

Universidade de Pernambuco Programa de Pós-Graduação em Engenharia da Computação (PPGEC)

Proposta de Dissertação de Mestrado

Área: Computação Inteligente

Título: Uma Abordagem de Redes Neurais Informadas por Física para Previsão de Enchentes

Orientador – Fernando Buarque de Lima Neto (fbln@ecomp.poli.br)

Co-orientador – Denis Mayr Lima Martins (martins.denis@usp.br)

Contexto

As mudanças climáticas têm exacerbado a frequência e a intensidade de eventos extremos, tornando a previsão precisa de enchentes uma prioridade global. Atualmente, existem duas abordagens principais para modelagem hidrológica [1]: Modelos Físicos Determinísticos (ex: HEC-RAS, SWAT), que se baseiam em equações diferenciais parciais (EDPs) e leis da conservação de massa e energia; e Modelos Baseados em Dados (Data-Driven), como Redes Neurais Profundas (DNNs) ou LSTM, que aprendem padrões estatísticos a partir de dados históricos.

Os modelos físicos tradicionais são confiáveis fisicamente, mas computacionalmente caros para previsão em tempo real, especialmente em cenários de alta resolução espacial e temporal. Por outro lado, os modelos puramente baseados em dados podem ser rápidos, mas frequentemente falham na generalização para eventos extremos não vistos durante o treinamento (problema de out-of-distribution), pois carecem de restrições físicas implícitas.

A linha de pesquisa em Physics-Informed Machine Learning (PIML) [2, 3] surge como uma solução promissora. Em vez de substituir os modelos físicos, esta abordagem integra leis físicas diretamente na arquitetura de um modelo de ML ou na função de perda (loss function), atuando como um regularizador que garante a consistência física das previsões. O objetivo é criar um modelo híbrido que mantenha a robustez hidrológica enquanto reduz o custo computacional para aplicações operacionais.

Problema

A previsão de enchentes enfrenta um dilema fundamental: existe uma tensão entre a precisão hidrológica (garantida por modelos físicos complexos) e a eficiência computacional necessária para sistemas de alerta precoce em tempo real. Modelos puramente baseados em dados tendem a superajustar (overfitting) aos dados históricos e falham em simular processos físicos subjacentes quando os dados são escassos ou ruidosos. A integração inadequada de conhecimento físico em redes neurais pode levar a arquiteturas instáveis ou à perda da capacidade preditiva do modelo.

Pergunta principal: De que maneira a integração de restrições físicas implícitas em redes neurais profundas pode otimizar o trade-off entre precisão hidrológica e eficiência computacional na previsão de enchentes, especialmente em cenários com dados limitados?

Objetivo

Desenvolver e validar um modelo híbrido Physics-Informed capaz de prever o comportamento hidrológico em tempo real para bacias hidrográficas específicas, otimizando a eficiência computacional e a acurácia.

Produtos esperados

- Revisão da literatura: Um mapeamento do estado da arte em Physics-Informed Machine Learning (PIML) aplicado às bacias hidrográficas, identificando lacunas na implementação de modelos híbridos para enchentes.
- Framework Aberto-Fonte (Software): Implementação do framework Physics-Informed, incluindo scripts de pré-processamento e treinamento, seguindo boas práticas de engenharia de software.
- Estudo de Caso Empírico: Um relatório técnico detalhando a aplicação do modelo em bacia hidrográfica específica, incluindo métricas de desempenho comparativo (AUC, erro quadrático médio) frente ao método tradicional.

Referências

- [1] JAIN, Sharad Kumar et al. A Brief review of flood forecasting techniques and their applications. *International journal of river basin management*, v. 16, n. 3, p. 329-344, 2018.
- [2] KARNIADAKIS, George Em et al. Physics-informed machine learning. *Nature Reviews Physics*, v. 3, n. 6, p. 422-440, 2021.
- [3] NAZARI, Luis Fernando; CAMPONOGARA, Eduardo; SEMAN, Laio Oriel. Physics-informed neural networks for modeling water flows in a river channel. *IEEE Transactions on Artificial Intelligence*, v. 5, n. 3, p. 1001-1015, 2022.