

# Evaluation et Analyse explicative d'un modèle de prévision pluie-débit basé sur un Multilayer-Perceptron (MLP), dans le cas de la rivière Sisaony, à Madagascar

Hanitriniaina Marielle RAKOTOZANANY<sup>1</sup>, Pierre NICOLLE<sup>2</sup>, Josué RATOVONDRAHONA<sup>1</sup>,  
Bob E. SAINT-FLEUR<sup>2</sup>, Andry RAZAKAMANANTSOA<sup>3</sup>,  
Samuel RAZANAKA<sup>4</sup>, Thomas MAHATODY<sup>1</sup>, Olivier PAYRASTRE<sup>2</sup>

<sup>1</sup> Université de Fianarantsoa, LIMAD, BP-1264 Fianarantsoa, Madagascar

<sup>2</sup> Univ Gustave Eiffel, GERS-LEE, F-44344 Bouguenais, France

<sup>3</sup> Univ Gustave Eiffel, GERS-GIE, F-44344 Bouguenais, France

<sup>4</sup> Centre National de Recherche pour l'Environnement, BP-1739 Antananarivo, Madagascar

## Résumé

*Cette étude évalue les performances d'un modèle pluie-débit basé sur un Multilayer Perceptron (MLP), complétée par une analyse d'explainable Artificial Intelligence (XAI) une approche fondée par la perturbation. Le modèle MLP prédit le débit instantané horaire de la rivière Sisaony, Madagascar. Les résultats d'évaluation montrent que le MLP est performant, en particulier pour les horizons longs. L'analyse du modèle par perturbation montre également que le comportement du modèle est cohérent avec les principes physiques de la relation hydrologique pluie-débit.*

## Mots-clés

*MLP, XAI, approche de perturbation, pluie-débit, rivière Sisaony.*

## Abstract

*This study evaluates the performance of a rainfall-runoff model based on a Multilayer Perceptron (MLP), supplemented by an Explainable Artificial Intelligence (XAI) analysis using a perturbation-based approach. The MLP model predicts the hourly instantaneous discharge of the Sisaony River in Madagascar. The evaluation results show that the MLP performs well, particularly for long-term forecasts. Analysis of the model using perturbation theory also shows that the behavior of the model is consistent with the physical principles underlying the rainfall-discharge relationship.*

## Keywords

*MLP, XAI, perturbation-based approach, rainfall-runoff, Sisaony River.*

## 1 Introduction

Avec l'essor de l'intelligence artificielle, Deep learning s'est imposé comme des outils puissants capables d'extraire automatiquement des relations complexes à partir de grandes bases de données, notamment pour des phé-

nomènes non linéaires. Il occupe une place importante dans la résolution de problèmes liés à l'environnement, mais ces modèles présentent comme limites une interprétabilité réduite [1, 2]. Dans le domaine de l'hydrologie, par exemple, les modèles de deep learning appliqués à la prévision hydrologique sont performants mais considérés comme des modèles "boîte noire" [3]. Dans cette étude, nous avons mis en place un modèle basé sur le deep learning, plus spécifiquement le Multilayer Perceptron (MLP), pour prévoir les débits de crue d'un cours d'eau. Pour maintenir une certaine transparence du modèle, nous avons combiné cette approche à l'utilisation de la technique XAI (Explainable Artificial Intelligence), l'approche de perturbation, pour interpréter le modèle afin de comprendre les paramètres qui influencent le plus le modèle de prédiction. Comme étude de cas, nous avons sélectionné une rivière, la Sisaony, délimitée par la carte à la figure 1, qui traverse la ville d'Antananarivo Madagascar, et qui permet de disposer des historiques d'observations horaires de précipitations et de débits passés. Compte tenu l'exposition de la ville aux risques d'inondation, Antananarivo dispose en effet d'un organisme chargé de la protection contre les inondations, l'Autorité pour la Protection contre les Inondations de la Plaine d'Antananarivo (APIPA), qui gère un système d'annonce de crue basé sur un réseau permanent d'observations pluviométriques et débitmétriques. L'APIPA ne dispose pas en revanche de modèle de prévision hydrologique, l'annonce de crues reposant principalement sur l'expérience des prévisionnistes, ainsi que sur l'analyse et l'observation des événements passés. Cette approche montre toutefois des limites dans une ville régulièrement touchée par les inondations, notamment en cas de rupture de digue.

Dans cette étude, les historiques de données d'observation de l'APIPA ont été mobilisées pour l'apprentissage et l'évaluation de modèles MLP prédisant les débits de crue de la Sisaony à plusieurs horizons (3h, 6h, 9h, 12h, 18h ou 24h). Les performances de ce modèle MLP ont été comparées à un modèle de prévision pluie-débit de type GRP [9], très

utilisé pour la prévision des crues en France. L'association d'un modèle basé sur le deep learning et d'approches XAI a par ailleurs permis d'analyser la nature des dépendances apprises par le modèle, afin de vérifier s'il repose principalement sur une dynamique autorégressive ou s'il capture effectivement les relations non linéaires complexes entre les variables hydrométéorologiques.

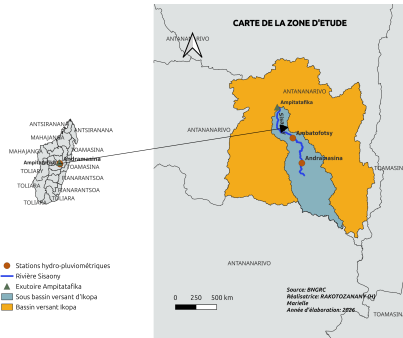


FIGURE 1 – Carte du bassin versant de la rivière Sisaony à Ampitatafika, montrant les stations hydro-pluviométriques situées en amont à Andramasina et Ambatofotsy, ainsi que la station hydrométrique à l'exutoire. La surface drainée du bassin est de  $726 \text{ km}^2$

## 2 Méthodologie

### 2.1 Données

Un ensemble de données hydrométéorologiques horaires, sur la période 2002 à 2008, a été collecté et utilisé pour alimenter les modèles de prévision de débits hydrologiques. Ces données comprennent les variables suivantes : la précipitations  $P$  : issues des stations pluviométriques locales de l'APIPA et moyennées sur le bassin versant de la rivière Sisaony à Ampitatafika à l'aide de la méthode de polygone de Thiessen ; l'évapotranspiration potentielle  $ETP_1$  calculée à partir des données de température extraites de la NASA POWER, en utilisant la méthode de Thornthwaite modifiée [6], l'évapotranspiration potentielle  $ETP_2$  calculée à partir des données de température, extraites de la NASA POWER, en utilisant la méthode d'Oudin [5] ; le débit brut instantané  $Q$  mesuré au pas de temps horaire à la station d'Ampitatafika de l'APIPA sur la rivière Sisaony ( $726 \text{ km}^2$  de surface drainée). Ces données représentent la variable cible à prédire dans le modèle pluie-débit. Après vérification, ces données présentent quelques valeurs manquantes sur certaines périodes. Ces périodes de lacunes ont été reconstituées avec un modèle hydrologique traditionnel GR4H [7] car le résultat de la simulation de débit de ce modèle suit mieux la tendance des données de débits observés.

### 2.2 Développement du modèle MLP

#### 2.2.1 Variables d'entrée utilisées

Pour estimer le débit  $Q(t)$  à un instant  $t$ , nous considérons que le débit dépend des précipitations  $P(t-i)$  et de l'évapotranspiration potentielle  $ETP(t-i)$  observées sur un historique de données ( $1 \leq i \leq p$ ), ainsi que du débit passé  $Q(t-j)$  ( $h \leq j \leq p$ ).  $p$  correspond à la fenêtre tempo-

relle de données prise en compte par le modèle : une fenêtre temporelle glissante de 10 jours consécutifs (soit  $p=240$  heures) a été utilisée ici.  $h$  correspond à l'horizon de prévision considéré, soit  $h \in \{3h, 6h, 9h, 12h, 18h, 24h\}$ . Pour chaque horizon de prévision  $h$ , le modèle apprend une relation de la forme :  $Q(t) = f(Q(t-j), P(t-i), ETP_1(t-i), ETP_2(t-i))$  où  $P(t-i)$  et  $ETP_n(t-i)$  (1). Les modèles utilisent donc les informations pluviométriques et d'ETP jusqu'à l'instant  $t$ . Pour réaliser de véritables prévisions avec ces modèles, il faut donc être en mesure d'effectuer des prévisions de pluie et d'ETP sur la période  $[t-h; t-i]$ . Dans un premier temps, les données observées ont été utilisées ici, ce qui permet de s'affranchir des incertitudes associées aux prévisions météorologiques.

#### 2.2.2 Découpage de données

Le tableau 1 présente en détail les périodes utilisées pour l'apprentissage et le test des données.

TABLE 1 – Périodes temporelles utilisées pour l'apprentissage et l'évaluation des modèles

Variables d'entrées	Variables cibles	Apprentissage/Validation	Test
Précipitation, ETP Oudin, ETP Thornthwaite, Débit brut reconstitué avec GR4H	Débit brut reconstitué avec GR4H	Début : 11/01/2002 00 :00 Fin : 10/08/2007 13 :00	Début : 10/08/2007 14 :00 Fin : 31/12/2008 23 :00

#### 2.2.3 Architecture et implémentation du modèle MLP

Un MLP est défini comme un réseau neuronal artificiel composé de trois (3) couches connectées : une couche d'entrée (input layer) qui reçoit les données d'entrée, une ou plusieurs couches cachées (hidden layers) qui contiennent un nombre variable de neurones connectés à tous les neurones de la couche précédente et de la suivante, et une couche de sortie (output layer) qui produit les valeurs de sortie [4]. Pour la création du modèle MLP, les valeurs suivantes d'hyperparamètres ont été retenus après une série de tests de sensibilité : trois (3) couches cachées (120-90-60 neurones), la fonction d'activation  $ReLU$ , la fonction d'optimisation  $Adam$ , la fonction coût  $MSE$ , le taux d'apprentissage 0.001, l'itération max 200. Pour chaque horizon de prévision  $h$  ( $3h, 6h, 9h, 12h, 18h$  et  $24h$ ), un modèle MLP distinct, partageant la même architecture et les mêmes hyperparamètres, a été entraîné séparément.

### 2.3 Le modèle GRP utilisé comme référence

Le modèle GRP est un modèle hydrologique de prévision, se servant des données des pluies disponibles sur un bassin versant pour calculer les débits à son exutoire. GRP est actuellement utilisé par une grande partie des Services de Prévisions de Crues (SPC) français [9]. GRP a une structure à réservoir construite sur trois modules : modèle d'accumulation et de fonte de la neige, le module de production et le module de transfert. Le critère de calage (apprentissage) pour GRP est l'erreur quadratique moyenne à l'horizon  $H$

(RMSEH).

## 2.4 Critères utilisés pour l'évaluation et la comparaison des modèles

Deux critères ont été utilisés, pour l'apprentissage et le test des modèles : le critère de Nash-Sutcliffe (NSE) et le score de persistance. NSE est défini par la formule (2) :

$$NSE = 1 - \frac{\sum_{t=1}^n (Q_o^t - Q_m^t)^2}{\sum_{t=1}^n (Q_o^t - \bar{Q}_o)^2} \quad (2) \text{ où } Q_o^t \text{ et } Q_m^t \text{ sont respectivement les débits observés et simulés (ou prévus) à l'instant } t, \text{ et } \bar{Q}_o \text{ est la moyenne des débits observés. Le critère de persistance est défini par la formule (3) suivante :}$$

$PI = \frac{\sum_{i=1}^{n-H} (Q_t^{obs} - Q_t^{prev})}{\sum_{i=1}^{n-H} (Q_t^{obs} - Q_{t-h}^{obs})} \quad (3) \text{ avec } Q_i^{prev} \text{ le débit prévu au pas de temps } i \text{ et } h \text{ l'horizon de prévision (exprimé en nombre de pas de temps). Une valeur (NSE ou persistance) proche de 1 indique une excellente correspondance entre les données simulées et observées, tandis qu'une valeur inférieure à 0 indique que le modèle est moins performant qu'une simple moyenne constante.}$

$PI = \frac{\sum_{i=1}^{n-H} (Q_t^{obs} - Q_t^{prev})}{\sum_{i=1}^{n-H} (Q_t^{obs} - Q_{t-h}^{obs})} \quad (3) \text{ avec } Q_i^{prev} \text{ le débit prévu au pas de temps } i \text{ et } h \text{ l'horizon de prévision (exprimé en nombre de pas de temps). Une valeur (NSE ou persistance) proche de 1 indique une excellente correspondance entre les données simulées et observées, tandis qu'une valeur inférieure à 0 indique que le modèle est moins performant qu'une simple moyenne constante.}$

## 2.5 Analyse explicative du modèle pluie-débit MLP

L'importance des variables a été évaluée à l'aide d'une méthode de perturbation consistant à remplacer successivement chaque variable explicative soit par la valeur zéro, soit par sa moyenne. Cette approche permet d'analyser la sensibilité du modèle à différentes entrées en quantifiant la baisse de ses performances. L'analyse est réalisée à deux niveaux de granularité : l'importance par groupe de variables et l'importance individuelle, et ce pour plusieurs horizons de prévision (de 3 à 24 heures).

## 3 Résultats

### 3.1 Évaluation des modèles

Les tableaux 2 et 3 présentent respectivement les scores de NSE et de persistance obtenus par les deux modèles MLP et GRP, pour les différents horizons de prévision.

Le modèle MLP atteint des scores NSE très élevés, en particulier pour les horizons courts (3h à 6h), où les valeurs dépassent 0,95 en apprentissage et en test (jusqu'à 0,98). Cela traduit une excellente capacité à reproduire les débits observés et une forte stabilité du modèle. Pour les horizons intermédiaires (9h–12h), les scores restent élevés (0,84–0,94 en test), confirmant une bonne performance du modèle. En comparaison, le modèle GRP présente également de bonnes performances, mais légèrement inférieures à celles du MLP, notamment pour les horizons longs (HP 24h–18h), où les scores chutent en phase de test autour de 0,66–0,74, contre 0,73–0,78 pour le MLP.

L'analyse du score de persistance confirme que le MLP reste globalement plus performant que le GRP, notamment pour les horizons longs (0,32–0,47, en validation contre 0,26–0,33 pour le GRP). Toutefois, les performances déclinent rapidement lorsque l'horizon se raccourcit, avec des scores proches de zéro pour l'horizon 3h, indiquant qu'aucun des modèles n'arrive à surpasser efficacement la persis-

tance sur cet horizon courts. Ceci conduit à relativiser fortement le pouvoir prédictif des modèles pour cet horizon.

TABLE 2 – Comparaison des score NSE des modèles MLP et GRP selon l'horizon de prévision

Horizon	MLP		GRP	
	Apprentissage	test	Apprentissage	test
3h	0.9814	0.9768	0.9865	0.9772
6h	0.9621	0.9479	0.9623	0.9366
9h	0.9482	0.8937	0.9376	0.8872
12h	0.9347	0.8517	0.9149	0.8334
18h	0.9126	0.7597	0.8824	0.7381
24h	0.9061	0.7348	0.8597	0.6633

TABLE 3 – Comparaison des scores de persistance des modèles MLP et GRP selon l'horizon de prévision

Horizon	MLP		GRP	
	Apprentissage	Test	Apprentissage	Test
3h	0.2977	0.0288	0.2441	0.0450
6h	0.4695	0.2635	0.3832	0.1044
9h	0.5959	0.2108	0.4702	0.1624
12h	0.6538	0.2900	0.5275	0.2023
18h	0.7124	0.3269	0.6050	0.2664
24h	0.7685	0.4723	0.6506	0.3301

### 3.2 Analyse explicative du modèle pluie-débit MLP

Les tableaux 4 et 5 présentent les résultats de l'analyse explicative du modèle pluie-débit basé sur MLP par l'approche de perturbation. La variable de débit passé (Q) apparaît comme la plus influente, avec des valeurs d'importance systématiquement plus élevées en valeur absolue, en particulier pour les horizons courts et intermédiaires, ce qui confirme son rôle structurant dans la dynamique du modèle pluie-débit.

TABLE 4 – Évaluation de l'importance des variables à l'aide d'une approche fondée sur la perturbation, consistant à remplacer chaque variable par zéro.

Horizons	Apprentissage			
	P	ETP1	ETP2	Q
3h	0,001	-0,017	-0,008	-0,381
6h	-0,005	-0,019	-0,047	-0,404
9h	-0,028	-0,0349	-0,027	-0,34
12h	-0,053	-0,060	-0,056	-0,343
18h	-0,015	0,007	0,002	-0,080
24h	-0,105	-0,168	-0,202	-0,176
Test				
Horizons	P	ETP1	ETP2	Q
3h	-0,012	-0,05	-0,026	-0,504
6h	-0,037	-0,024	-0,024	-0,571
9h	-0,043	-0,058	0,024	-0,508
12h	-0,076	0,014	0,075	-0,533
18h	-0,015	0,054	0,05	-0,099
24h	-0,208	0,026	0,138	-0,412

TABLE 5 – Évaluation de l’importance des variables à l’aide d’une approche fondée sur la perturbation, consistant à remplacer chaque variable par sa moyenne.

Apprentissage				
Horizons	P	ETP1	ETP2	Q
3h	0	0,008	0,005	-0,279
6h	-0,004	-0,004	-0,005	-0,327
9h	-0,023	-0,009	-0,007	-0,252
12h	-0,052	-0,026	-0,029	-0,215
18h	-0,172	-0,046	-0,055	-0,223
24h	-0,1	-0,044	-0,074	-0,144
Apprentissage				
Horizons	P	ETP1	ETP2	Q
3h	-0,012	-0,027	-0,019	-0,35
6h	-0,033	-0,024	-0,016	-0,432
9h	-0,035	0,003	0,023	-0,328
12h	-0,061	0,012	0,018	-0,273
18h	-0,144	-0,002	0,009	-0,247
24h	-0,192	0,055	0,047	-0,179

Les précipitations (P) montrent une influence plus marquée aux horizons longs (24h et 18h), tandis que leur impact diminue progressivement lorsque l’horizon de prévision se rapproche de 3h. Les variables d’évapotranspiration (ETP1 et ETP2) présentent une contribution globalement plus faible et plus instable, avec des valeurs proches de zéro dans plusieurs configurations, ce qui suggère une influence secondaire dans la prédiction. La comparaison entre les deux méthodes de perturbation montre que le remplacement par la moyenne conduit à des amplitudes d’importance légèrement atténuées mais conserve les mêmes tendances globales, ce qui renforce la robustesse des conclusions sur le rôle relatif des variables dans le modèle MLP.

## 4 Conclusion

L’étude démontre que le MLP constitue une méthode robuste pour la prévision des débits hydrologiques à horizons multiples, dont les performances s’avèrent au moins équivalentes à celles d’un modèle pluie-débit GRP lorsque les jeux de données d’apprentissage utilisés portent sur plusieurs années hydrologiques consécutives. L’analyse des modèles MLP identifie bien le débit passé comme variable dominante. Ceci confirme que le MLP propose une interprétation des relations entre variables cohérente avec la physique de la relation pluie-débit. Comme perspectives, pour renforcer la capacité prédictive et capturer les dépendances temporelles plus complexes portant sur une fenêtre temporelle dépassant les 10jours, l’utilisation de modèles séquentiels tels que LSTM ou de modèles basés sur Transformer [8] pourrait être explorée avec une analyse explicative des modèles par XAI de type SHAP (Shapley Additive exPlanations). Par ailleurs, l’intégration de données pluviométriques issues de satellites permettrait de tester le pouvoir prédictif des modèles de deep learning dans des contextes de données moins favorables, en particulier dans les zones non couvertes par les réseaux pluviométriques au sol, et où

les observations débitométriques ne sont disponibles qu’à des pas de temps de 12 ou 24h.

## Remerciements

Les auteurs remercient l’APIPA pour la fourniture des jeux de données nécessaires à ce travail. Ils remercient également le projet MADATLAS pour le financement de cette recherche, ainsi que Jean Donnée Rasolofoniaina pour son aide précieuse dans le développement du modèle.

## Références

- [1] C. Chen, Y. Liu, X. Sun, C. D. Cairano-Gilfedder, and S. Titmus. Automobile maintenance prediction using deep learning with gis data. *Procedia CIRP*, 81 :447–452, 2019.
- [2] A. W. Kiwelekar, G. S. Mahamunkar, L. D. Netak, and V. B. Nikam. Deep learning techniques for geospatial data analysis. In G. A. Tsihrantzis and L. C. Jain, editors, *Machine Learning Paradigms : Advances in Deep Learning-based Technological Applications*, pages 63–81. Springer International Publishing, Cham, 2020.
- [3] F. Kratzert, D. Klotz, C. Brenner, K. Schulz, and M. Herrnegger. Rainfall–runoff modelling using long short-term memory (Lstm) networks. *Hydrology and Earth System Sciences*, 22(11) :6005–6022, 2018.
- [4] M. Mohseni-Dargah, Z. Falahati, B. Dabirmanesh, P. Nasrollahi, and K. Khajeh. Machine learning in surface plasmon resonance for environmental monitoring. In *Artificial Intelligence and Data Science in Environmental Sensing*, pages 269–298. Academic Press, 2022.
- [5] L. Oudin et al. Which potential evapotranspiration input for a lumped rainfall-runoff model? part 2 : Towards a simple and efficient potential evapotranspiration model for rainfall-runoff modelling. *Journal of Hydrology*, 303(1–4) :290–306, 2005.
- [6] A. R. Pereira and W. O. Pruitt. Adaptation of the thornthwaite scheme for estimating daily reference evapotranspiration. *Agricultural Water Management*, 66(3) :251–257, 2004.
- [7] C. Perrin, C. Michel, and V. Andréassian. Modèles hydrologiques du génie rural (gr).
- [8] Alain Josué Ratovondrahona, Hanitriniaina Marielle Rakotozanany, Thomas Mahatody, and Victor Manantsoa. Human like programming using spade bdi agents and the gpt-3-based transformer. *Proceedings of the AHFE International Conference on Human Interaction and Emerging Technologies*, 2023.
- [9] F. Tilmant et al. Calage et application opérationnelle du modèle de prévision de crue grp - manuel d’utilisation (v2022.r3046), 2023. 93 pages, août 2023.