

Restitution du projet MUFFINS
09/06/2026

**Modélisation hydrologique hybride physique–IA
spatialement distribuée**


*Ngo Nghi Truyen Huynh, Pierre-André Garambois, François Colleoni, Benjamin Renard,
Mouad Ettalbi, Ngoc Bao Nguyen, Jérôme Monnier, Hélène Roux, et al.*

Modèle pluie-débit




Données météo, direction d'écoulement, etc.

\mathcal{M} ?




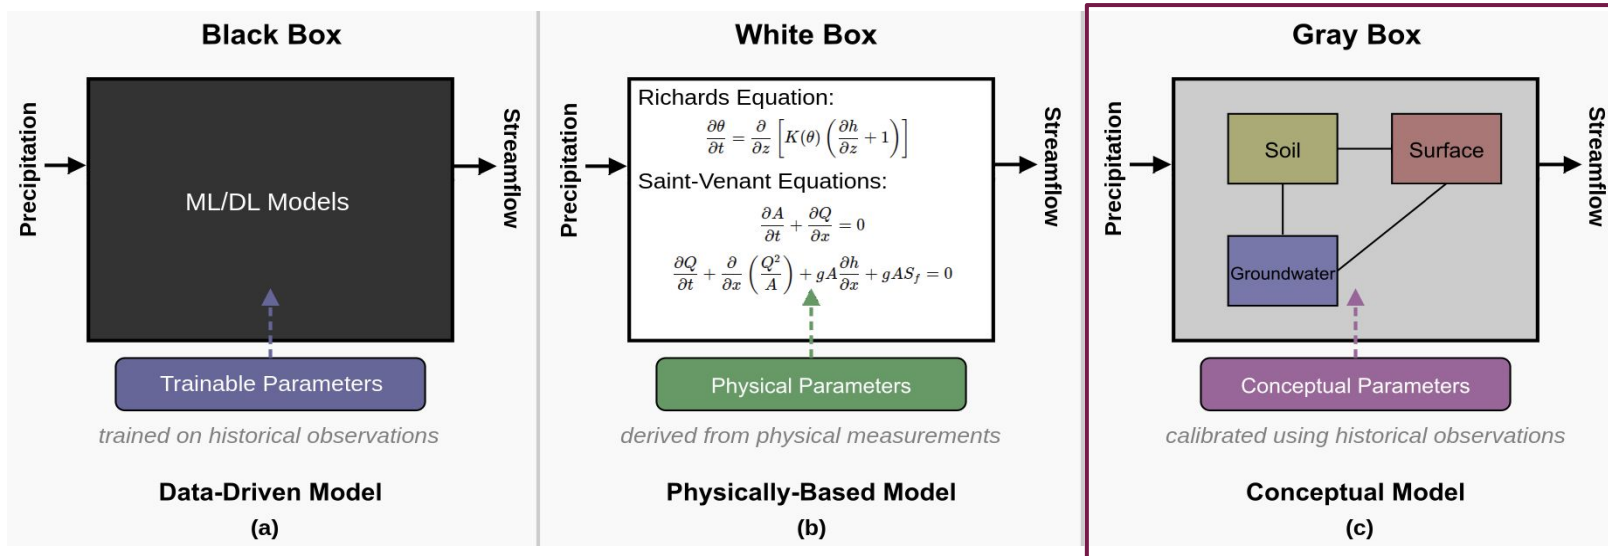
Paramètres du modèles
et états initiaux



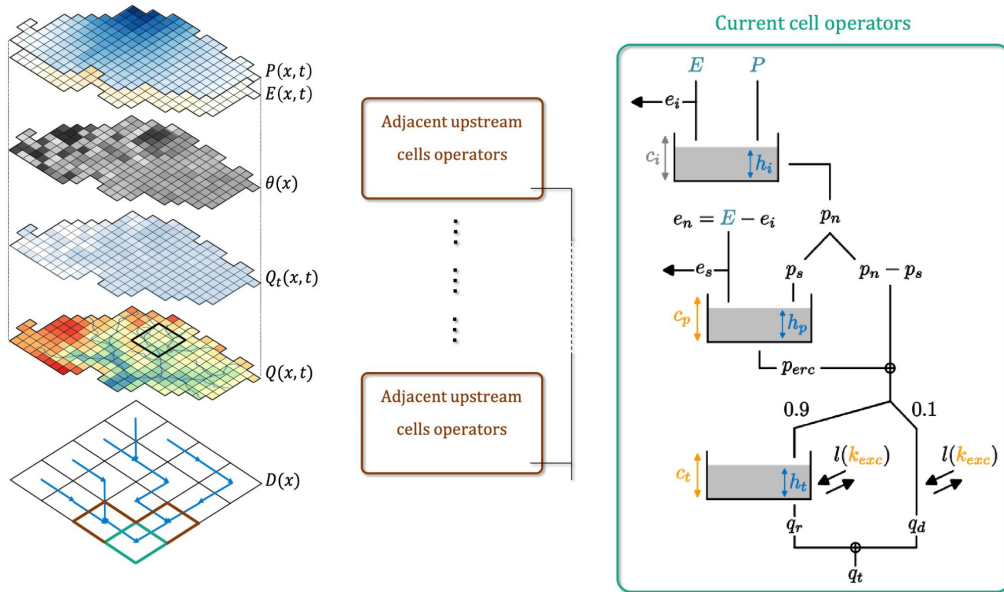
Débits/états du modèle

Quantification des débits de surface et en rivière ?

Différent types du modèle hydrologique




Pourquoi calibrer et régionaliser le modèle ?



Gridded GR-like structure ([Jay-Allemand et al. 2020](#), [Colleoni et al. 2025](#)), based on [Perrin et al. \(2003\)](#), with 4 conceptual parameters

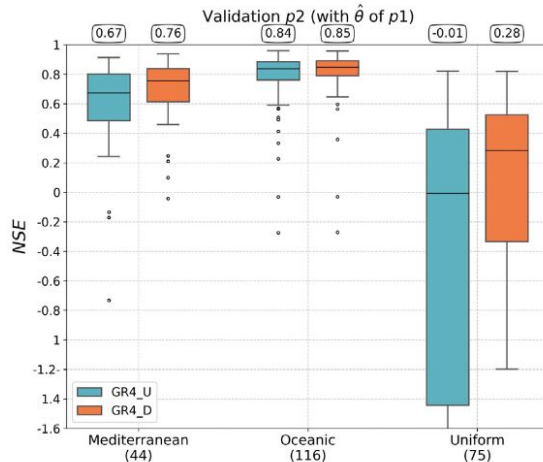
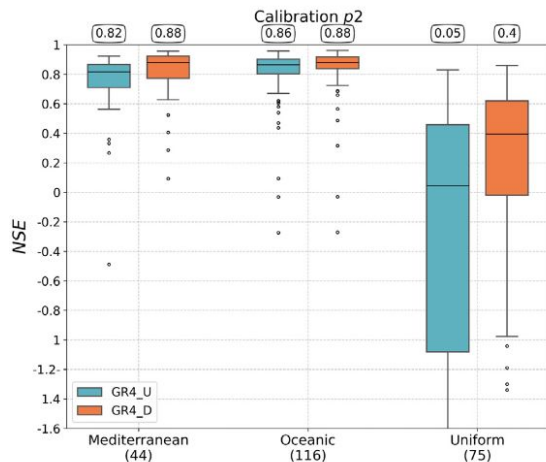
[Jay-Allemand et al. \(2020\)](#) calent un modèle GR distribué avec les méthodes d'assimilation de données variationnelle



- Gauged
- Ungauged

=> **Régionalisation** : estimer les paramètres du modèle sur les sites non-jaugés

Objectif : robustesse du modèle



Performance d'un modèle GR-like en calage, validation temporelle sur 235 bassins en France ([Garambois et al. 2025](#)), besoin de régionalisation pour extrapolation spatiale

Amélioration recherchées par intégration d'IA au sein du modèle physique (contrainte forte) :

- **Régionalisation** : fonction descripteurs-paramètres (linéaire, réseau de neurones)
- Correction de la structure modèle : **corriger/apprendre les flux internes et lois de fermeture**, qui sont très empiriques

=> Approximation universelle par de réseaux neuronaux ?

Résumé des travaux de thèse (2022-2025)

Approches hybrides physique-IA intégrant des réseaux neuronaux dans des modèles hydrologiques distribués pour la simulation des crues à l'échelle régionale

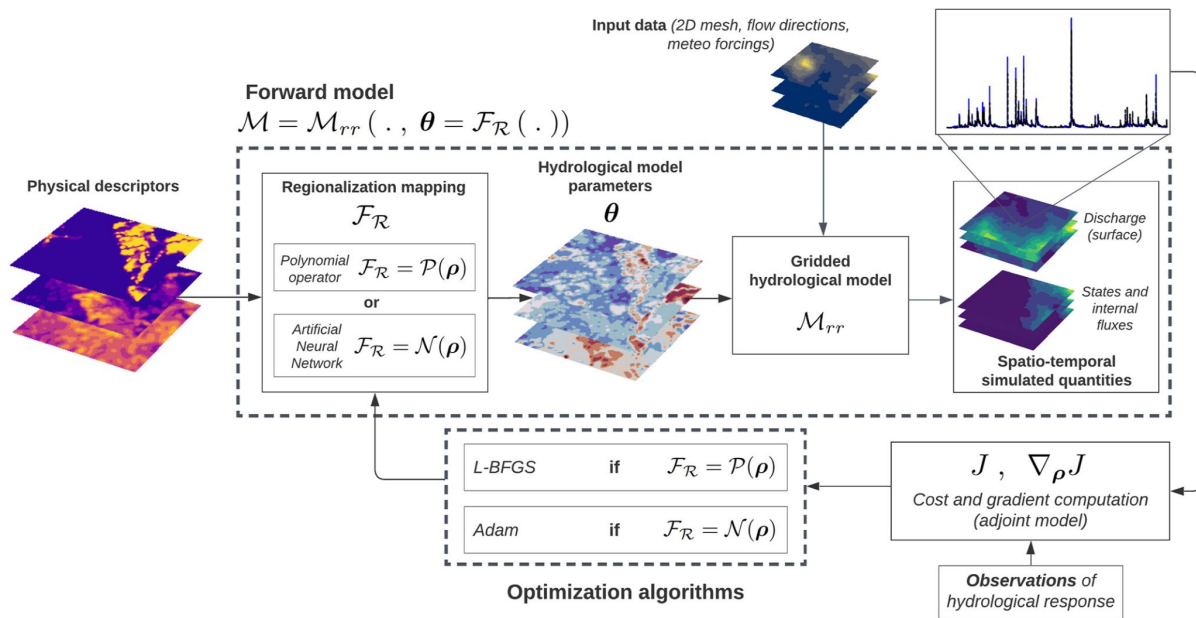
Directeur : *Pierre-André Garambois*

Co-encadrants : *Benjamin Renard, Hélène Roux*

1. Comment régionaliser les paramètres spatialisés dans un modèle hydrologique distribué ?
2. Comment mieux généraliser la structure du modèle avec des lois plus générique ?

=> Améliorer la performance du modèle et avancer la connaissance sur les processus hydrologiques avec de l'IA et de données

Régionalisation hybride, spatialisé, et différentiable



Learning regionalization mapping for fully distributed process-based models:

$$\theta(x) = NN(D(x), W)$$

Combination of numerical adjoint model and neural network Jacobian (through backpropagation):

$$\frac{\partial J}{\partial W} = \frac{\partial J}{\partial \theta} \cdot \frac{\partial \theta}{\partial W}$$

θ spatially distributed conceptual parameters

D physical descriptors

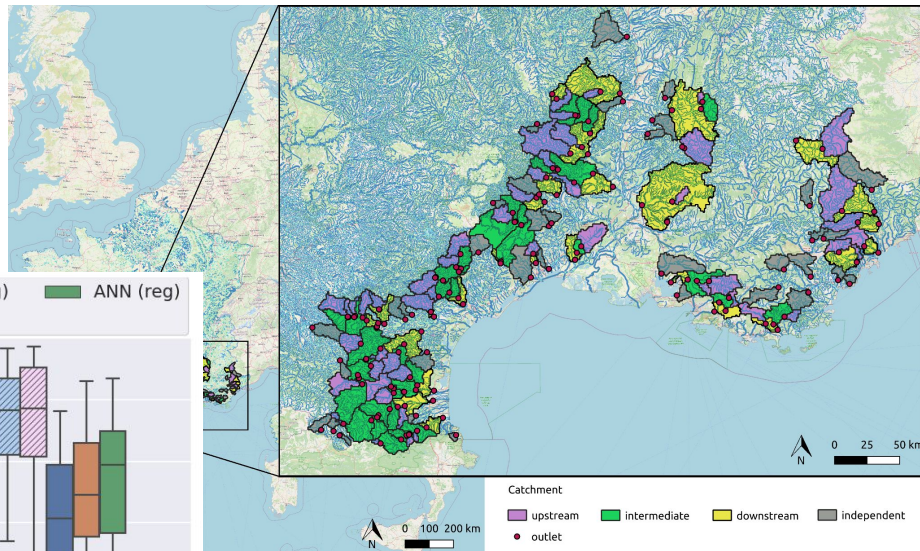
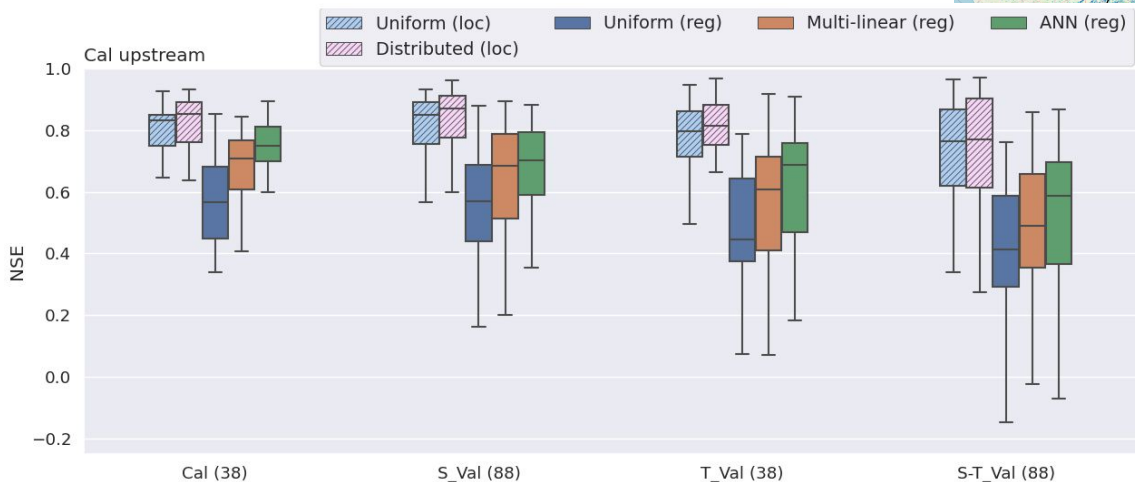
W trainable parameters of the neural network (NN)

J cost function to be minimized

Illustration of hybrid regionalization method for spatially distributed GR-like model (Huynh et al., 2024)

Régionalisation hybride : résultats


- **Local calibration** (*reference score*)
Uniform (loc), Distributed (loc)
- **Regionalization**
Uniform (reg), Multi-linear (reg), ANN (reg)



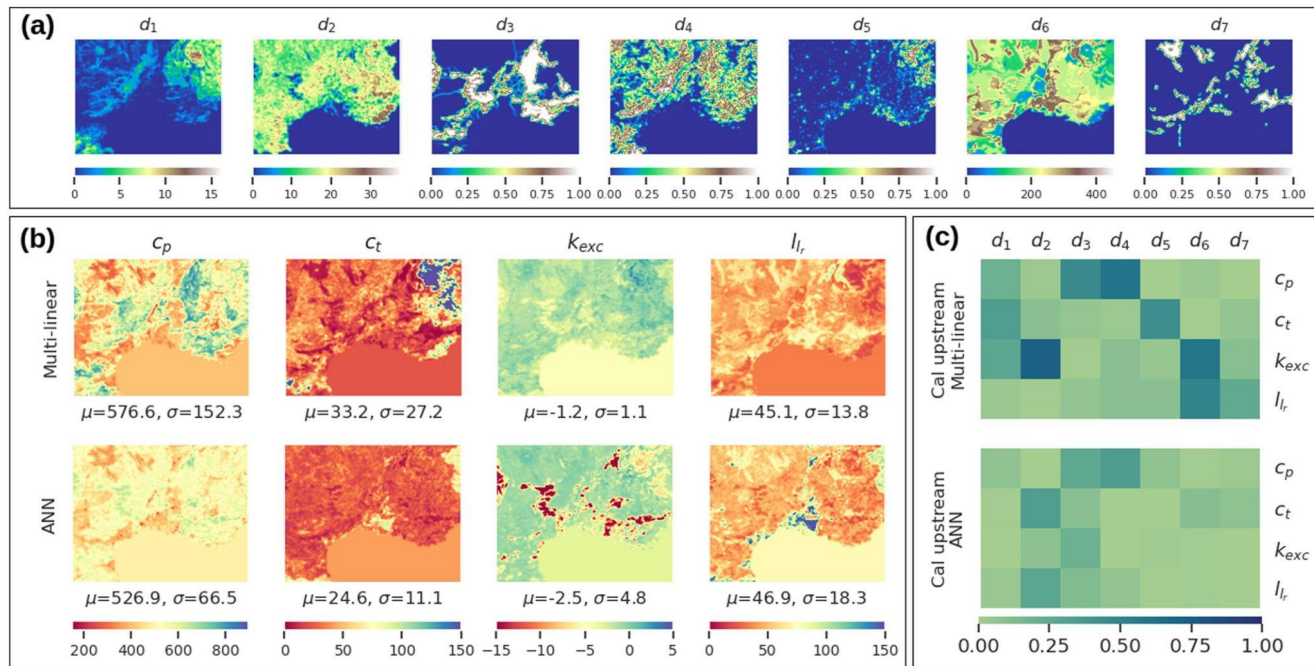
Map of France highlighting the ArcMed study area, covering 150,000 km² (100,000 km² excluding sea), comprising 126 catchments categorized as 38 catchments located upstream, 33 intermediate catchments, 24 catchments positioned downstream, and 31 independent catchments, representing a total drainage area of 26,000 km²

Boxplots of NSE scores across calibration and validation catchments for upstream calibration setup, compared to reference solutions obtained by local calibration methods (Uniform (loc) and Distributed (loc)). The numbers in parentheses indicate the count of evaluation samples

Régionalisation hybride : résultats



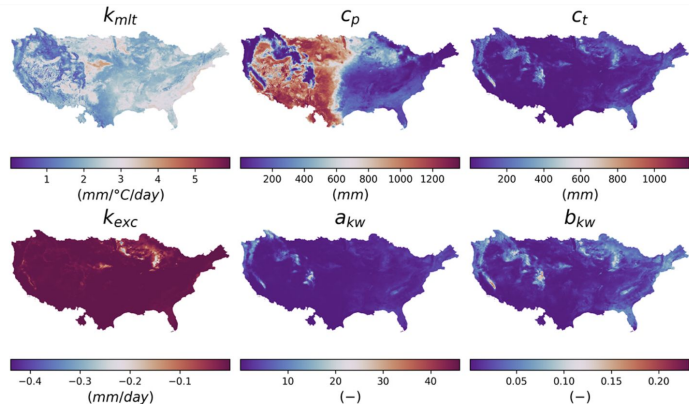
Relative error of flood flow (Eff) and peak flow (Epf) evaluated on a total of 1,737 flood events



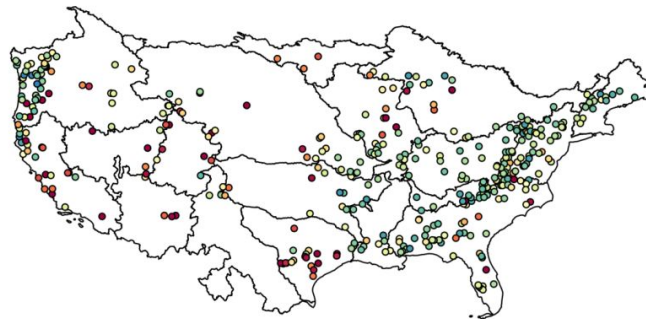
(a) Spatial distribution of physical descriptors; (b) Spatial distribution of calibrated hydrological parameters with μ and σ indicating their spatial average and standard deviation; (c) Linear correlation between descriptors and parameters within the spatial domain

Régionalisation hybride : évaluation large-échelle

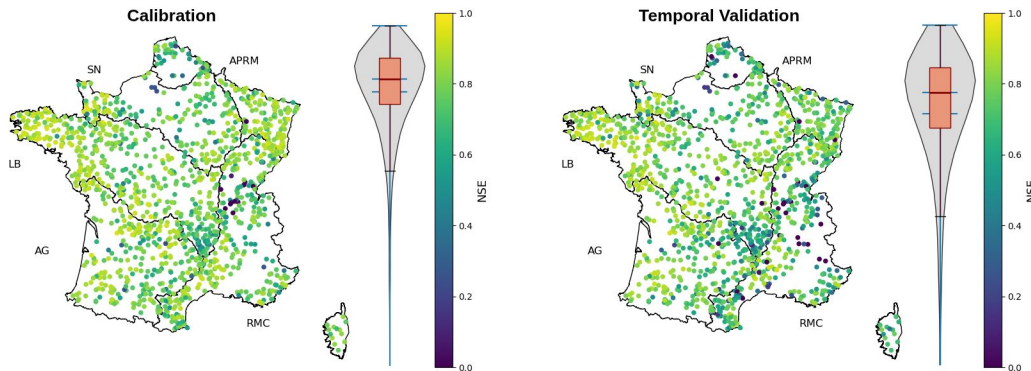
Régionalisation ANN (structure GR journalier, 3km) CARAVAN US ([Colleoni, Huynh et al. 2025](#))



Spatio-Temporal Validation p_2 ANN



Régionalisation multi-linéaire (structure GR, 15min, 1km) CAMELS-FR (Akhtari, Demargne, Javelle et al. in prep.)



Double hybridation (régionalisation+flux paramétrisation)

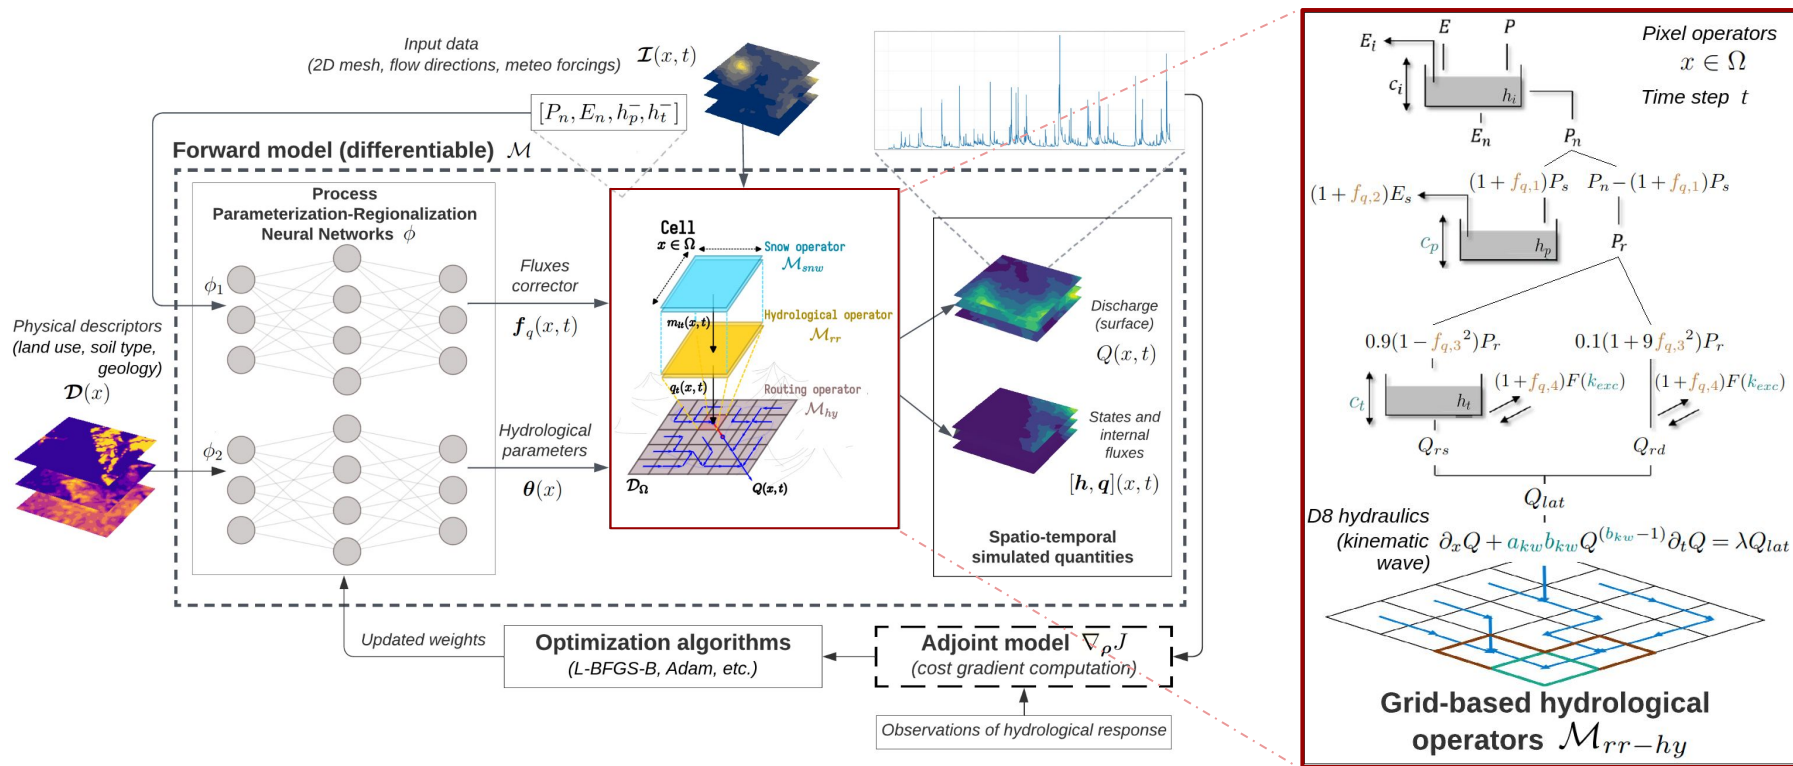


Illustration of the hybrid physics-AI framework, applied to the spatially distributed GR-like and kinematic wave model, involving a pair of process-parameterization and regionalization NNs (Huynh et al., 2025, 2026)

Double hybridation (régionalisation+flux paramétrisation)

Ordinary differential equations (ODEs) for updating model states:

$$\frac{dh}{dt} = f_{phys}(P, E, \theta, h)$$


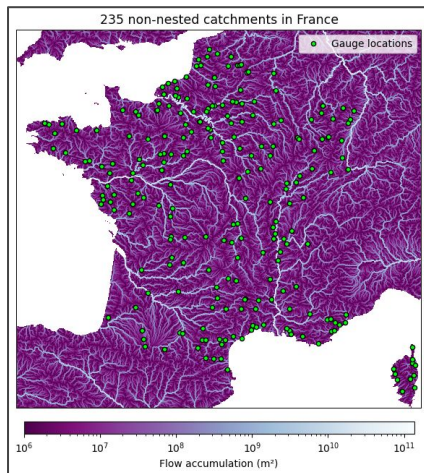
Universal differential equations (UDEs) for updating model states:

$$\frac{dh}{dt} = f_{phys-AI}(P, E, \theta, h)$$

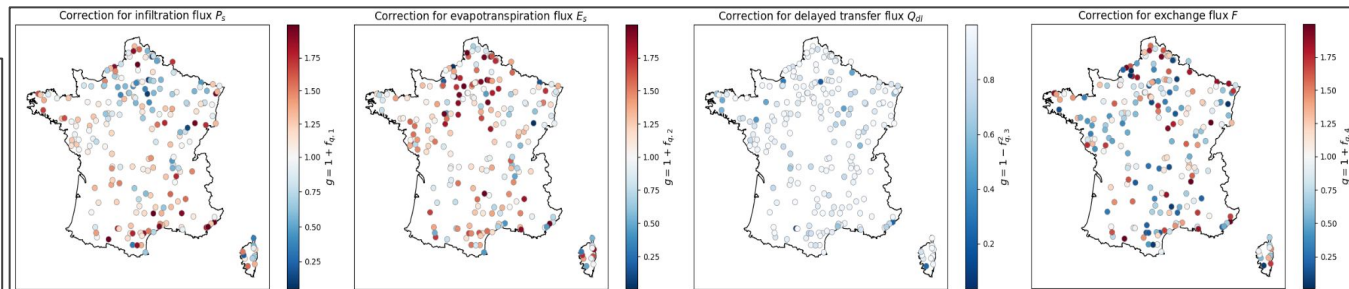
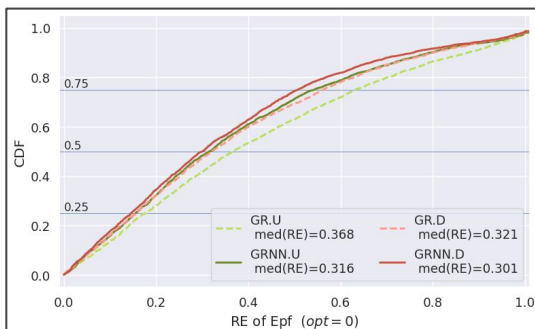
=> Algebraic formulation with sequential computations under specific assumptions in physical equations ([Huynh et al. 2025](#))

=> Numerical resolution using an implicit Euler scheme ([Huynh et al. 2026](#))

Double hybridation (régionalisation+flux paramétrisation)



Model performance comparison of local calibration methods. The two boxes in lighter colors represent the classical GR models (GR.U and GR.D), while the two boxes in darker colors represent the ϕ_1 -hybrid models (GRNN.U and GRNN.D)

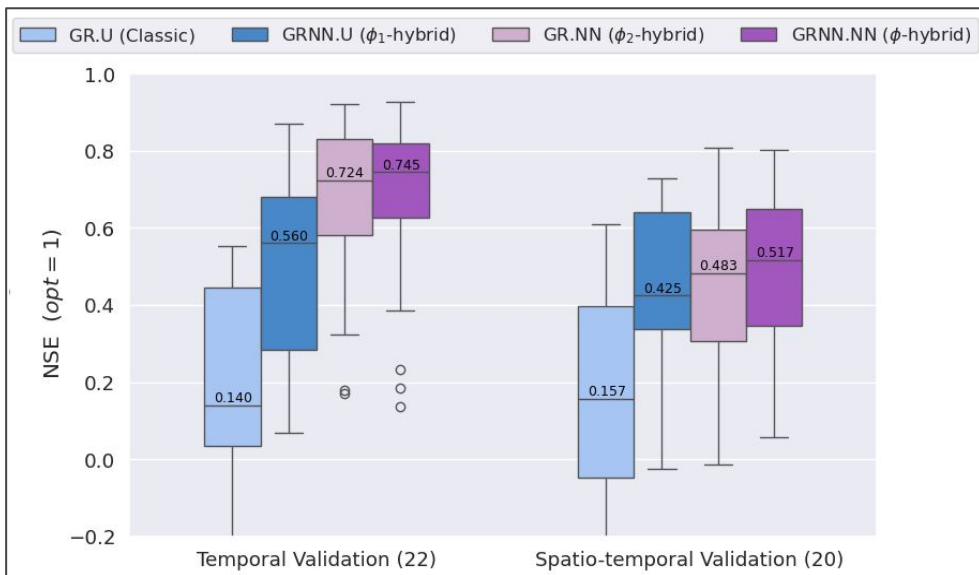


Maps of spatio-temporal average flux corrections for the 235 catchments, obtained through local calibrations of spatially uniform parameters with the hybrid model structure (GRNN.U)

Cumulative distribution function (CDF) of the relative error (RE) between observed and simulated peak flow (Epf)

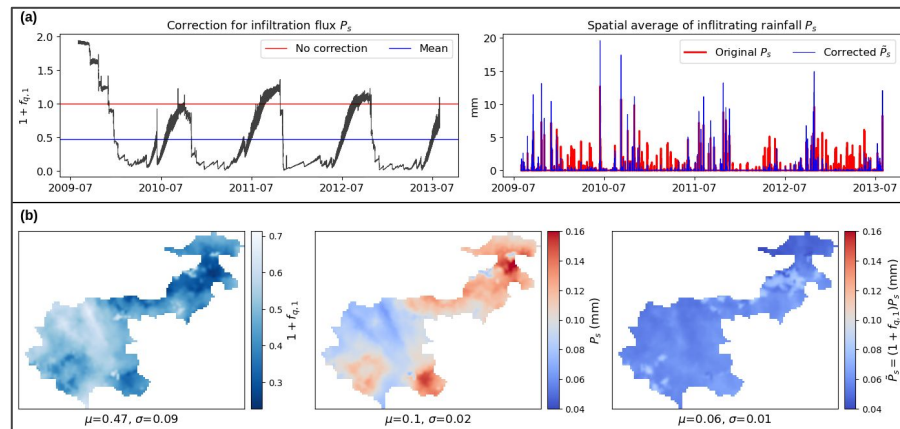
Double hybridation (régionalisation+flux paramétrisation)

Distinct spatio-temporal patterns emerged by the learned water fluxes



Comparison of model performance for different methods in temporal validation and spatio-temporal validation with a multi-site calibration setup

Hybrid models achieved superior accuracy and robustness in various validation scenarios



Visualization of flux corrections obtained through regional calibration of spatially uniform parameters with the hybrid model (GRNN.U): (a) Spatial average of infiltrating flux correction, original and corrected infiltrating rainfall; (b) Maps of time-averaged infiltration flux correction, original and corrected infiltration rainfall

Réservoirs neuronaux et vers une modélisation hybride physique-IA à grande échelle

Nouveau concept de “réservoirs neuronaux”

Réservoir classique :

$$\begin{cases} \frac{dh}{dt}(x, t) = \sum_i \mathbf{q}_i(x, t) = \sum_i \mathbf{f}_i(\cdot, x, \mathbf{h}(x, t)), & x \in \Omega, t > 0 \\ \mathbf{h}(x, 0) = \mathbf{h}_0(x) \end{cases},$$

Empirique

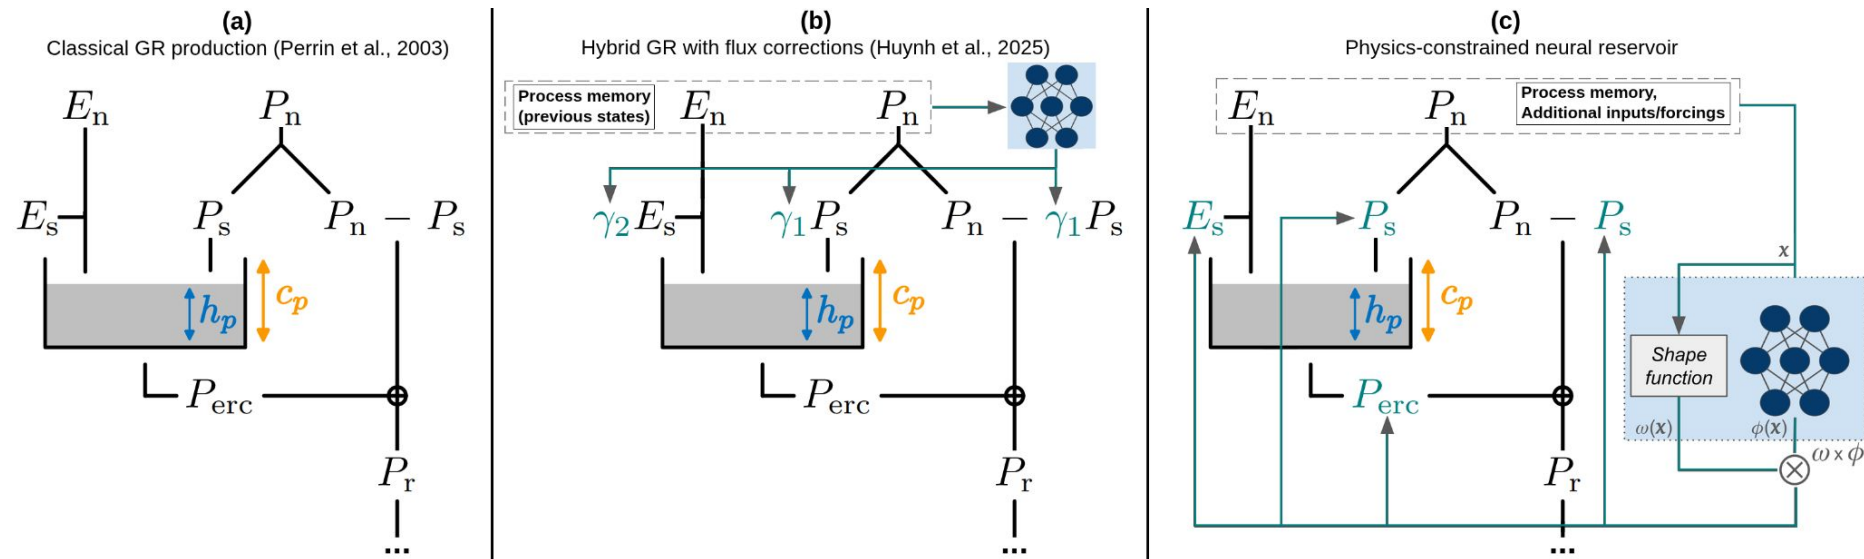
= **NN(.) ?**

Approximation universelle



- Initialisation ?
- Convergence ?
- Consistence physique ?

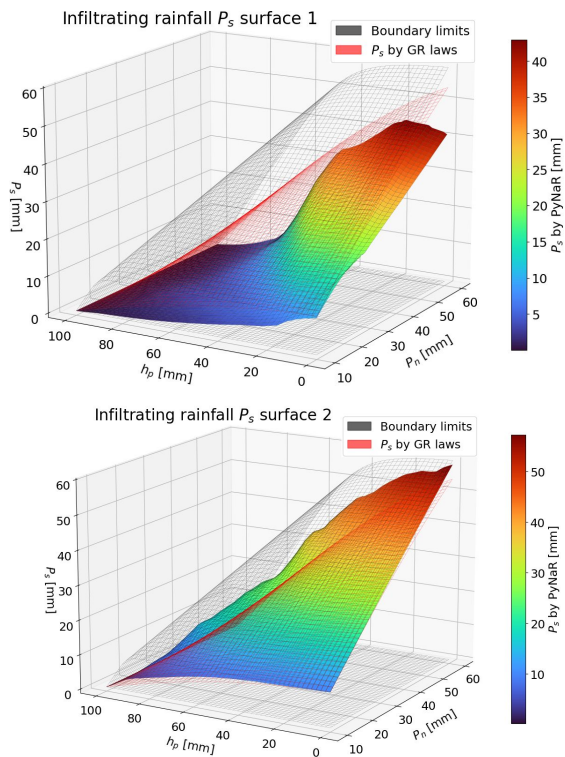
Nouveau concept de “réservoirs neuronaux”



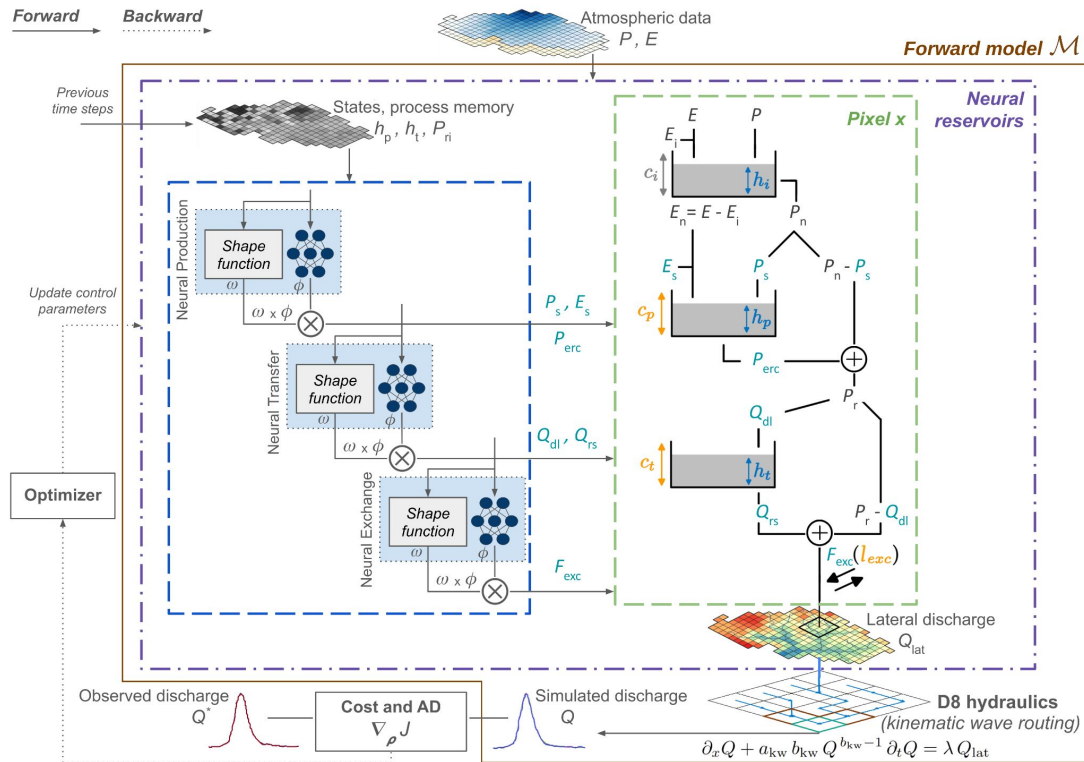
Exemple du réservoir de production dans le modèle GR, du modèle GR hybride avec correction de flux, et du réservoir neuronal (Huynh et al., 2026b, preprint)

$$\mathbf{h}(x, t) = \mathbf{h}(x, t - 1) + \sum_i \omega_i (\mathcal{I}(x, t), \mathbf{h}(x, t - 1)) \odot \phi_i(\cdot, \mathcal{I}(x, t), \mathbf{h}(x, t - 1))$$

Nouveau concept de “réservoirs neuronaux”




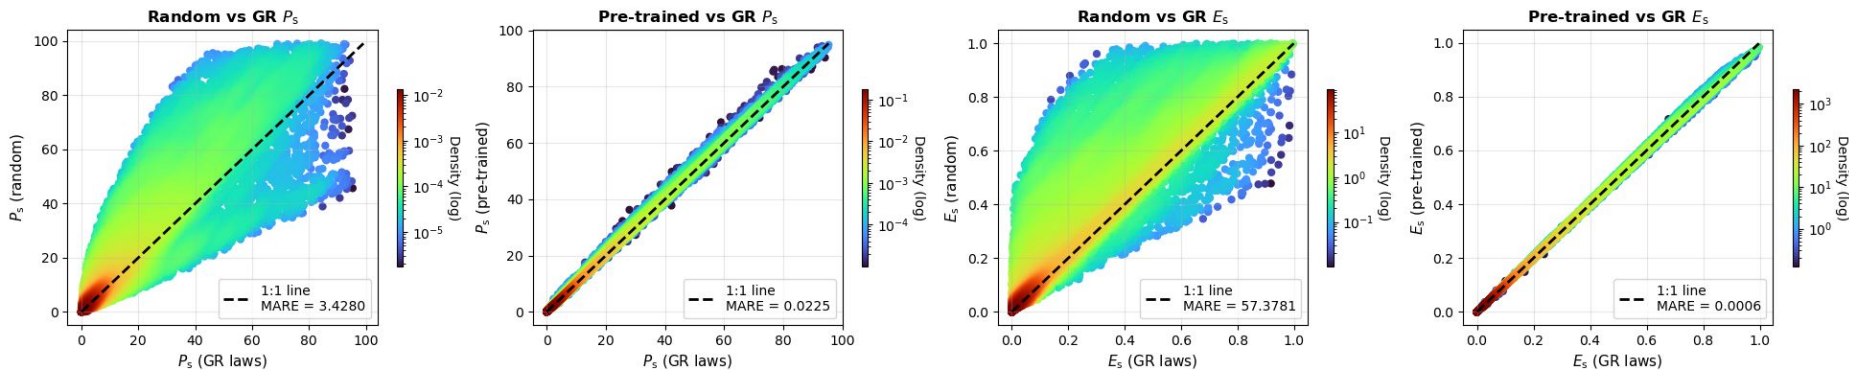
Exemples de surfaces de réponse du flux infiltré P_s en fonction de P_n et h_p , illustrant comment les réservoirs neuronaux entraînés (sur deux bassins versants différents) remodelent la réponse du modèle GR (maillage rouge) à l'intérieur des bornes admissibles (maillage gris)



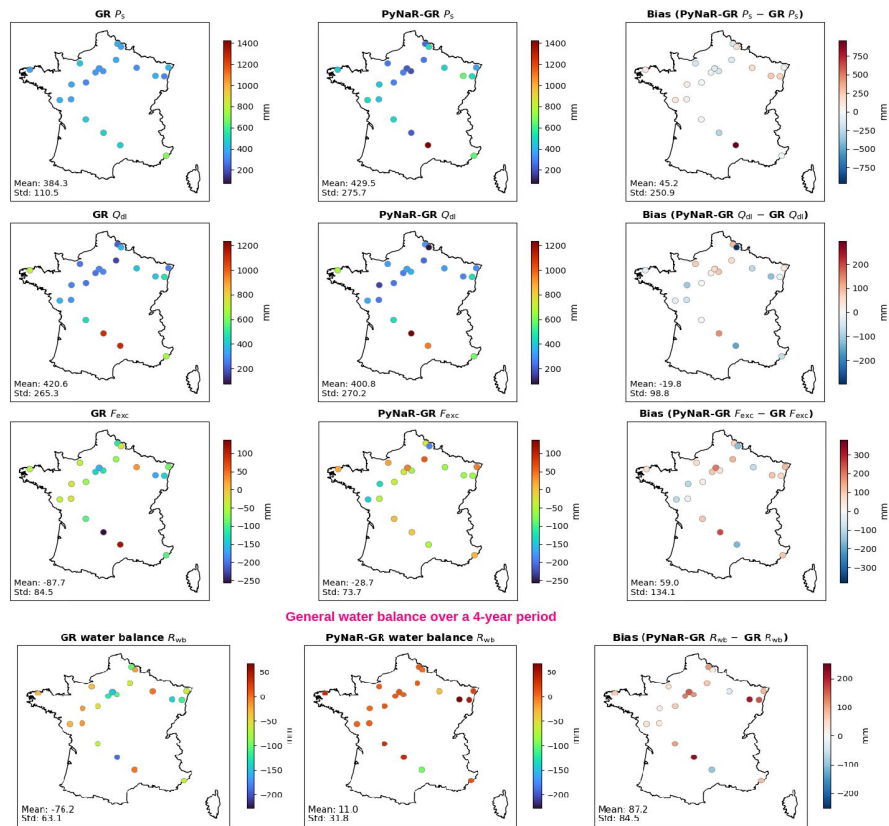
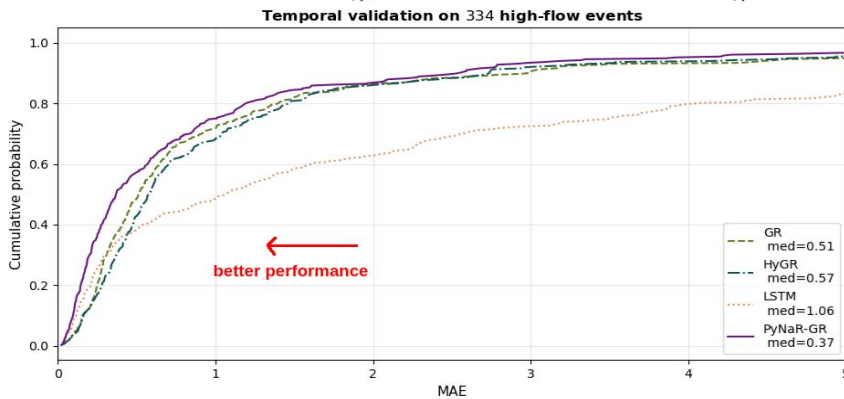
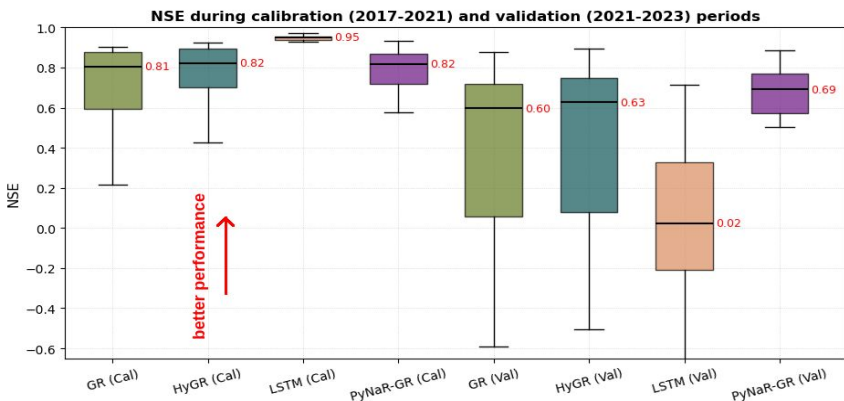
Représentation schématique de l'architecture des réservoirs neuronaux, PyNaR (Huynh et al., 2026b), et la rétro-propagation du modèle

Réservoirs neuronaux : résultats

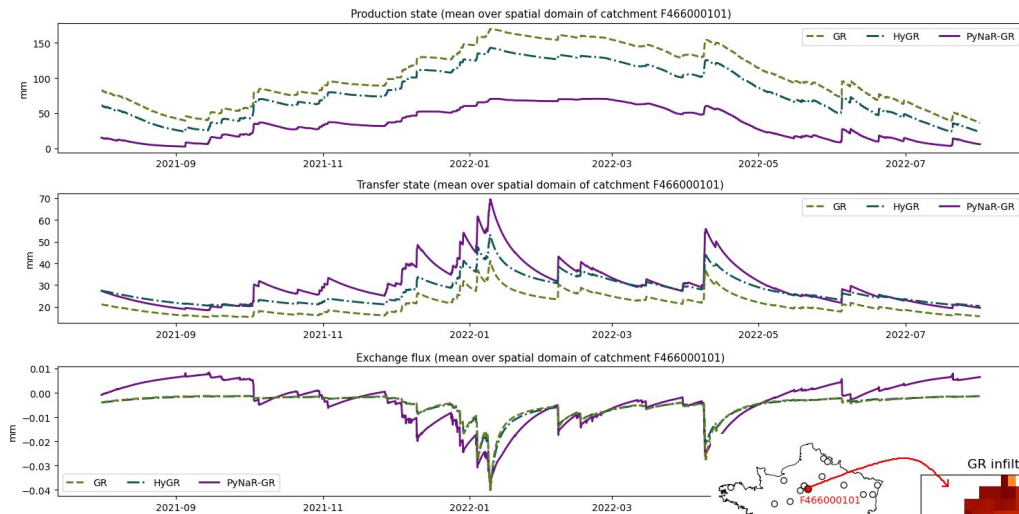
Pré-entraîner sur les flux synthétiques générés par les lois empiriques de GR :







Réservoirs neuronaux : résultats






Réservoirs neuronaux : résultats



Catchment-averaged time series of: production state, transfer state, and exchange flux.



Spatial distribution of the mean annual infiltrating rainfall obtained by GR, PyNaR-GR, and their difference. P_s response surfaces as a function of P_n and P_{ri} under dry, intermediate, and wet production states.



Conclusions

Contributions méthodologiques :

- Démontrer un jumeau numérique-IA robuste et performant, combinant la rigueur d'un modèle physique et la capacité d'approximation universelle des réseaux de neurones
- Ouvrir la voie vers des modèles plus intégrés et intelligents, capables d'un transfert plus large en numérique et en géosciences

Applications :

- Développer des méthodes applicables à différentes échelles (nationales voire globales) et à divers contextes
- Co-développer un code opérationnel (SMASH) avec une documentation complète pour faciliter les actions applicatives

Perspectives et travail en cours

- *Comment entraîner un modèle hybride sur large samples de manière efficace ?*
 - => Mini-batch training–stochastic optimization based on approximated batch gradients (Akhtari, Huynh et al. in prep)
 - => Application des modèles hybrides développés à l'échelle nationale voire globale (Huynh, Colleoni, Ettalbi, Garambois et al. in prep)
- *Comment transférer les méthodes développés dans un context plus large (la généralité des approches hybrides) ?*
 - => Hybridation d'autres modèles conceptuels (e.g. HBV), et de complexité croissante - e.g. à base physique J2000, collab en cours RECOVER–RiverLy (Guillaume, Huynh et al.)
- *Prédiction en temps réel (e.g. par short-range DA et/ou pure ML), application opérationnelle*
- *Toward a unified (hybrid) Hydrology-Hydraulic framework ([Garambois 2025 HDR](#))*
 - => Couplage de modèle hydrologique et hydraulique dans un framework entièrement différentiable (e.g. PyTorch, JAX)
 - => Apprentissage de friction, l'infiltration dans un SW 2D
 - => Régionalisation de Cartino2D envisagée

Merci !