

## XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

### **HYDROFORECAST: UM MODELO DE IA PARA PREVISÃO DE VAZÃO - APLICAÇÃO NA UHE CASTRO ALVES – RS**

*Diogo Lousa<sup>1</sup>; Thaiana Todeschini<sup>2</sup>; Melanie Feen<sup>3</sup>; Laura Read<sup>4</sup>; Beatriz Pires<sup>5</sup> & Sarah Carvalho<sup>6</sup>*

**Abstract:** Hydrological variability, intensified by climatic and anthropogenic factors, has compromised the efficient operation and safety of hydroelectric power plants. In Brazil, where the energy matrix is predominantly hydro-based, streamflow forecasting is essential for energy planning and risk mitigation. This study presents the application of the HydroForecast model at the Castro Alves Hydropower Power Plant, located in Rio Grande do Sul, a region frequently affected by extreme events in recent years. The model combines machine learning techniques with hydrological theory, generating hourly streamflow forecasts up to 10 days in advance. Model performance was evaluated using metrics such as NSE, RMSE, MAE, MAPE, and KGE, comparing HydroForecast hourly predictions to a persistence benchmark. During the validation period, the aggregated RMSE of HydroForecast was 40% lower than that of the benchmark (146.45 vs. 246.05), and the KGE was significantly higher (0.61 vs. -0.14). Model also continues to demonstrated similar performance in a four-month operational period so far. The results highlight the model's first use case in Brazil and its potential to support hydroelectric power plant management in the face of increasing climate uncertainty.

**Keywords** – machine learning, extreme hydrological events, energy system planning

**Resumo:** A variabilidade hidrológica, intensificada por fatores climáticos e antrópicos, tem comprometido a operação eficiente e a segurança de usinas hidrelétricas. No Brasil, onde a matriz elétrica é majoritariamente hidrelétrica, a previsão de vazão torna-se essencial para o planejamento energético e a mitigação de riscos. Este trabalho apresenta a aplicação do modelo HydroForecast na UHE Castro Alves, no Rio Grande do Sul, região frequentemente afetada por eventos climáticos extremos nos últimos anos. O modelo combina técnicas de aprendizagem de máquina com fundamentos da teoria hidrológica, gerando previsões de vazões horárias com até 10 dias de antecedência. Durante o período de validação, a avaliação do desempenho foi realizada com base em métricas como NSE, RMSE, MAE, MAPE e KGE, comparando as previsões horárias do HydroForecast com as de um modelo de persistência. O RMSE agregado do HydroForecast foi 40% inferior ao do *benchmark* (146,45 frente a 246,05), e o KGE foi significativamente superior (0,61 contra -0,14). O modelo também continua apresentando desempenho semelhante durante o período operacional de 4 meses até o momento. Os resultados destacam a primeira aplicação prática do modelo no Brasil e o potencial do modelo para apoiar a gestão hidrelétrica diante da crescente incerteza climática.

**Palavras-Chave** – machine learning, eventos hidrológicos extremos, planejamento energético

1) Afiliación: JD Energia, Goiânia, GO, Brasil, [dlousa@jdenergia.com](mailto:dlousa@jdenergia.com)

2) Afiliación: PPGRH/UFMT, Cuiabá/MT, [thaiana.todeschini@outlook.com](mailto:thaiana.todeschini@outlook.com)

3) Afiliación: Upstream Tech, United States, [melanie@upstream.tech](mailto:melanie@upstream.tech)

4) Afiliación: Upstream Tech, United States, [laura@upstream.tech](mailto:laura@upstream.tech)

5) Afiliación: CPFL, Campinas, SP, Brasil, [beatriz.pires@cpfl.com.br](mailto:beatriz.pires@cpfl.com.br)

6) Afiliación: CPFL, Campinas, SP, Brasil, [sarah.carvalho@cpfl.com.br](mailto:sarah.carvalho@cpfl.com.br)

## INTRODUÇÃO

A crescente demanda por recursos hídricos e energia impõe desafios cada vez mais complexos para o planejamento e a gestão de sistemas hidrelétricos (Silva *et al.*, 2022). A geração por fontes hídricas passou de 70.692 MW em 2003 para 109.106,565 MW em 2020, resultando em uma expansão de geração 54,3% (ANEEL, 2020).

A variabilidade hidrológica, intensificada por fatores climáticos e antrópicos, impacta diretamente a previsibilidade das vazões, comprometendo a operação eficiente e segurança das usinas hidrelétricas (MME,2024). Nesse contexto, a previsão de vazão surge como uma ferramenta estratégica, permitindo antecipar cenários, otimizar a geração de energia e garantir a segurança hídrica (Lappicy e Lima,2023).

No Brasil, onde a matriz elétrica é predominantemente hidrelétrica, com crescente aumento da participação de fontes renováveis intermitentes como solar e eólica, a precisão nas previsões de vazão é especialmente relevante, uma vez que influencia diretamente o planejamento energético e a tomada de decisões operacionais (BRASIL,2024). Usinas como a UHE Castro Alves, localizada no estado do Rio Grande do Sul, dependem fortemente dessas previsões para lidar com a variabilidade dos rios que a alimentam, enfrentando desafios crescentes para manter sua operação e segurança de forma eficiente e sustentável diante de eventos extremos na região.

No Rio Grande do Sul entre o final de abril e início de maio de 2024, ocorreram inundações que afetaram cerca de 96 % dos municípios do Rio Grande do Sul, configurando-se como o maior desastre climático da história do estado. Esse evento hidrológico extremo, caracterizado por chuvas intensas e persistentes, gerou inundações inéditas em diversas bacias, especialmente nos Vales do Taquari e dos rios Guaíba, Caiá, Antas e Jacuí. (Lima; Kuchinski; Paiva, 2024). Em setembro e novembro de 2023, e maio de 2024 foi registrada uma vazão máxima superior à vazão decamilenar estimada para o dimensionamento da barragem da UHE Castro Alves, no rio das Antas, afluente da cabeceira do rio Taquari (ONS, 2024). Esses episódios e o aumento global da frequência de eventos hidrológicos extremos (Gudmundsson *et al.*,2021) reforçam a urgência da adoção de modelos preditivos mais eficazes, capazes de antecipar eventos extremos com maior precisão e oferecer suporte estratégico à gestão operacional de usinas hidrelétricas em um cenário de crescente variabilidade climática.

Diante desse cenário, este trabalho apresenta a aplicação do modelo HydroForecast (Kratzert *et al.*, 2019), uma abordagem que combina técnicas avançadas de modelagem e análise de dados com fundamentos da teoria hidrológica. Desenvolvido para aprimorar a precisão das previsões de vazão, o estudo concentra-se na calibração e aplicação do modelo na UHE Castro Alves, localizada no Rio Grande do Sul, um dos estados brasileiros mais impactados pelas mudanças climáticas (Brêda *et al.*,2023). São destacados os resultados obtidos, as melhorias em relação às metodologias convencionais e as contribuições do modelo para a gestão operacional da usina.

O objetivo deste estudo foi operacionalizar as previsões de vazões horárias do HydroForecast para o horizonte de 10 dias. Além das vazões observadas, o modelo incorpora dados meteorológicos, imagens de satélite, informações geoespaciais e medições in situ.

## METODOLOGIA

O HydroForecast é um sistema operacional de previsão construído com base em uma única arquitetura de modelo de aprendizado de máquina orientado pela teoria hidrológica. É baseado em um bloco de construção de rede neural do tipo LSTM (*Long Short Term Memory*), introduzido por Hochreiter e Schmidhuber em 1997. Desde sua introdução na hidrologia, as redes LSTM têm sido

amplamente documentadas como superando regularmente os modelos físicos mais utilizados nos Estados Unidos e no Canadá, conforme demonstrado na literatura co-autorada pelo CTO da Upstream Tech, Alden Keefe Sampson (Kratzert *et al.*, 2019) e pela renomada hidróloga Julianne Mai (Mai *et al.*, 2022).

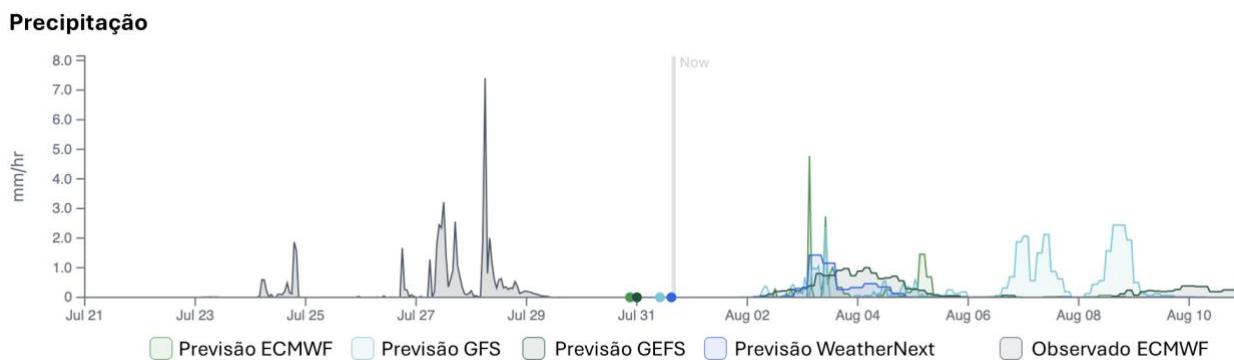
O HydroForecast aproveita os métodos mais avançados em hidrologia com aprendizado de máquina e foi projetado intencionalmente para superar dois problemas comuns em modelos hidrológicos e de aprendizado de máquina: 1) dependência excessiva de uma única previsão meteorológica incerta e 2) sobreajuste do modelo (overfitting).

As previsões meteorológicas são uma entrada principal e uma fonte significativa de incerteza em qualquer modelo hidrológico. Diferentemente da maioria dos outros modelos, o HydroForecast é treinado com previsões retroativas (*reforecasts*) de diversas fontes meteorológicas (por exemplo, NOAA GFS, GEFS; ECMWF HRES, entre outras) e, durante o processo de treinamento, aprende a aproveitar a informação mútua entre essas fontes para produzir a melhor previsão de vazão em diferentes locais e condições climáticas.

O uso de múltiplas fontes de previsão e o treinamento do modelo em diversos locais e condições tornam o HydroForecast mais adaptável às mudanças climáticas em curso, que vêm desafiando os métodos tradicionais de previsão. Além disso, ao ser treinado com um histórico de previsões retroativas, em vez de dados meteorológicos observados, o modelo incorpora padrões de erro típicos das previsões meteorológicas no processo operacional em tempo real, gerando previsões de vazão confiáveis, com desempenho igual ou superior ao do período de validação, e levando em conta a incerteza das previsões do tempo.

A Figura 1 ilustra um exemplo das entradas de previsão meteorológica no HydroForecast, destacando que, em momentos de incerteza e divergência nas previsões de precipitação futura, o modelo utiliza o aprendizado adquirido durante o treinamento para fazer a melhor previsão possível.

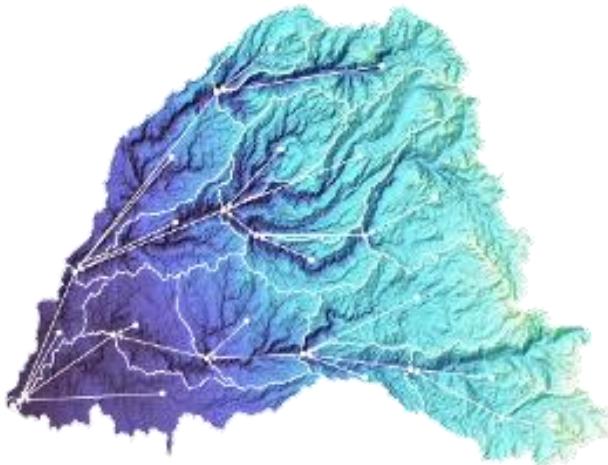
Figura 1. Série temporal de dados de precipitação observada e prevista por diversos modelos meteorológicos. O HydroForecast sintetiza múltiplas previsões simultaneamente, possibilitando maior precisão — especialmente durante eventos de precipitação difíceis de prever.



Até onde é de conhecimento, o HydroForecast é o único modelo hidrológico operacional com aprendizado de máquina distribuído, no qual uma única rede neural é otimizada para modelar tanto o escoamento superficial nas sub-bacias quanto o escoamento nos rios, permitindo alta precisão em passos horários, especialmente durante eventos de pico de vazão de rápida variação. A arquitetura do sistema HydroForecast utiliza uma coleção de múltiplas sub-bacias, onde cada região de sub-bacia é considerada uma unidade única. As previsões de escoamento de cada sub-bacia são integradas por meio de um módulo de roteamento fluvial que representa o fluxo ao longo da rede de rios.

Cada sub-bacia é modelada utilizando um bloco de rede neural LSTM, projetado para processar e compreender dados em séries temporais. A cada passo de previsão, a LSTM de cada sub-bacia recebe novos valores de entrada (as observações mais recentes e os dados previstos), atualiza internamente seus estados hidrológicos e, em seguida, gera uma previsão (escoamento e estados hidrológicos) para aquele momento. As previsões de escoamento das sub-bacias então alimentam um segundo componente da rede neural, que representa explicitamente a rede hidrográfica como um gráfico, aprendendo a prever os parâmetros de um hidrograma unitário para cada trecho e momento no tempo, somando os fluxos nas confluências e, por fim, produzindo previsões de vazão totais e locais em cada nó (como barragens, estações fluviométricas, confluências ou saídas de sub-bacias) do gráfico da bacia hidrográfica (Figura 2).

Figura 2. A rede neural distribuída do HydroForecast representa a rede hidrográfica como um gráfico, aprendendo a prever o escoamento em cada sub-bacia (delimitadas em branco) e a roteirizar o fluxo dos rios através da rede fluvial. Isso permite que o modelo represente explicitamente as diferentes condições meteorológicas e hidrológicas ao longo da bacia e aproveite as medições de vazão a montante.



A assimilação automática e robusta de dados fluviométricos, utilizando métodos de ponta (Nearing et al, 2022), já vem integrada ao HydroForecast, aumentando ainda mais a precisão das previsões de curto prazo, sem a necessidade de intervenção adicional do operador. Aproveitar medições recentes e em tempo real de estações fluviométricas e afluentes é um componente essencial para previsões hidrológicas de curto prazo precisas.

No entanto, leituras com erro, ruídos, dados ausentes e frequências de observação heterogêneas representam desafios que, normalmente, dificultam o uso desses dados pelos operadores de previsão. Sendo assim, o HydroForecast desenvolveu e refinou um processo de assimilação que aproveita as capacidades exclusivas de modelos de redes neurais para integrar automaticamente dados fluviométricos diversos, tanto nos pontos de previsão a jusante quanto em estações a montante.

Esse processo é resiliente à ausência total ou à disponibilidade esporádica de dados de observação, e é capaz de gerar previsões mesmo sem nenhuma observação disponível. A metodologia foi aprimorada com uma ampla variedade de observações do mundo real, desde medições horárias até estimativas de afluentes em reservatórios, onde o ruído nas observações muitas vezes supera o próprio sinal.

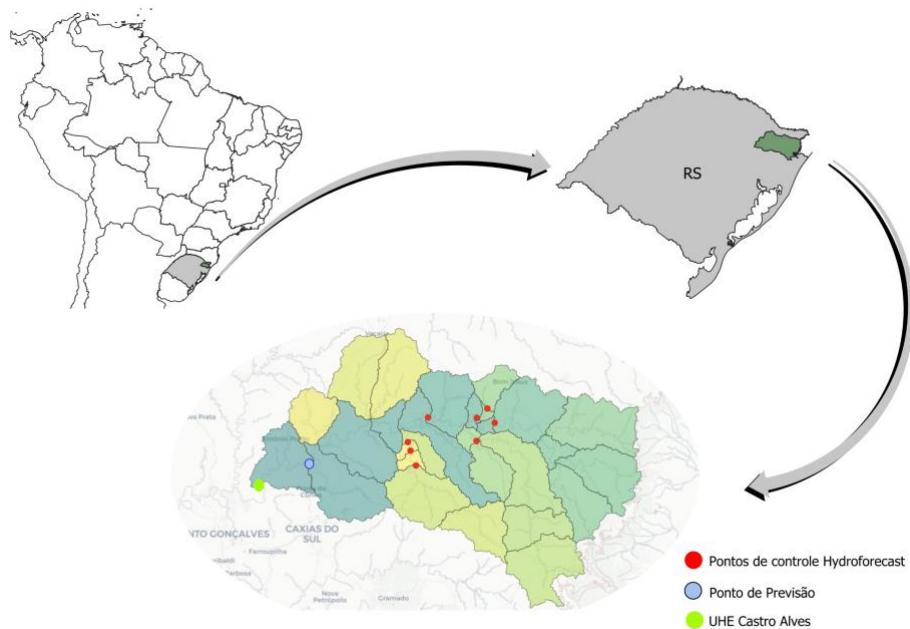
## Área de estudo

Para este estudo caso, foi selecionada UHE Castro Alves, operada atualmente pela CERAN – Companhia Energética Rio das Antas. A Ceran tem como investidores a CPFL – Geração de Energia S.A. (65 %), a Companhia Estadual de Geração de Energia Elétrica – CEEE-G (30 %) e a Statkraft

Energias Renováveis S.A. (5 %). Este estudo foi realizado em parceria com a equipe de hidrologia da CPFL Energia. A UHE Castro Alves está localizada no Rio das Antas, região norte do estado do Rio Grande do Sul, Brasil, conforme a Figura 3. A bacia estudada possui uma área de 7.748 km<sup>2</sup> e o seu exutório está localizado nas coordenadas 29° 0' 21" S, 51° 23' 5" W.

As UHE Castro Alves têm capacidade de geração de 130MW, a característica de operação a fio d'água, ou seja, as vazões defluentes são relativamente próximas à afluência e praticamente não possuem capacidade de regularização (Siqueira *et al.*, 2015).

Figura 3: Localização da área de estudo – UHE CASTRO ALVES. Fonte: Os autores, 2025.



Para o ponto de previsão foi escolhida a estação UHE Castro Alves (RS-122), conforme a Figura 3. Este ponto foi escolhido em função da disponibilidade e qualidade dos dados da série histórica. Além disso, a estação se encontra a montante do barramento da UHE Castro Alves e fora da área do reservatório, proporcionando leituras de vazões mais diretas para o estudo.

Tabela 1: Dados da Estação Fluviométrica. Fonte: Hidroweb, ANA (2025).

| Dados da Estação |                               |
|------------------|-------------------------------|
| Código           | 285651110                     |
| Nome Estação     | UHE CASTRO ALVES RS-122       |
| Bacia            | 8 - Atlântico, Trecho Sudeste |
| Sub-bacia        | 86 - RIO TAQUARI              |
| Rio              | RIO DAS ANTAS                 |
| Estado           | RIO GRANDE DO SUL             |
| Município        | ANTÔNIO PRADO                 |
| Responsável      | CERAN                         |
| Operadora        | CERAN                         |
| Latitude         | -28.9414                      |
| Longitude        | -51.1892                      |
| Altitude (m)     | 274                           |

Para treinamento e validação do modelo, foram utilizadas a series histórica horárias de 2016 a 2024. Os dados foram divididos em:

- Treinamento do modelo: 2016 a 2020 e outubro/2022 a dezembro/2024.
- Validação do modelo: dados de 01/10/2020 a 01/10/2022.
- Aplicação do modelo: 12/02/2025 a 31/05/2025.

Para os dados climatológicos, o HydroForecast, integra com diversas fontes de modelos climatológicos internacionais, incorporando os dados das previsões climatológicas para todo o período. Para as imagens de satélites utilizamos imagens dos satélites NASA VIIRS para observações diárias sobre vegetação e temperatura. Para os dados geoespaciais usamos dados do ERA5, USGS, NLDAS e Merit DEM para dados como elevação, inclinação, morfologia e uso do solo.

Para a avaliação dos resultados das previsões do modelo durante a fase de validação, foram utilizadas métricas tradicionais de avaliação como NSE, MSE, RMSE, MAE, MAPE, MAPE+, MAPE-, KGE, Alpha-NSE, Beta-NSE, Pearson r.

A "Eficiência de Kling-Gupta" (ou *Kling-Gupta Efficiency*, em inglês) é a principal métrica utilizada neste estudo, muito utilizada para avaliar a acurácia de previsões ou estimativas numéricas em comparação com os valores reais. Valores iguais a 1 significam um modelo perfeito e valores menores que zero significam modelos piores que uma média constante (Gupta *et al.*, 2009). Um KGE > 0.75 é considerado “muito bom”, KGE entre 0.5 – 0.75 é considerado “bom” e KGE < 0.5 é considerado “Ruim”.

Estes valores foram calculados em agregado para os 10 dias e específicos para cada horizonte de previsão (0 até 10 dias de antecedência para a previsão). Para uso como benchmark, foi selecionado o uso da Persistência. Na hidrologia, o conceito de persistência é amplamente utilizado como método de previsão de referência (baseline) e como ferramenta analítica para entender o comportamento de variáveis hidrológicas. Em termos gerais, a previsão de vazão por persistência assume que vazão no tempo atual será igual a vazão prevista para um tempo futuro. Para horizontes muito curtos (1–2 dias), a persistência pode ter desempenho surpreendentemente bom, especialmente em rios com escoamento regulado ou regime estável. Por exemplo, para um horizonte de previsão de 1 dia, a vazão horária observada de hoje às 9:00hrs será a previsão da vazão para amanhã às 9:00hrs.

Com isto criou-se uma comparação horária para toda a fase de validação entre os valores previstos pelo HydroForecast, valores previstos pelo *benchmark* (método Persistência) e os valores de vazões reais observados. Com base nestes dados, foram calculadas as métricas para HydroForecast, *benchmark* e comparados aos valores observados. Além disso foram calculadas as habilidades do modelo HydroForecast comparado com a *benchmark*. Para a fase de operação seguiu-se a mesma metodologia.

## RESULTADOS E DISCUSSÕES

A tabela 2 mostra um erro quadrático médio (RMSE) agregado 40% menor que comparado com o *benchmark* (RMSE Persistência = 246.05 e RMSE HydroForecast = 146.45). Quando analisamos o KGE agregado, vemos resultados semelhantes, KGE HydroForecast = 0.61 e KGE Persistência = -0.14. A tabela 3 detalha os valores em agregado (-1) e para cada horizonte de previsão em dias.

Tabela 2: Resumo da performance na fase de validação (Medias para os 10 dias de previsão).

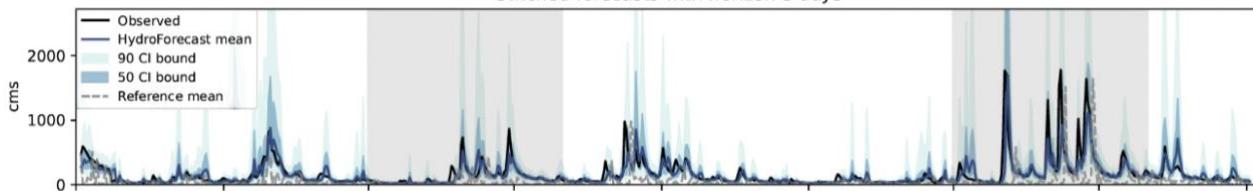
| Métrica | Benchmark (Persistência) | HydroForecast |
|---------|--------------------------|---------------|
| KGE     | -0.14                    | 0.61          |
| RMSE    | 246.05                   | 146.45        |

Tabela 3: Habilidade do modelo sobre o *benchmark* (horizonte de previsão em dias).

| DIAS | NSE  | MSE  | MAE  | RMSE | MAPE | MAPE+ | MAPE- | KGE  | Alpha-NSE | Beta-NSE | Pearson r |
|------|------|------|------|------|------|-------|-------|------|-----------|----------|-----------|
| -1   | 0.65 | 0.65 | 0.54 | 0.4  | 0.48 | 0.33  | 0.65  | 0.66 | 0.4       | 0.88     | 0.65      |
| 0    | 0.97 | 0.97 | 0.89 | 0.81 | 0.88 | 0.58  | 0.9   | 0.98 | 1.03      | 0.99     | 0.96      |
| 1    | 0.86 | 0.86 | 0.71 | 0.62 | 0.67 | 0.15  | 0.76  | 0.91 | 0.93      | 0.99     | 0.86      |
| 2    | 0.74 | 0.74 | 0.61 | 0.49 | 0.56 | 0.18  | 0.69  | 0.8  | 0.71      | 0.95     | 0.75      |
| 3    | 0.7  | 0.7  | 0.57 | 0.45 | 0.51 | 0.26  | 0.67  | 0.72 | 0.51      | 0.92     | 0.71      |
| 4    | 0.66 | 0.66 | 0.53 | 0.42 | 0.47 | 0.31  | 0.64  | 0.66 | 0.36      | 0.89     | 0.67      |
| 5    | 0.63 | 0.63 | 0.5  | 0.39 | 0.43 | 0.29  | 0.61  | 0.62 | 0.29      | 0.87     | 0.64      |
| 6    | 0.58 | 0.58 | 0.47 | 0.35 | 0.39 | 0.27  | 0.6   | 0.58 | 0.22      | 0.85     | 0.57      |
| 7    | 0.56 | 0.56 | 0.46 | 0.34 | 0.38 | 0.33  | 0.58  | 0.52 | 0.05      | 0.82     | 0.55      |
| 8    | 0.54 | 0.54 | 0.45 | 0.32 | 0.37 | 0.4   | 0.57  | 0.48 | -0.05     | 0.8      | 0.52      |
| 9    | 0.5  | 0.5  | 0.42 | 0.3  | 0.33 | 0.31  | 0.56  | 0.44 | -0.09     | 0.79     | 0.47      |
| 10   | 0.48 | 0.48 | 0.4  | 0.28 | 0.3  | 0.34  | 0.55  | 0.42 | -0.11     | 0.79     | 0.44      |

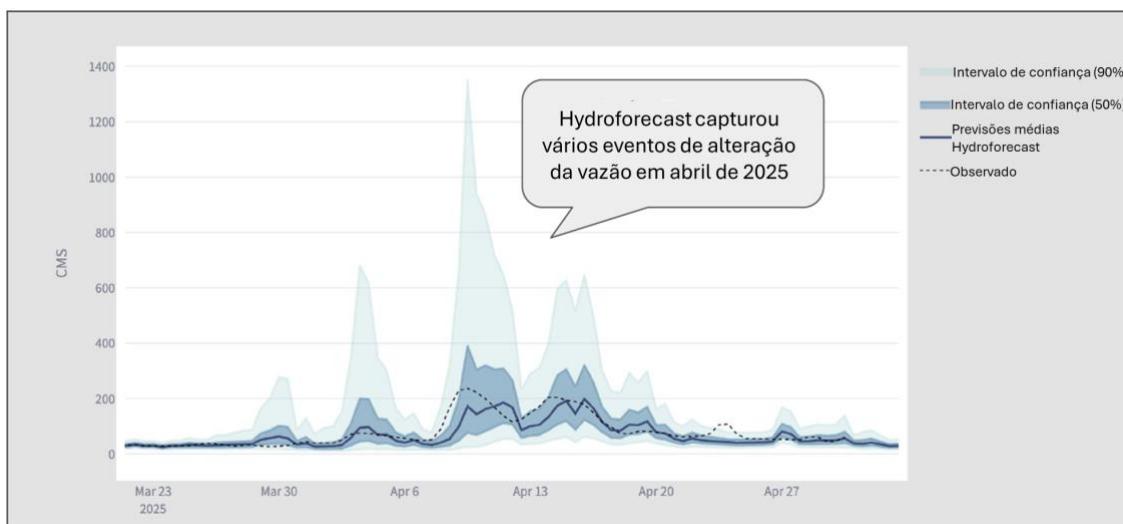
Para a análise visual das previsões da assertividade durante o período de validação, a figura 3, unificou em um gráfico as previsões médias do HydroForecast com seus intervalos de confiança de 50% e 90%, os valores médios do *Benchmark* (referência) e os valores observados. A avaliação dos resultados das previsões do modelo durante a fase de operação, foram utilizadas a mesma metodologia, focando a análise nos valores do RMSE e KGE.

Figura 3: Previsões do modelo HydroForecast – Fase Validação / Horizonte de previsão: 3 dias.



A figura 4 demonstra de forma visual a assertividade das previsões do período operacional durante os eventos do final de março e abril 2025.

Figura 4:Previsões do modelo HydroForecast – Fase Operação / Horizonte de previsão: 3 dias.



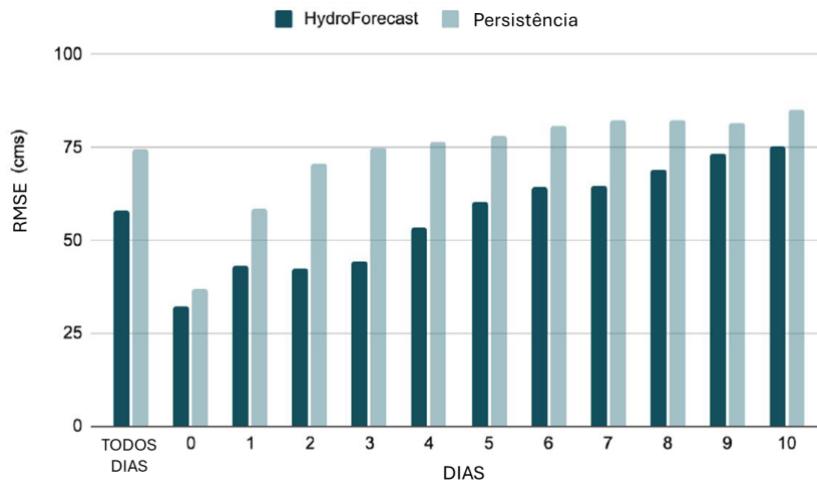
Foram realizadas avaliações de forma agregada para o período e para cada horizonte de previsão com os valores apresentados na tabela 4.

Tabela 4: Avaliação modelo na fase de operação agregada e para cada horizonte de previsão.

| Horizonte (dias) | HydroForecast RMSE (cms) | Persistência RMSE (cms) | HydroForecast % Melhoria em relação à persistência |
|------------------|--------------------------|-------------------------|--|
| Todos os dias    | 57.9                     | 74.5                    | 22.2   |
| 0                | 32.5                     | 37                      | 12.3   |
| 1                | 43.2                     | 58.5                    | 26.2   |
| 2                | 42.6                     | 70.7                    | 39.8   |
| 3                | 44.3                     | 75.6                    | 41   |
| 4                | 53.3                     | 76.6                    | 30.5   |
| 5                | 60.4                     | 78                      | 22.6   |
| 6                | 64.4                     | 80.6                    | 20.1   |
| 7                | 64.9                     | 82.5                    | 21.2   |
| 8                | 68.9                     | 82.3                    | 16.2   |
| 9                | 73.2                     | 81.5                    | 10   |
| 10               | 75.3                     | 85.2                    | 11.6   |

De forma geral, observa-se que o modelo em fase de operação manteve uma redução do erro quadrático médio (RMSE) agregado igual a 22.2%, em linha com o período de validação e superando significante a performance da Persistência. No horizonte de previsão de 3 dias, a performance do modelo sobre o benchmark superou 41%.

Figura 5: Avaliação modelo na fase de operação agregada e para cada horizonte de previsão.



Para o índice KGE, observa-se que o modelo em fase de operação obteve um KGE igual a 0.465, um pouco abaixo do obtido na fase de validação, mas novamente superando o benchmark. Esta redução pode ser explicada em parte pelo curto período de avaliação na fase de operação (4 meses).

Tabela 5: Resumo performance na fase de operação (Médias para os 10 dias de previsão).

| Métrica | Benchmark (Persistência) | HydroForecast |
|---------|--------------------------|---------------|
| KGE     | 0.32                     | 0.465         |
| RMSE    | 74.5                     | 57.9          |

## CONCLUSÃO

Neste trabalho foi demonstrado o potencial do uso de modelos construído com base em uma única arquitetura de modelo de aprendizado de máquina orientado pela teoria hidrológica e baseado em um bloco de construção de rede neural do tipo LSTM (*Long Short Term Memory*). Destacou-se não apenas a qualidade das previsões geradas, como também o nível de detalhamento e a assertividade das previsões horárias de curto prazo.

Além disso, demonstrou-se o potencial de uso e adaptação desse tipo de modelo para o território brasileiro, fazendo uso dos bancos de dados locais combinados as imagens de satélites e previsões climatológicas globais.

Este trabalho evidencia a capacidade dos modelos de aprendizagem de máquina, orientados por fundamentos da teoria hidrológica, em superar métodos tradicionais de previsão. Além disso, destaca sua aptidão para se adaptar e incorporar eventos associados às mudanças climáticas, especialmente os eventos extremos observados recentemente na Região Sul do Brasil. Previsões mais precisas são essenciais para a segurança e operação de usinas hidrelétricas, gestão do sistema elétrico nacional, transporte hidroviário, defesa civil e órgãos governamentais, contribuindo para uma resposta mais eficaz frente a cenários hidrológicos extremos.

## REFENRÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO – ANA (2024). *Hidroweb: Sistemas de informações hidrológicas*. Disponível em: <http://hidroweb.ana.gov.br/>. Acesso em: 20 jan 2024.
- BRASIL. ANEEL. BIG – *Banco de Informações de Geração* (2020). Disponível em: <https://www2.aneel.gov.br/aplicacoes/capacidadebrasil/Combustivel.cfm>. Acesso em: 15 de mar. 2020.
- BRASIL, MINISTÉRIO DE MINAS E ENERGIA. *Plano Decenal de Expansão de Energia 2034/Ministério de Minas e Energia*. Empresa de Pesquisa Energética (2024). Brasília: MME/EPE.
- BRÊDA, J. P. L. F.; PAIVA, R. C. D.; SIQUEIRA, V. A.; COLLISCHONN, W. *Assessing climate change impact on flood discharge in South America and the influence of its main drivers*. Journal of Hydrology, v. 619, 2023, n. 129284. ISSN 0022-1694.
- GUDMUNDSSON, L. et al. (2021). *Globally observed trends in mean and extreme river flow attributed to climate change*. Science, 371, 1159-1162. DOI: 10.1126/science.aba3996.
- GUPTA, H.V.; KLING, H.; YILMAZ, K.K.; MARTINEZ, G.F. (2009). *Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling*. Journal of Hydrology, Volume 377, Issues 1–2. <https://doi.org/10.1016/j.jhydrol.2009.08.003>.
- KRATZERT, F. et al. (2019). *Toward improved predictions in ungauged basins: Exploiting the power of machine learning*. Water Resources Research, 55(12), 11344-11354.
- LAPPICY, T.; LIMA, C. H. R. (2023). *Enhancing monthly streamflow forecasting for Brazilian hydropower plants through climate index integration with stochastic methods*. RBRH, v. 28, p. e48.

LIMA, Stefany G.; KUCHINSKI, Vinícius; PAIVA, Rodrigo C. D. Vazões excepcionais das grandes cheias de 1941, 2023 e 2024 no Rio Grande do Sul. In: *IV Encontro Nacional de Desastres*, Curitiba, PR, 8 a 11 de outubro de 2024. Curitiba: ABRHidro, 2024. ISSN 2764-9040.

NEARING, G. S. et al. (2022). *Data assimilation and autoregression for using near-real-time streamflow observations in long short-term memory networks*. *Hydrol. Earth Syst. Sci.*, 26, 5493–5513. <https://doi.org/10.5194/hess-26-5493-2022>.

OPERADOR NACIONAL DO SISTEMA (ONS, 2024). *Portal SINtegre*. Acessado: dezembro de 2024 [Online]. Disponível em: <https://sintegre.ons.org.br/paginas/busca.aspx>

SIQUEIRA, V.A.; FLEISCHMANN, A.S.; COLLISCHONN, W. (2000). *Simulação da propagação de cheias em reservatórios e barragens na bacia do Taquari-Antas*. In: Anais do XXI Simpósio Brasileiro de Recursos Hídricos, Nov. 2015.

SILVA, K.B.O.; JUNIOR, L.R.; ALVES, G.H.; DIAS, M.C.; SILVA, A.M.B. (2022). *Desvendando a engenharia: sua abrangência e multidisciplinaridade* - volume 4. Editora Científica Digital, 83-104 p. DOI: <10.37885/220609201>.

## AGRADECIMENTOS

Agrademos à CERAN (Companhia Energética Rio das Antas) pelo apoio e a CPFL Energia, por promover projetos de inovação na hidrologia, suporte institucional e confiança na realização deste trabalho.

## ANEXOS

A Upstream Tech é uma empresa de software orientada por missão, fundada em 2016, que oferece serviços de software para mais de duzentos clientes corporativos, governamentais e do setor sem fins lucrativos. Os dois produtos da Upstream Tech, HydroForecast e Lens, têm como objetivo melhorar a gestão de recursos naturais e a tomada de decisões em um contexto climatológico cada vez mais incerto e em transformação.

O HydroForecast é publicado academicamente e busca contribuir para o avanço de toda a área de previsão de vazão em rios, compartilhando seus progressos em hidrologia com aprendizado de máquina para que outros na comunidade possam se beneficiar e desenvolver ainda mais.

A Upstream Tech já foi reconhecida por suas contribuições, incluindo quatro prêmios por pesquisa inovadora concedidos pelo Departamento de Energia dos EUA (2020, 2021, 2023) e pela Administração Nacional Oceânica e Atmosférica dos EUA (2023), além do prêmio Outstanding Stewards of America's Waters de 2022 da Associação Nacional de Hidroenergia, por “demonstrar as previsões de vazão mais precisas da América do Norte”, e a inclusão dos dois fundadores na lista Forbes 30 Under 30 na categoria Energia.