



HAL
open science

Modélisation des hauteurs d'eau dans les plaines d'inondation avec les GNN

Fadil Boodoo, Carole Delenne, Franco Alberto Cardillo, Joris Guérin, Renaud Hostache

► **To cite this version:**

Fadil Boodoo, Carole Delenne, Franco Alberto Cardillo, Joris Guérin, Renaud Hostache. Modélisation des hauteurs d'eau dans les plaines d'inondation avec les GNN. Congrès Eau & Intelligence Artificielle 2026, Mar 2026, Grenoble, France. <hal-05507025>

HAL Id: hal-05507025

<https://hal.science/hal-05507025v1>

Submitted on 12 Feb 2026

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

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



Distributed under a Creative Commons CC BY-NC-SA 4.0 - Attribution - Non-commercial use - ShareAlike - International License

Modélisation des hauteurs d’eau dans les plaines d’inondation avec les GNN

Fadil Boodoo^a, Carole Delenne^b, Franco Alberto Cardillo^c, Joris Guérin^d, Renaud Hostache^d

^a HSM, Univ. Montpellier, CNRS, IRD, Montpellier, France
fadil.boodoo@gmail.com

^b IUSTI, Aix Marseille Univ., CNRS, Marseilles, France
carole.delenne@univ-amu.fr

^c Consiglio Nazionale delle Ricerche (CNR), Pise, Italie
francoalberto.cardillo@cnr.it

^d Espace-Dev, UMR Espace-Dev, Univ. Montpellier, IRD, Univ. Réunion, Univ. Guyane, Univ.
Nouvelle Calédonie, Univ. Antilles, UPVD
{Joris.guerin, renaud.hostache}@ird.fr

Mots-clés : *modélisation hydraulique, prévision spatio-temporelle, machine learning, graph neural networks (GNN)*

1 Introduction

Le changement climatique accroît la fréquence et l’intensité des événements hydrologiques extrêmes, rendant essentielle une modélisation fiable des inondations pour l’anticipation des risques [5]. Les modèles hydrodynamiques physiques basés sur les équations de Saint-Venant offrent une description détaillée des écoulements, mais leur coût computationnel et leur dépendance au maillage limitent leur usage opérationnel [7]. Les réseaux de neurones artificiels (ANN) et les modèles empiriques de manière générale permettent des simulations rapides, mais souffrent d’une faible généralisation et d’une forte dépendance aux données d’entraînement [2]. Les réseaux de neurones à graphes (GNN) constituent une alternative prometteuse en intégrant explicitement les dépendances spatiales, notamment pour les dynamiques spatio-temporelles [6]. Des approches récentes combinant GNN et schémas numériques hydrauliques montrent un fort potentiel, mais restent majoritairement évaluées sur des cas synthétiques [1]. Dans cet article, nous proposons Hydro-GCN, un modèle spatio-temporel pour la simulation des inondations, inspiré de T-GCN [9]. Hydro-GCN est évalué avec succès sur un cas test d’un canal rectiligne synthétique.

2 Matériel et Méthode

2.1 Le modèle T-GCN

Le modèle T-GCN [9] représente le système étudié sous forme de graphe $G = (\mathbf{V}, \mathbf{E})$, où les nœuds correspondent aux entités spatiales (par exemple, les cellules d’un domaine hydraulique) et les arêtes encodent leurs interactions. À chaque instant t , chaque nœud est associé à un vecteur de caractéristiques, et l’ensemble de ces vecteurs forme la matrice d’entrée $\mathbf{X}_t \in \mathbb{R}^{N \times F}$, utilisée pour modéliser l’état spatio-temporel du système, où N désigne le nombre total de nœuds et F le nombre de variables ou de caractéristiques par nœud.

La couche GCN réalise une convolution sur graphe afin d’agréger, pour chaque nœud, ses propres caractéristiques et celles de son voisinage immédiat, selon la structure encodée par la matrice d’adjacence. Cette opération, normalisée par la matrice d’identité et incluant des boucles réflexives, permet d’apprendre des représentations spatiales cohérentes, reflétant la

propagation locale de l’information dans des systèmes maillés tels que les réseaux routiers ou les domaines hydrauliques.

Afin de modéliser l’évolution temporelle du système, le T-GCN combine l’agrégation spatiale des GCN avec une architecture récurrente de type GRU, capable de capturer les dépendances temporelles à court et long terme. À chaque instant, les représentations spatiales extraites par la couche GCN sont intégrées dans l’état caché du réseau récurrent, permettant une mise à jour dynamique et continue de la représentation temporelle du phénomène étudié.

Cette architecture hybride GCN–GRU permet un apprentissage end-to-end des dynamiques spatio-temporelles et offre de bonnes performances prédictives sur des systèmes dynamiques tels que les réseaux de trafic en minimisant une erreur quadratique moyenne par rétropropagation du gradient à travers le temps.

2.2 Le modèle HydroGCN

À partir de l’architecture T-GCN, nous avons développé un modèle destiné à prédire la hauteur d’eau à l’instant $T + 1$ sur un domaine hydraulique discrétisé et représenté sous forme de graphe, où chaque nœud correspond à une cellule du maillage. Le modèle utilise comme entrée les hauteurs d’eau (pour l’ensemble des nœuds) et les débits imposés aux nœuds amont, et s’appuie sur ses propres prédictions passées pour reconstruire la dynamique temporelle. Il prend en entrée un tenseur $\mathbf{X} \in \mathbb{R}^{T \times N \times F}$, où T représente la longueur de la séquence d’entrée — égale à 1 dans notre cas — et produit en sortie un vecteur $\mathbf{O} \in \mathbb{R}^{N \times 1}$ correspondant aux hauteurs d’eau prédites à l’instant suivant. Les différentes couches du modèles sont les suivantes :

Encodeur. Une couche entièrement connectée projette les caractéristiques d’entrée $\mathbf{X} \in \mathbb{R}^{N \times F}$ (hauteur d’eau et débit) vers un espace latent $\mathbf{H}_0 \in \mathbb{R}^{N \times d_h}$ via $\mathbf{H}_0 = \text{ReLU}(\mathbf{X}\mathbf{W}_e + \mathbf{b}_e)$, où $\mathbf{W}_e \in \mathbb{R}^{F \times d_h}$ et $\mathbf{b}_e \in \mathbb{R}^{1 \times d_h}$ sont appris, et d_h est le nombre de neurones dans la couche cachés. Cette couche augmente le nombre de paramètres du modèle et enrichit la représentation, compensant la faible capacité de la couche GCN seule. La fonction ReLU introduit la non-linéarité nécessaire pour mieux capturer les structures complexes des données.

Couche spatiale (GCN). Deux convolutions sur graphe successives sont appliquées pour mettre à jour les représentations des nœuds : $\mathbf{Z}_1 = \text{ReLU}(\text{GCN}(\mathbf{H}_0, \mathbf{A}))$, $\mathbf{Z}_2 = \text{GCN}(\mathbf{Z}_1, \mathbf{A})$, où \mathbf{H}_0 est la représentation latente issue de l’encodeur et \mathbf{A} la matrice d’adjacence du graphe. La première convolution avec ReLU introduit la non-linéarité, tandis que la seconde affine les représentations. Les expérimentations ont montré que deux applications suffisent à stabiliser la performance, les passages supplémentaires n’apportant aucun gain significatif.

Couche temporelle. Pour simplifier le modèle et en raison de séquences d’entrée courtes ($T = 1$), le RNN du T-GCN est remplacé par une couche entièrement connectée. Elle prend en entrée la concaténation de l’état précédent \mathbf{H} et de la sortie GCN \mathbf{Z}_2 : $\mathbf{Z} = \sigma([\mathbf{Z}_2 \parallel \mathbf{H}]\mathbf{W}_z + \mathbf{b}_z)$, où σ est la fonction sigmoïde et \mathbf{W}_z , \mathbf{b}_z sont les paramètres appris. Cette couche fusionne les informations spatiales et temporelles pour mettre à jour la représentation du système.

Décodeur. Une couche entièrement connectée génère la sortie finale : $\mathbf{O} = \tanh(\mathbf{Z}\mathbf{W}_d + \mathbf{b}_d)$, où $\mathbf{Z} \in \mathbb{R}^{N \times h_d}$ provient de la couche temporelle, $\mathbf{W}_d \in \mathbb{R}^{h_d \times 1}$ et $\mathbf{b}_d \in \mathbb{R}^{1 \times 1}$ sont les paramètres appris. La sortie $\mathbf{O} \in \mathbb{R}^{N \times 1}$ correspond aux hauteurs d’eau prédites pour chaque nœud. La fonction tanh garantit que les valeurs restent dans un intervalle approprié.

2.3 Cas test sur un canal rectiligne synthétique

Les données d’apprentissage ont été générées à l’aide du modèle à base physique SW2D [4, 3], une suite de modélisation hydrodynamique qui résout les équations shallow water 2D sur

maillages non structurés à l’aide d’un schéma aux volumes finis (<https://sw2d.inria.fr>). Nous avons évalué les performances du modèle *HydroGCN* sur un jeu de données synthétique généré par *SW2D* dans sa version 2D classique, i.e. sans porosité.

Le scénario de test repose sur une géométrie de $500\text{m} \times 150\text{m}$ avec trois niveaux de terrain : cours d’eau central, berge gauche $+0.5\text{ m}$ et berge droite $+1\text{m}$, en pente descendante le long du domaine (voir Figure 1). La discrétisation spatiale de *SW2D* utilise un maillage 3×10 cellules de 50 m de côté. Pour *HydroGCN*, ce domaine est représenté par un graphe de 30 nœuds en grille 3×10 , chaque nœud étant connecté uniquement à ses voisins directs (2, 3 ou 4 selon les nœuds).




FIG. 1 – Géométrie synthétique utilisée pour le test du modèle *HydroGCN*.

Un débit réaliste, issu de la rivière Severn, est appliqué à l’entrée (nœud 20), des conditions hauteur-débit à l’aval et des limites imperméables sur les autres bords. *SW2D* simule ensuite l’évolution des hauteurs d’eau, utilisées comme données d’apprentissage et de validation pour *HydroGCN*.

Les entrées (*features*) du modèle sont les hauteurs d’eau aux nœuds et le débit amont à l’instant t (ou sur les T derniers pas de temps si $T > 1$). Les sorties (*labels*) sont les hauteurs à $t + 1$. Le modèle adopte une approche auto-régressive : les prédictions à $t + 1$ sont réinjectées pour prédire $t + 2$. Une fois le modèle entraîné, seules les hauteurs initiales et les débits amont lui sont nécessaires pour estimer les niveaux futurs.

3 Résultats et Discussion

En utilisant une taille de couche cachée $h_d = 30$ et un batch de 256, le modèle *HydroGCN* atteint un score NSE de 0,9671 sur la période de validation et l’ensemble du domaine spatial, traduisant une bonne capacité de prédiction.

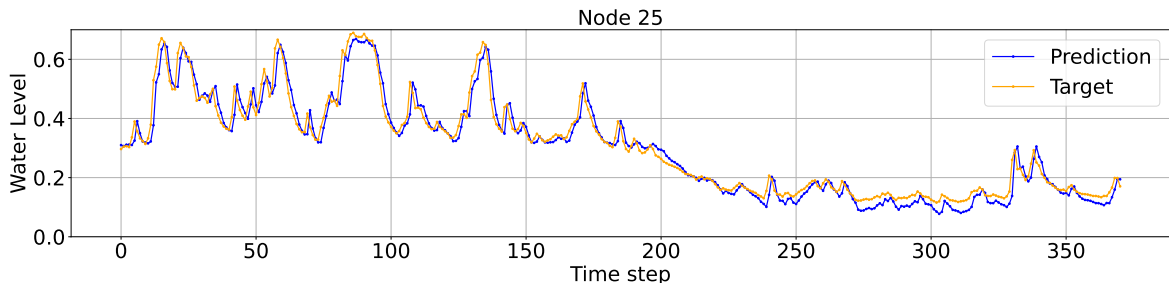


FIG. 2 – Niveaux d’eau prédits par *HydroGCN* au nœud n°25 (bleu) comparés aux données de référence (*SW2D*, orange). Un pas de temps correspond à 6 h.

La Figure (2) détaille cette évolution pour le nœud n°25 à titre d’exemple. Quelques écarts sont toutefois observables dans les zones de transition rapide ou lors de pics de variation ainsi que dans les périodes de basses eaux, où le modèle tend à légèrement lisser ou sous-estimer

les niveaux d'eau. Ces différences peuvent notamment s'expliquer par l'absence de conditions aux limites en aval pour le GNN, contrairement à SW2D, et par les effets d'inertie propres à l'architecture.

4 Conclusions et perspectives

Le modèle *HydroGCN* démontre sa capacité à prédire les hauteurs d'eau dans un domaine discret en capturant efficacement les dynamiques spatio-temporelles. Les résultats sur un cas synthétique montrent une bonne concordance avec les données de référence, bien que certaines variations locales rapides soient légèrement sous-estimées. Ces performances confirment la pertinence du modèle comme outil prédictif hydraulique, et justifient son test ultérieur sur un cas réel d'une plaine d'inondation d'un bassin versant.

Références

- [1] Bentivoglio, R., Isufi, E., Jonkman, S. N., Taormina, R., *Rapid spatio-temporal flood modeling via hydraulics-based graph neural networks*, Hydrology and Earth System Sciences, vol. 27, no. 23, pp. 4227–4246, Nov. 2023. <http://dx.doi.org/10.5194/hess-27-4227-2023>
- [2] Beven, K., *Rainfall-Runoff Modelling : The Primer*, Wiley, 2001, ISBN 9781119951001.
- [3] Caldas Steinstraesser, J.G. and Delenne, C. and Guinot, V. and Finaud-Guyot, P., Kahn Casapia, J.L. and Rousseau, A. *SimHydro 2021 : Models for complex and global water issues – Practices & expectations*, Jun 2021, Sophia Antipolis, France. pp.23 – 40. <https://hal.science/hal-03798534v2>
- [4] Guinot, V., Delenne, C., Rousseau, A., Boutron, O., *Flux closures and source term models for shallow water models with depth-dependent integral porosity*, Advances in Water Resources, vol. 109, pp. 133–157, 2018. <https://hal.science/hal-01582224>
- [5] Intergovernmental Panel on Climate Change (IPCC), *Climate Change 2021 : The Physical Science Basis. Summary for Policymakers*, Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change, IPCC, 2021. <https://www.ipcc.ch/report/ar6/wg1/>
- [6] Scarselli, F., Gori, M., Tsoi, A. C., Hagenbuchner, M., Monfardini, G., *The Graph Neural Network Model*, IEEE Transactions on Neural Networks, vol. 20, no. 1, pp. 61–80, 2009. <https://doi.org/10.1109/TNN.2008.2005605>
- [7] Teng, J., Jakeman, A.J., Vaze, J., Croke, B.F.W., Dutta, D., Kim, S., *Flood inundation modelling : A review of methods, recent advances and uncertainty analysis*, Environmental Modelling & Software, vol. 90, pp. 201–216, Apr. 2017, Elsevier BV, ISSN 1364-8152. <http://dx.doi.org/10.1016/j.envsoft.2017.01.006>
- [8] Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., Yu, P. S., *A comprehensive survey on graph neural networks*, IEEE Transactions on Neural Networks and Learning Systems, vol. 32, no. 1, pp. 4–24, 2020, IEEE.
- [9] Zhao, L., Song, Y., Zhang, C., Liu, Y., Wang, P., Lin, T., Deng, M., Li, H., *T-GCN : A Temporal Graph Convolutional Network for Traffic Prediction*, IEEE Transactions on Intelligent Transportation Systems, vol. 21, no. 9, pp. 3848–3858, 2020. <https://doi.org/10.1109/TITS.2019.2935152>