

Titre: Développement d'une méthode de réduction d'échelle pour la
prévision des crues

Auteur: Nelson Stache

Date: 2025

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Stache, N. (2025). Développement d'une méthode de réduction d'échelle pour la
prévision des crues [Mémoire de maîtrise, Polytechnique Montréal]. PolyPublie.
Citation: <https://publications.polymtl.ca/62989/>

 **Document en libre accès dans PolyPublie**
Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/62989/>
PolyPublie URL:

Directeurs de recherche: Ahmad Shakibaeinia, & Julie Carreau
Advisors:

Programme: Génie civil
Program:

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

**Développement d'une méthode de réduction d'échelle pour la prévision des
crues**

NELSON STACHE

Département des génies civil, géologique et des mines

Mémoire présenté en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

Génie civil

Janvier 2025

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

Ce mémoire intitulé :

Développement d'une méthode de réduction d'échelle pour la prévision des crues

présenté par **Nelson STACHE**

en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

a été dûment accepté par le jury d'examen constitué de :

Elmira HASSANZADEH, présidente

Ahmad SHAKIBAEINIA, membre et directeur de recherche

Julie CARREAU, membre et codirectrice de recherche

Tewfik MAHDI, membre

DÉDICACE

À ma famille qui m'a toujours soutenu.

REMERCIEMENTS

Je tiens tout d'abord à exprimer ma profonde gratitude envers Ahmad Shakibaeinia, mon directeur de recherche et Julie Carreau, ma codirectrice de recherche, pour leurs précieux conseils tout au long de l'élaboration de ce mémoire.

J'aimerais ensuite remercier les organismes suivants pour leur soutien financier : le Conseil de recherches en sciences naturelles et en génie du Canada (CRSNG) et Environnement et Changement Climatique Canada (ECCC).

Mes sincères remerciements vont également aux autres étudiants à la maîtrise et au doctorat et aux chercheurs de la chaire de recherche en hydrosystèmes numériques que j'ai eu la chance de côtoyer: Meriam, Nariman, Herman, Mohamed, Saeed, Faramarz, Can et Gabriel. Je tiens également à souligner l'aide précieuse de Hamza pour son assistance avec le logiciel Delft3D. Merci pour votre soutien inestimable et nos discussions enrichissantes.

Finalement, je souhaite exprimer ma reconnaissance envers mes parents et mon petit frère, qui ont été une source constante de soutien moral et émotionnel. Leur compréhension et leurs encouragements ont été essentiels pour traverser les défis rencontrés durant cette période.

RÉSUMÉ

Déterminer les caractéristiques hydrodynamiques, telles que la profondeur de l'eau et le champ de vitesses, est essentielle pour de nombreuses applications hydro-environnementales. La conception de barrages et d'autres ouvrages de génie civil, la gestion des ressources en eau et l'aménagement du territoire sont des exemples d'applications hydro-environnementales. Depuis de nombreuses décennies, ces caractéristiques sont déterminées à l'aide de modèles physiques 3D qui résolvent les équations de Navier-Stokes ou de modèles physiques 2D qui résolvent les équations de Saint-Venant. Cependant, l'utilisation de ces modèles physiques pour des simulations à haute résolution sur de grandes zones s'avère souvent impraticable en raison du coût de calcul élevé. Avec les avancées technologiques des ordinateurs modernes, une solution au problème de résolution est l'utilisation du calcul haute performance (CHP). Cependant, le coût de calcul demeure élevé dans de nombreux cas, surtout lorsqu'une prévision en temps réel est requise. En conséquence, la résolution spatiale doit souvent être réduite pour conserver un temps de calcul raisonnable tout en sacrifiant une partie de la précision des résultats.

Ces dernières années, de nouvelles approches basées sur l'apprentissage automatique (AA) se sont considérablement développées. Parmi ces approches, une sera particulièrement étudiée dans ce mémoire, il s'agit de la réduction d'échelle statistique. L'objectif est de créer un modèle statistique (ici un modèle basé sur l'AA) capable de trouver des relations mathématiques entre des données de basse résolution, qui ont un coût de calcul faible et une précision faible, et des données de haute résolution, qui ont un coût de calcul élevé et une précision élevée. Ainsi, il sera possible de combiner les avantages des deux résolutions, soit un coût de calcul raisonnable et une haute précision.

Dans ce mémoire, trois modèles d'AA sont introduits et comparés dans la tâche de réduction d'échelle. Un cas d'étude artificiel présentant la confluence de deux canaux est utilisé. Les résultats montrent qu'un réseau de neurones convolutifs (RNC) de type U-Net offre les meilleurs résultats grâce à ses couches de convolution, sa fonction d'activation non linéaire et ses *skip connections*. Par la suite, ce même modèle de type U-Net est utilisé pour améliorer la résolution spatiale d'un système fluvial réel, celui d'un segment du fleuve Saint-Laurent au Canada. Les résultats sont concluants, permettant ainsi d'aller plus loin dans l'approche proposée. Jusqu'à présent, seule une résolution d'entrée (basse résolution) et une résolution de sortie (haute résolution) ont été

considérées. Dans la dernière section de ce mémoire, deux résolutions d'entrée sont testées de façon à déterminer si la performance du modèle de type U-Net est sensible à la résolution d'entrée. Les résultats montrent que même en utilisant une très basse résolution de départ, le modèle de type U-Net est capable de reproduire fidèlement les résultats de la simulation à haute résolution.

Les travaux menés dans le cadre de la rédaction de ce mémoire démontrent l'efficacité des RNC, particulièrement des modèles de type U-Net, dans l'amélioration de la résolution spatiale des modèles hydrodynamiques. Ces modèles permettant de traiter des domaines plus vastes de manière plus efficiente, un défi majeur pour les applications pratiques dans l'hydrologie et l'ingénierie environnementale. Des pistes d'amélioration sont proposées. Est-ce que d'autres modèles d'AA seraient encore plus efficaces (modèles PINN, LSTM)? L'intégration des équations physiques dans la fonction de coût du modèle basé sur l'AA améliore-t-elle l'exactitude et la précision des résultats?

ABSTRACT

Determining hydrodynamic characteristics, such as water depth and velocity fields, with accuracy is essential for many hydro-environmental applications. The design of dams and other civil engineering structures, water resource management, and land use planning are examples of hydro-environmental applications. For many decades, these characteristics have been determined using 3D physics-based numerical models that solve the Navier-Stokes equations or 2D physics-based numerical models that solve the Saint-Venant equations. However, the use of these physics-based numerical models for high-resolution simulations over large areas is often impractical due to the high computational cost. With the technological advancements of modern computers, a solution to the resolution problem is the use of high-performance computing. However, the computational cost remains high in many cases, especially when real-time forecasting is required. As a result, the spatial resolution often needs to be reduced to maintain a reasonable computation time, while sacrificing some accuracy in the results.

In recent years, new approaches based on machine learning (ML) have developed significantly. Among these approaches, one will be particularly studied in this thesis: statistical downscaling. The objective is to create a statistical model (here, an ML-based model) capable of finding mathematical relationships between low-resolution data, which have low computational cost and low accuracy, and high-resolution data, which have high computational cost and high accuracy. Thus, it will be possible to combine the advantages of both resolutions—reasonable computational cost and high accuracy.

In this thesis, three ML models are introduced and compared in the downscaling task. An artificial case study, featuring the confluence of two channels, is used. The results show that a deep neural network (DNN), the U-Net style, gives the best results due to its convolutional layers, non-linear activation function and skip connections. Then, this same U-Net model is used to enhance the spatial resolution of a real river system, a section of the St. Lawrence River in Canada. The results are promising, allowing further exploration of the proposed approach. So far, only one input resolution (low resolution) and one output resolution (high resolution) have been considered. In the final section of this thesis, two input resolutions are tested to determine whether the performance of the U-Net model is sensitive to the input resolution. The results show that even if

we use a very low input resolution, the U-Net model is capable of faithfully reproducing the high-resolution simulation results.

The work conducted in this thesis demonstrates the effectiveness of DNN, particularly U-Net models, in improving the spatial resolution of hydrodynamic models. These models can efficiently consider larger domains, a major challenge for practical applications in hydrology and environmental engineering. Suggestions for improvement are made. Would other ML models be even more effective (PINN, LSTM models)? Does the integration of physical equations into the cost function of the ML-based model improve the accuracy and precision of the results?

TABLE DES MATIÈRES

DÉDICACE.....	III
REMERCIEMENTS	IV
RÉSUMÉ.....	V
ABSTRACT	VII
TABLE DES MATIÈRES	IX
LISTE DES TABLEAUX.....	XII
LISTE DES FIGURES.....	XIII
LISTE DES SIGLES ET ABRÉVIATIONS	XVI
CHAPITRE 1 INTRODUCTION.....	1
1.1 Contexte	1
1.2 Problématique.....	2
CHAPITRE 2 REVUE DE LITTÉRATURE	5
2.1 Inondations	5
2.2 Modèles de prédiction des crues basés sur la physique	6
2.2.1 Équations et hypothèses	6
2.2.2 Méthodes numériques	8
2.2.3 Données requises.....	8
2.2.4 Défi computationnel et calcul haute performance.....	9
2.3 Modèles de prédiction des crues basés sur l'apprentissage automatique.....	10
2.3.1 Principes généraux	12
2.3.2 Machines à vecteur de support	14
2.3.3 Arbres de décision.....	16
2.3.4 Réseaux de neurones artificiels	17

2.4	Modèles hybrides	21
2.4.1	Réduction d'échelle.....	21
2.5	Objectifs	23
CHAPITRE 3 MÉTHODOLOGIE.....		26
3.1	Étape 1	26
3.2	Étape 2.....	26
3.3	Étape 3.....	27
CHAPITRE 4 ARTICLE 1: EVALUATION OF ML TECHNIQUES FOR DOWNSCALING HYDRODYNAMIC SIMULATIONS		28
4.1	Introduction	28
4.2	Models	30
4.2.1	Test cases.....	30
4.2.2	Neural networks models.....	33
4.3	Results and discussions	36
4.3.1	Synthetic test case	36
4.3.2	St-Lawrence River case.....	37
4.4	Conclusion.....	39
4.5	Acknowledgements	40
CHAPITRE 5 EFFET DU FACTEUR D'ÉCHELLE: ÉTUDE SUR LA RIVIÈRE ATHABASCA		41
5.1	Présentation du cas d'étude	41
5.2	Modèles	44
5.2.1	Modèle physique	44
5.2.2	Modèle basé sur l'AA	47
5.3	Résultats	48

5.3.1	Modèle physique	48
5.3.2	Modèle basé sur l'AA	53
5.4	Conclusion.....	60
CHAPITRE 6 CONCLUSION		61
6.1	Synthèse des travaux	61
6.2	Limitation de la solution proposée	61
6.3	Améliorations futures	62
RÉFÉRENCES.....		63

LISTE DES TABLEAUX

Tableau 2.1 Types de fonctions d'activation	19
Tableau 2.2 Articles traitant de la réduction d'échelle	24
Table 4.1 Event and resolution related to each simulation	31
Table 4.2 Minimal, mean, and maximal values for the 4 simulations.	36
Table 4.3 Performance of each model in terms of MAE.	37
Table 4.4 Minimal, mean, and maximal values for both resolutions.	38
Tableau 5.1 Paramètres des trois simulations DELFT3D-FLOW	46
Tableau 5.2 Informations géographiques sur la section transversale utilisée pour la calibration .	46
Tableau 5.3 Résultats du modèle physique	49
Tableau 5.4 Résultats du modèle basé sur l'AA (U-Net).....	54

LISTE DES FIGURES

Figure 1.1 Barrage du lac Vyrnwy (Pays de Galles) permettant l’approvisionnement en eau au comté de Merseyside (Angleterre)	1
Figure 2.1 Types d'apprentissage	11
Figure 2.2 Compromis biais-variance	13
Figure 2.3 Ensemble de données suivant une tendance quadratique avec une régression de degré 1 (a), de degré 2 (b) et de degré 6 (c)	14
Figure 2.4 Machine à vecteurs de support, par Alisneaky et Zirguezzi, 2011, Wikimedia Commons (https://commons.wikimedia.org/wiki/File:Kernel_Machine.svg). CC BY-SA.....	15
Figure 2.5 Exemple d’arbre (à droite) avec son illustration correspondante de la segmentation de l’espace des prédicteurs \mathbf{x} (à gauche)	16
Figure 2.6 Architecture d'un réseau de neurones à propagation avant (RNPA)	18
Figure 2.7 Représentation schématique de la réduction d'échelle.....	21
Figure 4.1 Representation of the synthetic hydrodynamic system.....	30
Figure 4.2 Flow hydrographs for the upstream boundary conditions for Event 1 and Event 2. ...	32
Figure 4.3 St-Lawrence River Study Area (in blue).	32
Figure 4.4 Neural Networks architectures for the synthetic test case. For the real case, the only changes are the shapes of the last Dense layer (499329) and the last Reshape layer (166443, 3).....	35
Figure 4.5 Zoom on the 90° channel confluence. Velocity norm for the four models, the low-resolution and the ground truth at $t = 8.9h$	38
Figure 4.6 q_{norm} for the U-Net, the low-resolution and the ground truth at $t =$ December 24th, 2022, 9:00 AM. The graph under the three subplots shows q_{norm} for the cross-section (orange line).....	39
Figure 5.1 Cas d’étude de la rivière Athabasca.....	42
Figure 5.2 Débits à l'amont	43

Figure 5.3 Niveaux d'eau à l'aval	43
Figure 5.4 Débits des tributaires	44
Figure 5.5 Comparaison entre la norme de la vitesse mesurée et la norme de la vitesse simulée et comparaison entre le niveau d'eau mesuré et le niveau d'eau simulé pour la date du 15 septembre 2004 à 12h00. Calibration effectuée à la section transversale <i>Reach 4</i>	47
Figure 5.6 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 1)	50
Figure 5.7 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 2)	51
Figure 5.8 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 3)	51
Figure 5.9 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 1).....	52
Figure 5.10 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 2).....	52
Figure 5.11 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 3).....	53
Figure 5.12 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (cas 1)	55
Figure 5.13 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (cas 2)	56
Figure 5.14 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (cas 1)	56
Figure 5.15 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (cas 2)	57
Figure 5.16 Erreur absolue moyenne de la norme de la vitesse (m/s) pour un segment de la rivière Athabasca (cas 1)	58

Figure 5.17 Erreur absolue moyenne de la norme de la vitesse (m/s) pour un segment de la rivière Athabasca (cas 2)	58
Figure 5.18 Courbe de l'erreur d'entraînement et de validation pour le cas 1	59
Figure 5.19 Courbe de l'erreur d'entraînement et de validation pour le cas 2	59

LISTE DES SIGLES ET ABRÉVIATIONS

AA	Apprentissage automatique
ACP	Analyse par composantes principales
CFL	Courant-Friedrich-Lewy
CHP	Calcul haute performance
CRED	Centre for Research on the Epidemiology of Disasters
ECCC	Environnement et Changement climatique Canada/Environment and Climate Change Canada
GIEC/IPCC	Groupe d'experts intergouvernemental sur l'évolution du climat/Intergovernmental Panel on Climate Change
IA	Intelligence artificielle
LSTM	Long short-term memory
MDF	Méthode des différences finies
MEF	Méthode des éléments finis
MVF	Méthode des volumes finis
MNT	Modèle numérique de terrain
MSE	Mean squared error
MVS	Machine à vecteurs de support
OOB	Out-of-bag
PINN	Physics-informed neural network
REQM	Racine de l'erreur quadratique moyenne
RNA	Réseau de neurones artificiels
RNPA	Réseau de neurones à propagation avant
RNC	Réseau de neurones convolutifs
RNR	Réseau de neurones récurrents

RVS	Régression à vecteurs de support
UCT	Unités centrales de traitement
USACE	United States Army Corps of Engineers
UTG	Unités de traitement graphique

Article 1 (en anglais):

DNN	Deep neural network
MAE	Mean absolute error
ML	Machine learning
MSE	Mean squared error
SWE	Shallow water equations

CHAPITRE 1 INTRODUCTION

1.1 Contexte

La modélisation hydrodynamique est un outil clé pour comprendre et simuler les mouvements de l'eau dans divers environnements naturels et artificiels. Elle repose sur la résolution de systèmes d'équations différentielles qui décrivent le comportement de l'eau en fonction de variables telles que la vitesse, la profondeur, la pente du lit et la viscosité. Ces modèles permettent notamment de reproduire les phénomènes hydrauliques complexes observés dans les rivières, tels que les variations du débit, les interactions entre l'eau et les structures riveraines, ainsi que les effets de la topographie locale.

Un exemple concret d'application de la modélisation hydrodynamique est celui du barrage du lac Vyrnwy, situé à Llanwddyn au Pays de Galles, voir Figure 1.1. Ce barrage, construit au XIX^e siècle, est un élément clé de l'approvisionnement en eau de la région du Merseyside, en Angleterre (Liverpool John Moores University, 2024).



Figure 1.1 Barrage du lac Vyrnwy (Pays de Galles) permettant l'approvisionnement en eau au comté de Merseyside (Angleterre)

L'une des applications les plus importantes de la modélisation hydrodynamique dans les rivières est la gestion des risques d'inondation. En simulant les crues et en prédisant les hauteurs d'eau à différents points d'une rivière, ces modèles permettent de mieux comprendre les zones susceptibles d'être inondées, d'élaborer des plans d'évacuation et d'optimiser les infrastructures de protection comme les digues et les barrages. Les modèles hydrodynamiques permettent aussi de simuler les effets de différents scénarios de gestion de l'eau, facilitant ainsi la prise de décisions éclairées en cas d'alerte. Ce mémoire porte précisément sur l'application de la modélisation hydrodynamique sur les rivières.

En dehors de la gestion des inondations, la modélisation hydrodynamique est également utilisée dans d'autres domaines essentiels. Elle est par exemple cruciale pour la gestion durable des ressources en eau. En prévoyant l'évolution des débits et des niveaux d'eau dans les rivières, ces modèles aident à la gestion des prélèvements d'eau pour l'agriculture, l'industrie et les besoins domestiques, tout en préservant l'écosystème aquatique. La qualité de l'eau, qui dépend fortement des courants et de la diffusion des polluants, est également étudiée à travers ces modèles, permettant de prévoir et d'atténuer les risques de contamination.

D'autres applications concernent l'aménagement du territoire, où la modélisation hydrodynamique permet de concevoir des infrastructures telles que les ponts, les routes et les barrages et de minimiser leur impact sur les dynamiques fluviales. Elle est aussi utilisée dans les études d'impact sur l'environnement pour évaluer les effets des projets d'aménagement sur les habitats aquatiques. Enfin, face aux défis du changement climatique, ces modèles permettent d'analyser l'évolution probable des régimes hydrologiques, en anticipant des phénomènes comme l'augmentation de la fréquence et de l'intensité des crues, ou la modification des régimes de débit. Il est ainsi possible de soutenir des stratégies d'adaptation efficaces.

1.2 Problématique

D'après un rapport publié par le Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC), entre la période préindustrielle (1850-1900) et la décennie 2006-2015, la température moyenne à la surface du globe a augmenté de 0,87°C (Intergovernmental Panel on Climate Change (IPCC), 2022). Toujours selon le même rapport, si le taux de croissance des températures reste identique (0,2°C par décennie), on pourrait atteindre une augmentation de la température moyenne de 1,5°C aux alentours de 2040 (Intergovernmental Panel on Climate Change (IPCC), 2022). Dans

ce contexte de changements climatiques, les précipitations extrêmes seront plus intenses dans de larges régions dans le monde (IPCC, 2021; Tabari, 2020). En effet, un air plus chaud de 1°C peut contenir environ 7% de vapeur d'eau en plus (Intergovernmental Panel on Climate Change (IPCC), 2023). La fréquence de ces précipitations risque également d'augmenter. Par exemple, depuis 30 ans, les pluies d'une intensité excédant 50 mm/h ont augmenté d'un facteur 1,4 au Japon (Okuno et al., 2021). En Ontario, les projections montrent une augmentation des précipitations annuelles de 18,4% entre 2013 et 2100 (Rincón et al., 2022). Par conséquent, les projections montrent que l'intensité et la fréquence des inondations va augmenter avec l'amplification des événements extrêmes de précipitations (Tabari, 2020).

Au niveau mondial, l'Organisation mondiale de la Santé estime que les inondations ont affecté deux milliards de personnes entre 1998 et 2017 (World Health Organization, 2023). En 2022, selon le Centre de recherche sur l'épidémiologie des catastrophes (CRED), 45% de toutes les catastrophes naturelles de l'année, soit 176 sur 387, sont classées dans la catégorie des inondations. La même année, elles ont affecté plus de 57 millions de personnes et en ont tué 7954 notamment dans des régions densément peuplées telles que le Pakistan, l'Inde et le Brésil (CRED, 2023). Les inondations peuvent contribuer à la propagation des maladies, causer des risques chimiques et provoquer des ruptures des systèmes de santé dans les lieux inondés (World Health Organization, 2023). Plus localement, au Québec, les inondations font partie des catastrophes naturelles les plus dévastatrices. Au cours des dernières années, les coûts socioéconomiques associés aux inondations n'ont cessé d'augmenter (Gouvernement du Québec, 2023). L'organisme Ouranos estime d'ailleurs le coût annuel des inondations au Québec à 70 millions de dollars canadiens. Toutefois, lors d'inondations majeures, comme en 2017 et en 2019, les coûts sont montés respectivement à 360 et 438 millions de dollars canadiens (Ouranos, 2024). Dans le monde, ces coûts s'élèvent à 44,9 milliards de dollars américains (61,5 milliards de dollars canadiens) pour l'année 2022 (CRED, 2023).

Dans ce contexte, il sera d'autant plus important de prévoir avec exactitude et précision les crues et leurs caractéristiques (niveaux d'eau et vitesses et carte des inondations) afin de laisser suffisamment de temps aux autorités de procéder à une évacuation de la zone à risque. Traditionnellement, pour prévoir les crues, on utilise une approche basée sur la physique. Cette approche repose sur la discrétisation des équations de Saint-Venant (pour une modélisation unidimensionnelle ou bi-dimensionnelle) ou des équations de Navier-Stokes (pour une modélisation

tri-dimensionnelle) pour trouver les caractéristiques des crues. Cependant, le coût de calcul pour les modèles basés sur la physique peut être très important, surtout lorsqu'on cherche à modéliser une rivière à une échelle très fine et/ou sur un large domaine. C'est également problématique dans les situations suivantes : simulations en temps réel (moins de quelques heures d'intervalle avant l'évènement de crue), conceptions d'ouvrages hydrauliques massifs (comme des barrages), simulations de différents scénarios et simulations répétées. Il est ainsi important de trouver d'autres approches. Une approche possible est le calcul haute performance (CHP) qui permet d'accélérer le temps de calcul. Plus récemment, une nouvelle approche basée sur l'intelligence artificielle (IA) a fait son entrée pour la prévision de variables hydrologiques. Dans ce cas, on n'utilise pas les équations mathématiques décrivant le phénomène physique pour trouver les caractéristiques des crues, mais des relations statistiques. Le temps de calcul y est réduit par rapport aux modèles basés sur la physique.

Dans ce mémoire, une nouvelle approche de prédiction des crues sera développée. Cette approche, qui sera détaillée dans les chapitres suivants, consiste en une modélisation hybride combinant un modèle numérique à un modèle d'IA. Plus précisément, il sera question d'une méthode de réduction d'échelle basée sur l'IA, c'est-à-dire qu'on cherche à reconstruire une simulation à haute-résolution à partir d'une simulation de basse résolution basée sur la physique.

Ce mémoire sera composé de six chapitres. Le premier chapitre présente le contexte et la problématique du projet de recherche. Le deuxième chapitre consiste en une revue de littérature sur le sujet. Le troisième chapitre présente la méthodologie du mémoire. Le quatrième chapitre consiste en un article de conférence. Dans cet article, un cas d'étude artificiel est utilisé pour déterminer la meilleure architecture de réseaux de neurones à utiliser dans un contexte de réduction d'échelle. Ensuite, toujours dans le même chapitre, un cas d'étude réel est utilisé afin de confirmer la nouvelle méthode développée. Le cinquième chapitre consiste en une extension de l'article de conférence. Il s'agit de l'application du réseau de neurones sur un nouveau cas d'étude en considérant plusieurs résolutions d'entrée. Le but est de déterminer si le réseau de neurones est capable de reproduire des données de haute résolution à partir de données de très basse résolution. Finalement, le sixième chapitre sert de conclusion à ce mémoire.

CHAPITRE 2 REVUE DE LITTÉRATURE

Ce chapitre est consacré à la revue de littérature. La première section traite des inondations, la deuxième traite des modèles basés sur la physique, la troisième porte sur les modèles basés sur l'apprentissage automatique (AA) et la quatrième porte sur des modèles hybrides (combinaisons des deux catégories)

2.1 Inondations

Une inondation survient lorsque le volume d'eau dans un cours d'eau excède sa capacité (Bayat & Tavakkoli, 2022). L'eau ne peut plus être contenue entre les rives, elle sort du lit de la rivière et elle s'étale dans la plaine inondable avoisinante. L'eau peut y séjourner sur une période plus ou moins longue de quelques heures à quelques mois. Les inondations sont des phénomènes naturels et courants au Canada (Environnement et Changement climatique Canada (ECCC), 2010). Les inondations peuvent également survenir en milieu côtier. Cette fois ce ne sont plus les rivières qui débordent, mais le niveau de la mer qui augmente (Intergovernmental Panel on Climate Change (IPCC), 2023) et qui peut submerger les terres riveraines (Environnement et Changement climatique Canada (ECCC), 2013).

Les causes des inondations sont multiples. Le type d'inondations le plus fréquent au Canada est la crue printanière. Au printemps, lorsque le rayonnement solaire est plus fort et les températures plus douces, la neige et la glace qui se sont accumulés sur le sol pendant l'hiver commencent à fondre (Bayat & Tavakkoli, 2022). Comme le sol est encore gelé, l'eau ne peut pas s'infiltrer et elle ruisselle donc vers les rivières. Si l'accumulation de neige a été importante durant l'hiver et/ou si le dégel est soudain, le risque d'inondations augmente fortement (Environnement et Changement climatique Canada (ECCC), 2013). Un autre type de crue très présent au Canada sont les crues d'orage. Elles sont extrêmement dangereuses puisqu'elles sont imprévisibles. À cause du grand volume de précipitations sur un intervalle de temps très court, le sol se retrouve rapidement saturé et le pic de crue est atteint dans les six heures suivant le début des précipitations. Les orages étant très localisés, ce sont surtout les petits cours d'eau qui débordent (Environnement et Changement climatique Canada (ECCC), 2013). Ce type de crues est également très présent au Japon (inondations de l'île de Kyushu en 2017) (Okuno et al., 2021). Un troisième type de crue, lié aux embâcles de glace, soit des accumulations de blocs de glace, peut provoquer des inondations au printemps. Dans ce cas, la friction entre la face inférieure de la glace et l'eau provoque un

ralentissement de l'écoulement et par conséquent une hausse du niveau d'eau (Environnement et Changement climatique Canada (ECCC), 2013). Les tempêtes côtières et les ouragans, qui combinent vents forts et vagues fortes, ainsi que les tsunamis touchent surtout les régions côtières du Canada (Environnement et Changement climatique Canada (ECCC), 2013) à proximité de l'océan Atlantique et de l'océan Pacifique. Le dernier type d'inondations commun est l'inondation urbaine. Dans ce cas, lors d'une forte pluie, la capacité des réseaux d'égouts peut être dépassée ce qui provoque l'inondation des sous-sols et des routes (Environnement et Changement climatique Canada (ECCC), 2013).

En plus du changement climatique qui va multiplier les phénomènes météorologiques extrêmes (Intergovernmental Panel on Climate Change (IPCC), 2022; Rincón et al., 2022), plusieurs autres facteurs peuvent influencer les inondations. Les principaux sont les suivants : la distance d'un point par rapport à la rivière, la pente du bassin versant, l'altitude du bassin versant, la composition des sols, le mauvais aménagement des bassins versants, la déforestation, les changements d'occupation des sols, l'accroissement de l'urbanisation et les activités économiques dans les zones propices aux inondations (Costache et al., 2020; Rincón et al., 2022). Les constructions humaines, comme les barrages, qui altèrent le débit naturel de l'eau, influencent également les inondations (Nevo et al., 2022). Par exemple, dans la ville de Carlisle, au nord de l'Angleterre, des murs anti-inondations ont été construits. Ces derniers modifient le comportement naturel de la rivière en retardant l'arrivée de l'eau dans la ville. Les autorités ont ainsi eu plus de temps pour réfléchir aux actions à prendre pour réduire les risques. En contrepartie, si l'eau entre plus lentement dans les zones protégées par les murs, elle prend également plus de temps pour en sortir (Kabir et al., 2020).

2.2 Modèles de prédiction des crues basés sur la physique

Cette section traite des modèles de prédictions des crues basés sur la physique. On y mentionne les équations générales et les hypothèses liées, les méthodes numériques utilisées, les données requises ainsi que le défi computationnel et calcul haute performance.

2.2.1 Équations et hypothèses

Les modèles basés sur la physique sont les modèles utilisés traditionnellement dans la prévision des crues (Bayat & Tavakkoli, 2022; Cheng et al., 2021; Hosseiny et al., 2020). Dans la plupart des cas, ces modèles résolvent les équations de Navier-Stokes, pour une modélisation des

écoulements en 3D, ou les équations de St-Venant, pour une modélisation en 2D ou en 1D (Teng et al., 2017). Les équations de Saint-Venant, aussi appelées équations d'eau peu profonde, sont une forme simplifiée des équations de Navier-Stokes. Les modèles 2D basés sur ces équations sont reconnus comme étant l'approche de référence pour la modélisation hydrodynamique (Bomers & Hulscher, 2023; Carreau & Guinot, 2021; Teng et al., 2017). L'hypothèse de base pour obtenir les équations de Saint-Venant (2D) est que l'échelle verticale (direction z) soit beaucoup plus petite que les échelles horizontales (directions x et y). Par conséquent, la vitesse verticale est négligeable par rapport aux autres composantes et les pressions sont considérées comme hydrostatiques. L'équation de la quantité de mouvement dans la direction z peut être simplifiée en l'équation de la pression hydrostatique. Les vitesses sont également moyennées selon la profondeur (Mintgen & Manhart, 2018). Les équations de Saint-Venant sont composées de trois parties, une partie pour la conservation de la masse et deux parties pour la conservation de la quantité de mouvement en x et en y . La forme compacte (vectorielle) des équations de Saint-Venant est présentée à l'équation 2.1 (Morales-Hernández et al., 2021).

$$\frac{\partial \mathbf{U}}{\partial t} + \frac{\partial \mathbf{F}}{\partial x} + \frac{\partial \mathbf{G}}{\partial y} = \mathbf{S}_r + \mathbf{S}_b + \mathbf{S}_f \quad (2.1)$$

$$\text{Avec } \mathbf{U} = \begin{pmatrix} h \\ q_x \\ q_y \end{pmatrix}, \quad \mathbf{F} = \begin{pmatrix} q_x \\ q_x^2 + \frac{1}{2}gh^2 \\ \frac{q_x q_y}{h} \end{pmatrix}, \quad \mathbf{G} = \begin{pmatrix} q_y \\ \frac{q_x q_y}{h} \\ q_y^2 + \frac{1}{2}gh^2 \end{pmatrix}, \quad \mathbf{S}_r = \begin{pmatrix} r \\ 0 \\ 0 \end{pmatrix},$$

$$\mathbf{S}_b = \begin{pmatrix} 0 \\ -gh \frac{\partial z}{\partial x} \\ -gh \frac{\partial z}{\partial y} \end{pmatrix}, \quad \mathbf{S}_f = \begin{pmatrix} 0 \\ -\frac{gn^2}{h^3} q_x \sqrt{q_x^2 + q_y^2} \\ -\frac{gn^2}{h^3} q_y \sqrt{q_x^2 + q_y^2} \end{pmatrix}$$

Dans l'équation 2.1, le vecteur \mathbf{U} comporte les variables de l'écoulement qui sont inconnues, soit la profondeur d'eau (h) et les débits unitaires dans les directions x (q_x) et y (q_y) de l'espace. \mathbf{G} et \mathbf{F} sont les vecteurs de flux dans les directions x et y respectivement. Les termes de sources sont du côté droit de l'équation. \mathbf{S}_r exprime le taux de ruissellement (pluie totale dont on soustrait les pertes dues à l'infiltration et à l'évapotranspiration et à laquelle on rajoute le débit de base). \mathbf{S}_b est le terme

correspondant à la pente du lit de la rivière et S_f est le terme de frottement exprimé avec la loi de Gauckler-Manning (Morales-Hernández et al., 2021).

2.2.2 Méthodes numériques

Aujourd'hui, dans sa forme complète, aucune solution n'existe pour l'équation 2.1 (Teng et al., 2017). Les modèles développés utilisent donc des méthodes numériques. Par exemple, le logiciel « ADaptive Hydraulics (ADH) » développé par le Corps du génie de l'armée de terre des États-Unis (USACE) utilise une méthode d'éléments finis (MEF) pour résoudre les équations de Saint-Venant (Savant et al., 2011). Dans le cas des logiciels à code ouvert HiPIMS (Xia et al., 2019), TRITON (Morales-Hernández et al., 2021) et SERGHEI (Caviedes-Voullième et al., 2023) et du logiciel HEC-RAS 2D (également développé par l'USACE) (USACE Hydrologic Engineering Center, 2023), une méthode de volumes finis (MVF) est utilisée. Le logiciel commercial TUFLOW utilise quant à lui une méthode de différences finis (MDF) (Mudashiru et al., 2021). La résolution peut se faire avec un schéma implicite ou explicite. Dans un schéma numérique explicite, les pas de temps doivent être suffisamment petits pour respecter la condition de Courant-Friedrich-Lewy (CFL) et ainsi s'assurer de la convergence et de la stabilité de la solution numérique (Morales-Hernández et al., 2021; Popescu, 2014). La condition CFL dépend à la fois de la taille des cellules et de la vitesse du fluide (Ming et al., 2020). Avec la discrétisation explicite, les variables inconnues dans chaque cellule pour un nouveau pas de temps sont déterminées uniquement en se basant sur les valeurs connues du pas de temps précédant. L'avantage de ce type de discrétisation est la facilité d'implémentation du code dans un programme informatique puisque, la plupart du temps, aucun système d'équations algébriques n'est formé. Ainsi, il n'est pas nécessaire d'utiliser un solveur (Popescu, 2014). Dans un schéma implicite, la solution est stable inconditionnellement, mais comme les valeurs des variables inconnues dans une cellule sont déterminées à partir des valeurs des cellules adjacentes au même pas de temps, un système d'équations algébriques est créé (Popescu, 2014). Un solveur est alors nécessaire et devra itérer sur le système d'équations à de multiples reprises à chaque pas de temps (Feng et al., 2023).

2.2.3 Données requises

Un modèle basé sur la physique a besoin de plusieurs données d'entrée pour mener la simulation. Premièrement, il est nécessaire d'avoir des données topographiques, comme celles provenant d'un modèle numérique de terrain (MNT), couvrant l'ensemble du bassin versant à l'étude (Morales-

Hernández et al., 2021). Les données topographiques ne représentent que les formes du terrain au-dessus du niveau de l'eau. Cependant, pour modéliser des phénomènes hydrodynamiques, il est essentiel d'avoir, en plus de la topographie, des données bathymétriques donnant des informations sur les sections transversales des rivières (Xia et al., 2019). Deuxièmement, une carte d'occupation du sol permettant d'estimer et d'ajuster le coefficient de friction (le plus souvent le coefficient de Manning) est très utile. En sachant la composition du sol, il est possible de consulter la littérature scientifique pour trouver l'intervalle du coefficient de Manning à utiliser. Généralement, on utilise un coefficient de Manning pour l'ensemble du bassin versant (Caviedes-Voullième et al., 2023; Morales-Hernández et al., 2021) ou deux coefficients de Manning, soit un pour les canaux des rivières et un autre pour les plaines inondables (Ming et al., 2020; Xia et al., 2019). La valeur du coefficient de Manning pour les plaines inondables est plus élevée (plus grande résistance à l'écoulement) que celle pour le canal (Ming et al., 2020; Xia et al., 2019). Pour calibrer le modèle, on ajuste le coefficient de Manning de manière à obtenir les surfaces libres correspondant aux débits connus pour une station de calibration (Hosseiny et al., 2020). Cette station de calibration doit être suffisamment éloignée des extrémités du domaine de calcul afin d'éviter l'influence des conditions frontières. Finalement, des données hydrométriques (hydrogrammes, courbes de tarage ou valeurs de débits et de hauteurs d'eau constantes) sont utilisées pour les conditions initiales et les conditions frontières (Xia et al., 2019).

2.2.4 Défi computationnel et calcul haute performance

Même si les modèles 2D sont capables de prédire les caractéristiques des crues (vitesses de l'eau, étendue de l'inondation, hauteurs d'eau) correctement, il n'en demeure pas moins que le coût de calcul est très élevé (Teng et al., 2017). Pour des superficies supérieures à 1000 km² avec une résolution requise de moins de 10 mètres, il n'est pas envisageable d'utiliser un modèle 2D (Teng et al., 2017). Les avancées récentes réalisées dans le calcul haute performance (CHP) permettent de défier ces limitations. Le CHP consiste en l'utilisation de plusieurs unités centrales de traitement (UCT) ou de plusieurs unités de traitement graphique (UTG) interconnectées pour effectuer des calculs en parallèle (Parmar et al., 2022). Par exemple, le logiciel TRITON (Two-dimensional Runoff Inundation Toolkit for Operational Needs) a été implémenté de manière à ce que les utilisateurs peuvent utiliser plusieurs UCT ou UTG en parallèle pour faire les calculs (bien que les simulations sur les UTG sont plus rapides) (Morales-Hernández et al., 2021). En 2019, d'autres chercheurs ont simulé une inondation sur le bassin versant de Carlisle en Angleterre (2500 km²) en utilisant le logiciel HiPIMS (High-Performance

Integrated hydrodynamic Modelling System). Ce modèle utilisant le CHP est conçu pour être lancé sur de multiples UCT afin d'améliorer son efficacité de calcul (Xia et al., 2019). Pour un évènement de pluie de 96 heures et une résolution de 5 mètres, la simulation a duré 37,5 heures. Même si la durée de la simulation est 2,5 fois plus petite que la durée de l'évènement de pluie lui-même, cela ne laisse pas beaucoup de délai aux autorités pour prendre les décisions qui s'imposent avant l'arrivée de la crue. Si l'on réduit la résolution à 40 m, le temps de simulation n'est que de 0,15 heures (Xia et al., 2019). Cependant, il n'est pas toujours possible de réduire la résolution, notamment dans les zones sensibles (aires urbaines) où une précision de l'ordre de quelques mètres est requise pour avoir un modèle efficace (Carreau & Guinot, 2021; Hartnett & Nash, 2017). De plus, pour des simulations sur le long terme (plusieurs années), qui sont utiles pour évaluer l'impact des changements climatiques, les modèles basés sur le CHP ont encore un coût de calcul trop élevé. Pour ces raisons, des modèles conceptuels se basant sur des concepts hydrauliques simplifiés et qui ne résolvent pas d'équations différentielles se sont développés (McGrath et al., 2018). Par ailleurs, ces dernières années, ce sont les modèles basés sur les données, plus particulièrement ceux basés sur l'apprentissage automatique (AA), qui se sont imposés dans le milieu de la recherche étant donné leur faible coût de calcul et leur bonne performance pour la prédiction des inondations (Bomers & Hulscher, 2023; Karim et al., 2023; Mosavi et al., 2018).

En conclusion, bien que les modèles basés sur la physique soient essentiels pour comprendre les dynamiques des rivières et prédire les inondations, ils présentent des limitations, notamment en termes de complexité computationnelle et de dépendance aux données précises. Même en utilisant le CHP, il y a des situations où le coût de calcul demeure trop important. Cependant, avec les avancées récentes, les méthodes d'AA émergent comme une solution complémentaire prometteuse pour la prévision des inondations. Ces techniques permettent de traiter des ensembles de données vastes et complexes, d'identifier des motifs cachés et d'améliorer la précision des prédictions, ouvrant ainsi de nouvelles perspectives pour une gestion plus efficace des risques d'inondation.

2.3 Modèles de prédiction des crues basés sur l'apprentissage automatique

L'AA est défini comme étant « [...] la capacité des [algorithmes] à établir des tendances, à apprendre à partir de données, à faire des inférences et à prendre des décisions sans avoir été programmés explicitement pour ces tâches. » (Conseil national de recherches Canada, 2020) Il s'agit d'un sous-domaine de l'intelligence artificielle (IA) (Conseil national de recherches Canada, 2020; Karim et al., 2023; Mosavi et al., 2018). L'AA utilise des outils mathématiques à l'intersection de plusieurs domaines tels que les statistiques, les probabilités, les sciences

informatiques, l'algèbre linéaire, l'analyse fonctionnelle et la géométrie (Karim et al., 2023). L'AA se décompose en plusieurs catégories (Bishop, 2006), comme le montre la Figure 2.1.

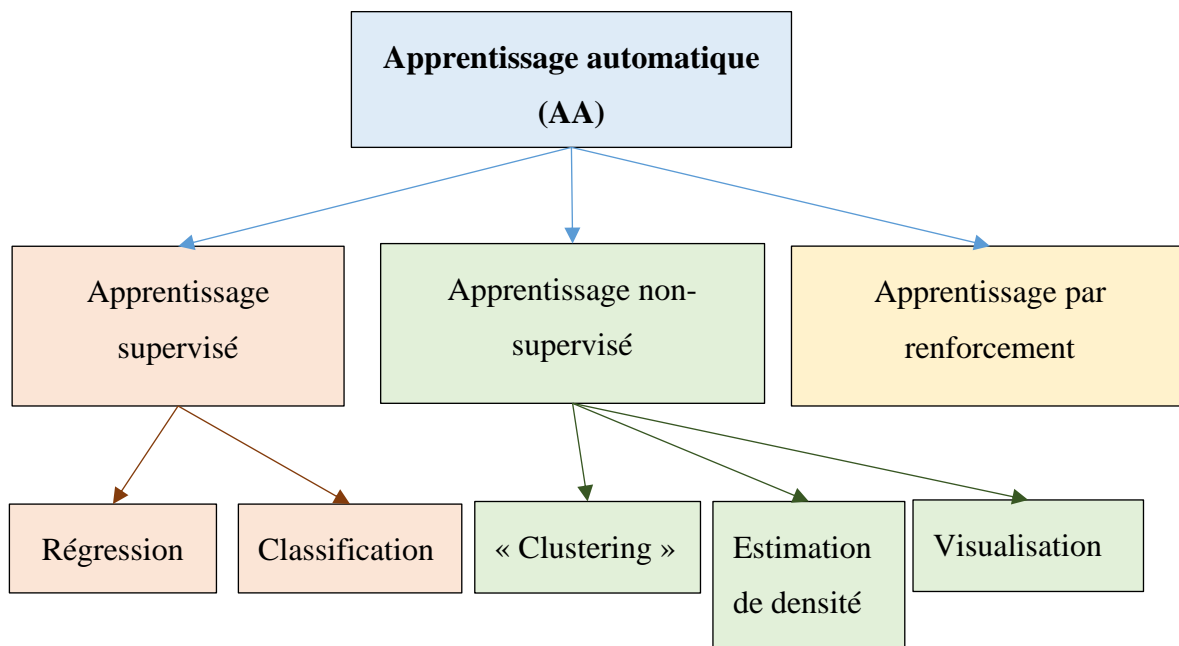


Figure 2.1 Types d'apprentissage

Lorsque les données d'entraînement comprennent des données étiquetées, c'est-à-dire que pour chaque intrant \mathbf{X} , on connaît la valeur de sortie associée \mathbf{Y} (aussi appelée cible), l'apprentissage est dit supervisé. Cette catégorie est elle-même subdivisée en deux sous-catégories : la régression (lorsque les données de sorties sont des variables continues) et la classification (lorsque les données de sortie sont des variables discrètes) (Bishop, 2006).

À l'inverse, lorsque les données d'entraînement ne sont pas étiquetées, on parle d'apprentissage non-supervisé. Celui-ci est subdivisé en trois catégories : le regroupement (aussi appelé « clustering ») où l'algorithme doit tenter de découvrir des groupes d'exemples similaires à partir des données, l'estimation de densité visant à déterminer la distribution des données dans l'espace et la projection de données de haute-dimension sur un espace à 2 ou 3 dimensions pour faciliter la visualisation (Bishop, 2006).

Finalement, le dernier type d'AA est l'apprentissage par renforcement. Dans ce cas, contrairement à l'apprentissage supervisé, on ne donne pas les réponses optimales à l'algorithme, on lui laisse

plutôt les découvrir dans un processus d'essais et erreurs. L'algorithme doit alors trouver une suite d'actions à entreprendre dans une situation donnée de manière à maximiser une récompense (Bishop, 2006).

Dans le cadre de ce mémoire, les algorithmes utilisés entrent dans la catégorie d'apprentissage supervisé. Ces algorithmes seront détaillés dans les sous-sections suivantes.

2.3.1 Principes généraux

L'ensemble de données peut être séparé en trois groupes. Le premier groupe, appelé ensemble d'entraînement, sert, comme son nom l'indique, à entraîner le modèle (trouver les valeurs des paramètres). Le deuxième ensemble, appelé ensemble de validation, sert à optimiser les valeurs des hyperparamètres (complexité du modèle). Le troisième ensemble, appelé ensemble de test, sert à évaluer la performance du modèle (Bishop, 2006). Il est important de noter que le modèle ne doit jamais avoir utilisé ce dernier ensemble. Il existe plusieurs mesures mathématiques pour évaluer la performance du modèle. La mesure la plus utilisée est la racine de l'erreur quadratique moyenne (REQM), (équation 2.2), où h_m représente la valeur prédite par le modèle, h_o , la valeur observée et N le nombre d'observations.

$$REQM = \sqrt{\sum_{n=1}^N \frac{(h_m^n - h_o^n)^2}{N}} \quad (2.2)$$

Une valeur faible de REQM indique une plus grande exactitude du modèle d'AA. Une valeur de 0 correspond à un ajustement parfait des données (Ming et al., 2020).

Les paramètres du modèle sont choisis de façon à minimiser une fonction d'erreur (aussi appelée fonction de coût). Différentes fonctions de coût existent, dont l'erreur quadratique moyenne (*Mean squared error (MSE)*), voir équation 2.3. L'équation 2.3 est similaire à l'équation 2.2 : la différence réside dans la présence d'une racine carrée dans l'équation 2.2.

$$MSE = \sum_{n=1}^N \frac{(h_m^n - h_o^n)^2}{N} \quad (2.3)$$

En traçant une fonction de coût théorique sur un graphique (erreur en fonction de la complexité du modèle), il est possible d'obtenir la courbe théorique orange pour l'ensemble de validation et la courbe théorique bleue pour l'ensemble d'entraînement sur la Figure 2.2.




Figure 2.2 Compromis biais-variance

Plus on augmente la complexité du modèle, plus l'erreur d'entraînement diminue. En effet, le modèle s'ajuste de plus en plus aux données ce qui réduit l'écart entre les valeurs prédites et les valeurs connues. Cependant, la courbe de l'erreur de validation suit une parabole. Le point le plus bas de la courbe correspond à la complexité idéale du modèle (flèche rouge dans la Figure 2.2). Si la complexité est trop faible, alors le modèle n'arrive pas à trouver la relation entre les données, car il n'a pas la flexibilité nécessaire. C'est la zone de sous-apprentissage (biais) et l'erreur est élevée. Au contraire, quand la complexité est trop élevée, le modèle « colle » trop aux données, c'est la zone de sur-apprentissage (variance), et l'erreur est aussi élevée. Ce phénomène est visible sur la Figure 2.3 où un jeu de données qui semble suivre une tendance quadratique est présenté. Trois polynômes de complexité croissante ont été ajustés aux données. Il s'agit d'un polynôme de degré 1, d'un polynôme de degré 2 et d'un polynôme de degré 6. Alors que le polynôme de degré 1 n'arrive pas à capturer la tendance des données (sous-apprentissage), le polynôme de degré 6 sur-

apprend (présence d'oscillations). Le polynôme de degré 2, quant à lui, représente le parfait compromis biais-variance, soit la complexité optimale (flèche rouge dans la Figure 2.2).

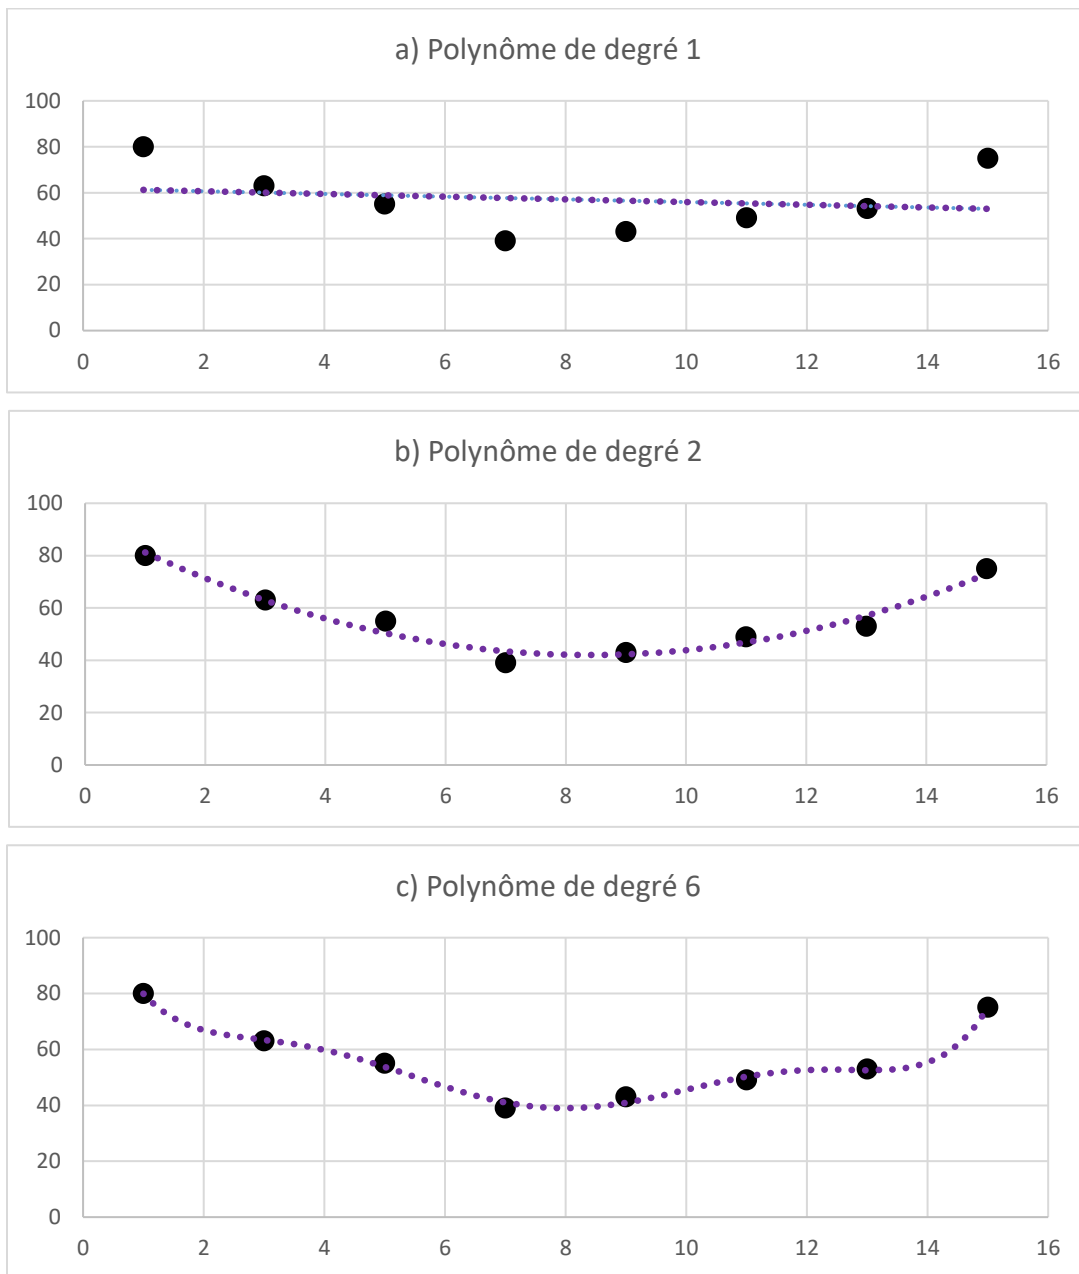


Figure 2.3 Ensemble de données suivant une tendance quadratique avec une régression de degré 1 (a), de degré 2 (b) et de degré 6 (c)

2.3.2 Machines à vecteur de support

Les machines à vecteurs de support (MVS) sont des algorithmes populaires dans les problèmes de classification et de régression (Bishop, 2006). C'est en 1995 que Cortes et Vapnik ont développé

ce nouveau type d'AA, d'abord utilisé pour des problèmes de classification à deux groupes (Cortes & Vapnik, 1995). Le principe est le suivant : il faut trouver une droite dans un espace 1D (ou un hyper-plan lorsqu'on est dans un espace à haute dimension), qui puisse séparer les points appartenant à des classes différentes avec la plus grande marge possible (Bayat & Tavakkoli, 2022). La marge est définie comme étant la distance perpendiculaire entre la frontière de décision et les points les plus proches, peu importe la classe. La marge est la même de chaque côté de la frontière. Elle peut être souple si quelques données d'entraînement peuvent être mal classifiées ou rigide si aucune violation de la marge n'est autorisée. La régression à vecteurs de support (RVS) est une technique dérivée des MVS (Bishop, 2006). Dans le cas où les données ne suivent pas une distribution linéaire, il faut projeter, à l'aide d'une fonction non-linéaire, les données sur un espace à haute dimension, appelé espace transformé. Ensuite, il est possible de réaliser une régression linéaire avec l'algorithme RVS sur ce nouvel espace (Raghavendra. N & Deka, 2014; Yu et al., 2006). La Figure 2.4 illustre l'algorithme de MVS.




Figure 2.4 Machine à vecteurs de support, par Alisneaky et Zirguezzi, 2011, Wikimedia Commons (https://commons.wikimedia.org/wiki/File:Kernel_Machine.svg). CC BY-SA.

Dans la Figure 2.4, il y a deux classes de données; les points blancs et les points noirs. Les lignes pointillées représentent les marges et la ligne rouge la frontière de décision. La fonction ϕ permet le passage d'un espace non-linéaire (à gauche) à un espace linéaire à haute dimension (à droite). Les vecteurs de support sont les points situés sur les lignes pointillées.

Plusieurs auteurs ont utilisé les MVS pour faire de la classification dans le domaine de la prédiction des crues (Madhuri et al. (2021) et Talukdar et al. (2021)) alors que d'autres (Jang et al. (2022) et Kabir et al. (2020), à titre de méthode comparative dans ce dernier cas) ont plutôt utilisé la RVS.

2.3.3 Arbres de décision

Les modèles basés sur les arbres de décision sont faciles à interpréter et permettent une prédiction rapide (Bayat & Tavakkoli, 2022). Les modèles partitionnent l'espace des prédicteurs en régions rectangulaires où les arrêtes sont parallèles aux axes (Bishop, 2006). L'objectif est que les données ayant une valeur cible similaire soient groupées dans une même section de l'espace. À chaque itération une séparation est créée sur un prédicteur avec un seuil associé. En minimisant une fonction de coût, comme l'entropie, il est possible de déterminer si la séparation est optimale. Les arbres sont autant utiles pour faire de la classification que pour faire de la régression (Karim et al., 2023). Un exemple d'arbre avec son illustration correspondante de la segmentation de l'espace des prédicteurs \mathbf{x} (dans ce cas x_1 et x_2) est présenté à la Figure 2.5.




Figure 2.5 Exemple d'arbre (à droite) avec son illustration correspondante de la segmentation de l'espace des prédicteurs \mathbf{x} (à gauche)

Comme les arbres sont vulnérables au sur-apprentissage et ne sont pas capable de bien généraliser (c'est-à-dire qu'un petit changement dans les données peut provoquer un grand changement dans le résultat final), des méthodes d'ensemble combinant plusieurs arbres de décision ont été créés (*bagging*, *boosting* et forêts aléatoires) (Bayat & Tavakkoli, 2022; James et al., 2021). Le *bagging*, ou *bootstrap aggregation*, consiste à créer un arbre de décision pour chacun des B échantillons *bootstrap* (B tirages aléatoires avec remplacement) qui agissent comme des ensembles d'entraînement. Avec cette méthode, il est facile d'estimer l'erreur de généralisation sans avoir à

utiliser la validation croisée. En effet, en moyenne, chaque arbre n'utilise que deux tiers des n données. Il y a donc $n/3$ données qui ne sont pas utilisées pour ajuster l'arbre, c'est ce qu'on appelle des observations *out-of-bag* (*OOB*). Pour trouver la prédiction relative à l'observation i , on calcule un vote de majorité sur tous les arbres où la donnée i est OOB (c'est-à-dire qu'elle est non utilisée). En répétant cette étape pour les n observations, il est possible d'estimer l'erreur de généralisation. Quand le nombre d'arbres B est suffisamment élevé, l'erreur est équivalente à celle qui aurait été calculée avec une validation croisée. Dans le cas de la régression, on calcule la moyenne des résultats prédits. Le *bagging* permet de réduire la variance. Les forêts aléatoires fonctionnent selon le même principe que le *bagging* à l'exception qu'à chaque nœud on ne considère qu'un sous-ensemble aléatoire de prédictors ($m \approx \sqrt{p}$). Cela permet de décorréliser les arbres et ainsi réduire la variance du *bagging*. Avec le *boosting*, les ensembles d'arbres ne sont plus construits de manière indépendante, mais de manière séquentielle. Pour chaque nouvel arbre, un poids est assigné à chaque observation dépendamment de la performance des arbres précédents. En effet, un poids plus grand sera accordé aux données mal classifiées précédemment. Lors du vote de majorité, un plus grand poids est accordé aux classifieurs donnant les résultats les plus justes.

Hosseiny et al. (2020) utilisent une forêt aléatoire de 50 arbres pour identifier les nœuds inondés et les nœuds secs d'un domaine de calcul dans le cadre de la prédiction des crues. Hou et al. (2021) combinent l'algorithme de la forêt aléatoire avec l'algorithme des K plus proches voisins (KNN) pour calculer des hauteurs d'eau. La méthode de boosting a été utilisée par Madhuri et al. (2021) (AdaBoost et XGBoost), par Ma et al. (2021) (XGBoost) et par Costache et al. (2020) (TreeNet Gradient Boosting Machine) pour classifier les régions de leur cas d'étude. Selon la probabilité d'inondation associée à chaque région, un niveau de risque situé entre très faible et très élevé (entre faible et élevé pour Madhuri et al. (2021)) y est associé.

2.3.4 Réseaux de neurones artificiels

L'invention des réseaux de neurones artificiels (RNA), qui remonte aussi loin que 1943, avait pour but premier de tenter d'imiter les processus biologiques du cerveau humain (Bishop, 2006). Si aujourd'hui la plausibilité biologique des RNA est questionnable (Macpherson et al., 2021), ils sont néanmoins très efficaces pour faire des prédictions dans de nombreux domaines. Il existe de nombreux types de réseaux de neurones différents. Les plus utilisés dans le cadre de la prédiction des crues seront décrits dans cette section.

Le type le plus simple de RNA est le réseau de neurones à propagation avant (RNPA), parfois appelé perceptron multicouche. Ce dernier terme est à éviter puisque dans un RNPA les fonctions d'activation non-linéaires sont continues alors que dans un perceptron multicouche elles sont discontinues (Bishop, 2006). Une illustration de RNPA est présentée à la Figure 2.6.

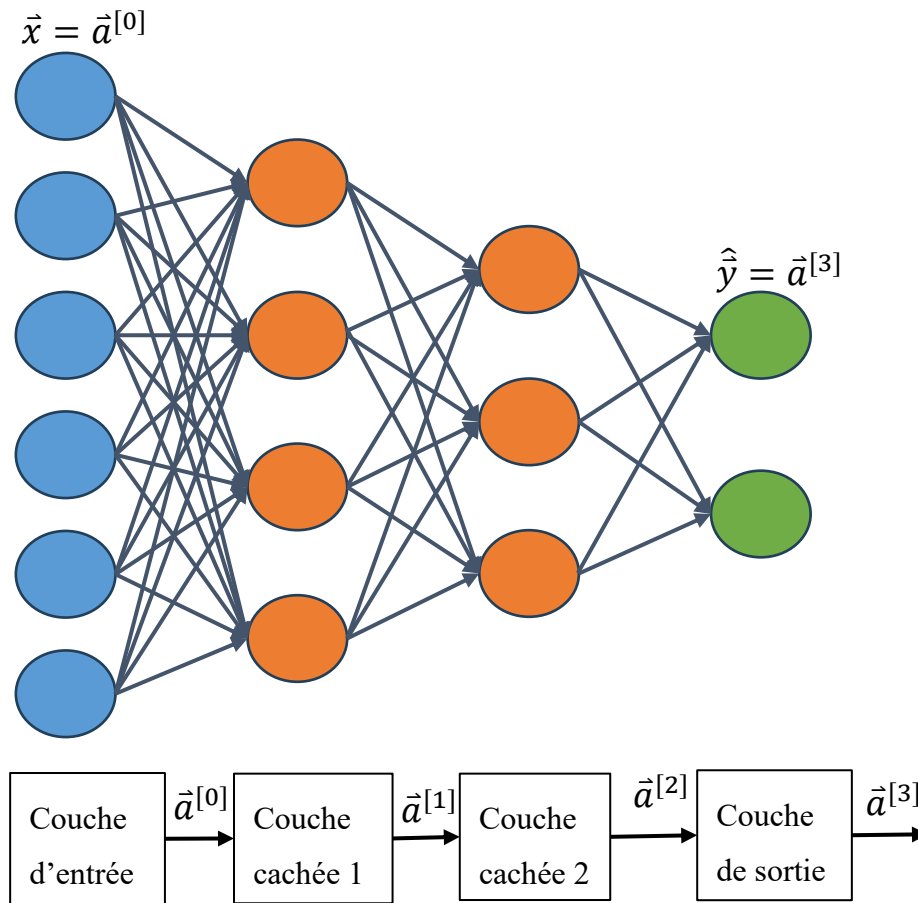


Figure 2.6 Architecture d'un réseau de neurones à propagation avant (RNPA)

Dans la Figure 2.6, les cercles de couleurs représentent les neurones. Les lignes reliant ces cercles représentent les paramètres (poids) \mathbf{w} ($\mathbf{w} = \mathbf{w}^{[1]}, \mathbf{w}^{[2]}, \dots, \mathbf{w}^{[l]}, \dots$). Les flèches indiquent la direction du flux d'information. Comme son nom l'indique, un RNPA déplace l'information d'une couche vers la suivante, de la couche d'entrée \mathbf{x} (couche bleue) à la couche de sortie $\hat{\mathbf{y}}$ (couche verte) en passant par les couches cachées (couches orange). Chaque couche, sauf la couche d'entrée, a un intrant $\mathbf{a}^{[l-1]}$ et un extrant $\mathbf{a}^{[l]}$ où l représente le numéro de la couche depuis la

première couche cachée et où $\mathbf{a}^{[l-1]}$ est une combinaison linéaire, voir équation 2.4. Comme cela est visible sur la Figure 2.6, un RNPA a des couches complètement connectées, c'est-à-dire que tous les neurones d'une couche $[l - 1]$ sont connectés à tous les neurones de la couche $[l]$.

$$\tilde{\mathbf{a}}^{[l]} = g(\mathbf{w}^{[l]} \cdot \tilde{\mathbf{a}}^{[l-1]} + \mathbf{b}^{[l]}) \quad (2.4)$$

Dans l'équation 2.4, g représente la fonction d'activation à utiliser. Cette fonction est parfois linéaire, comme à la couche de sortie. Cependant, il doit y avoir au moins une relation non-linéaire dans le RNA. En effet, si l'on utilisait des fonctions d'activation linéaires pour chaque couche cachée, cela reviendrait à une régression linéaire. Les fonctions d'activation les plus communes sont présentées dans le Tableau 2.1 (Dubey et al., 2022).

Tableau 2.1 Types de fonctions d'activation

Fonction d'activation	Équation
Linéaire	$g(x) = x$
ReLU	$g(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$
Sigmoïde	$g(x) = \frac{1}{1 + e^{-x}}$
Tangente hyperbolique	$g(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
Tangente-Sigmoïde hyperbolique (Hosseiny et al., 2020)	$g(x) = \frac{2}{1 + e^{-2x}} - 1$

Pour trouver les paramètres \mathbf{w} optimaux, durant la phase d'entraînement, on utilise l'optimisation par descente de gradient (Bishop, 2006).

Le deuxième type de RNA est le réseau de neurones récurrents (RNR). Contrairement aux RNPA, l'information ne voyage pas que dans un seul sens. Dans RNR, l'extrait d'une couche cachée est fonction de son entrée, ainsi que de son état au pas de temps précédent. La présence de ces

connexions de rétroactions aide le réseau à se souvenir des informations importantes du passé (Bayat & Tavakkoli, 2022).

Le troisième type de RNA est le réseau de neurones convolutifs (RNC) qui a d'abord été utilisé pour le traitement des données d'images et pour les problèmes de vision par ordinateur. Le principe est de combiner des couches de convolution avec des couches de sous-échantillonnage. Généralement, la dernière couche est une couche entièrement connectée (Bishop, 2006).

Les RNA ont été utilisés à de multiples reprises dans le domaine de la prédiction des crues. Par exemple, Hosseiny et al. (2020) utilisent un RNPA à quatre couches cachées composées de 150, 100, 50 et 30 neurones respectivement. Les données d'entrée représentent des débits alors que les données de sortie sont les profondeurs d'eau à chaque nœud inondé. Le gain de temps d'une simulation effectuée avec un RNA par rapport à un modèle basé sur la physique est considérable. Dans leur cas, la simulation avec le RNA n'a duré que 5 secondes alors qu'il a fallu 60 fois plus de temps pour réaliser la simulation avec le modèle iRIC qui est basé sur la physique (Hosseiny et al., 2020). Nevo et al. (2022) et Le et al. (2019), de leur côté, utilisent un type de RNR appelé LSTM (Long short-term memory) qui est particulièrement efficace à trouver les dépendances temporelles sur le long terme. Kabir et al. (2020) a développé un RNC, avec deux couches de convolution et trois couches entièrement connectées, qu'il a ensuite comparé à la RVS. En plus de présenter des erreurs de prédiction de profondeurs d'eau plus faibles que celles de la RVS, le RNC a l'avantage de pouvoir faire des prédictions sur des domaines de calcul contenant des centaines de milliers de cellules et peut être réentraîné aisément pour prendre en compte de futurs changements topographiques. Il est également possible de combiner les RNA avec d'autres algorithmes. Par exemple, dans le domaine de la prédiction des crues, Forghani et al. (2021) utilisent l'analyse par composantes principales (ACP) avant d'utiliser un RNPA pour prédire les vitesses d'eau. Le but de l'ACP est de réduire le nombre de dimensions des données. Pour ce faire, il faut les projeter sur un sous-espace linéaire qui maximise la variance des données projetées et qui minimise les erreurs de projection (Bishop, 2006). Toujours dans le même article, Forghani et al. (2021) combinent plusieurs RNA dans un même algorithme, soit un RNC, suivi d'un RNPA et finalement d'un autre RNC. Le premier RNC sert à réduire la dimension des données d'entrée tandis que le dernier sert à augmenter la dimension des données de sortie, les vitesses. C'est ce qu'on appelle un encodeur-décodeur supervisé.

2.4 Modèles hybrides

Pour l'instant, les modèles basés sur la physique et ceux basés l'AA ont été présentés séparément. Un désavantage majeur des modèles basés uniquement sur l'AA est le manque de signification physique dans les relations apprises. Pour pallier ce problème, il existe une catégorie de modèles qui combinent les deux catégories de modèles, il s'agit des modèles hybrides. Par exemple, plusieurs auteurs comme Subramaniam et al. (2020), Bode et al. (2021) et Feng et al. (2023) incluent les résidus des équations différentielles (par exemple l'équation de continuité) dans la fonction de coût traditionnelle d'un RNA. Ces modèles peuvent être qualifiés de PINN (*Physics-informed neural networks*). Une autre de ces techniques, nommée réduction d'échelle, est abordée dans la prochaine section.

2.4.1 Réduction d'échelle

La réduction d'échelle vise à obtenir des données de haute-résolution à partir des données de basse résolution. En d'autres mots, cela implique de réduire la taille des cellules de la grille (et en augmenter le nombre), comme cela est illustré à la Figure 2.7. L'objectif est d'avoir un résultat précis et exact tout en maintenant un coût de calcul abordable.




Figure 2.7 Représentation schématique de la réduction d'échelle

Il existe deux approches de réduction d'échelle : la réduction d'échelle statistique et la réduction d'échelle dynamique. Dans le cadre de la réduction d'échelle dynamique, une simulation de modèle à haute résolution à échelle locale est effectuée avec les conditions frontières obtenues à partir des

modèles à grande échelle (Feng et al., 2023). Il s'agit d'une approche couramment utilisée dans la modélisation du climat qui est basée sur les équations de la physique (Fowler et al., 2007). Cependant, comme tout modèle basé sur la physique, le coût de calcul pour cette méthode de réduction d'échelle est élevé, d'où l'avantage d'utiliser la réduction d'échelle statistique (Fowler et al., 2007). Dans ce cas, une relation statistique entre le modèle à grande échelle et le modèle à échelle locale est créée (Feng et al., 2023). Cette relation peut prendre plusieurs formes, dont la régression linéaire et les RNA (Feng et al., 2023).

Si la réduction d'échelle statistique est utilisée dans le domaine de la modélisation climatique depuis de nombreuses années (Fowler et al., 2007; Höhle et al., 2020; Rampal et al., 2022), les applications dans le domaine de la prédiction des crues restent limitées. Dans le cas de Rampal et al. (2022), les RNA créés ont pour but de trouver la précipitation moyenne et extrême sur une région néozélandaise. La taille de maillage de départ est de 50 km par 50 km alors que la taille de maillage à la sortie des RNA est de 5 km par 5 km. Höhle et al. (2020) ont voulu faire une réduction d'échelle pour le champ des vents en Europe en utilisant divers types de RNA, dont des modèles linéaires et de RNC. Des détails supplémentaires sont fournis dans le Tableau 2.2.

L'utilisation des RNA pour la réduction d'échelle dans la prédiction des crues a notamment été faite par Carreau et al. (2021), Carreau et al. (2023) et Feng et al. (2023). Dans le premier article, les chercheurs proposent deux modèles de réduction d'échelle. Le premier modèle consiste à d'abord appliquer l'ACP sur les données à basse résolution afin de réduire le nombre de dimensions. Ensuite, ils utilisent autant de RNPA qu'il y a de cellules haute résolution pour estimer les indicateurs de crue (profondeurs d'eau et débits unitaires). Le second modèle consiste à appliquer l'ACP à la fois sur les données à basse résolution et sur les données à haute résolution. Ensuite, un unique RNPA est construit de façon à trouver la relation entre les deux ensembles à dimensions réduites par l'ACP. Finalement, la projection de l'ACP est inversée pour trouver les indicateurs de crue à haute résolution (Carreau & Guinot, 2021). Dans le second article, les auteurs utilisent la méthode des ondelettes discrètes (Carreau & Naveau, 2023). Dans le troisième article, ce sont des PINN qui sont utilisés pour passer d'une résolution grossière à une résolution fine. Ils résolvent les équations aux dérivées partielles en utilisant des architectures de RNPA tout en étant contraints de respecter les lois physiques correspondantes (Raissi et al., 2019). Les solutions inconnues des équations gouvernantes sont déduites des conditions initiales, des conditions

frontières des variables d'état (hauteurs d'eau et vitesses) et des résidus des équations gouvernantes (Feng et al., 2023).

Dans ces trois articles, ce sont des données géométriques synthétiques qui sont utilisées. Lorsque des géométries réelles sont utilisées, par exemple des données sur la géométrie d'un quartier de la ville de Sacramento, elles ne présentent pas de dénivelés (Carreau & Guinot, 2021; Carreau & Naveau, 2023). De plus, les modèles d'AA traitent les variables d'écoulement (hauteurs d'eau, vitesses, débits) séparément (Carreau & Guinot, 2021; Carreau & Naveau, 2023).

2.5 Objectifs

Le but de ce mémoire est de proposer une nouvelle approche de réduction d'échelle statistique pour la prédiction des crues basée sur les RNA. Par rapport aux travaux réalisés précédemment, deux innovations seront explorées simultanément, soit l'utilisation d'une topographie réelle qui présente des élévations variables ainsi que la prédiction de différentes variables d'écoulement conjointement dans un même modèle d'AA. Ensuite, il sera nécessaire de déterminer si la performance du modèle d'AA est sensible à la résolution d'entrée (facteur d'échelle).

Tableau 2.2 Articles traitant de la réduction d'échelle

Article	Objectif	Taille de la couche d'entrée	Taille de la couche de sortie	Types de RNA	Nombre de paramètres	Autres informations
Rampal et al. (2022)	Réduction d'échelle de la précipitation moyenne et extrême sur la région de la Nouvelle-Zélande	50km x 50km 96 pixels x 64 pixels 1 à 6 couches d'entrée (différentes combinaisons sont utilisées)	5km x 5km 960 pixels x 640 pixels 3 couches de sortie (probabilité de pluie et les paramètres d'échelle et de forme de la distribution de gamma)	Non-Linear CNN (Gamma) Linear CNN Non-Linear Gamma Linear Gamma Linear Dense	4.85 millions à 16.72 millions de paramètres dépendant du modèle	Dropout regularisation (rate=0.6) Adam optimizer (initial rate= 10^{-4}) Taille de batch = 50 jours Nombre de epochs = 40 to 60 Fonction de coût = Bernoulli-Gamma ou MSE Temps pour entrainer = 2–4 min sur un serveur NVIDIA Tesla P100

Tableau 2.2 Articles traitant de la réduction d'échelle (suite)

Article	Objectif	Taille de la couche d'entrée	Taille de la couche de sortie	Types de RNA	Nombre de paramètres	Autres informations
Höhlein et al. (2020)	Réduction d'échelle des champs de vent en Europe	1918 points 36 x 60 2 couches: U (vent meridional) V (vent zonal)	20416 points 144 x 180 2 couches: U (vent meridional) V (vent zonal)	Linear-CNN DeepRU FSRCNN EnhanceNet DeepSD LinearEnsemble	68.9k pour linear CNN 37.11 millions pour DeepRU 3.31 millions pour LinearEnsemble	Dropout regularisation (rate=0.1) for DeepRU Weight decay = 10^{-4} Taille de batch = 220 Fonction de coût = MSE Temps pour entrainer =0.7h (Linear-CNN), 13.5h (DeepRU), 25.8h (Linear Ensemble) sur un serveurur NVIDIA TITAN RTX GPU avec 24 GB de mémoire vidéo

CHAPITRE 3 MÉTHODOLOGIE

Ce chapitre présente la méthodologie de ce mémoire. Il y a trois grandes étapes dans la méthodologie.

3.1 Étape 1

Trois types de RNA sont testés pour la méthode de réduction d'échelle développée dans ce mémoire. Le premier type est un RNPA avec une seule couche cachée et une fonction d'activation linéaire. Il s'agit du modèle le plus simple des trois. Le deuxième type est un RNC appelé Encodeur-Décodeur. Le troisième type est un modèle de type U-Net, soit un Encodeur-Décodeur qui contient des « skip connections » qui aident à l'apprentissage du modèle.

Le cas d'étude choisi est un cas artificiel de confluence à 90° de deux canaux rectilignes. Ce cas d'étude a été choisi, car il ne requiert pas de données. De plus, contrairement à un cas artificiel d'un seul canal, la rencontre de deux canaux permet de rajouter de la complexité dans le modèle, notamment à cause de la présence de recirculation.

Deux scénarios d'écoulement sont simulés. Les données obtenues (hauteur d'eau et vitesses dans les directions X et Y) sont combinées. Un ensemble de données d'entraînement (80% des données) et un ensemble de données de validation (20% des données) sont créés de manière aléatoire afin de capturer une grande diversité de pas de temps dans chaque ensemble de données. Il s'agit d'une répartition ensemble d'entraînement/ensemble de validation typique dans le domaine de l'AA (Géron, 2019). Les trois modèles sont testés avec les mêmes ensembles de données et le meilleur modèle, le modèle de type U-Net sera utilisé dans les étapes 2 et 3. Les résultats sont présentés dans le chapitre 4.

3.2 Étape 2

À l'étape 1, le modèle de type U-Net a prouvé qu'il arrivait à bien à reproduire les résultats de la haute résolution à partir des données de basse résolution. Cependant, puisque le cas d'étude de l'étape 1 était un cas artificiel, il est nécessaire de valider la méthode de réduction d'échelle sur un cas d'étude réel. Le cas d'étude choisi est une portion du fleuve St-Laurent de 437,52 km² autour de l'île d'Orléans située près de Québec. Pour ce cas d'étude, les données du client (ECCC) sont

utilisées. Le modèle de type U-Net a été validé pour un cas réel. Les résultats sont présentés dans le chapitre 4.

3.3 Étape 3

Dans les étapes 1 et 2, les réductions d'échelle n'ont utilisé qu'une seule résolution d'entrée (basse résolution) et une seule résolution de sortie (haute résolution). Or, plus la résolution d'entrée est faible, moins il y a d'information disponible ce qui peut influencer la reconstruction de la haute résolution. Avec un nouveau cas d'étude réel, un segment de la rivière Athabasca en Alberta, on souhaite évaluer l'effet du facteur d'échelle (c'est-à-dire le facteur entre la basse résolution et la haute résolution) sur les résultats. Il y aura également une étude sur la comparaison de temps de calcul entre les modèles basés sur la physique et les modèles hybrides effectuant la réduction d'échelle. Les résultats sont présentés dans le chapitre 5.

CHAPITRE 4 ARTICLE 1: EVALUATION OF ML TECHNIQUES FOR DOWNSCALING HYDRODYNAMIC SIMULATIONS

Soumis le 13/02/2024 dans River Flow 2024 par CRC Press/Balkema, Taylor and Francis Group

N. Stache, A. Shakibaeinia, J. Carreau

Polytechnique Montréal, Montréal, Québec, Canada

P. Matte

Environment and Climate Change Canada, Québec, Québec, Canada

ABSTRACT: The accurate representation of fluvial hydrodynamic characteristics, including water depth, and velocity field, is crucial for many hydro-environmental, geomorphological, and engineering applications. Traditionally, the hydrodynamic characteristics are determined using a 2D physics-based model that solves the shallow-water equations. However, employing these physics-based models for fine resolution simulations on large domains is often impractical due to the high computational cost. Consequently, spatial resolution often needs to be reduced to enable simulations. In this paper, we introduce and compare three Machine Learning (ML) approaches for downscaling: a linear dense model, as well as two deep neural networks (DNN) with convolution layers and fully connected layers. The objective is to enhance the spatial resolution of hydrodynamic models while maintaining reasonable computational efficiency and high precision. To evaluate and compare the different neural networks, a synthetic test case, the confluence of two synthetic channels, will be used. The results showcase that a DNN, the U-Net style, gives the best results due to the powerful convolutional layers, the non-linear activation function and skip connections. Then, we used a similar U-Net model to enhance the spatial resolution of a real-world riverine system in the St. Lawrence River, Canada. In conclusion, we will identify the strengths and weaknesses of existing architectures in different hydrodynamic contexts. This can pave the way for the development of an architecture specific to hydrodynamic phenomena.

4.1 Introduction

Hydrodynamic models are indispensable tools for many engineering applications such as ocean and coastal engineering (Xie et al., 2022) or flood inundation modelling (Teng et al., 2017). In all

of the cases, the objective is to replicate fluid motion. The widely used approach for hydrodynamic simulations is the use of models that solve the two-dimensional (2D) shallow water equations (SWE) (Bomers & Hulscher, 2023; Carreau & Guinot, 2021; Teng et al., 2017). The solutions obtained by solving these equations are the water depth and the horizontal (streamwise and lateral) velocity components over space and time. Many numerical methods, based on techniques such as finite element, finite difference, and finite volume methods, have been developed to provide numerical solutions to SWE (Teng et al., 2017). The main issue with these so-called physics-based numerical models is their expensive computational cost (Carreau & Guinot, 2021), especially when large spatial or temporal scales simulation in high-resolution is needed (Teng et al., 2017). For example, Xia et al. (2019) simulated a 96-hour flood event on a 2500 km² catchment with a high-performance modelling framework called HiPIMS. For a 5 meters resolution, the simulation took 37.5 hours to run as opposed to 0.15 hours to run for the 40 meters resolution. However, reducing the resolution might not be appropriate in many cases, such as in urban areas where fine resolution is required. Indeed, the high population density in urban areas, coupled with complex road geometries and buildings, can lead to overestimation or underestimation of flow rates, potentially resulting in loss of life and property damage (Kim et al., 2019).

A solution to the high computational cost is to develop a downscaling method, where we increase (refine) the resolution of the results from a low-resolution physics-based simulation. There are two types of downscaling: dynamic downscaling and statistical downscaling. Downscaling was initially developed for climate studies. In the first case, large-scale model output and lateral boundary conditions are used to produce high-resolution results. This method solves the physics equations within each sub-grid and therefore requires high computational resources (Fowler et al., 2007; Tang et al., 2016). The second method, less computationally expensive, builds statistical relationships between large-scale models and high-resolution models (Feng et al., 2023; Tang et al., 2016). Machine learning (ML) approaches are a subgroup of statistical downscaling that has been widely studied in the last few years. For instance, different deep neural networks (DNN) models were used to downscale extreme rainfall (Rampal et al., 2022) and wind fields (Höhlein et al., 2020). Moreover, a combined Principal component analysis (PCA)-neural network approach was used to downscale flow (Carreau & Guinot, 2021). A physics-informed neural network was also used to downscale flow on six synthetic case studies (Feng et al., 2023).

In this paper, we will develop a downscaling approach within a hydraulic context, as most of the existing literature focuses on climate downscaling. More precisely, we will use a synthetic open channel to measure the feasibility of using DNN in a downscaling context. To handle the large size of both inputs and outputs, it will be necessary to decrease their dimensions using a dense layer. Subsequently, among the three developed architectures (nested from the simplest to the most complex), we will apply the architecture that gives the lowest reconstruction error to a real-world riverine system in the St-Lawrence River, Canada. The novelty of our approach is that all the three variables are downscaled together in the same architecture.

4.2 Models

This section will present: (i) the synthetic test case and the real case (St. Lawrence River), along with their respective numerical models, and (ii) the structure and specifications of each DNN. The synthetic test case is employed to develop and examine various DNN architectures, while the real case is presented to evaluate the chosen approach for addressing a real-world problem.

4.2.1 Test cases

The synthetic test case is composed of a 90° channel confluence and is chosen due to its complexity of horizontal flow features. Moreover, two different cross-sections were chosen to add complexity to our model. The dimensions of the channels (in meters) are indicated in Figure 4.1. The two blue lines represent upstream boundaries, while the red line corresponds to the downstream boundary. A constant Manning coefficient of 0.06 is used on the entire domain.




Figure 4.1 Representation of the synthetic hydrodynamic system

We decided to use HEC-RAS 2D for the hydrodynamic model since it is a widely used software for flood prediction (Teng et al., 2017). HEC-RAS is a software developed by the U.S. Army Corps of Engineers that solves the 2D SWE with an implicit finite volume method. To represent the synthetic system presented in Figure 3.1, we use 100 m² square cells (10 x 10 meters) for the low-resolution and 1 m² square cells (1 x 1 meter) for the high-resolution. In total, there are 283,800 cells in the high-resolution and 2838 cells in the low-resolution. For both resolutions, two synthetic flood events were simulated, called respectively Event 1 and Event 2. A total of 4 simulations are run and the denomination of each simulation is presented in Table 3.1.

Table 4.1 Event and resolution related to each simulation

Simulation	Event	Resolution
Simulation 1	Event 1	Low-resolution
Simulation 2	Event 1	High-resolution
Simulation 3	Event 2	Low-resolution
Simulation 4	Event 2	High-resolution

The upstream boundary conditions are fixed with the synthetic hydrographs presented on Figure 4.2. The downstream boundary condition considers the normal depth. The computational interval is set at 5 seconds, with results generated every minute (2041 timesteps).




Figure 4.2 Flow hydrographs for the upstream boundary conditions for Event 1 and Event 2.

For the real case, we consider a portion of the St-Lawrence River, a freshwater estuary with average tidal ranges of about 5 m (Matte et al., 2017a, 2017b). The study area, represented in Figure 3.3, is a subdomain of 437.52 km² around Orléans Island, near Quebec City.




Figure 4.3 St-Lawrence River Study Area (in blue).

Unlike the synthetic test case, the H2D2 finite element software developed at INRS-ETE (2020), which solves the SWE, is used for the real case. This physics-based model uses linear 6-node triangular elements (T6L), which are a combination of 4 identical 3-node linear triangular elements (T3). A linear approximation for water levels is implemented on the main triangle, whereas the approximation is linear on each T3 sub-triangle for specific discharges (Heniche et al., 2000). Two simulations were run: one low-resolution and one high-resolution simulations, each producing results in the study area over 15,137 and 166,443 nodes, respectively. The inputs of the model include the flows and water levels at the tributaries and upstream and downstream model boundaries. Additionally, the model considers wind velocities (x and y directions), the Manning coefficient and the ice cover for each node. The outputs are the specific discharge in the x-direction (q_x), the specific discharge in the y-direction (q_y) and the water level (WL) for each node at 3-minute intervals. The simulation period goes from December 21st, 2022 (7:00 AM) to December 28th, 2022 (1:00 PM) for a total of 3480 timesteps covering a storm surge event that led to the most extreme water levels ever observed in Quebec City, flooding the old port area. The data was produced by Environment and Climate Change Canada (ECCC).

4.2.2 Neural networks models

To form the datasets, we matched the high-resolution simulations together and the low-resolution simulations together. Also, all the three variables (u , v and h for the synthetic test case, and q_x , q_y and WL for the St-Lawrence River study case) are combined. The low-resolution data will be the inputs of our ML models. The size of the inputs is (2838, 3) for the synthetic test case and (15137, 3) for the St-Lawrence River study case where the first component is the number of cells/nodes and the second component is the number of variables. The high-resolution data will be the outputs of our architectures. The size of the outputs is (283800, 3) for the synthetic test case and (166443, 3) for the St-Lawrence River study case.

The first architecture used is a linear dense model. It consists of a feed-forward neural network with a single fully connected layer (dense layer). The single layer has 256 neurons, and the activation function is the linear function. The role of the single layer in this linear dense model is to reduce the dimensionality of the input (otherwise the number of parameters would be intractable). The second architecture consists of an encoder-decoder model, which comprises two primary components: the encoder and the decoder. The encoder is a sequence of convolution layers

and MaxPooling layers that transforms the low-resolution data into a latent space. Then, the decoder transforms the latent space into high-resolution output with UpSampling layers and transposed convolutional layers. For each convolutional or transposed convolutional layer, we assign a kernel size of 3, the activation function to tanh, the number of strides to 1, the padding to “same” and the kernel initializer to “He-normal”. Although other choices are possible, these choices are standard in the literature (Forghani et al., 2021). The last architecture is a U-Net. The U-Net model works similarly to an encoder-decoder, except that skip connections (Ronneberger et al., 2015) are added to the layers. A skip connection concatenates the output of a building block (combination of multiple layers) with the result of a deeper building block. All the architectures are presented in Figure 3.4. For the last two architectures, a dense layer is used before the network to reduce the dimensions of the inputs to 256. Similarly, a dense layer is present after the network to increase the dimensions to the output size. Indeed, the size of the data is so large that it is necessary to reduce the data size to maintain a reasonable number of parameters that can be processed by the computer. Furthermore, the data is not organized in a grid-like topology. Therefore, to apply convolutional layers, it is necessary to organize the data into a rectangle-shaped image, or square-shaped image in the case of this paper (16 x 16). In the two cases, the activation function is the linear function. Also, the use of dense layers before and after the networks is very useful because the architectures are not dependent on the input size. Thus, it is easy to use a similar architecture for our two study cases even if the input size is different. All the architectures are nested within each other with the linear one being the simplest, then the encoder-decoder and finally the U-Net. All the models were built using TensorFlow library and run on a NVIDIA Tesla P40 GPU. To compare the performance of our models, a baseline model, which increases the resolution by duplicating the values of low-resolution cells in the corresponding high-resolution cells, was used for the synthetic test case. We split randomly 80% of the data in a training set and the remaining data in a test set. We used the mean squared error (MSE) as the cost function on the training set while performance on the test set is measured with mean absolute error (MAE). The batch size is 72 and the number of epochs is 300. The gradient descent method used is the Adam optimization algorithm with a learning rate of 0.0001 (0.001 for the real case), a decay rate of 0.001, a β_1 value of 0.9 and a β_2 value of 0.99.

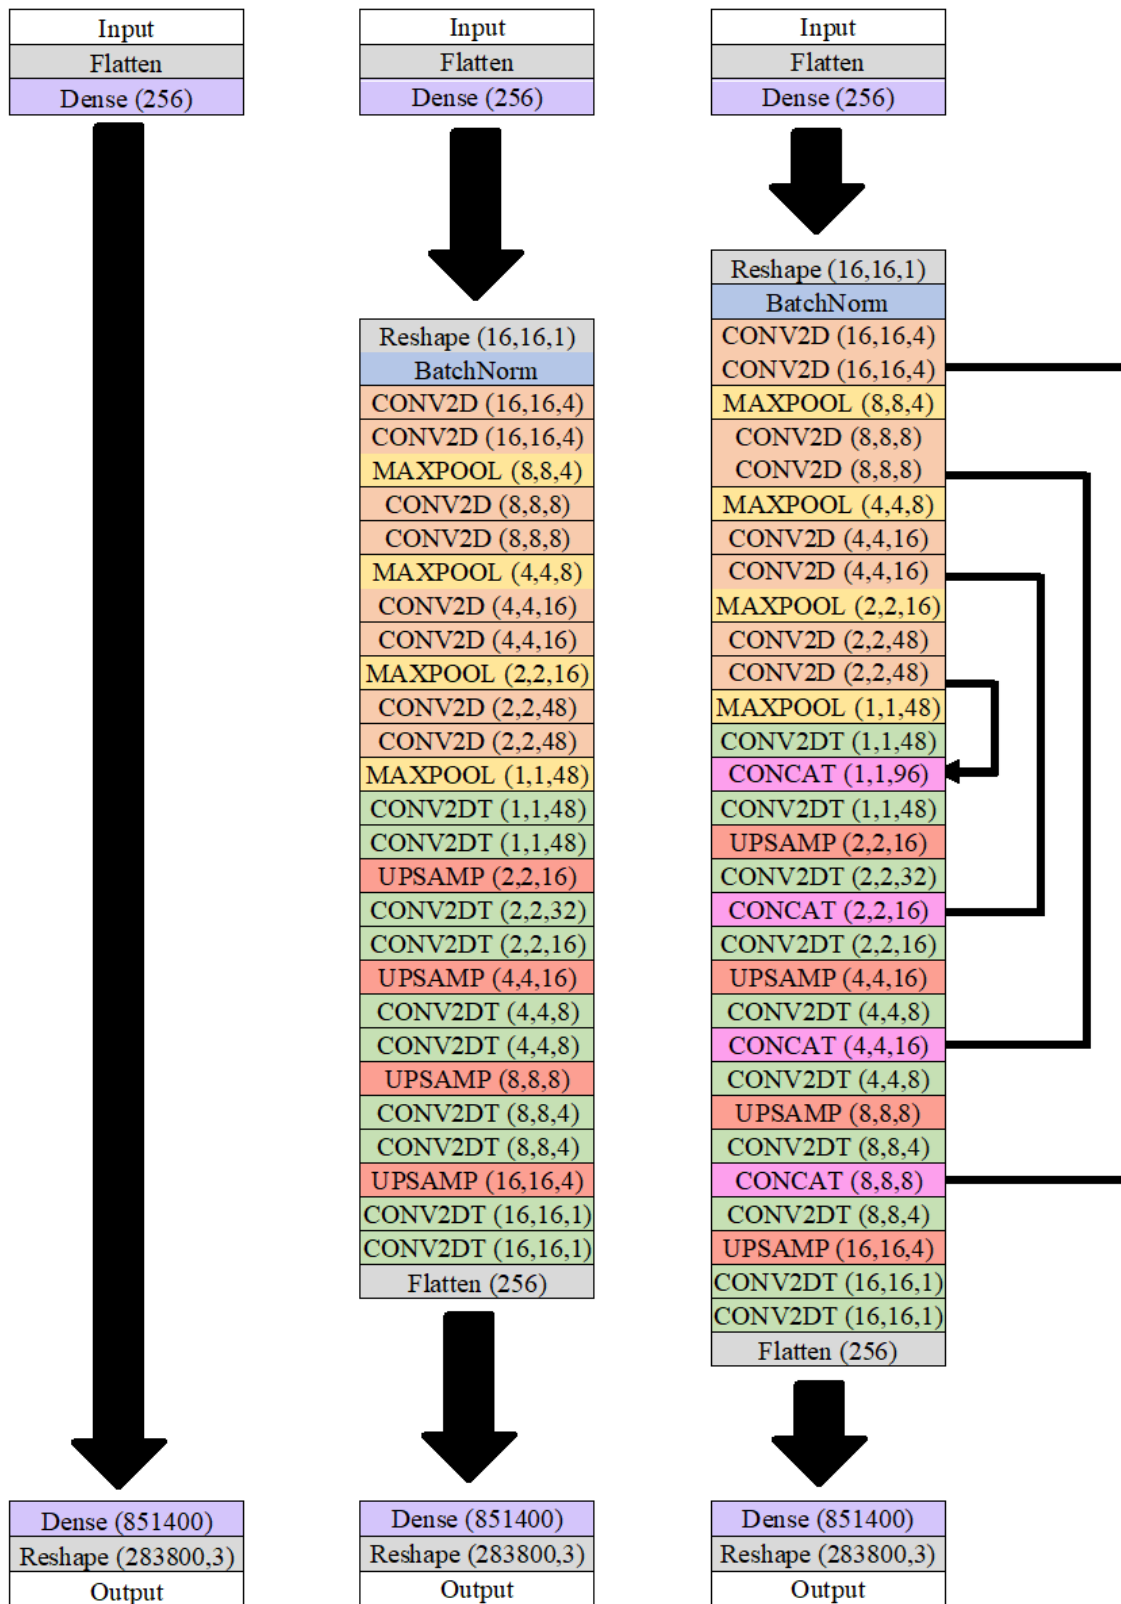


Figure 4.4 Neural Networks architectures for the synthetic test case. For the real case, the only changes are the shapes of the last Dense layer (499329) and the last Reshape layer (166443, 3).

4.3 Results and discussions

This section will present the results and discussions related to: (i) the synthetic test case; (ii) the St-Lawrence River case.

4.3.1 Synthetic test case

For each simulation, the minimal and the maximal values as well as the mean of h , u , and v are presented in Table 3.2. Considering all the simulations, h varies between 0 and 4.98 m, u varies between -0.89 and 2.86 m/s and v varies between -2.00 and 0.23 m/s. For Simulation 1 and Simulation 3 (low-resolution) the computation time is of 105 and 59 seconds respectively. For Simulation 2 and Simulation 4 (high-resolution), the computation time is of 3 and 2 hours respectively.

Table 4.2 Minimal, mean, and maximal values for the 4 simulations.

		Simulation 1	Simulation 2	Simulation 3	Simulation 4
Min	h (m)	0.00	0.00	0.00	0.00
	u (m/s)	-0.24	-0.89	-0.06	-0.53
	v (m/s)	-1.16	-1.98	-1.02	-2.00
Mean	h (m)	1.96	1.52	1.05	0.73
	u (m/s)	0.65	0.61	0.35	0.28
	v (m/s)	-0.10	-0.10	-0.08	-0.07
Max	h (m)	4.96	4.98	3.53	3.54
	u (m/s)	2.84	2.86	2.23	2.27
	v (m/s)	0.45	0.42	0.12	0.23

To compare the performance of our ML models and our baseline model, we will calculate the mean absolute error (MAE) for h , u , and v on the entire domain (on our test set), see Equation 3.1:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (3.1)$$

where n is the number of cells; Y_i = the value given by the physics-based model; and \hat{Y}_i = the value predicted by the ML model. The results are presented in Table 3.3.

Table 4.3 Performance of each model in terms of MAE.

Variable	Baseline	Linear Dense	Encoder-Decoder	U-Net
h (m)	0.38446	0.00529	0.00622	0.00453
u (m/s)	0.09107	0.00500	0.00615	0.00388
v (m/s)	0.01092	0.00159	0.00208	0.00181

As we can see in Table 3.3, all the models surpassed the baseline model. This is the expected behavior, as our baseline model has no parameters and only duplicates the values of low-resolution cells in the corresponding high-resolution cells. The model that gives the lowest errors is the U-Net with a MAE of 0.00453, 0.00388 and 0.00181 for h , u , and v respectively. Even if the number of parameters is similar in all the models (around 221M parameters for each model), the presence of a non-linear activation function and the skip connections helps the model to learn the non-linearity present in the SWE. For the three ML architectures, the training time is around 50 minutes. In order to evaluate the performance of the four models on a local scale, we calculated and compared the velocity norm at the time step $t = 8.9$ hours after the beginning of Event 1. The results are presented in Figure 3.5.

4.3.2 St-Lawrence River case

For both resolutions (high and low), minimal, maximal, and mean values are presented in Table 3.4. Considering both resolutions, q_x varies between -137.51 and 122.16 m²/s, q_y varies between -106.97 and 104.80 m²/s and WL varies between -8.01 and 8.30 m.




Figure 4.5 Zoom on the 90° channel confluence. Velocity norm for the four models, the low-resolution and the ground truth at $t = 8.9h$.

Table 4.4 Minimal, mean, and maximal values for both resolutions.

Resolution		Min	Mean	Max
Low-resolution	q_x (m ² /s)	-72.911	1.24	122.16
	q_y (m ² /s)	-102.76	1.00	95.22
	WL (m)	-5.34	0.75	6.438
High-resolution	q_x (m ² /s)	-137.51	1.08	75.29
	q_y (m ² /s)	-106.97	0.52	104.80
	WL (m)	-8.01	0.97	8.30

Since we prove the strong performance of the U-Net model, we will use it to downscale St-Lawrence River low-resolution data. Since the input size isn't the same, the number of parameters is different. In this case, the number of parameters is 140M. In the same way as we did in the previous section, we calculated the MAE on all nodes (on the test set) for the three variables. For q_x , q_y and WL , the MAE is equal to 0.06320, 0.05549 and 0.03788 respectively. The training time is 29 minutes. To evaluate the performance of the U-Net across a spatial scale, we calculated the specific discharge norm (q_{norm}) for a specific time step (December 24th, 2022, 9:00 AM). The results are presented in Figure 3.6.

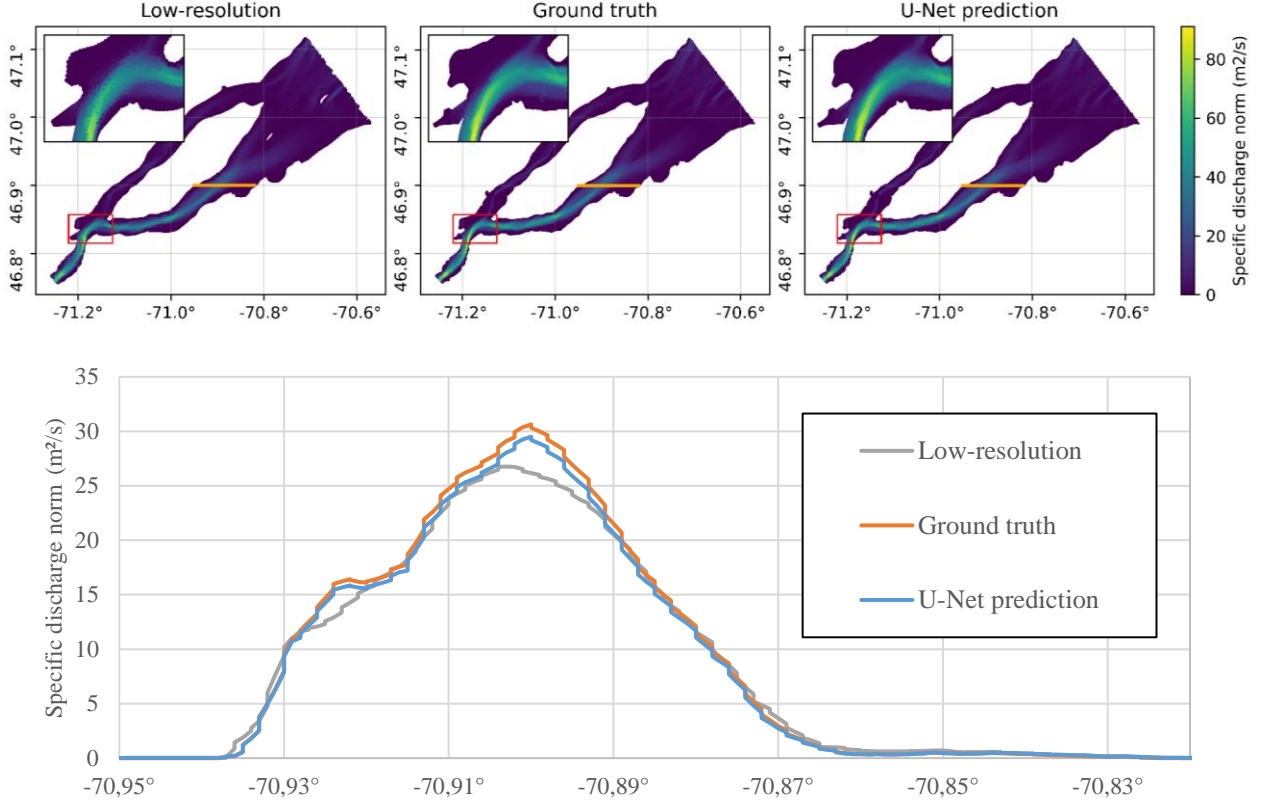


Figure 4.6 q_{norm} for the U-Net, the low-resolution and the ground truth at $t = \text{December 24th, 2022, 9:00 AM}$. The graph under the three subplots shows q_{norm} for the cross-section (orange line)

The cross-section graph represented in Figure 3.6 shows that q_{norm} values increase when the resolution is higher. The U-Net is capable of faithfully representing high-resolution simulation.

4.4 Conclusion

In conclusion, this paper addresses the common challenge of computational cost, particularly in expansive study areas with fine resolution requirements by presenting a novel downscaling method based on ML. Using a synthetic open channel as a testing ground with two flood events, we assess the feasibility of employing DNN architectures in a downscaling context. The innovation in our approach lies in the simultaneous downscaling of all three variables—water depth (h), velocity in the x -direction (u), and velocity in the y -direction (v)—within the same architecture. For our synthetic case test, we prove that the best DNN algorithm is the U-Net that includes non-linear functions, convolutional layers and skip connections. The MAE is 0.00453, 0.00388 and 0.00181

for h , u , and v respectively. Should our approach prove successful, its application could extend to real-world riverine systems, offering a scalable and efficient solution to the computational challenges associated with hydrodynamic modeling. For instance, a similar U-Net was used to downscale St-Lawrence River simulations. The MAE is 0.06320, 0.05549 and 0.03788 for the specific discharge in the x-direction (q_x), the specific discharge in the y-direction (q_y), and the water level (WL) respectively. For future work, we will explore even more complex ML algorithms such as physics-informed neural networks (PINN) or 3D convolutional neural network to achieve a better precision and accuracy on our predictions.

4.5 Acknowledgements

We gratefully acknowledge the financial support provided by the Environment and Climate Change Canada (ECCC) for this research.

CHAPITRE 5 EFFET DU FACTEUR D'ÉCHELLE: ÉTUDE SUR LA RIVIÈRE ATHABASCA

Jusqu'à présent, seule une résolution d'entrée (basse résolution) et une résolution de sortie (haute résolution) ont été considérées dans les RNA. Ce chapitre vise à tester différentes basses résolutions d'entrée afin de déterminer si le facteur d'échelle a une importance dans la reconstruction des données de haute résolution. Pour atteindre cet objectif, un nouveau cas d'étude, celui de la rivière Athabasca située en Alberta, est utilisé. Plusieurs simulations de résolutions différentes seront simulées sur le logiciel Delft3D. Ensuite, le RNA utilisé, le modèle de type U-Net, doit reconstruire la haute-résolution à partir de différentes basses résolutions. Or, plus la résolution de départ est faible, plus de l'information risque d'être perdue, d'où l'intérêt de déterminer s'il existe un facteur minimal requis pour obtenir une reconstruction juste.

5.1 Présentation du cas d'étude

Dans ce chapitre, un tronçon d'environ 57 km de la rivière Athabasca (Alberta, Canada), voir Figure 5.1, sera utilisé à titre de cas d'étude.

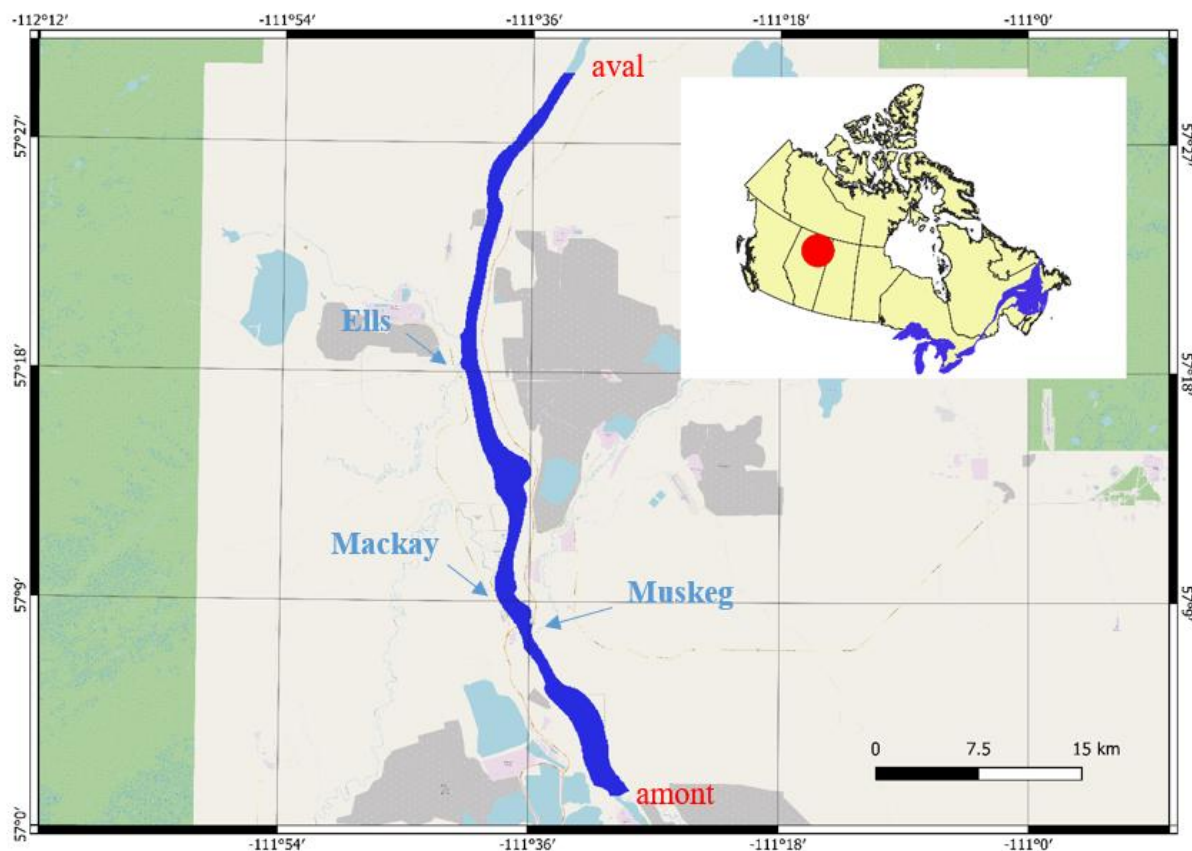


Figure 5.1 Cas d'étude de la rivière Athabasca

En plus de la condition frontière en amont (débits représentés à la Figure 5.2) et de la condition frontière en aval (niveaux d'eau représentés à la Figure 5.3), il faut également considérer les conditions frontières (débits représentés à la Figure 5.4) provenant des trois tributaires suivants : Muskeg, Mackay et Ells. La période de simulation va du 1^{er} septembre 2004 au 30 septembre 2004 et les données sont journalières.




Figure 5.2 Débits à l'amont




Figure 5.3 Niveaux d'eau à l'aval




Figure 5.4 Débits des tributaires

5.2 Modèles

Dans cette section, sont détaillées les caractéristiques du modèle physique ainsi que celles du modèle basé sur l'AA.

5.2.1 Modèle physique

Afin de construire le modèle physique de la rivière Athabasca, le logiciel libre Delft3D développé par Deltares est utilisé. Plus précisément, le module FLOW permettant de faire des simulations hydrodynamiques en 2D est utilisé. Delft3D-FLOW résout les équations de Navier-Stokes en considérant les hypothèses de Saint-Venant et de Boussineq. Comme méthode numérique, Delft3D-FLOW utilise une MDF (Deltares, 2024a).

Pour exécuter une simulation sur Delft3D-FLOW, il faut les fichiers suivants :

- Le fichier de maillage. Dans ce fichier d'extension « .grid », il faut définir le type de cellules souhaitées, des cellules carrées pour ce cas d'étude, et ensuite tracer le maillage en fonction de la localisation des plaines inondables. C'est l'outil RGFGRID qui a été utilisé ici. Un fichier portant l'extension « .enc » est également créé en même temps (Deltares, 2024c).
- Le fichier de bathymétrie appliquée aux cellules (depth). À partir d'une bathymétrie existante de format « .xyz » et du fichier de maillage de format « .grid » créé précédemment, il est possible de créer le fichier de bathymétrie appliquée aux cellules

(*depth*) d'extension « .dep. ». C'est l'outil QUICKIN qui a été utilisé ici. Grâce à la fonction *Triangular Interpolation* (qui est la meilleure méthode pour des données de bathymétrie dont la résolution est égale ou plus faible que la résolution du maillage), il est possible d'attribuer une valeur unique de bathymétrie à chaque cellule. Puis, grâce à la fonction *Internal Diffusion*, il est possible d'attribuer une valeur de bathymétrie aux cellules vides (là où la *Triangular Interpolation* n'a pas fonctionné). Finalement, il est nécessaire de multiplier toutes les valeurs de bathymétrie par -1 avec la fonction *Multiply Depth with Uniform Value*, car les valeurs du fichier « .dep » doivent être négatives (Deltares, 2024b).

- Le fichier de simulation. Ce fichier portant l'extension « .mdf » contient les différents paramètres numériques (coefficient de Manning, dates de simulations, pas de temps de calcul, pas de temps de sortie des résultats, les processus physiques à considérer, etc.) De plus, on y retrouve les liens vers les fichiers de format « .dep », « .enc » et « .grid » créés précédemment. On y retrouve également toutes les données concernant l'emplacement des conditions frontières amont et aval et les tributaires. Plus précisément, c'est dans le fichier de format « .bnd » (créé automatiquement avec le fichier de format « .mdf ») que l'on trouve ces informations. Finalement, c'est dans le fichier de format « .bct » (toujours créé automatiquement avec le fichier de format « .mdf ») que l'on retrouve les données hydrométriques, c'est-à-dire les débits journaliers pour la station à l'amont et les tributaires et les niveaux d'eau journaliers pour la station à l'aval (Deltares, 2024a).

Trois simulations de trois résolutions différentes ont été simulées. Elles sont nommées « Simulation 1 », « Simulation 2 » et « Simulation 3 » de la plus basse résolution à la plus haute résolution. Les paramètres numériques sont présentés dans le Tableau 5.1. Le maillage original est celui utilisé dans la simulation 2. Pour obtenir le maillage de la simulation 1, le facteur d'échelle a été divisé par 2 dans chaque direction (x et y), ce qui divise le nombre de cellule par 4. À l'inverse, pour la simulation 3, le facteur d'échelle est multiplié par 2 dans chaque direction (x et y), ce qui multiplie le nombre de cellules par 4.

Tableau 5.1 Paramètres des trois simulations DELFT3D-FLOW

	Simulation 1	Simulation 2	Simulation 3
Type de maillage	Cartésien	Cartésien	Cartésien
Nombre de cellules	2665	11 715	46 860
Tailles des cellules	150 m x 150 m	75 m x 75 m	37,5 m x 37,5 m
Pas de temps de calcul	0,5 minute	0,5 minute	0,1 minute
Pas de temps de sortie	15 minutes	15 minutes	15 minutes

Un coefficient de Manning de 0,02 a été utilisé dans les trois simulations. Afin de valider la valeur du coefficient de Manning, le niveau d'eau simulé en date du 15 septembre 2004 à 12h00 a été comparé à celui mesuré à la même date et à la même heure. La Figure 5.5 compare le niveau d'eau et la norme de la vitesse mesurés au niveau d'eau et la norme de la vitesse simulés sur Delft3D (Simulation 2) pour une section transversale, appelée *Reach 4* et dont les coordonnées se trouvent dans le Tableau 5.2, située au milieu de la section de rivière. La bathymétrie est également présente dans la Figure 5.5. Un niveau d'eau initial de 229,45 m a été considéré. Pour chaque simulation, il y a un total de 2785 pas de temps.

Tableau 5.2 Informations géographiques sur la section transversale utilisée pour la calibration

Nom de la section transversale	Reach 4
Coordonnées du début de la section transversale (UTM zone 12N)	460064,1299 ; 6359948,7910
Coordonnées de la fin de la section transversale (UTM zone 12N)	460900,0340 ; 6359854,6910




Figure 5.5 Comparaison entre la norme de la vitesse mesurée et la norme de la vitesse simulée et comparaison entre le niveau d'eau mesuré et le niveau d'eau simulé pour la date du 15 septembre 2004 à 12h00. Calibration effectuée à la section transversale *Reach 4*.

Comme le montre la Figure 5.5, il y a une bonne correspondance entre le niveau d'eau mesuré et le niveau d'eau simulé. De plus, les normes des vitesses mesurée et simulée sont dans le même ordre de grandeur. Cela valide la valeur de 0,02 pour le coefficient de Manning. Cette valeur est utilisée dans toutes les simulations effectuées sur Delft3D-FLOW.

5.2.2 Modèle basé sur l'AA

Le modèle basé sur l'AA cherche à prédire la simulation haute résolution à partir de la simulation basse résolution via la méthode de réduction d'échelle (*downscaling*) développée au chapitre 3. Le type d'AA utilisé est le RNA. Le premier cas de réduction d'échelle (cas 1) considère les données

de la simulation 1 comme les données d'entrée du RNA, alors que les données de la simulation 3 (haute résolution) sont les données de sortie. Dans le deuxième cas de réduction d'échelle (cas 2), ce sont plutôt les données de la simulation 2 qui sont utilisées comme données d'entrée (les données de sortie demeurent les données de la simulation 3).

L'architecture du RNA qui est utilisée dans ce chapitre est le « U-Net », développé au chapitre 3, voir architecture de droite dans la Figure 4.4. Étant donné que le modèle de type U-Net comporte une couche linéaire avec 256 neurones (*dense layer*) juste après la couche d'entrée, il est possible d'utiliser exactement la même architecture du chapitre 3 sans changer aucune caractéristique des différentes couches. Cependant, puisque le cas d'étude a changé, il est nécessaire de réentraîner le modèle de type U-Net pour le cas 1 et le cas 2 du présent chapitre. Les valeurs des paramètres (*batch size, number of epochs, cost function, gradient descent method, learning rate et decay rate*) sont les mêmes que celles utilisées dans le chapitre 3. Pour l'entraînement, un ensemble aléatoire comprenant 80% des données est utilisé. Le reste des données sert à la phase de validation. Il est important de noter que les données provenant des 96 premiers pas de temps, qui correspondent à la première journée de simulation, sont retirées des ensembles d'entraînement et de validation de façon à ne pas tenir compte de l'influence des conditions initiales.

5.3 Résultats

Cette section présente les résultats provenant du modèle physique et ceux provenant de la réduction d'échelle basée sur l'AA.

5.3.1 Modèle physique

Les principaux résultats (niveaux d'eau, vitesses horizontales (X et Y)) et les temps de calcul provenant des simulations créées avec le logiciel Delft3D-FLOW sont présentés dans le Tableau 5.3. Il y a un total de trois simulations, Simulation 1, Simulation 2, Simulation 3, dont les caractéristiques ont été présentées dans le Tableau 5.1.

Tableau 5.3 Résultats du modèle physique

	Simulation 1	Simulation 2	Simulation 3
Niveau d'eau (m)	Min: 226,62 Max: 248,04 Moyenne: 230,04 Écart type : 3,26	Min: 226,65 Max: 267,84 Moyenne : 231,26 Écart type : 3,58	Min: 226,65 Max: 268,86 Moyenne: 231,71 Écart type : 4,04
Vitesse direction X (m/s)	Min: -0,39 Max: 0,29 Moyenne: -6.94e-05 Écart type : 6,51e-03	Min: -1,77 Max: 1,13 Moyenne: -3,45e-02 Écart type : 0,21	Min: -1,69 Max: 1,59 Moyenne: -3,12e-02 Écart type : 0,21
Vitesse direction Y (m/s)	Min: -0,37 Max: 4,43 Moyenne: 2,07e-04 Écart type : 9,88e-03	Min: -0,29 Max: 2,28 Moyenne: 0,31 Écart type : 0,34	Min: -0,76 Max: 2,69 Moyenne: 0,31 Écart type : 0,35
Temps de calcul	0,56 heure	1,69 heure	39,43 heures

En observant les statistiques (valeur minimale, valeur maximale, valeur moyenne et écart-type) de chacune des variables, il est possible de remarquer que les résultats provenant des simulations 2 et 3 sont similaires. La simulation 1, qui utilise la plus basse résolution, présente des valeurs éloignées des deux autres simulations. En effet, le niveau d'eau moyen est de 231,26 m pour la simulation 2 et 231,71 m pour la simulation 3 contre 230,04 m pour la simulation 1. L'écart entre les simulations 2 et 3 et la simulation 1 est encore plus grand pour les vitesses horizontales. Par exemple, la vitesse moyenne horizontale dans la direction Y est de 2,07e-04 m/s pour la simulation 1, soit une valeur 1500 fois plus faible que la moyenne des simulations 2 et 3, soit 0,31 m/s. Ceci peut être expliqué par la taille de maillage particulièrement grande de la simulation 1 (150 m x 150 m). Lorsque la

taille du maillage augmente, les valeurs de niveau d'eau et de vitesses horizontales sont associées à une plus grande aire. Il y a donc une homogénéisation des valeurs. On remarque ce phénomène en observant que l'écart type diminue lorsque la résolution diminue. Ainsi, pour la vitesse horizontale dans la direction Y, l'écart type passe 0,35 m/s pour la simulation 3 à 0,34 m/s pour la simulation 2 et à $9,88 \times 10^{-3}$ m/s pour la simulation 1.

Pour un pas de temps arbitraire, soit le 12 septembre 2004 à 10h15, le niveau d'eau pour un segment de rivière Athabasca est illustré à la Figure 5.6 pour la simulation 1, à la Figure 5.7 pour la simulation 2 et à la Figure 5.8 pour la simulation 3. Similairement, pour le même moment, la norme de la vitesse est illustrée à la Figure 5.9 pour la simulation 1, à la Figure 5.10 pour la simulation 2 et à la Figure 5.11 pour la simulation 3.

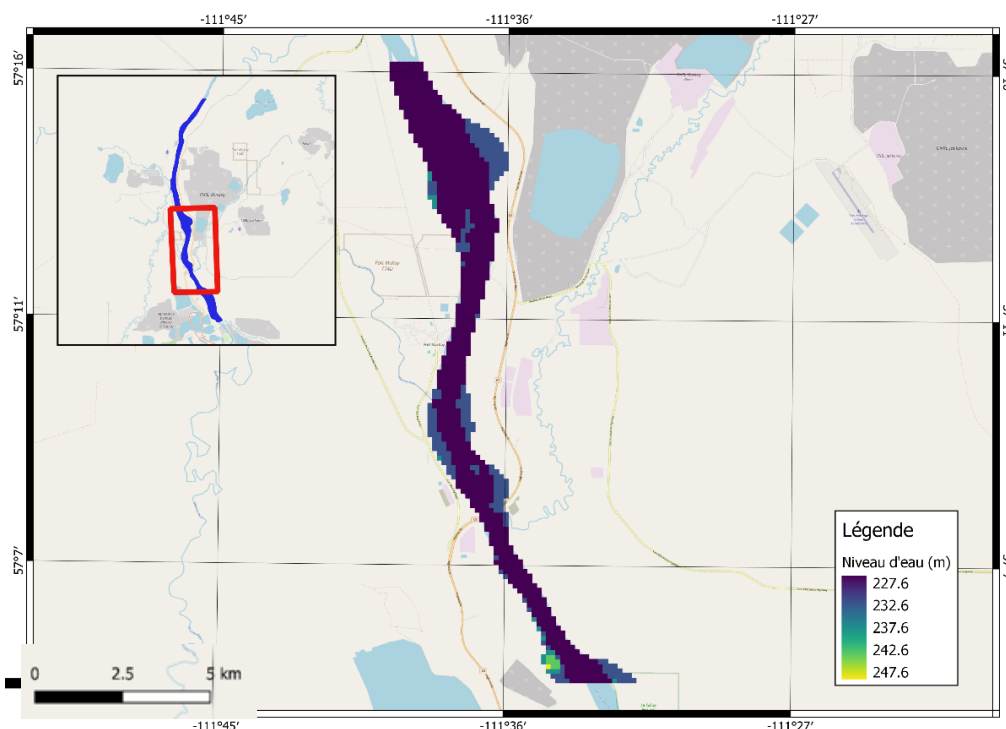


Figure 5.6 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 1)

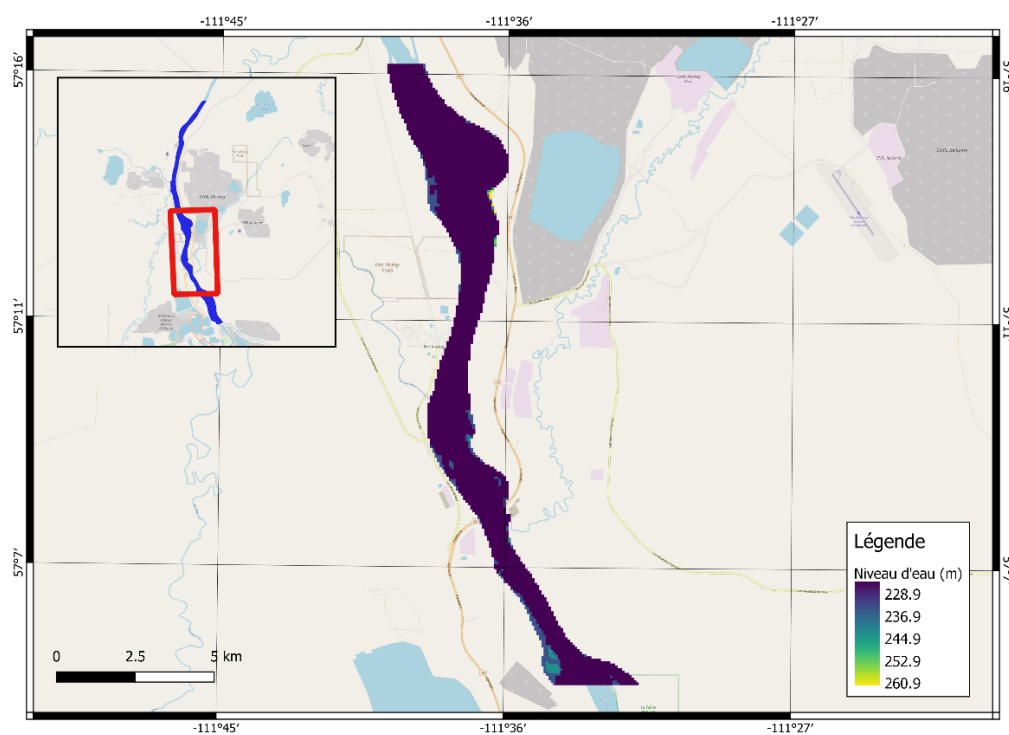


Figure 5.7 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 2)

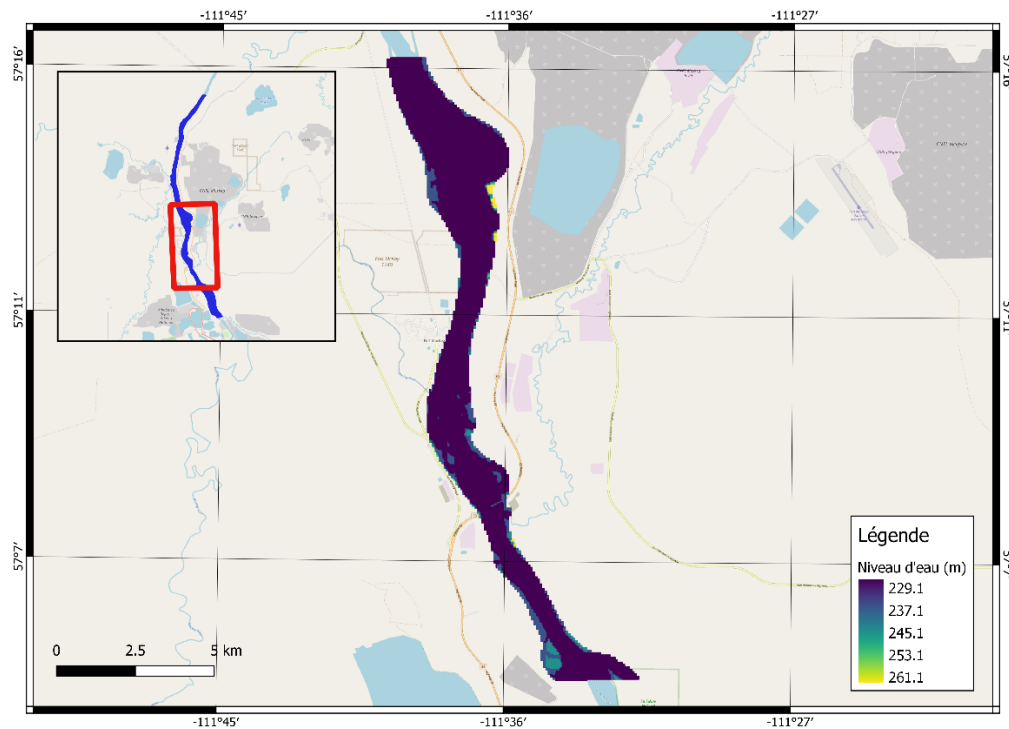


Figure 5.8 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 3)

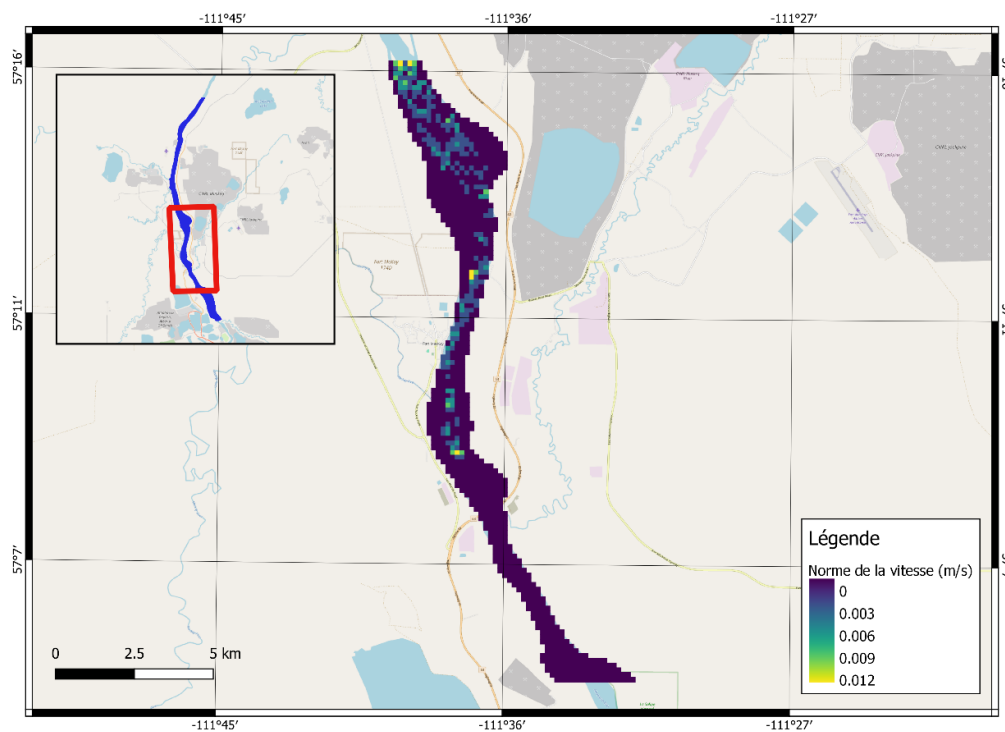


Figure 5.9 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 1)

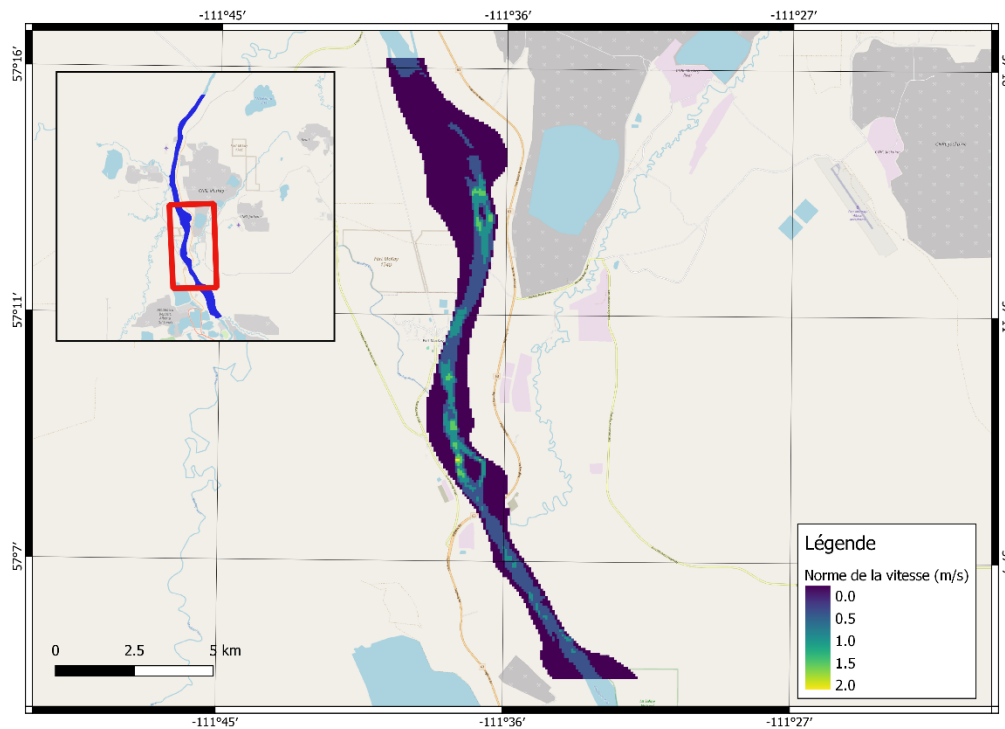


Figure 5.10 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 2)

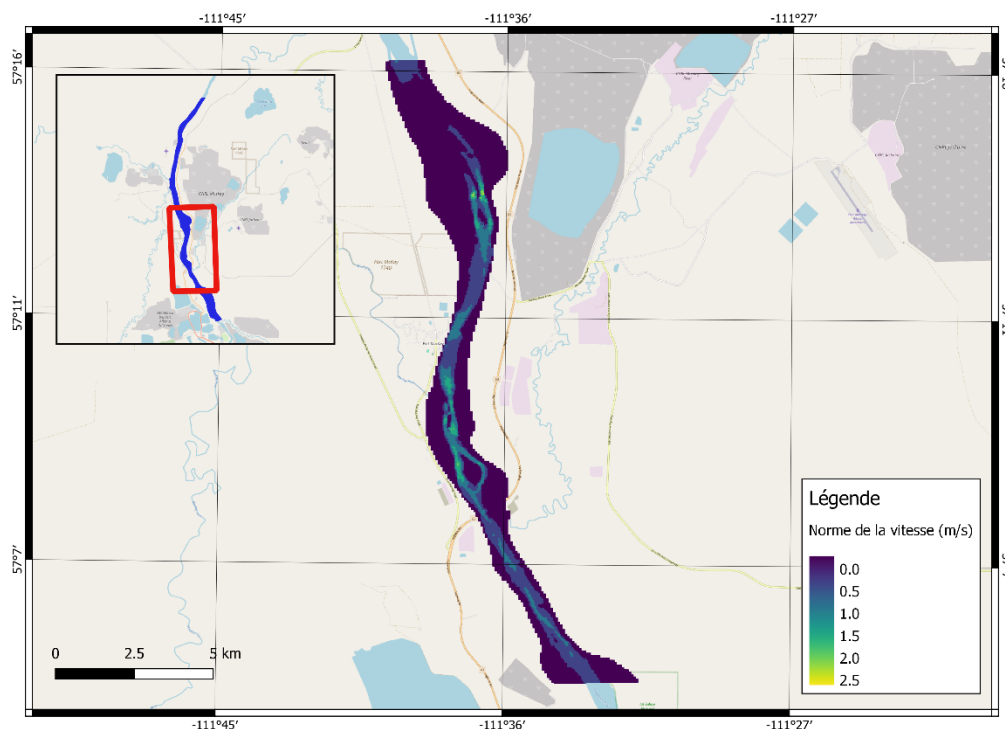


Figure 5.11 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (Simulation 3)

Les données de temps de calcul se trouvent dans le fichier de sortie nommé « tri-diag ». Les résultats physiques se trouvent dans les fichiers de sortie nommés « com-» et « trim-».

5.3.2 Modèle basé sur l'AA

Cette section présente les résultats des deux réductions d'échelle effectuées (cas 1 et cas 2).

Les principaux résultats (niveaux d'eau, vitesses horizontales (X et Y) provenant du modèle basé sur l'AA (U-Net) utilisé pour la réduction d'échelle sont présentés dans le Tableau 5.4. Dans ce tableau, se trouvent également l'erreur absolue moyenne et l'écart type pour chaque variable. L'erreur absolue moyenne est calculée en considérant les valeurs données par le modèle de type U-Net et les valeurs provenant de la simulation 3 (modèle physique). Sont également présents dans le Tableau 5.4, le nombre de paramètres dans le modèle de type U-Net et le temps de calcul pour l'entraînement.

Tableau 5.4 Résultats du modèle basé sur l'AA (U-Net)

	Simulation 1 → Simulation 3 (cas 1)	Simulation 2 → Simulation 3 (cas 2)
Niveau d'eau (m)	Min: 227,36 Max: 268,83 Moyenne: 231,69 Écart type : 4,03 Erreur absolue moyenne : 0,134	Min: 227,16 Max: 269,02 Moyenne: 231,71 Écart type : 4,04 Erreur absolue moyenne : 0,111
Vitesse direction X (m/s)	Min: -1,60 Max: 1,36 Moyenne: -3,07e-02 Écart type : 0,21 Erreur absolue moyenne : 0,014	Min: -1,60 Max: 1,36 Moyenne: -3,07e-02 Écart type : 0,21 Erreur absolue moyenne : 0,014
Vitesse direction Y (m/s)	Min: -0,59 Max: 2,50 Moyenne: 0,31 Écart type : 0,34 Erreur absolue moyenne : 0,030	Min: -0,59 Max: 2,50 Moyenne: 0,31 Écart type : 0,34 Erreur absolue moyenne : 0,030
Nombre de paramètres (U-Net)	38 285 147	45 235 547
Temps de calcul pour l'entraînement	16 minutes	21 minutes

En observant les résultats présentés dans le Tableau 5.4, on observe que le modèle de type U-Net est capable de reproduire les niveaux d'eau moyens ainsi que les vitesses horizontales moyennes dans les directions X et Y dans le cas 1 et dans le cas 2. Les écarts-types sont également semblables à ceux trouvés dans la simulation 3. Pour le cas 2, c'est un résultat attendu puisque les valeurs des différentes variables de la simulation 2 sont très semblables à celles de la simulation 3. Cependant, même dans le cas 1, où les valeurs des différentes variables (particulièrement les vitesses horizontales) de la simulation 1 diffèrent grandement de celles de la simulation 3, le modèle de type U-Net reproduit de bons résultats.

Afin d'avoir une comparaison visuelle avec les résultats physiques, le niveau d'eau pour le segment de la rivière Athabasca utilisé à la section 5.3.1 (au même moment du 12 septembre 2004 à 10h15) est illustré à la Figure 5.12 pour le cas 1 et à la Figure 5.13 pour le cas 2. Similairement, pour le même moment, la norme de la vitesse est illustrée à la Figure 5.14 pour le cas 1 et à la Figure 5.15 pour le cas 2.

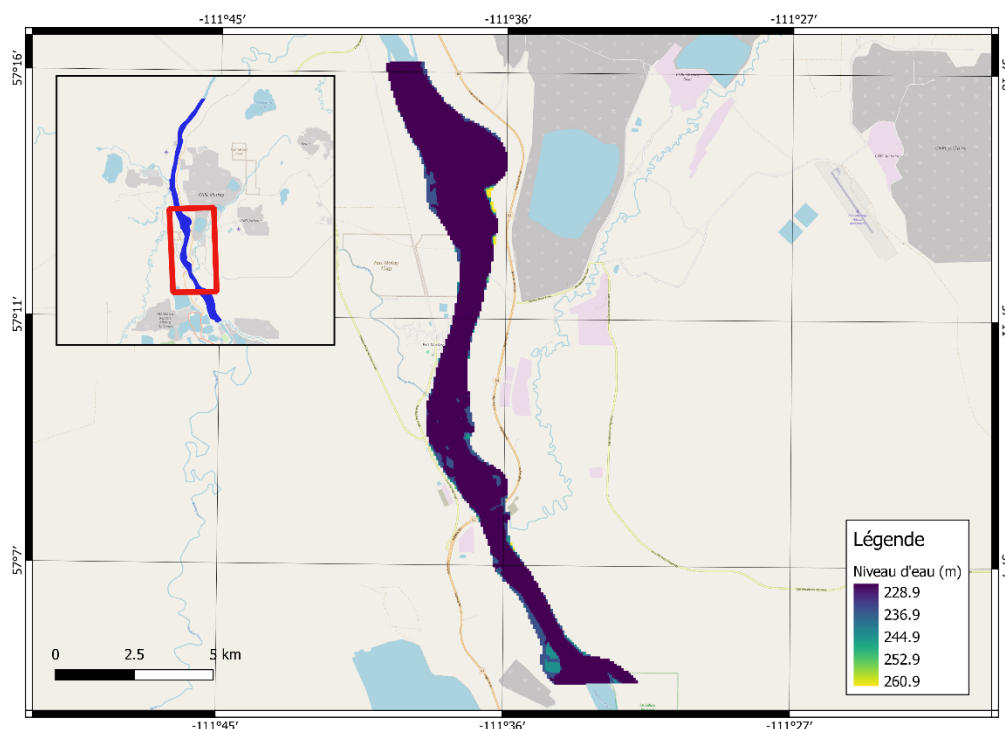


Figure 5.12 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (cas 1)

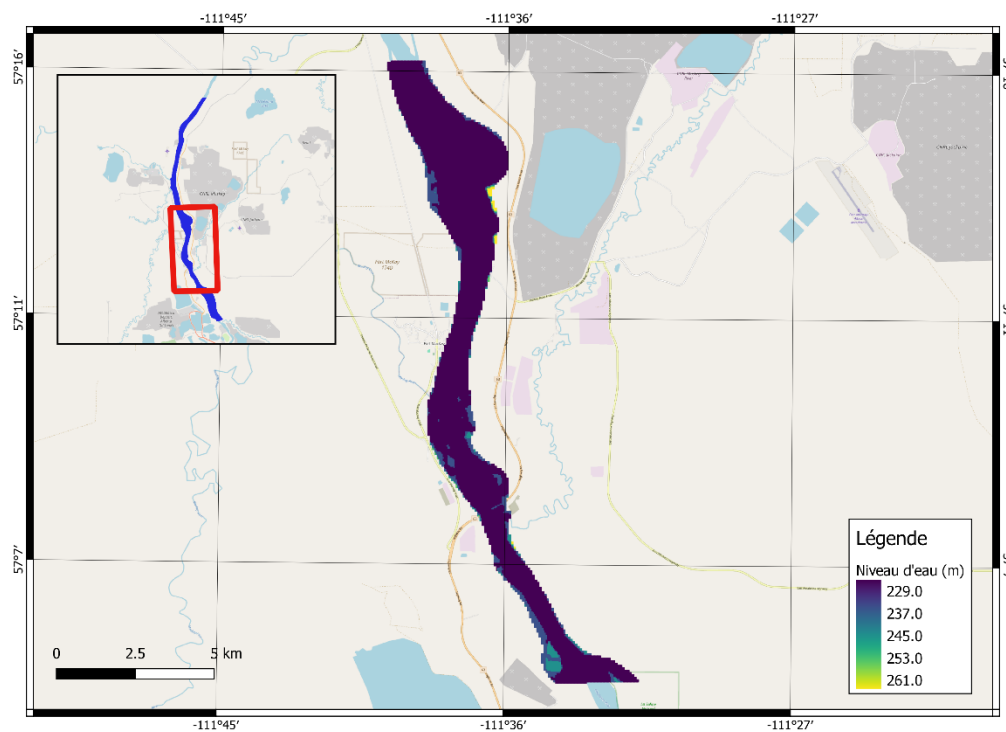


Figure 5.13 Niveau d'eau (m) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (cas 2)

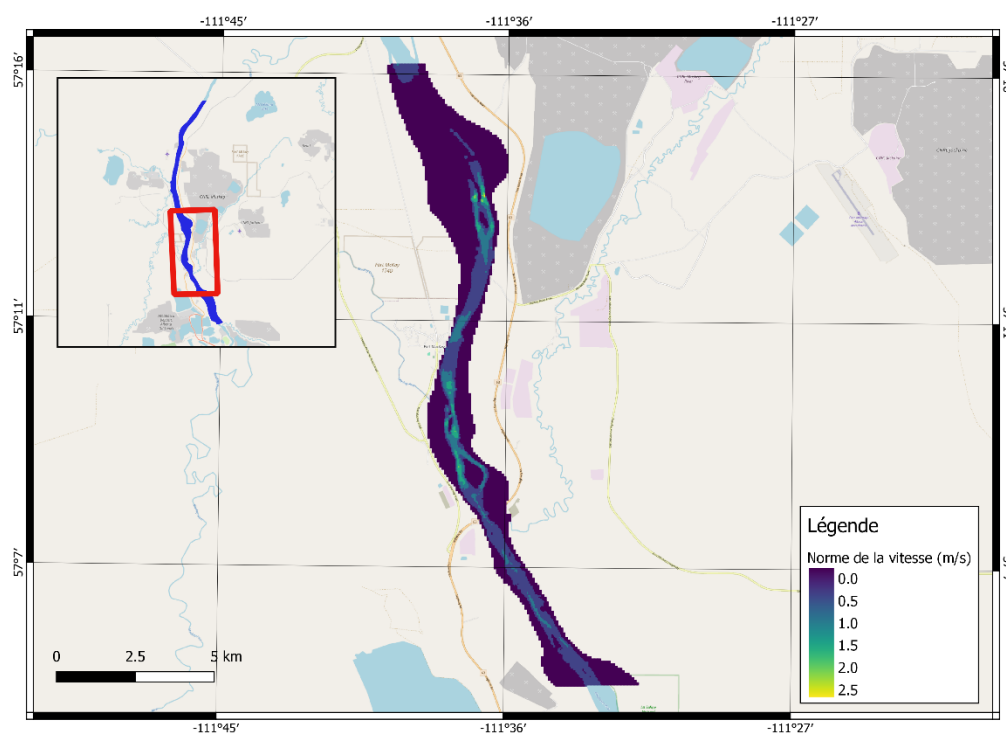


Figure 5.14 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (cas 1)

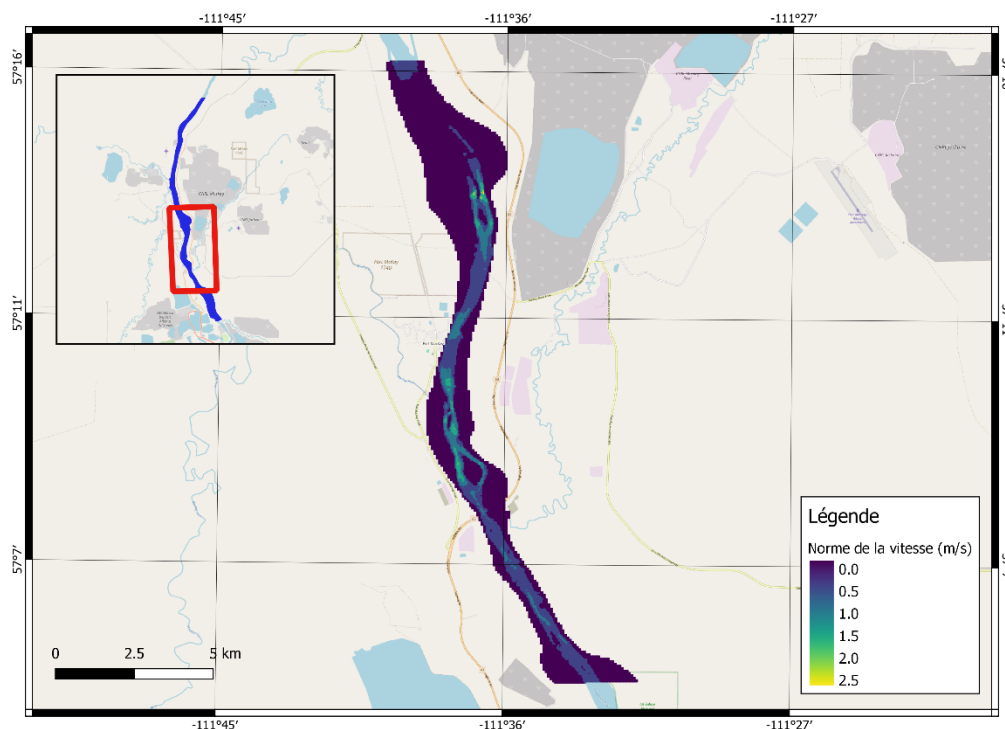


Figure 5.15 Norme de la vitesse (m/s) en date du 12 septembre 2004 à 10h15 pour un segment de la rivière Athabasca (cas 2)

En comparant la Figure 5.12 et la Figure 5.13 (niveaux d'eau simulés avec le modèle de type U-Net) à la Figure 5.8 (niveau d'eau simulé avec Delft3D-FLOW en haute résolution) on constate que le modèle de type U-Net reproduit fidèlement les données de haute résolution. Le même constat peut être déduit avec la norme de la vitesse en comparant la Figure 5.14 et la Figure 5.15 à la Figure 5.11.

La Figure 5.16 et la Figure 5.17 présentent, respectivement pour le cas 1 et pour le cas 2, l'erreur absolue moyenne (qui a été calculée sur l'ensemble des pas de temps de l'ensemble de validation) pour un segment de la rivière Athabasca. Les erreurs vont jusqu'à 0,06 m/s pour le cas 1 et jusqu'à 0,05 m/s pour le cas 2. Les erreurs sont plus élevées dans la section centrale de la rivière, soit à l'endroit où la norme de la vitesse est la plus élevée.

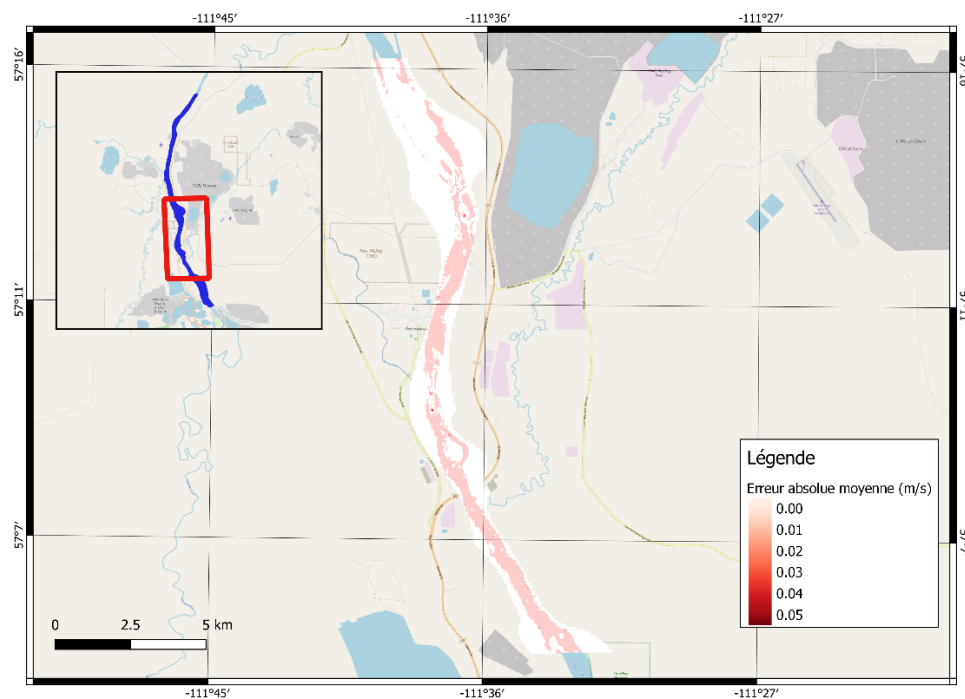


Figure 5.16 Erreur absolue moyenne de la norme de la vitesse (m/s) pour un segment de la rivière Athabasca (cas 1)

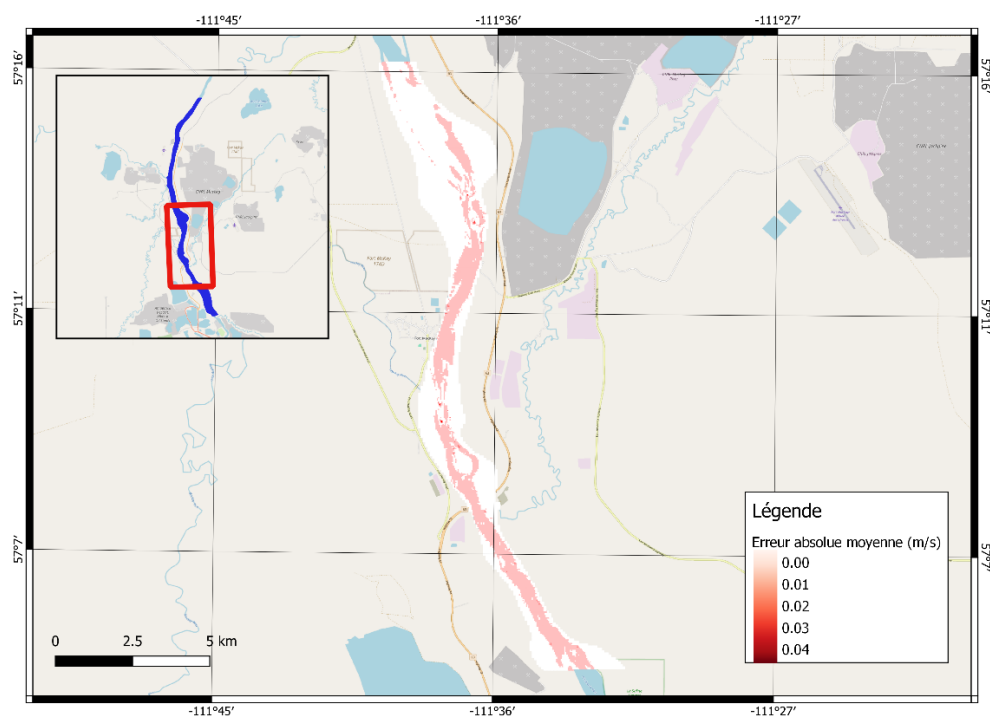


Figure 5.17 Erreur absolue moyenne de la norme de la vitesse (m/s) pour un segment de la rivière Athabasca (cas 2)

Les courbes de la fonction de coût (erreur quadratique moyenne (MSE)) pour la réduction d'échelle à partir de la simulation 1 (cas 1) est présentée à la Figure 5.18 et celle à partir de la simulation 2 (cas 2) est présentée à la Figure 5.19.




Figure 5.18 Courbe de l'erreur d'entraînement et de validation pour le cas 1




Figure 5.19 Courbe de l'erreur d'entraînement et de validation pour le cas 2

Le comportement des courbes tracées dans la Figure 5.18 et dans la Figure 5.19 est conforme à la théorie puisque les valeurs d'erreur d'entraînement et de validation diminuent au fur et à mesure que le nombre d'itérations (*epochs*) augmente.

5.4 Conclusion

En conclusion, ce chapitre a permis de confirmer que la méthode de réduction d'échelle qui utilise un modèle d'AA de type U-Net fonctionne pour les deux résolutions d'entrée testées, 150 m x 150 m et 75 m x 75 m. Pour le cas de la rivière Athabasca, il ne semble pas y avoir d'effet significatif du facteur d'échelle. La plus petite résolution est constituée de 2665 cellules carrées de taille 150 m x 150 m alors que la haute résolution est constituée de 46 860 cellules carrées de taille 37,5 m x 37,5 m, soit un ratio de 16 (4 x 4). Pour ce cas précis de réduction d'échelle, les erreurs de reconstruction pour le niveau d'eau et les vitesses horizontales dans les directions X et Y sont respectivement de 0,111 m, 0,014 m/s et 0,030 m/s. La différence de temps de calcul entre la méthode physique et la méthode combinée physique-AA est considérable. En effet, il a fallu 39,43 heures pour la haute résolution (simulation 3) contre 0,56 heure pour la plus basse résolution (simulation 1). Il est toutefois important de noter qu'un total de 16 minutes pour l'entraînement du modèle de type U-Net doivent être rajoutées au temps donné pour la simulation 1. Le facteur de réduction de temps de calcul est de près de 48. De plus, une fois que l'entraînement est effectué pour un cas d'étude et des résolutions d'entrée et de sortie données, il n'est plus nécessaire de réentraîner le modèle si les conditions frontières (données hydrométriques telles que les débits et les niveaux d'eau) changent. Ainsi, pour un nouvel évènement de crue, il suffit de simuler de nouvelles données de basse résolution avec le modèle basé sur la physique et le modèle de type U-Net peut donner de nouveaux résultats de haute résolution en quelques secondes.

CHAPITRE 6 CONCLUSION

Ce chapitre sert de conclusion à ce mémoire.

6.1 Synthèse des travaux

Dans ce mémoire, la problématique liée aux modèles basés sur la physique a été exposée. Cette problématique est le coût de calcul élevé lorsque la résolution requise est très fine et/ou lorsque le domaine de calcul est très grand. Pour contrer cet inconvénient, une méthode hybride basée sur l'AA, plus précisément sur des RNA, a été développée. La méthode hybride est une méthode de réduction d'échelle où la basse résolution, simulée à l'aide d'un modèle basé sur la physique, sert de données d'entrée au RNA. La couche de sortie, quant à elle, correspond à la simulation haute-résolution. Les variables de l'écoulement (hauteur d'eau/niveau d'eau et débits/vitesses dans les directions X et Y) sont prédites conjointement. Avec cette méthode, le temps de calcul est réduit tout en garantissant un niveau de précision élevé. Le chapitre 4 a permis de déterminer quel est le meilleur type de RNA pour la réduction d'échelle en utilisant le cas fictif d'une confluence à 90° de deux canaux rectilignes. Le meilleur modèle de RNA est le modèle de type U-Net, un RNC qui comprend des « *skip connections* » afin d'améliorer l'apprentissage. Le U-Net a ensuite été testé sur un cas réel, le cas du fleuve Saint-Laurent. Finalement, le chapitre 5 avait pour but de déterminer si le modèle de type U-Net est capable de prédire, avec la même efficacité, les données de haute résolution à partir de données d'entrée provenant de diverses basses résolutions. Il a été démontré que le modèle de type U-Net a été aussi efficace avec les deux résolutions d'entrée testées, 150 m x 150 m et 75 m x 75 m.

6.2 Limitation de la solution proposée

L'avantage du modèle de type U-Net développé dans ce mémoire est qu'il fonctionne indépendamment de la taille du maillage (c'est-à-dire qu'il n'est pas nécessaire de modifier la structure du RNA lorsque le format des données d'entrée change). Ceci est pratique lorsqu'on souhaite utiliser une même structure de modèle pour différents cas d'étude. Cependant, si un changement des conditions frontières (données hydrométriques telles que les débits et les niveaux d'eau) ne nécessite pas de réentraîner le RNA, il est nécessaire de réentraîner le RNA à chaque fois que le cas d'étude change ou que le format des données d'entrée et/ou de sortie change, notamment lorsqu'on teste différentes résolutions. Il est également essentiel de souligner que le RNA ne pourra

prédire correctement les variables de l'écoulement que si les conditions aux frontières se situent dans une plage de valeurs déjà rencontrées lors de son apprentissage. Dans ce mémoire, uniquement de courts segments de rivière ont été modélisés (437,52 km² pour le fleuve St-Laurent et 65,9 km² pour la rivière Athabasca). En effet, déjà pour de courts segments, le nombre de paramètres dans le modèle de type U-Net est très grand, 221 millions pour le cas artificiel, 140 millions pour le cas du fleuve St-Laurent et 38 à 45 millions pour le cas de la rivière Athabasca.

6.3 Améliorations futures

Pour améliorer la méthode proposée dans ce mémoire, quelques pistes sont proposées. Premièrement, il serait intéressant d'incorporer les lois basées sur la physique (équations différentielles) dans la fonction de coût du RNA. En rajoutant ainsi de l'information physique dans le RNA, il est attendu que l'erreur de reconstruction sera plus faible. Une possibilité serait d'explorer les PINN brièvement abordés dans la section 2.4. Deuxièmement, il pourrait être avantageux de rajouter davantage de données d'entrée. Pour l'instant, seule une couche de données de basse résolution est utilisée. Or en rajoutant d'autres couches (comme la bathymétrie), l'efficacité du RNA devrait être meilleure. Troisièmement, l'utilisation de modèles qui tient compte des dépendances temporelles, comme les modèles de type LSTM, serait intéressante à tester.

RÉFÉRENCES

- Bayat, M., & Tavakkoli, O. (2022). Application of machine learning in flood forecasting. *Future Technology*, 1(1), 1-6. <https://doi.org/10.55670/fpll.futech.1.1.1>
- Bishop, C. (2006). *Pattern Recognition and Machine Learning*. Springer. <https://www.microsoft.com/en-us/research/publication/pattern-recognition-machine-learning/>
- Bomers, A., & Hulscher, S. J. M. H. (2023). Neural networks for fast fluvial flood predictions: Too good to be true? *River Research and Applications*, 39(8), 1652-1658. <https://doi.org/10.1002/rra.4144>
- Carreau, J., & Guinot, V. (2021). A PCA spatial pattern based artificial neural network downscaling model for urban flood hazard assessment. *Advances in Water Resources*, 147. <https://doi.org/10.1016/j.advwatres.2020.103821>
- Carreau, J., & Naveau, P. (2023). A spatially adaptive multi-resolution generative algorithm: Application to simulating flood wave propagation. *Weather and Climate Extremes*, 41. <https://doi.org/10.1016/j.wace.2023.100580>
- Caviedes-Voullième, D., Morales-Hernández, M., Norman, M. R., & Özgen-Xian, I. (2023). SERGHEI (SERGHEI-SWE) v1.0: a performance-portable high-performance parallel-computing shallow-water solver for hydrology and environmental hydraulics. *Geoscientific Model Development*, 16(3), 977-1008. <https://doi.org/10.5194/gmd-16-977-2023>
- Cheng, M., Fang, F., Navon, I. M., & Pain, C. C. (2021). A real-time flow forecasting with deep convolutional generative adversarial network: Application to flooding event in Denmark. *Physics of Fluids*, 33(5). <https://doi.org/10.1063/5.0051213>
- Conseil national de recherches Canada. (2020). *Apprentissage automatique*. <https://nrc.canada.ca/fr/recherche-developpement/produits-services/services-techniques-consultatifs/apprentissage-automatique>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/bf00994018>
- Costache, R., Pham, Q. B., Avand, M., Thuy Linh, N. T., Vojtek, M., Vojtekova, J., . . . Dung, T. D. (2020). Novel hybrid models between bivariate statistics, artificial neural networks and boosting algorithms for flood susceptibility assessment. *J Environ Manage*, 265, 110485. <https://doi.org/10.1016/j.jenvman.2020.110485>
- CRED. (2023). *2022 Disasters in numbers*. Brussels: CRED. https://cred.be/sites/default/files/2022_EMDAT_report.pdf
- Deltares. (2024a). *Delft3D-FLOW User Manual*. Deltares. https://content.oss.deltares.nl/delft3d4/Delft3D-FLOW_User_Manual.pdf
- Deltares. (2024b). *QUICKIN User Manual*. Deltares. https://content.oss.deltares.nl/delft3d4/QUICKIN_User_Manual.pdf
- Deltares. (2024c). *RGFGRID User Manual*. Deltares. https://content.oss.deltares.nl/delft3d4/RGFGRID_User_Manual.pdf

- Dubey, S. R., Singh, S. K., & Chaudhuri, B. B. (2022). Activation functions in deep learning: A comprehensive survey and benchmark. *Neurocomputing*, 503, 92-108. <https://doi.org/10.1016/j.neucom.2022.06.111>
- Environnement et Changement climatique Canada (ECCC). (2010). *Les inondations : renseignements généraux*. <https://www.canada.ca/fr/environnement-changement-climatique/services/eau-aperçu/volume/inondations/renseignements-generaux.html>
- Environnement et Changement climatique Canada (ECCC). (2013). *Les causes des inondations*. <https://www.canada.ca/fr/environnement-changement-climatique/services/eau-aperçu/volume/causes-inondation.html>
- Feng, D., Tan, Z., & He, Q. (2023). Physics-Informed Neural Networks of the Saint-Venant Equations for Downscaling a Large-Scale River Model. *Water Resources Research*, 59(2). <https://doi.org/10.1029/2022wr033168>
- Forghani, M., Qian, Y., Lee, J., Farthing, M. W., Hesser, T., Kitanidis, P. K., & Darve, E. F. (2021). Application of deep learning to large scale riverine flow velocity estimation. *Stochastic Environmental Research and Risk Assessment*, 35(5), 1069-1088. <https://doi.org/10.1007/s00477-021-01988-0>
- Fowler, H. J., Blenkinsop, S., & Tebaldi, C. (2007). Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *International Journal of Climatology*, 27(12), 1547-1578. <https://doi.org/10.1002/joc.1556>
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras and TensorFlow : concepts, tools, and techniques to build intelligent systems* (2^e éd.). O'Reilly Media, Inc.
- Gouvernement du Québec. (2023). *Plan de protection du territoire face aux inondations : des solutions durables pour mieux protéger nos milieux de vie*. <https://www.quebec.ca/gouvernement/politiques-orientations/plan-de-protection-du-territoire-face-aux-inondations>
- Hartnett, M., & Nash, S. (2017). High-resolution flood modeling of urban areas using MSN_Flood. *Water Science and Engineering*, 10(3), 175-183. <https://doi.org/10.1016/j.wse.2017.10.003>
- Heniche, M., Secretan, Y., Boudreau, P., & Leclerc, M. (2000). A two-dimensional finite element drying-wetting shallow water model for rivers and estuaries. *Advances in Water Resources*, 23(4), 359-372. [https://doi.org/10.1016/S0309-1708\(99\)00031-7](https://doi.org/10.1016/S0309-1708(99)00031-7)
- Höhlein, K., Kern, M., Hewson, T., & Westermann, R. (2020). A comparative study of convolutional neural network models for wind field downscaling. *Meteorological Applications*, 27(6). <https://doi.org/10.1002/met.1961>
- Hosseiny, H., Nazari, F., Smith, V., & Nataraj, C. (2020). A Framework for Modeling Flood Depth Using a Hybrid of Hydraulics and Machine Learning. *Sci Rep*, 10(1), 8222. <https://doi.org/10.1038/s41598-020-65232-5>
- Hou, J., Zhou, N., Chen, G., Huang, M., & Bai, G. (2021). Rapid forecasting of urban flood inundation using multiple machine learning models. *Natural Hazards*, 108(2), 2335-2356. <https://doi.org/10.1007/s11069-021-04782-x>
- INRS-ETE. (2020). <https://gitlab.com/h2d2/H2D2>. <https://gitlab.com/h2d2/H2D2>

- Intergovernmental Panel on Climate Change (IPCC). (2022). Framing and Context. Dans *Global Warming of 1.5°C: IPCC Special Report on Impacts of Global Warming of 1.5°C above Pre-industrial Levels in Context of Strengthening Response to Climate Change, Sustainable Development, and Efforts to Eradicate Poverty* (pp. 49-92) (p. 49-92). Cambridge: Cambridge University Press.
- Intergovernmental Panel on Climate Change (IPCC). (2023). Water Cycle Changes. Dans *Climate Change 2021 – The Physical Science Basis: Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* (p. 1055-1210). Cambridge University Press,.
- IPCC. (9 août 2021). *Climate change widespread, rapid, and intensifying* https://www.ipcc.ch/site/assets/uploads/2021/08/IPCC_WGI-AR6-Press-Release_en.pdf
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning with Applications in R* (2^e éd.). Springer.
- Jang, J.-H., Hsieh, C.-Y., & Li, T.-W. (2022). Flood mapping based on the combination of support vector regression and Heun's scheme. *Journal of Hydrology*, 613. <https://doi.org/10.1016/j.jhydrol.2022.128477>
- Kabir, S., Patidar, S., Xia, X., Liang, Q., Neal, J., & Pender, G. (2020). A deep convolutional neural network model for rapid prediction of fluvial flood inundation. *Journal of Hydrology*, 590. <https://doi.org/10.1016/j.jhydrol.2020.125481>
- Karim, F., Armin, M. A., Ahmedt-Aristizabal, D., Tychsen-Smith, L., & Petersson, L. (2023). A Review of Hydrodynamic and Machine Learning Approaches for Flood Inundation Modeling. *Water*, 15(3). <https://doi.org/10.3390/w15030566>
- Kim, Y. D., Tak, Y. H., Park, M. H., & Kang, B. (2019). Improvement of urban flood damage estimation using a high-resolution digital terrain. *Journal of Flood Risk Management*, 13(S1). <https://doi.org/10.1111/jfr3.12575>
- Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water*, 11(7). <https://doi.org/ARTN 1387>
10.3390/w11071387
- Liverpool John Moores University. (2024). *Field Trips*. <https://www.ljmu.ac.uk/conferences/river-flow/field-trips>
- Ma, M., Zhao, G., He, B., Li, Q., Dong, H., Wang, S., & Wang, Z. (2021). XGBoost-based method for flash flood risk assessment. *Journal of Hydrology*, 598. <https://doi.org/10.1016/j.jhydrol.2021.126382>
- Macpherson, T., Churchland, A., Sejnowski, T., DiCarlo, J., Kamitani, Y., Takahashi, H., & Hikida, T. (2021). Natural and Artificial Intelligence: A brief introduction to the interplay between AI and neuroscience research. *Neural Netw*, 144, 603-613. <https://doi.org/10.1016/j.neunet.2021.09.018>
- Madhuri, R., Sistla, S., & Srinivasa Raju, K. (2021). Application of machine learning algorithms for flood susceptibility assessment and risk management. *Journal of Water and Climate Change*, 12(6), 2608-2623. <https://doi.org/10.2166/wcc.2021.051>

- Matte, P., Secretan, Y., & Morin, J. (2017a). Hydrodynamic Modeling of the St. Lawrence Fluvial Estuary. I: Model Setup, Calibration, and Validation. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 143(5). [https://doi.org/10.1061/\(asce\)ww.1943-5460.0000397](https://doi.org/10.1061/(asce)ww.1943-5460.0000397)
- Matte, P., Secretan, Y., & Morin, J. (2017b). Hydrodynamic Modeling of the St. Lawrence Fluvial Estuary. II: Reproduction of Spatial and Temporal Patterns. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 143(5). [https://doi.org/10.1061/\(asce\)ww.1943-5460.0000394](https://doi.org/10.1061/(asce)ww.1943-5460.0000394)
- McGrath, H., Bourgon, J.-F., Proulx-Bourque, J.-S., Nastev, M., & Abo El Ezz, A. (2018). A comparison of simplified conceptual models for rapid web-based flood inundation mapping. *Natural Hazards*, 93(2), 905-920. <https://doi.org/10.1007/s11069-018-3331-y>
- Ming, X., Liang, Q., Xia, X., Li, D., & Fowler, H. J. (2020). Real-Time Flood Forecasting Based on a High-Performance 2-D Hydrodynamic Model and Numerical Weather Predictions. *Water Resources Research*, 56(7). <https://doi.org/10.1029/2019wr025583>
- Mintgen, F., & Manhart, M. (2018). A bi-directional coupling of 2D shallow water and 3D Reynolds-averaged Navier–Stokes models. *Journal of Hydraulic Research*, 56(6), 771-785. <https://doi.org/10.1080/00221686.2017.1419989>
- Morales-Hernández, M., Sharif, M. B., Kalyanapu, A., Ghafoor, S. K., Dullo, T. T., Gangrade, S., . . . Evans, K. J. (2021). TRITON: A Multi-GPU open source 2D hydrodynamic flood model. *Environmental Modelling & Software*, 141. <https://doi.org/10.1016/j.envsoft.2021.105034>
- Mosavi, A., Ozturk, P., & Chau, K.-w. (2018). Flood Prediction Using Machine Learning Models: Literature Review. *Water*, 10(11). <https://doi.org/10.3390/w10111536>
- Mudashiru, R. B., Sabtu, N., Abustan, I., & Balogun, W. (2021). Flood hazard mapping methods: A review. *Journal of Hydrology*, 603. <https://doi.org/10.1016/j.jhydrol.2021.126846>
- Nevo, S., Morin, E., Gerzi Rosenthal, A., Metzger, A., Barshai, C., Weitzner, D., . . . Matias, Y. (2022). Flood forecasting with machine learning models in an operational framework. *Hydrology and Earth System Sciences*, 26(15), 4013-4032. <https://doi.org/10.5194/hess-26-4013-2022>
- Okuno, S., Ikeuchi, K., & Aihara, K. (2021). Practical Data-Driven Flood Forecasting Based on Dynamical Systems Theory. *Water Resources Research*, 57(3). <https://doi.org/10.1029/2020wr028427>
- Ouranos. (2024). *Crues et inondations - Impacts*. <https://www.ouranos.ca/fr/phenomenes-climatiques/crues-inondations-impacts>
- Parmar, R., Patel, D., Panchal, N., Chauhan, U., & Bhatia, J. (2022). 5G-enabled deep learning-based framework for healthcare mining: State of the art and challenges. Dans *Blockchain Applications for Healthcare Informatics* (p. 401-420).
- Popescu, I. (2014). *Computational hydraulics : numerical methods and modelling*. IWA Pub.
- Raghavendra. N, S., & Deka, P. C. (2014). Support vector machine applications in the field of hydrology: A review. *Applied Soft Computing*, 19, 372-386. <https://doi.org/10.1016/j.asoc.2014.02.002>

- Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- Rampal, N., Gibson, P. B., Sood, A., Stuart, S., Fauchereau, N. C., Brandolino, C., . . . Meyers, T. (2022). High-resolution downscaling with interpretable deep learning: Rainfall extremes over New Zealand. *Weather and Climate Extremes*, 38. <https://doi.org/10.1016/j.wace.2022.100525>
- Rincón, D., Velandia, J. F., Tsanis, I., & Khan, U. T. (2022). Stochastic Flood Risk Assessment under Climate Change Scenarios for Toronto, Canada Using CAPRA. *Water*, 14(2). <https://doi.org/10.3390/w14020227>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. Dans *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (p. 234-241).
- Savant, G., Berger, C., McAlpin, T. O., & Tate, J. N. (2011). Efficient Implicit Finite-Element Hydrodynamic Model for Dam and Levee Breach. *Journal of Hydraulic Engineering*, 137(9), 1005-1018. [https://doi.org/10.1061/\(asce\)hy.1943-7900.0000372](https://doi.org/10.1061/(asce)hy.1943-7900.0000372)
- Tabari, H. (2020). Climate change impact on flood and extreme precipitation increases with water availability. *Sci Rep*, 10(1), 13768. <https://doi.org/10.1038/s41598-020-70816-2>
- Talukdar, S., Mankotia, S., Shamimuzzaman, M., Shahfahad, & Mahato, S. (2021). Wetland-Inundated Area Modeling and Monitoring Using Supervised and Machine Learning Classifiers. Dans *Advances in Remote Sensing for Natural Resource Monitoring* (p. 346-365).
- Tang, J., Niu, X., Wang, S., Gao, H., Wang, X., & Wu, J. (2016). Statistical downscaling and dynamical downscaling of regional climate in China: Present climate evaluations and future climate projections. *Journal of Geophysical Research: Atmospheres*, 121(5), 2110-2129. <https://doi.org/10.1002/2015jd023977>
- Teng, J., Jakeman, A. J., Vaze, J., Croke, B. F. W., Dutta, D., & Kim, S. (2017). Flood inundation modelling: A review of methods, recent advances and uncertainty analysis. *Environmental Modelling & Software*, 90, 201-216. <https://doi.org/10.1016/j.envsoft.2017.01.006>
- USACE Hydrologic Engineering Center. (2023). *HEC-RAS 2D Modeling Advantages/Capabilities*. <https://www.hec.usace.army.mil/confluence/rasdocs/r2dum/latest/introduction/hecras-2d-modeling-advantages-capabilities>
- World Health Organization. (2023). *Floods*. https://www.who.int/health-topics/floods#tab=tab_1
- Xia, X., Liang, Q., & Ming, X. (2019). A full-scale fluvial flood modelling framework based on a high-performance integrated hydrodynamic modelling system (HiPIMS). *Advances in Water Resources*, 132. <https://doi.org/10.1016/j.advwatres.2019.103392>
- Xie, F., Zhao, W., & Wan, D. (2022). Overview of Moving Particle Semi-implicit Techniques for Hydrodynamic Problems in Ocean Engineering. *Journal of Marine Science and Application*, 21(3), 1-22. <https://doi.org/10.1007/s11804-022-00284-9>

Yu, P.-S., Chen, S.-T., & Chang, I. F. (2006). Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 328(3-4), 704-716.
<https://doi.org/10.1016/j.jhydrol.2006.01.021>