hydrological Processes*, 31(26), 4757-4761. <https://doi.org/10.1002/hyp.11300>
- Michaelides, S., Levizzani, V., Anagnostou, E., Bauer, P., Kasparis, T., & Lane, J. E. (2009). Precipitation : Measurement, remote sensing, climatology and modeling. *Atmospheric Research*, 94(4), 512-533. <https://doi.org/10.1016/j.atmosres.2009.08.017>
- Michel, C. (1983). Que peut-on faire en hydrologie avec modèle conceptuel à un seul paramètre ? *La Houille Blanche*, 69(1), 39-44. <https://doi.org/10.1051/lhb/1983004>

-
- Mildrexler, D. J., Zhao, M., & Running, S. W. (2011). Satellite Finds Highest Land Skin Temperatures on Earth. *Bulletin of the American Meteorological Society*, 92(7), 855-860. <https://doi.org/10.1175/2011BAMS3067.1>
- Morbidegli, R., Corradini, C., Saltalippi, C., Flammini, A., Dari, J., & Govindaraju, R. (2018). Rainfall Infiltration Modeling : A Review. *Water*, 10(12), 1873. <https://doi.org/10.3390/w10121873>
- Morin, G., Fortin, J. P., Lardeau, J. P., Sochanska, W., & Paquette, S. (1981). *Modèle CEQUEAU: manuel d'utilisation* (N° 93; p. 459). INRS-EAU.
- Mosavi, A., Ozturk, P., & Chau, K. (2018). Flood Prediction Using Machine Learning Models : Literature Review. *Water*, 10(11), 1536. <https://doi.org/10.3390/w10111536>
- Moulin, L. (2009). *Prévision des crues rapides avec des modèles hydrologiques globaux. Applications aux bassins opérationnels de la Loire supérieure : Évaluation des modélisations, prise en compte des incertitudes sur les précipitations moyennes spatiales et utilisation de prévisions météorologiques*. 653.
- Nalbantis, I., & Tsakiris, G. (2009). Assessment of Hydrological Drought Revisited. *Water Resources Management*, 23(5), 881-897. <https://doi.org/10.1007/s11269-008-9305-1>
- Nasrollahi, N., Hsu, K., & Sorooshian, S. (2013). An Artificial Neural Network Model to Reduce False Alarms in Satellite Precipitation Products Using MODIS and *CloudSat* Observations. *Journal of Hydrometeorology*, 14(6), 1872-1883. <https://doi.org/10.1175/JHM-D-12-0172.1>
- Nearing, G. S., Kratzert, F., Sampson, A. K., Pelissier, C. S., Klotz, D., Frame, J. M., Prieto, C., & Gupta, H. V. (2021). What Role Does Hydrological Science Play in the Age of Machine Learning? *Water Resources Research*, 57(3). <https://doi.org/10.1029/2020WR028091>
- Ni, L., Wang, D., Wu, J., Wang, Y., Tao, Y., Zhang, J., & Liu, J. (2020). Streamflow forecasting using extreme gradient boosting model coupled with Gaussian mixture model. *Journal of Hydrology*, 586, 124901. <https://doi.org/10.1016/j.jhydrol.2020.124901>

- Nourani, V., Hosseini Baghanam, A., Adamowski, J., & Kisi, O. (2014). Applications of hybrid wavelet–Artificial Intelligence models in hydrology : A review. *Journal of Hydrology*, 514, 358-377. <https://doi.org/10.1016/j.jhydrol.2014.03.057>
- Nourani, V., Kisi, Ö., & Komasi, M. (2011). Two hybrid Artificial Intelligence approaches for modeling rainfall–runoff process. *Journal of Hydrology*, 402(1-2), 41-59. <https://doi.org/10.1016/j.jhydrol.2011.03.002>
- Obled, C., Zin, I., & Hingray, B. (2009). Choix des pas de temps et d’espace pour des modélisations parcimonieuses en hydrologie des crues. *La Houille Blanche*, 95(5), 81-87. <https://doi.org/10.1051/lhb/2009059>
- Oddos, A. (2002). *Intérêt d’une approche semi-distribuée par rapport à une approche globale en modélisation pluie-débit*. 99.
- Oudin, L. (2005). *Recherche d’un modèle d’évapotranspiration potentielle pertinent comme entrée d’un modèle pluie-débit global*. 496.
- Oyebode, O., & Stretch, D. (2018). Neural network modeling of hydrological systems : A review of implementation techniques. *Natural Resource Modeling*, e12189. <https://doi.org/10.1111/nrm.12189>
- Pagano, T. C., Wood, A. W., Ramos, M.-H., Cloke, H. L., Pappenberger, F., Clark, M. P., Cranston, M., Kavetski, D., Mathevet, T., Sorooshian, S., & Verkade, J. S. (2014). Challenges of Operational River Forecasting. *Journal of Hydrometeorology*, 15(4), 1692-1707. <https://doi.org/10.1175/JHM-D-13-0188.1>
- Pappenberger, F., Bogner, K., Wetterhall, F., He, Y., Cloke, H. L., & Thielen, J. (2011). Forecast convergence score : A forecaster’s approach to analysing hydro-meteorological forecast systems. *Advances in Geosciences*, 29, 27-32. <https://doi.org/10.5194/adgeo-29-27-2011>

-
- Pappenberger, F., Stephens, E., Thielen, J., Salamon, P., Demeritt, D., van Andel, S. J., Wetterhall, F., & Alfieri, L. (2013). Visualizing probabilistic flood forecast information : Expert preferences and perceptions of best practice in uncertainty communication: visualising probabilistic flood forecast information. *Hydrological Processes*, 27(1), 132-146. <https://doi.org/10.1002/hyp.9253>
- Partal, T., Cigizoglu, H. K., & Kahya, E. (2015). Daily precipitation predictions using three different wavelet neural network algorithms by meteorological data. *Stochastic Environmental Research and Risk Assessment*, 29(5), 1317-1329. <https://doi.org/10.1007/s00477-015-1061-1>
- Payal, A., Rai, C. S., & Reddy, B. V. R. (2013). *Comparative analysis of Bayesian regularization and Levenberg-Marquardt training algorithm for localization in wireless sensor network*. 4.
- Peddinti, V., Povey, D., & Khudanpur, S. (2015). A time delay neural network architecture for efficient modeling of long temporal contexts. *Interspeech 2015*, 3214-3218. <https://doi.org/10.21437/Interspeech.2015-647>
- Perrin, C., Michel, C., & Andréassian, V. (2003). Improvement of a parsimonious model for streamflow simulation. *Journal of Hydrology*, 279(1-4), 275-289. [https://doi.org/10.1016/S0022-1694\(03\)00225-7](https://doi.org/10.1016/S0022-1694(03)00225-7)
- Pham, L. T., Luo, L., & Finley, A. (2021). Evaluation of random forests for short-term daily streamflow forecasting in rainfall- and snowmelt-driven watersheds. *Hydrology and Earth System Sciences*, 25(6), 2997-3015. <https://doi.org/10.5194/hess-25-2997-2021>
- Phukoetphim, P., Shamseldin, A. Y., & Melville, B. W. (2014). Knowledge Extraction from Artificial Neural Networks for Rainfall-Runoff Model Combination Systems. *Journal of Hydrologic Engineering*, 19(7), 1422-1429. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000941](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000941)
- Pini, M., Scalvini, A., Liaqat, M. U., Ranzi, R., Serina, I., & Mehmood, T. (2020). Evaluation of Machine Learning Techniques for Inflow Prediction in Lake Como, Italy. *Procedia Computer Science*, 176, 918-927. <https://doi.org/10.1016/j.procs.2020.09.087>

- Prigent, C. (2010). Precipitation retrieval from space : An overview. *Comptes Rendus Geoscience*, 342(4-5), 380-389. <https://doi.org/10.1016/j.crte.2010.01.004>
- Rains, D., De Lannoy, G. J. M., Lievens, H., Walker, J. P., & Verhoest, N. E. C. (2018). SMOS and SMAP Brightness Temperature Assimilation Over the Murrumbidgee Basin. *IEEE Geoscience and Remote Sensing Letters*, 15(11), 1652-1656. <https://doi.org/10.1109/LGRS.2018.2855188>
- Rajabi, R., & Estebarsari, A. (2019). Deep Learning Based Forecasting of Individual Residential Loads Using Recurrence Plots. 2019 *IEEE Milan PowerTech*, 1-5. <https://doi.org/10.1109/PTC.2019.8810899>
- Razavi, T., & Coulibaly, P. (2013). Streamflow Prediction in Ungauged Basins : Review of Regionalization Methods. *Journal of Hydrologic Engineering*, 18(8), 958-975. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000690](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000690)
- Riad, S., Mania, J., Bouchaou, L., & Najjar, Y. (2004). Rainfall-runoff model usingan artificial neural network approach. *Mathematical and Computer Modelling*, 40(7-8), 839-846. <https://doi.org/10.1016/j.mcm.2004.10.012>
- Romano, N. (2014). Soil moisture at local scale : Measurements and simulations. *Journal of Hydrology*, 516, 6-20. <https://doi.org/10.1016/j.jhydrol.2014.01.026>
- Roux, E., Santos da Silva, J., Cesar Vieira Getirana, A., Bonnet, M.-P., Calmant, S., Martinez, J.-M., & Seyler, F. (2010). Producing time series of river water height by means of satellite radar altimetry—A comparative study. *Hydrological Sciences Journal*, 55(1), 104-120. <https://doi.org/10.1080/02626660903529023>
- Salvail-Bérard, A. (2012). Réseaux de neurones. *CaMUS (Cahiers Mathématiques de l'Université de Sherbrooke)*, 3, 54-69.
- Sanò, P., Panegrossi, G., Casella, D., Di Paola, F., Milani, L., Mugnai, A., Petracca, M., & Dietrich, S. (2015). The Passive microwave Neural network Precipitation Retrieval (PNPR) algorithm for

-
- AMSU/MHS observations : Description and application to European case studies. *Atmospheric Measurement Techniques*, 8(2), 837-857. <https://doi.org/10.5194/amt-8-837-2015>
- Scornet, E. (2012). *Apprentissage et forêts aléatoires* (p. 12). École Normale Supérieure.
- Seneviratne, S. I., Corti, T., Davin, E. L., Hirschi, M., Jaeger, E. B., Lehner, I., Orlowsky, B., & Teuling, A. J. (2010). Investigating soil moisture–climate interactions in a changing climate : A review. *Earth-Science Reviews*, 99(3-4), 125-161. <https://doi.org/10.1016/j.earscirev.2010.02.004>
- Seo, Y., Kim, S., Kisi, O., & Singh, V. P. (2015). Daily water level forecasting using wavelet decomposition and artificial intelligence techniques. *Journal of Hydrology*, 520, 224-243. <https://doi.org/10.1016/j.jhydrol.2014.11.050>
- Shah, D., & Mishra, V. (2020). Integrated Drought Index (IDI) for Drought Monitoring and Assessment in India. *Water Resources Research*, 56(2). <https://doi.org/10.1029/2019WR026284>
- Sheela, K. G., & Deepa, S. N. (2013). Review on Methods to Fix Number of Hidden Neurons in Neural Networks. *Mathematical Problems in Engineering*, 2013, 1-11. <https://doi.org/10.1155/2013/425740>
- Shein, K. (2022). *Linking citizen scientists with technology to reduce climate data gaps* [Other]. display. <https://doi.org/10.5194/egusphere-egu22-10634>
- Shen, C. (2018). A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. *Water Resources Research*, 54(11), 8558-8593. <https://doi.org/10.1029/2018WR022643>
- Shen, C., & Lawson, K. (2021). Applications of Deep Learning in Hydrology. Dans G. Camps-Valls, D. Tuia, X. X. Zhu, & M. Reichstein (Éds.), *Deep Learning for the Earth Sciences* (1^{re} éd., p. 283-297). Wiley. <https://doi.org/10.1002/9781119646181.ch19>
- Shu, X., Ding, W., & Peng, Y. (2021). *Monthly streamflow forecasting using convolutional neural network*. 35, 5089-5104. <https://doi.org/10.1007/s11269-021-02961-w>

- Singh, V. P. (1997). Effect of spatial and temporal variability in rainfall and watershed characteristics on stream flow hydrograph. *Hydrological Processes*, 11(12), 1649-1669. [https://doi.org/10.1002/\(SICI\)1099-1085\(19971015\)11:12<1649::AID-HYP495>3.0.CO;2-1](https://doi.org/10.1002/(SICI)1099-1085(19971015)11:12<1649::AID-HYP495>3.0.CO;2-1)
- Singh, V. P., & Frevert, D. K. (2006). *Watershed models*. Taylor & Francis.
- Singh, V. P., & Woolhiser, D. A. (2002). Mathematical Modeling of Watershed Hydrology. *Journal of Hydrologic Engineering*, 7(4), 270-292. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2002\)7:4\(270\)](https://doi.org/10.1061/(ASCE)1084-0699(2002)7:4(270))
- Sit, M., Demiray, B. Z., Xiang, Z., Ewing, G. J., Sermet, Y., & Demir, I. (2020). A comprehensive review of deep learning applications in hydrology and water resources. *Water Science and Technology*, 82(12), 2635-2670. <https://doi.org/10.2166/wst.2020.369>
- Stangor, C., Walinga, J., BC Open Textbook Project, & BCcampus. (2014). *Introduction to psychology*. <http://open.bccampus.ca/find-open-textbooks/?uuid=8390d51e-0efe-493c-881c-cf86852a612f>
- Stathakis, D. (2009). How many hidden layers and nodes? *International Journal of Remote Sensing*, 30(8), 2133-2147. <https://doi.org/10.1080/01431160802549278>
- Takala, M., Luoju, K., Pulliainen, J., Derksen, C., Lemmetyinen, J., Kärnä, J.-P., Koskinen, J., & Bojkov, B. (2011). Estimating northern hemisphere snow water equivalent for climate research through assimilation of space-borne radiometer data and ground-based measurements. *Remote Sensing of Environment*, 115(12), 3517-3529. <https://doi.org/10.1016/j.rse.2011.08.014>
- Tamiru, H., & Wagari, M. (2021). Comparison of ANN model and GIS tools for delineation of groundwater potential zones, Fincha Catchment, Abay Basin, Ethiopia. *Geocarto International*, 1-19. <https://doi.org/10.1080/10106049.2021.1946171>
- Tayfur, G., & Brocca, L. (2015). Fuzzy Logic for Rainfall-Runoff Modelling Considering Soil Moisture. *Water Resources Management*, 29(10), 3519-3533. <https://doi.org/10.1007/s11269-015-1012-0>

-
- Tayfur, G., Zucco, G., Brocca, L., & Moramarco, T. (2014). Coupling soil moisture and precipitation observations for predicting hourly runoff at small catchment scale. *Journal of Hydrology*, 510, 363-371. <https://doi.org/10.1016/j.jhydrol.2013.12.045>
- Ternynck, C., Ben Alaya, M. A., Chebana, F., Dabo-Niang, S., & Ouarda, T. B. M. J. (2016). Streamflow Hydrograph Classification Using Functional Data Analysis. *Journal of Hydrometeorology*, 17(1), 327-344. <https://doi.org/10.1175/JHM-D-14-0200.1>
- Tian, J., Han, Z., Bogena, H. R., Huisman, J. A., Montzka, C., Zhang, B., & He, C. (2020). Estimation of subsurface soil moisture from surface soil moisture in cold mountainous areas. *Hydrology and Earth System Sciences*, 24(9), 4659-4674. <https://doi.org/10.5194/hess-24-4659-2020>
- Tolson, B. A., & Shoemaker, C. A. (2007). Dynamically dimensioned search algorithm for computationally efficient watershed model calibration: DYNAMICALLY DIMENSIONED SEARCH ALGORITHM. *Water Resources Research*, 43(1). <https://doi.org/10.1029/2005WR004723>
- Topp, G. C., Davis, J. L., & Annan, A. P. (1980). Electromagnetic determination of soil water content : Measurements in coaxial transmission lines. *Water Resources Research*, 16(3), 574-582. <https://doi.org/10.1029/WR016i003p00574>
- Tremblay, V. (2020). *Étude comparative de la performance de données d'humidité du sol in situ et satellitaires pour la simulation hydrologique* [Mémoire de maîtrise]. Université de Sherbrooke.
- Turcotte, R. (2010). *Éléments du calade et de l'implantation d'un modèle hydrologique dans une perspective d'utilisation opérationnelle en prévision hydrologique*. INRS.
- UNISDR. (2012). *Impacts of Disasters since the 1992 Rio de Janeiro Earth Summit*.
- Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 10(5), 988-999. <https://doi.org/10.1109/72.788640>
- Vereecken, H., Huisman, J. A., Pachepsky, Y., Montzka, C., van der Kruk, J., Bogena, H., Weihermüller, L., Herbst, M., Martinez, G., & Vanderborght, J. (2014). On the spatio-temporal dynamics of soil

- moisture at the field scale. *Journal of Hydrology*, 516, 76-96.
<https://doi.org/10.1016/j.jhydrol.2013.11.061>
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A Multiscalar Drought Index Sensitive to Global Warming: The Standardized Precipitation Evapotranspiration Index. *Journal of Climate*, 23(7), 1696-1718. <https://doi.org/10.1175/2009JCLI2909.1>
- Viterbo, F., Mahoney, K., Read, L., Salas, F., Bates, B., Elliott, J., Cosgrove, B., Dugger, A., Gochis, D., & Cifelli, R. (2020). A Multiscale, Hydrometeorological Forecast Evaluation of National Water Model Forecasts of the May 2018 Ellicott City, Maryland, Flood. *Journal of Hydrometeorology*, 21(3), 475-499. <https://doi.org/10.1175/JHM-D-19-0125.1>
- Vos, N. J. D., & Rientjes, T. H. M. (2005). *Constraints of artificial neural networks for rainfall-runoff modelling : Trade-offs in hydrological state representation and model evaluation*. 52.
- Wagena, M. B., Goering, D., Collick, A. S., Bock, E., Fuka, D. R., Buda, A., & Easton, Z. M. (2020). Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models. *Environmental Modelling & Software*, 126, 104669. <https://doi.org/10.1016/j.envsoft.2020.104669>
- Wanders, N., Karssenbergh, D., de Roo, A., de Jong, S. M., & Bierkens, M. F. P. (2014). The suitability of remotely sensed soil moisture for improving operational flood forecasting. *Hydrology and Earth System Sciences*, 18(6), 2343-2357. <https://doi.org/10.5194/hess-18-2343-2014>
- Wang, L., Chen, Y., Tang, L., Fan, R., & Yao, Y. (2018). Object-Based Convolutional Neural Networks for Cloud and Snow Detection in High-Resolution Multispectral Imagers. *Water*, 10(11), 1666. <https://doi.org/10.3390/w10111666>
- Weerts, A. H., & El Serafy, G. Y. H. (2006). Particle filtering and ensemble Kalman filtering for state updating with hydrological conceptual rainfall-runoff models : Particle and ensemble Kalman filtering. *Water Resources Research*, 42(9). <https://doi.org/10.1029/2005WR004093>

-
- Wigmosta, M. S., Vail, L. W., & Lettenmaier, D. P. (1994). A distributed hydrology-vegetation model for complex terrain. *Water Resources Research*, 30(6), 1665-1679. <https://doi.org/10.1029/94WR00436>
- Wilson, D. J., Western, A. W., Grayson, R. B., Berg, A. A., Lear, M. S., Rodell, M., Famiglietti, J. S., Woods, R. A., & McMahon, T. A. (2003). Spatial distribution of soil moisture over 6 and 30cm depth, Mahurangi river catchment, New Zealand. *Journal of Hydrology*, 276(1-4), 254-274. [https://doi.org/10.1016/S0022-1694\(03\)00060-X](https://doi.org/10.1016/S0022-1694(03)00060-X)
- Wood, A. W., & Lettenmaier, D. P. (2006). A Test Bed for New Seasonal Hydrologic Forecasting Approaches in the Western United States. *Bulletin of the American Meteorological Society*, 87(12), 1699-1712. <https://doi.org/10.1175/BAMS-87-12-1699>
- Wood, E. F., Sivapalan, M., Beven, K., & Band, L. (1988). Effects of spatial variability and scale with implications to hydrologic modeling. *Journal of Hydrology*, 102(1-4), 29-47. [https://doi.org/10.1016/0022-1694\(88\)90090-X](https://doi.org/10.1016/0022-1694(88)90090-X)
- Xie, X., & Zhang, D. (2010). Data assimilation for distributed hydrological catchment modeling via ensemble Kalman filter. *Advances in Water Resources*, 33(6), 678-690. <https://doi.org/10.1016/j.advwatres.2010.03.012>
- Xu, C. Y., & Singh, V. P. (2001). *Cross Comparison of Empirical Equations for Calculating Potential Evapotranspiration with Data from Switzerland*. 23.
- Xu, T., & Liang, F. (2021). Machine learning for hydrologic sciences : An introductory overview. *WIREs Water*, 8(5). <https://doi.org/10.1002/wat2.1533>
- Yang, T., Asanjan, A. A., Welles, E., Gao, X., Sorooshian, S., & Liu, X. (2017). Developing reservoir monthly inflow forecasts using artificial intelligence and climate phenomenon information : Reservoir inflow forecasts. *Water Resources Research*, 53(4), 2786-2812. <https://doi.org/10.1002/2017WR020482>

- Yang, T., Gao, X., Sorooshian, S., & Li, X. (2016). Simulating California reservoir operation using the classification and regression-tree algorithm combined with a shuffled cross-validation scheme : Simulating reservoir operation in California. *Water Resources Research*, 52(3), 1626-1651. <https://doi.org/10.1002/2015WR017394>
- Yaseen, Z. M., El-shafie, A., Jaafar, O., Afan, H. A., & Sayl, K. N. (2015). Artificial intelligence based models for stream-flow forecasting: 2000–2015. *Journal of Hydrology*, 530, 829-844. <https://doi.org/10.1016/j.jhydrol.2015.10.038>
- Yonaba, H., Anctil, F., & Fortin, V. (2010). Comparing Sigmoid Transfer Functions for Neural Network Multistep Ahead Streamflow Forecasting. *Journal of Hydrologic Engineering*, 15(4), 275-283. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000188](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000188)
- Zealand, C. M., Burn, D. H., & Simonovic, S. P. (1999). Short term streamflow forecasting using artificial neural networks. *Journal of Hydrology*, 214(1-4), 32-48. [https://doi.org/10.1016/S0022-1694\(98\)00242-X](https://doi.org/10.1016/S0022-1694(98)00242-X)
- Zhang, Z., Zhang, Q., & Singh, V. P. (2018). Univariate streamflow forecasting using commonly used data-driven models: Literature review and case study. *Hydrological Sciences Journal*, 63(7), 1091-1111. <https://doi.org/10.1080/02626667.2018.1469756>
- Zhao, B., Dai, Q., Han, D., Dai, H., Mao, J., Zhuo, L., & Rong, G. (2019). Estimation of soil moisture using modified antecedent precipitation index with application in landslide predictions. *Landslides*, 16(12), 2381-2393. <https://doi.org/10.1007/s10346-019-01255-y>
- Zhu, S., Lu, H., Ptak, M., Dai, J., & Ji, Q. (2020). Lake water-level fluctuation forecasting using machine learning models : A systematic review. *Environmental Science and Pollution Research*, 27(36), 44807-44819. <https://doi.org/10.1007/s11356-020-10917-7>