

## L'intelligence artificielle au service de la radioprotection

Valérie Nicoulaud-Gouin<sup>(1)</sup>, Taha Hamadene<sup>(1)</sup>, Frédérique Eyrolle<sup>(1)</sup>, Hugo Lepage<sup>(2)</sup>, Kathleen Pelé<sup>(1)</sup>

<sup>(1)</sup>ASNR/DREE/STAAR/LRTA ; <sup>(2)</sup>ASNR/DREE/SERPEN/LESE

valerie.nicoulaudgouin@asnr.fr

L'intelligence artificielle (IA) désigne les méthodes algorithmiques qui exploitent des ensembles de données pour apprendre les comportements d'un phénomène étudié afin de pouvoir réaliser des prédictions. L'apprentissage profond (Deep Learning) est une des branches de l'IA qui se caractérise notamment par les réseaux de neurones. Ces réseaux sont inspirés du fonctionnement du cerveau humain, composé de couches de nœuds interconnectés dits « neurones » pour traiter et analyser des données. Chaque neurone reçoit des informations, les traite et les transmet aux autres couches pour rendre l'information plus compréhensible, permettant ainsi au réseau d'apprendre des relations complexes à partir de jeux de données. Il existe une grande variété de réseaux de neurones, chacun étant adapté à des types spécifiques de tâches.

A l'ASNR, nous évaluons/étudions la pertinence de cette approche pour répondre à des problématiques de radioprotection. Plusieurs architectures de réseaux ont ainsi été développées pour apporter une réponse aux problématiques suivantes :

- Proposer une meilleure modélisation des concentrations de matières en suspension dans les cours d'eau,
- Aider la détection d'anomalies de concentration en <sup>137</sup>Cs dans les aérosols,
- Reconstruire et prédire les grandes tendances des concentrations de contaminants dans les sédiments aux exutoires des grands fleuves de France (ANR Trajectoire).

La qualité (et le nombre) des données environnementales disponibles représente l'un des principaux défis de l'IA dans l'exploitation de celles-ci. Nous avons ainsi mis en place deux solutions pour répondre à cet enjeu : le transfert de connaissance (transfer learning) et la génération de données.

Par ailleurs, il peut parfois être compliqué de comprendre et de donner un sens physique aux résultats de ces réseaux qui restent des boîtes noires. L'analyse de sensibilité permet de mieux connaître les données les plus influentes dans les prédictions obtenues et a été effectuée par les indices de Shapley.

Les travaux présentés ici restituent ces différents développements et leur application.

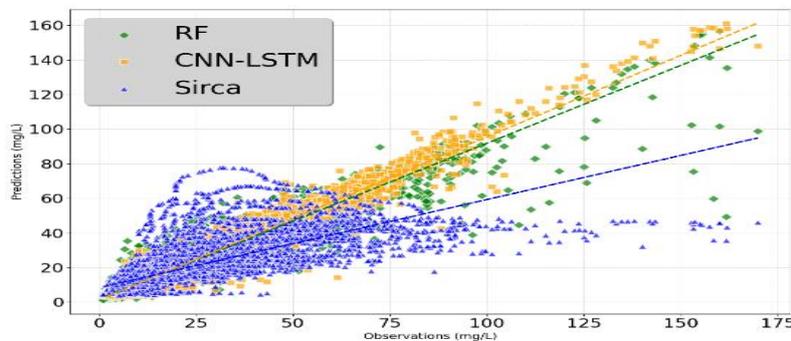
### L'IA en tant qu'architecte des données :

#### Alternative à la modélisation de la dynamique des matières en suspension dans les affluents du Rhône

La compréhension de la dynamique des matières en suspension (MES) dans les rivières est un élément clé pour mieux appréhender le transport des contaminants, notamment les radionucléides. Dans le contexte du Rhône, cette problématique est particulièrement importante compte tenu de la présence de plusieurs installations nucléaires rejetant dans le bassin. Les flux de MES par les affluents du Rhône sont donc essentiels à quantifier. L'Observatoire des Sédiments du Rhône (OSR), dans lequel l'ASNR est partenaire scientifique, a pu recueillir sur les principaux affluents du Rhône (Drôme, Durance, Ain, Saône,

Fier, Bourbre, Arve et Isère) entre 3000 et 60000 données horaires renseignant les concentrations des MES sur les quatre à dix dernières années.

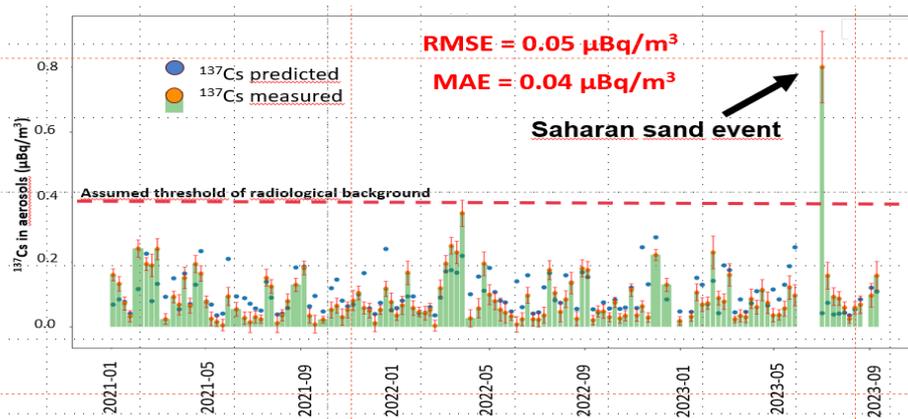
Afin de quantifier les flux solides et combler les lacunes de mesures, les travaux de l'OSR utilisent un modèle empirique, SiRCA, basé sur une analyse des points de rupture et de changement dans les relations charge/débit. Toutefois, cette approche se révèle encore trop imprécise dans certaines études en particulier pour les conditions d'étiage ou de crue. Des approches par réseau neuronal ont déjà été développées pour prédire les concentrations de MES à pas de temps journalier (Li et al. 2022). Mais pour mieux comprendre et mieux prendre en compte les dépendances temporelles des données horaires, le réseau de neurones **CNN-LSTM a été implémenté**. Il est une combinaison de **réseau convolutif CNN** filtrant les données de débits et de précipitations, et de **réseau récurrent de type LSTM** régulant le flux d'information et les conservant sur de longues périodes. Ce réseau a la capacité de prendre en compte des séquences d'observations décalées des données d'entrée pour capturer les dépendances temporelles. Le modèle CNN-LSTM surpasse le modèle empirique SiRCA, avec des R<sup>2</sup> (coefficient de détermination) autour de 0.9 (au lieu des 0.5 à 0.7 pour SiRCA) (Figure 1).



**Figure 1 : Prédiction des concentrations dans les MES sur la Saône en fonction des mesures pour les modèles de forêt aléatoire (RF), CNN-LSTM et SiRCA**

Aider la détection d'anomalies de concentration en <sup>137</sup>Cs dans les aérosols

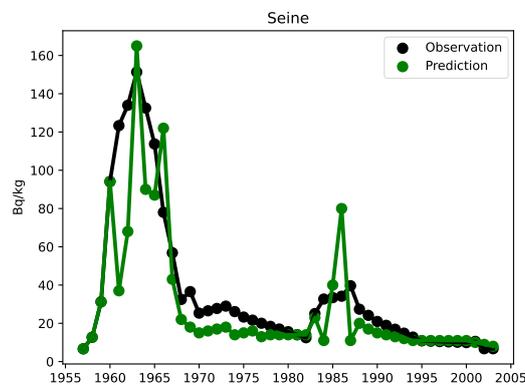
Depuis le siècle dernier, l'environnement français (sol, eau, air) est marqué par la présence de <sup>137</sup>Cs, émis notamment lors des essais atmosphériques et de l'accident de Tchernobyl. Sa présence aujourd'hui dans les aérosols est en partie contrôlée par les conditions météorologiques (précipitation, origine des masses d'air...) qui peuvent faire varier les concentrations sur un ordre de grandeur. Afin d'évaluer si les concentrations mesurées lors de la surveillance de l'environnement sont proches des valeurs de référentiel attendues, un réseau neuronal alliant des **couches de convolution CNN**, et un **réseau récurrent de type GRU (Gated Recurrent Unit)**, a été développé. L'originalité de ce réseau réside dans l'**architecture « many-to-one »**, prenant plusieurs points (spatiaux et temporels) de données météorologiques en entrée et générant une seule sortie de concentration dans les aérosols. Il a été appliqué aux mesures d'Orsay et d'Houdelaincourt avec un RMSE (racine carrée de l'erreur quadratique moyenne) de l'ordre de 0.05 µBq/m<sup>3</sup> et 0.07 µBq/m<sup>3</sup> respectivement (Figure 2).



**Figure 2 : Prédiction du bruit de fond radiologique en  $^{137}\text{Cs}$  dans les aérosols à Orsay sur la base de test.**

Reconstruire et prédire les grandes tendances annuelles des concentrations de contaminants dans les sédiments à l'exutoire des grands fleuves de France.

En radioprotection, il est essentiel de comprendre le devenir des radionucléides et les capacités de résilience à long terme des milieux récepteurs. L'un des objectifs du projet **Trajectoire** était de reconstruire un siècle de concentration de  $^{137}\text{Cs}$  dans les rivières françaises nucléarisées à l'aide d'archives sédimentaires et de prédire l'évolution des concentrations à venir à partir de scénario de changement climatique. Pour répondre à cet enjeu, le réseau de neurones encodeur-décodeur **HRHN a été implémenté** (Pelé et al. 2024). Il comporte des **couches de convolution (CNN)**, des **réseaux récurrents (RHN)** mais également des **couches d'attention**. La reconstruction des chroniques passées conduit par exemple à des RMSE de 13 Bq/kg pour la Seine à 65 Bq/kg pour le Rhin (Figure 3).



**Figure 3 : Prédiction des concentrations en  $^{137}\text{Cs}$  dans les sédiments sur la Seine, par le modèle HRHN et mesures de l'archive sédimentaire associée**

**Rareté des données environnementales : génération de données et transfer learning:**

Que ce soit pour la modélisation des concentrations de MES, ou pour l'exploitation des archives sédimentaires du projet Trajectoire, nos travaux se sont parfois heurtés à des jeux de données trop limités ne permettant pas de produire des résultats suffisamment robustes. Nous avons donc mis en place deux approches pour améliorer la qualité des prédictions des réseaux :

- La **technique de génération de données** s'effectue sur les données qui vont servir de base d'apprentissage du réseau (Iwana, 2021). Elle s'effectue en sélectionnant

aléatoirement des portions de données dans le jeu de données et en y ajoutant du bruit pour les réintégrer par la suite aux données d'origine. Cette méthode a été notamment utilisée pour l'apprentissage du réseau HRHN.

- Le **transfer learning** est une technique où un modèle pré-entraîné sur une tâche donnée est réutilisé ou adapté pour une autre tâche plus spécifique (Xu et al. 2023). Cela permet de tirer parti des connaissances acquises sur un grand ensemble de données pour accélérer l'entraînement ou améliorer les performances sur un ensemble plus spécifique et souvent plus petit. Cette technique a été utilisée pour prédire les concentrations de MES de l'Ardèche par le modèle CNN-LSTM. Afin de sélectionner le bassin versant le mieux adapté pour effectuer le transfer learning, une approche par **carte auto-organisatrice (SOM)** via le réseau de neurones **Kohonen** a été utilisée (Kohonen, 2001). Il s'agit d'un type de réseau de neurones non supervisé qui projette des données de haute dimension sur une grille de faible dimension tout en préservant leurs relations topologiques, facilitant ainsi la visualisation et le regroupement des données. Ainsi, il a été possible d'obtenir une modélisation des concentrations dans les MES de l'Ardèche ne comportant que 80 mesures valides à partir d'une modélisation sur le bassin versant de la Durance.

## Vers l'intelligibilité des modèles basées sur les données ou IA explique toi !

Les méthodes de Deep Learning sont parfois tellement complexes qu'elles deviennent des boîtes noires et perdent en explicabilité. L'analyse de sensibilité évalue l'impact des variations des paramètres d'entrée sur les résultats d'un modèle. Elle permet d'identifier les variables les plus influentes et de mieux comprendre le fonctionnement ou la robustesse des réseaux de neurones. Pour nos trois études, la méthode d'analyse de sensibilité retenue est celle basée sur les indices de **Shapley** (Aas et al. 2021). Ces indices permettent de mesurer l'importance de chaque variable dans un modèle en calculant sa contribution moyenne aux résultats. Chaque valeur Shapley indique dans quelle mesure une caractéristique contribue à augmenter ou diminuer la prédiction. Une valeur positive signifie que la caractéristique a augmenté la valeur de la prédiction, tandis qu'une valeur négative indique qu'elle a abaissé la valeur de la prédiction. L'importance de chaque variable est mesurée de manière équitable en tenant compte de toutes les combinaisons possibles de variables, offrant ainsi une vue transparente et précise de l'influence de chaque facteur.

## Références

K. Aas, M. Jullum, A. Løland, 2021, Explaining individual predictions when features are dependent: More accurate approximations to Shapley values, *Artificial Intelligence*, 103502.

B. K. Iwana, S. Uchida, 2021, An empirical survey of data augmentation for time series classification with neural networks, *Public Library of Science*.

T. Kohonen, 2001, *Self-Organizing Maps*, Springer-Verlag, Berlin.

S. Li, Q. Xie, J. Yang, 2022, Daily suspended sediment forecast by an integrated dynamic neural network, *Journal of Hydrology*, 127258.

Pele, K., Nicoulaud-Gouin, V., and Lepage, H., 2024. A neural network encoder-decoder for time series prediction: Application on 137Cs particulate concentrations in nuclearized rivers. *Ecological Informatics*, 102463.

Y. Xu, K. Lin, C. Hu, S. Wang, Q. Wu, L. Zhang, G. Ran, 2023, Deep transfer learning based on transformer for flood forecasting in data-sparse basins, *Journal of Hydrology, Part A*, 129956.