



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Evandro Cardozo da Silva

**Modelagem de Séries Temporais via Temporal Fusion Transformers (TFT) para
Previsão de Vazão Natural Afluyente no Âmbito da Programação Mensal da
Operação (PMO)**

Florianópolis
2023

Evandro Cardozo da Silva

**Modelagem de séries temporais via Temporal Fusion Transformers (TFT) para
previsão de vazão natural afluente no âmbito da Programação Mensal da
Operação (PMO)**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica.

Orientador: Prof. Erlon Cristian Finardi, Dr.

Florianópolis

2023

Silva, Evandro Cardozo da

Modelagem de séries temporais via Temporal Fusion Transformers (TFT) para previsão de vazão natural afluente no âmbito da Programação Mensal da Operação (PMO) / Evandro Cardozo da Silva ; orientador, Erlon Cristian Finardi, 2023.

76 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Elétrica, Florianópolis, 2023.

Inclui referências.

1. Engenharia Elétrica. 2. Temporal Fusion Transformer. 3. Séries temporais. 4. Previsão de vazões. 5. Programa Mensal da Operação. I. Finardi, Erlon Cristian . II. Universidade Federal de Santa Catarina. Programa de Pós Graduação em Engenharia Elétrica. III. Título.

Evandro Cardozo da Silva

**Modelagem de séries temporais via Temporal Fusion Transformers (TFT) para
previsão de vazão natural afluente no âmbito da Programação Mensal da
Operação (PMO)**

O presente trabalho em nível de Mestrado foi avaliado e aprovado, em 26 de janeiro de 2023, pela banca examinadora composta pelos seguintes membros:

Prof. Erlon Cristian Finardi, Ph.D
Universidade Federal de Santa Catarina

Stefano Frizzo Stefenon, Ph.D
Fondazione Bruno Kessler

Felipe Beltrán Rodríguez, Dr.
Norus Energy

Certificamos que esta é a versão original e final do trabalho de conclusão que foi julgado adequado para obtenção do título de Mestre em Engenharia Elétrica com ênfase em Sistemas de Energia Elétrica.

Insira neste espaço a
assinatura digital

Prof. Telles Brunelli Lazzarin, Dr.
Coordenação do Programa de Pós-Graduação

Insira neste espaço a
assinatura digital

Prof. Erlon Cristian Finardi, Dr.
Orientador

Florianópolis
2023

RESUMO

O Brasil possui um parque gerador representado majoritariamente por uma base hidroelétrica, tornando-o dependente de fatores climáticos que apresentam alta variabilidade. Tal característica faz a previsão de vazões afluentes, elaborado pelo Operador Nacional do Sistema Elétrica (ONS), um insumo indispensável na tomada de decisões no âmbito do Programa Mensal da Operação (PMO). Um dos desafios inerentes ao PMO é avaliar o comportamento de um sistema que possui características estocásticas, não-lineares e não-estacionárias em relação a vazão afluente. Nesse contexto, modelos baseados em aprendizado de máquina têm ganhado espaço como alternativa para uma previsão mais assertiva sobre a vazão afluente natural nos aproveitamentos hidrelétricos. De maneira a contribuir para o estado da arte na previsão de vazões, foi investigado o desempenho da TFT em comparação aos modelos LSTM, TCN e as previsões do modelo SMAP em relação as vazões observadas para um horizonte de 14 dias para a UHE Tucuruí na bacia do rio Tocantins (Norte). Algumas características dessas arquiteturas que as tornam atrativas destacando-se os mecanismos de portão para ignorar quaisquer componentes irrelevantes para a arquitetura por meio do contexto externo fornecido pelas estatísticas dos dados, o processamento local através de módulos *Encoder-Decoder-LSTM* para captura de dependências temporais de curto prazo e a presença de blocos de auto-atenção para captura de dependências temporais de longo prazo. O modelo TFT mostrou-se adequado para previsão de vazão para os próximos 14 dias, apresentando assertividade próximo ao modelo LSTM e SMAP, mas com melhor desempenho ao longo de todo o horizonte.

Palavras-chave: Temporal Fusion Transformer, Séries temporais, Previsão de vazões, Programa Mensal da Operação.

ABSTRACT

The Brazilian electricity generation system relies heavily on hydroelectric power, which is subject to high variability due to its dependence on climatic factors. As a result, the accurate prediction of inflow flows is crucial for effective decision-making within the Monthly Operation Program (PMO) and is accomplished by the National Electric System Operator (ONS). However, the PMO faces significant challenges due to the stochastic, nonlinear, and non-stationary nature of the hydrological system. In this context, machine learning-based models have emerged as a promising alternative for predicting natural inflow flows in hydroelectric developments. Specifically, this study investigates the performance of the Transformer-based Time-series Forecasting (TFT) model in comparison to the Long Short-Term Memory (LSTM), Temporal Convolutional Networks (TCN), and Soil Moisture Active Passive (SMAP) models. The models were evaluated in terms of their ability to predict observed flows for a 14-day horizon at the Tucuruí Hydroelectric Power Plant in the Tocantins River basin (North). The investigated models possess attractive features, such as gate mechanisms for excluding irrelevant components through external context provided by data statistics, local processing through Encoder-Decoder-LSTM modules for capturing short-term temporal dependencies, and the inclusion of self-attention blocks for capturing long-term temporal dependencies. The findings of this study demonstrate that the TFT model is a suitable alternative for predicting inflow flows for the next 14 days, exhibiting accuracy levels comparable to those of the LSTM and SMAP models. Moreover, the TFT model demonstrates superior performance over the entire horizon. These results contribute to the state-of-the-art in flow prediction and provide valuable insights for the decision-making processes within the Brazilian electricity sector.

keywords: Temporal Fusion Transformer, Time series, Streamflow forecasting, Monthly Planning and Operation Program.

LISTA DE FIGURAS

Figura 1 - Processo de decisão para sistemas hidrotérmicos.....	12
Figura 2 - Matriz energética por fonte no Brasil em 2022.....	13
Figura 3 - Cronograma do Programa Mensal da Operação.....	21
Figura 4 - Metodologia de previsão de vazão aplicada pelo ONS.....	22
Figura 5 - Esquemático do modelo SMAP.....	26
Figura 7 – Processo geral de treinamento de uma rede neural.....	36
Figura 9 - Processo de amostragem de dados temporais.....	40
Figura 10. Processo de treinamento com variáveis temporais.....	41
Figura 11 - Arquitetura do modelo TFT.....	42
Figura 12. Arquitetura de um bloco GRN.....	44
Figura 13 - Bloco de seleção de variáveis.....	46
Figura 14 - Localização UHE Tucuruí (a) e diagrama de usinas (b).....	51
Figura 15 - Padrão de precipitação anual UHE Tucuruí.....	52
Figura 16 - Hidrograma UHE Tucuruí.....	52
Figura 17. Características de dispersão dos modelos para (a) covariável de precipitação e (b) covariável de vazão.....	59
Figura 18. Desempenho ao longo do horizonte para UHE Tucuruí para o período seco: (a) Covariável precipitação e (b) covariável vazão observada. Período úmido: (c) Covariável precipitação e (d) covariável vazão observada.....	60
Figura 19. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo LSTM utilizando covariável de precipitação.....	61
Figura 20. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo LSTM utilizando covariável de vazão.....	62
Figura 21. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo TCN utilizando covariável de precipitação.....	63
Figura 22. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo TCN utilizando covariável de vazão.....	63
Figura 23. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo TFT utilizando covariável de precipitação.....	64
Figura 24. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo TFT utilizando covariável de vazão.....	65

LISTA DE QUADROS

Quadro 1. Covariáveis por modelo.....	38
Quadro 2. Experimentos propostos.....	55

LISTA DE TABELAS

Tabela 1 – Parâmetros do modelo SMAP	25
Tabela 2 - Alternativas de modelagem estocásticas do modelo PREVIVAZ.....	30
Tabela 3 – Exemplo de estrutura de dados para amostragem.....	39
Tabela 4 – Informações sobre o banco de dados utilizados sobre precipitação.....	49
Tabela 5 - Produtibilidades	51
Tabela 6 - Resumo estatístico de precipitação e vazão para UHE Tucuruí.	53
Tabela 7. Especificações da arquitetura do modelo TFT.....	56
Tabela 8. Especificações da arquitetura do modelo LSTM	56
Tabela 9. especificações da arquitetura do modelo TCN	56
Tabela 10 – MAPE e Nash para UHE Tucuruí – Tocantins (Norte).....	57

LISTA DE ABREVIATURAS E SIGLAS

SIN	<i>Sistema Interligado Nacional</i>
ONS	<i>Operador Nacional do Sistema</i>
SMAP	<i>Soil Moisture Accounting Procedure</i>
PMO	<i>Programa Mensal da Operação</i>
CEPEL	<i>Centro de Pesquisas de Energia Elétrica</i>
UHE	<i>Usina hidrelétrica</i>
ANA	<i>Agência Nacional de Águas</i>
PLD	<i>Preço de Liquidação das Diferenças</i>
RNA	<i>Rede Neural Artificial</i>
LSTM	<i>Long Short-Term Memory</i>
MLP	<i>Multilayer Perceptron</i>
TCNN	<i>Temporal Convolutional Neural Network</i>
TFT	<i>Temporal Fusion Transformers</i>
GRN	<i>Gated Residual Network</i>
GLU	<i>Gated Linear Unit</i>
MAPE	<i>Mean Absolute Percentage Error</i>
RELU	<i>Rectified Linear Unit</i>
ELU	<i>Exponential Linear Unit</i>

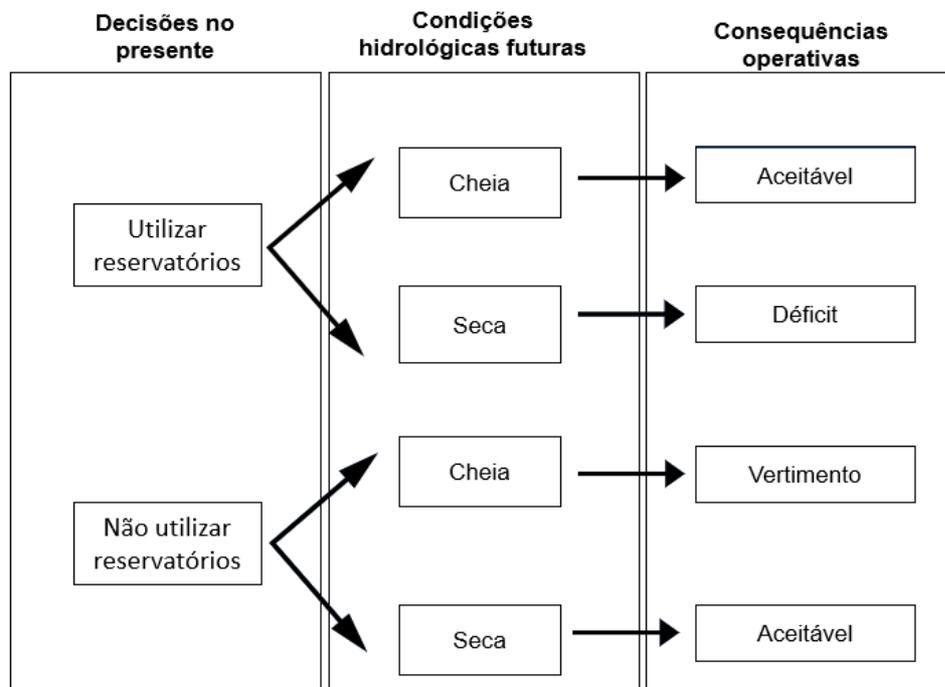
SUMÁRIO

1	INTRODUÇÃO	12
1.1	ESTADO DA ARTE.....	14
1.2	OBJETIVOS E CONTRIBUIÇÕES.....	18
1.3	ORGANIZAÇÃO DA DISSERTAÇÃO	19
2	PREVISÃO DE VAZÕES NO ÂMBITO DO PROGRAMA MENSAL DA OPERAÇÃO.....	20
2.1	PROCESSO DE PREVISÃO DE VAZÕES NO PMO.....	20
2.2	MODELOS DE PREVISÃO DE VAZÃO	23
2.2.1	Modelo SMAP.....	23
1.1.1	Previvaz	30
3	MODELAGEM DE SÉRIES TEMPORAIS VIA REDES NEURAIIS	33
3.1	TREINAMENTO E OTIMIZAÇÃO DE REDES NEURAIIS	34
3.2	SÉRIES TEMPORAIS.....	37
3.2.1	Criação de amostras temporais via amostragem.....	38
3.2.2	Treinamento.....	40
3.3	TEMPORAL FUSION TRANSFORMER	41
3.3.1	Entradas do modelo	43
3.3.2	Gating mechanisms	43
3.3.3	Variable selection.....	45
3.3.4	Sequence-to-sequence: bloco LSTM.....	47
3.3.5	Interpretable multi-head attention.....	47
4	METODOLOGIA.....	49
4.1	PRECIPITAÇÃO OBSERVADA	49
4.2	VAZÕES OBSERVADAS	49
4.3	LOCAL DE ESTUDO.....	50
4.3.1	Submercado Norte: 275-Tucuruí.....	51
4.4	INDICADORES DA QUALIDADE DA PREVISÃO DE VAZÃO	53
5	RESULTADOS E DISCUSSÕES.....	55
5.1	EXPERIMENTOS COMPUTACIONAIS.....	55
5.2	RESULTADOS	57
6	CONCLUSÕES.....	66
	REFERÊNCIAS.....	68
	ANEXO A – LISTA DOS POSTOS E RESPECTIVOS MODELOS APLICADOS	75

1 INTRODUÇÃO

O problema da operação de sistemas hidrotérmicos está atrelado ao dilema clássico da operação, onde o estado de armazenamento dos reservatórios e as afluições que chegam nas usinas determinam a dinâmica da operação do presente e planejamento do futuro. Assim, o nível nos reservatórios no presente e a operação futura é consequência das decisões tomadas no passado e agora (Figura 1).

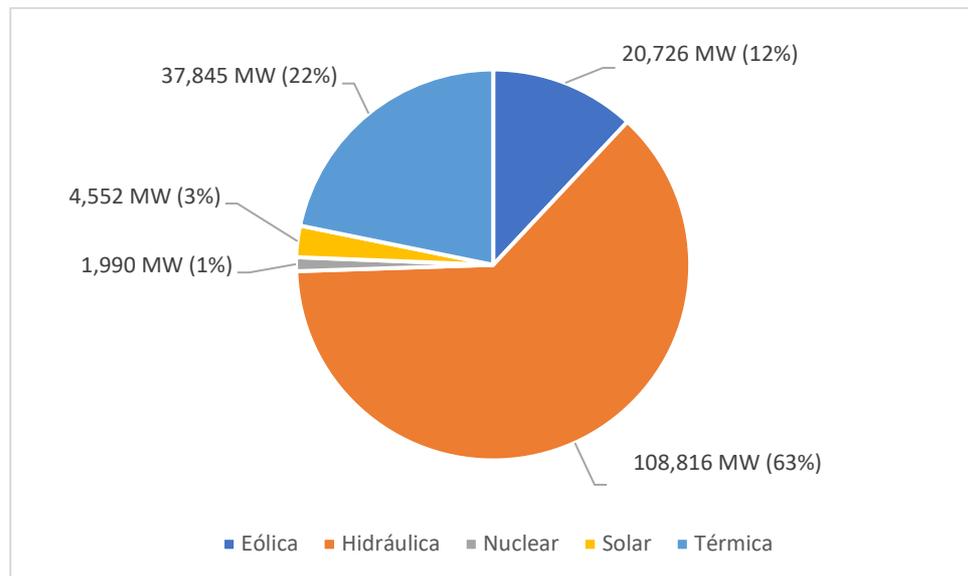
Figura 1 - Processo de decisão para sistemas hidrotérmicos



Fonte: adaptado de Silva, E.L. (2012)

Essa necessidade de planejamento é uma característica determinante em sistemas hidrotérmicos, como é o caso do SIN, onde a matriz é predominantemente hidráulica e representa aproximadamente 63% (Figura 2). Em razão disso, há uma forte dependência da informação hidrológica, o que torna o planejamento da operação uma atividade desafiadora devido ao comportamento estocástico das chuvas. Nesse contexto de incertezas, a previsão de vazão natural afluyente aos locais de aproveitamentos hidroelétricos é um insumo fundamental para a programação da operação do SIN pelo Operador Nacional do Sistema Elétrico (ONS).

Figura 2 - Matriz energética por fonte no Brasil em 2022.



Fonte: ONS (2022).

Atualmente, o ONS é responsável pela elaboração das previsões de vazões naturais afluentes médias diárias, semanais e mensais para todos os aproveitamentos hidrelétricos do SIN. Considerando a predominância significativa da hidroeletricidade na matriz energética do Brasil, a qualidade dessas previsões é de suma importância para o planejamento da operação pelo ONS. Com base nessas informações, o ONS decide a política de operação mais apropriada visando a redução da incerteza de maneira a mitigar riscos, minimizar os custos e otimizar o uso dos recursos disponíveis.

Dada a relevância da previsão de vazão como um dos fatores decisivos no planejamento e operação do sistema, o ONS vem buscando aprimorar seus modelos. No entanto, a complexidade da modelagem dos fenômenos hidráulicos e hidrológicos representa um dos maiores desafios na atual abordagem com modelos conceituais, como é o caso do SMAP. Por se tratar de um problema físico com características não-lineares, considerando a relação entre as variáveis de precipitação, infiltração, evapotranspiração e características físicas do solo em cada bacia torna-se bastante complexa.

Diante de tal dificuldade, modelos baseados em aprendizado de máquina têm ganhado espaço como alternativa para uma previsão mais assertiva sobre a vazão afluente natural nos aproveitamentos hidrelétricos. O desenvolvimento de modelos baseados em redes neurais artificiais (RNAs) são recorrentes na literatura devido a sua escalabilidade em problemas de previsão de séries temporais.

1.1 ESTADO DA ARTE

A matriz energética brasileira tem como principal fonte a hidroeletricidade, o que faz com que a programação do sistema hidrotérmico esteja altamente dependente das vazões naturais e incrementais que fluem em direção aos aproveitamentos hidrelétricos distribuídos nas bacias hidrográficas (BRAGA et al., 2014). Para isso, cabe ao Operador Nacional do Sistema Elétrico (ONS) a responsabilidade de realizar a previsão de vazões naturais médias diárias para todos os locais de aproveitamento hidroelétrico do Sistema Interligado Nacional (SIN), que são utilizadas como insumos básicos para a cadeia de modelos de otimização do ONS (BRAGA et al., 2014). A qualidade da previsão de vazão para o ONS é de extrema importância, tendo em vista a influência direta das condições de afluência no risco de racionamento e no preço da energia (SIGNORIELLO, 2014). Portanto, a precisão das previsões é um fator crítico para o sucesso do sistema elétrico brasileiro.

Atualmente, o ONS utiliza dois modelos para realizar a previsão de vazões para o programa mensal da operação (PMO). Um modelo determinístico de simulação hidrológica do tipo transformação chuva-vazão, conhecido como SMAP, do inglês *Soil Moisture Accounting Procedure*, e outro modelo hidrológico estocástico de séries temporais baseado no histórico de vazões, conhecido como PREVIVAZ. No entanto há algumas limitações quanto a precisão e desempenho desses modelos, especialmente se os dados de calibração e entrada conterem imprecisões e certo grau de erro de medição (HU et al., 2020). Portanto, novas abordagens têm sido estudadas de maneira a melhorar as previsões, dada a sua importância para um planejamento e operação adequados.

Recentemente na literatura, novas metodologias baseadas em modelos de inteligência artificial têm se mostrado alternativas promissoras em relação a modelo físicos determinísticos que modelam os aspectos do fenômeno hidrológico, como o SMAP. Modelos como o de redes neurais artificiais (RNAs), baseiam-se nos padrões

encontrados das relações entre chuva e vazão observada, contornando problemas relacionados a não-linearidade entre as variáveis e complexidade dos modelos físicos (HU et al., 2020).

Em um estudo realizado por LE et al. (2021), foi investigado o desempenho de diversos modelos de previsão de vazões afluentes, incluindo feed-forward neural network (FFNN), convolutional neural network (CNN) e quatro variações de long short-term memory (LSTM), aplicados à bacia do Rio Vermelho, localizada no Vietnã. Os resultados mostraram que as quatro variantes do modelo LSTM apresentaram uma precisão significativa e um desempenho e estabilidade superiores quando comparados aos modelos FFNN e CNN. Esses achados indicam a eficácia do uso de modelos LSTM na previsão de vazões, especialmente em bacias hidrográficas com características semelhantes às da bacia do Rio Vermelho. Essa informação é importante para o desenvolvimento de modelos de previsão mais precisos e confiáveis para sistemas de gerenciamento de recursos hídricos, contribuindo para o planejamento e a operação adequados dos sistemas elétricos e hidráulicos.

HU et al. (2020) conduziram um estudo utilizando um modelo LSTM para prever a vazão afluente de estações hidrológicas com seis horas de antecedência. Os resultados mostraram que o modelo LSTM teve um desempenho superior quando comparado a outros modelos de aprendizado de máquina, como Support Vector Regression (SVR) e Multilayer Perceptrons (MLP). Esses resultados sugerem que o uso de modelos LSTM pode ser uma abordagem promissora para a previsão de vazões em sistemas hidrológicos, contribuindo para o desenvolvimento de modelos de previsão mais precisos e confiáveis para o gerenciamento de recursos hídricos.

De acordo com Faria et al. (2022), os modelos clássicos de MLP são considerados os mais simples na tarefa de previsão de vazões quando comparados a modelos de camadas profundas. No entanto, os autores concluíram que mesmo modelos de MLP fornecem maior precisão em relação a modelos hidrológicos utilizados pelo Operador Nacional do Sistema Elétrico (ONS) para previsões de curto prazo. Esses resultados reforçam a importância de avaliar diferentes modelos de previsão de vazões em sistemas hidrológicos, incluindo modelos de aprendizado de máquina, com o objetivo de identificar qual o melhor modelo a ser utilizado em cada contexto e obter previsões mais precisas e confiáveis.

Barino, F.O e dos Santos, A.B (2020) propuseram um modelo alternativo, fundamentado na arquitetura de redes neurais convolucionais (CNNs), visando

aprimorar a previsão de múltiplos dias de horizonte em ambientes fluviais. O modelo proposto, denominado CNN-1D, foi avaliado a partir de diferentes variáveis de entrada, como registros de vazões históricas e turbidez, utilizando-se dados coletados no rio Madeira, localizado na bacia do rio Amazonas. Os resultados apontaram que a utilização conjunta de registros de vazões passadas e de turbidez da água conferiu maior confiabilidade às previsões, sugerindo a eficácia do modelo CNN-1D proposto pelos autores.

Na literatura, há propostas de modelos mais sofisticados que utilizam arquiteturas como Long Short-Term Memory (LSTM) e redes neurais convolucionais (CNN), as quais apresentam potencial para a identificação de padrões temporais e espaciais em dados hidrológicos. Alguns autores têm sugerido abordagens híbridas, como o modelo CNN-LSTM, que combina características individuais de cada modelo. Em um estudo realizado na bacia do rio Elbe, na Alemanha, Li P. et al. (2022) demonstraram que o modelo CNN-LSTM é superior para a estimativa da disponibilidade de água em reservatórios e riscos de inundações.

Maciel, G.M. et al. (2020) propuseram uma adaptação do modelo híbrido CNN-LSTM para a previsão de vazões em ambientes hidrológicos, acoplando-o ao modelo hidrológico SMAP, amplamente utilizado no processo de planejamento da operação pelo Operador Nacional do Sistema Elétrico (ONS). A eficácia do modelo adaptado foi avaliada em um estudo que comparou seus resultados com os obtidos pelo modelo isolado. Os resultados evidenciaram uma melhora significativa para a previsão de vazões no horizonte de 7 dias, indicando a potencialidade da abordagem híbrida proposta pelos autores.

Embora os modelos existentes apresentem boa resposta ao problema de previsão de vazões, ainda há espaço para melhorias em arquiteturas mais especializadas na modelagem de séries temporais, especialmente no que diz respeito à complexidade da modelagem de relações não lineares e dependência temporal de longo prazo. Nesse contexto, Lim, B. et al. (2020) propuseram recentemente uma nova arquitetura de redes neurais, denominada Temporal Fusion Transformer (TFT), que combina os mecanismos de modelos como as camadas LSTM e attention heads utilizadas em modelos Transformers. Em diversos estudos aplicados, como previsão de carga, tráfego, vendas e volatilidade de estoques, os autores mostraram um aumento significativo tanto no desempenho computacional quanto na precisão dos

resultados em comparação aos modelos de referência amplamente utilizados na literatura.

Em um estudo recente, Srivastava e Cano (2021) analisaram diferentes modelos de deep learning, incluindo LSTM, GRU, RNN e TFT, para análise e previsão dos níveis de pH. Os autores demonstraram que o modelo TFT apresentou melhor desempenho em comparação aos demais modelos de deep learning, fornecendo a melhor estimativa de pH.

Wu, B., et al. (2022) aplicaram o modelo Temporal Fusion Transformer (TFT) multivariado para prever com alta precisão a velocidade do vento. A abordagem se mostrou promissora em comparação aos demais modelos de deep learning, que apresentam limitações em termos de precisão ou de exigência computacional. Os autores utilizaram técnicas de decomposição modal variacional e evolução diferencial adaptativa para otimizar os parâmetros da rede neural. O sistema de previsão proposto apresentou resultados satisfatórios e superou a maioria dos outros modelos comparados na análise. Esta pesquisa foi pioneira na aplicação do modelo TFT para previsão de velocidade do vento

Pesquisadores têm investigado o potencial do modelo TFT em diferentes áreas, incluindo a previsão de precipitação. Civitarese, C.S., et al. (2021) pioneiramente aplicaram o modelo TFT para prever eventos climáticos extremos. Os autores compararam as previsões do modelo com o modelo climatológico Seasonal Forecast (SEAS5) do European Centre for Medium-Range Weather Forecasts (ECMWF), utilizado como referência para validação dos resultados. Os resultados mostraram que as previsões do modelo TFT para precipitação máxima diária em cada semana, com um horizonte de 6 meses, superaram significativamente os resultados obtidos com o modelo SEAS5.

Gunnarsson, A. e Franc, C. (2021) investigaram o potencial do modelo TFT na previsão de vendas de produtos em um mercado, com o objetivo de reduzir o desperdício de alimentos. Os autores compararam diferentes configurações do modelo TFT com os modelos autorregressivos (AR) e LSTM, usados como referência no estudo. Os resultados obtidos demonstraram que o modelo TFT superou significativamente os demais modelos analisados em termos de desempenho preditivo. A abordagem proposta pelos autores apresenta, portanto, uma alternativa promissora para prever as vendas de produtos em mercados, contribuindo para a redução do desperdício de alimentos e para a gestão eficiente de estoques

Sappl et al. (2021) apresentaram uma solução inovadora utilizando o modelo TFT para prever a taxa de geração de biogás em um biodigestor anaeróbico real localizado em Tyrol, Austria. A abordagem proposta treinou o modelo para gerar previsões diárias com base nos dados dos últimos sete dias. Os autores avaliaram o desempenho do modelo TFT em comparação com modelos clássicos de aprendizagem de máquina, como o modelo k-nearest neighbors (KNN), ARIMA e redes neurais simples, utilizados como referência para este estudo. Os resultados mostraram que o modelo TFT superou significativamente os modelos de referência, fornecendo previsões precisas e melhorando a eficiência da operação do biodigestor anaeróbico. A abordagem proposta pode ser uma ferramenta valiosa para aprimorar a tomada de decisão na gestão de sistemas de biodigestores anaeróbicos.

De acordo com a literatura existente, a maioria dos estudos no campo de previsão de vazões utiliza modelos tradicionais baseados em deep learning, sendo que muitas das aplicações que empregam o modelo TFT foram pioneiras em suas áreas de atuação. No entanto, até o presente momento, nenhum estudo na literatura propôs uma investigação do modelo TFT para previsão de vazões. Portanto, há uma necessidade clara de investigar a eficácia do modelo TFT na previsão de vazões em comparação com os modelos tradicionais de deep learning.

1.2 OBJETIVOS E CONTRIBUIÇÕES

Neste trabalho é proposto a aplicação do modelo TFT que é inédito na previsão de vazões afluentes em aproveitamentos hidrelétricos, até onde se tem conhecimento. A partir de experimentos computacionais aplicados em diferentes cenários, o modelo será comparado com os modelos *LSTM*, *TCN* e *SMAP* para um horizonte de 14 dias. Com base nos resultados obtidos será analisado o impacto das variáveis de chuva e vazão observados na previsão de vazões afluentes para 14 dias de horizonte para o aproveitamento hidrelétrico de Tucuruí, na bacia do rio Tocantis, Brasil.

As principais contribuições deste trabalho incluem:

- Comparação do modelo TFT com modelos baseados em *deep learning* que são comuns na literatura como LSTM, e TCN e o modelo físico determinístico SMAP atualmente utilizado pelo ONS.

- Aplicação do modelo TFT para realizar a previsão de vazões afluentes em aproveitamentos hidrelétricos, avaliando o impacto durante o regime anual de precipitação sobre a qualidade da vazão prevista durante os períodos úmido e seco.
- Análise sobre a influência da combinação de diferentes variáveis de entrada de chuva e vazão observada conforme cenários de previsões.

1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

A dissertação é estruturada da seguinte forma: o Capítulo 2 apresenta uma revisão sobre os processos de operação e planejamento do sistema adotados pelo ONS, bem como as metodologias dos modelos SMAP e PREVIVAZ, que são atualmente utilizados para previsão diária e semanal de vazões. No Capítulo 3, são introduzidos os conceitos fundamentais e aspectos principais sobre a modelagem de redes neurais artificiais, bem como as principais características e metodologia do modelo TFT proposto a ser avaliado neste trabalho. O Capítulo 4 apresenta os resultados dos experimentos testados em cada cenário analisado. Por fim, o Capítulo 5 resume os principais resultados encontrados e apresenta as considerações finais da dissertação.

2 PREVISÃO DE VAZÕES NO ÂMBITO DO PROGRAMA MENSAL DA OPERAÇÃO

O parque gerador de energia elétrica do Brasil é composto principalmente por hidrelétricas, o que torna a previsão de vazões afluente uma ferramenta essencial para a tomada de decisões no planejamento e operação do sistema elétrico, como parte do Programa Mensal de Operação (PMO). O ONS, em colaboração com alguns agentes, produz semanalmente previsões de vazões para todos os reservatórios hidrelétricos em quatro sub-mercados: Sudeste/Centro-Oeste, Sul, Nordeste e Norte. Essas previsões são cruciais para garantir a segurança e a eficiência da geração de energia hidrelétrica no país.

Um dos desafios inerentes ao processo de previsão de vazão em rios é a complexidade do comportamento estocástico, não-linear e não-estacionário da vazão afluente (BARINO; SANTOS, 2020). Para lidar com essa complexidade, modelos matemáticos alternativos têm sido estudados e desenvolvidos, com o objetivo de se obter um modelo mais preciso e próximo do comportamento real da vazão (MACIEL et al., 2020). Desde 2008, o Operador Nacional do Sistema Elétrico (ONS) e outros agentes vêm buscando novas metodologias e modelos computacionais para melhorar a qualidade das previsões de vazões. Atualmente, para previsões de vazão para a primeira e segunda semanas operativas, tem-se utilizado o modelo hidrológico determinístico SMAP, baseado em dados de precipitação observada e em previsões combinadas dos modelos de previsão numérica de tempo ECMWF (European Centre for Medium-Range Weather Forecasts), GEFS (Global Ensemble Forecast System) e ETA (GT-SMAP, 2022).

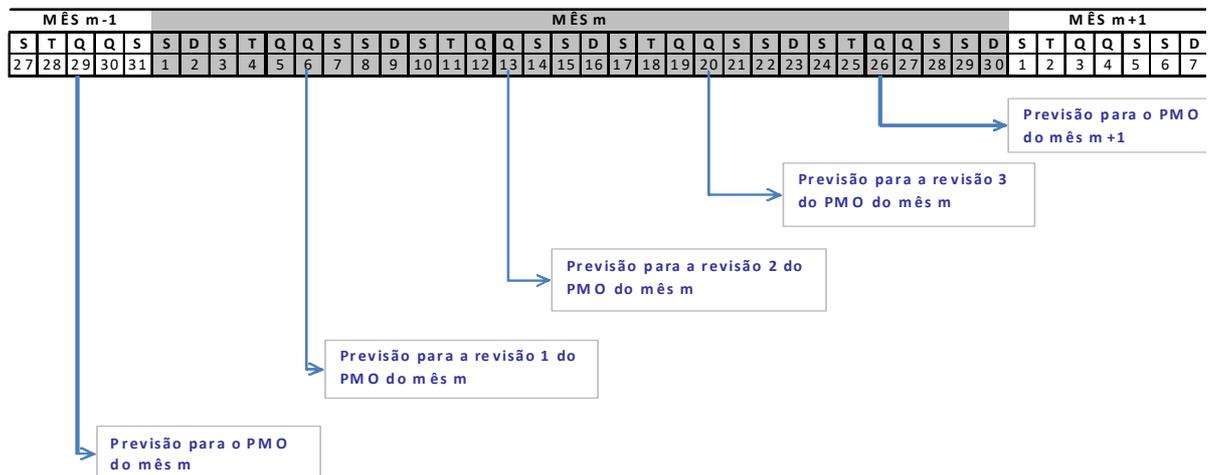
2.1 PROCESSO DE PREVISÃO DE VAZÕES NO PMO

No processo de planejamento da operação no âmbito do Programa Mensal de Operação (PMO), as previsões de vazões naturais afluentes são insumos básicos utilizados para determinar o despacho ótimo para a semana seguinte, visando minimizar o custo de operação (CMO) e calcular o preço de liquidação das diferenças (PLD), utilizado nas transações entre agentes e geradores (MACEIRA, 2002). Conforme definido por Filho et al. (2020), as vazões naturais afluentes compreendem as vazões fornecidas pela natureza, incluindo aquelas que ocorreriam naturalmente

em uma seção do rio caso não houvesse operação de reservatórios a montante, bem como a vazão resultante de lagos artificiais e captações de água para uso consuntivo.

O ONS é responsável por organizar o processo de planejamento da operação em revisões semanais. A primeira dessas revisões é conhecida como PMO, na qual se prevê as vazões para as próximas semanas operativas. A elaboração de cada revisão ocorre, em geral, às quintas-feiras e, eventualmente, na quarta-feira que antecede a semana operativa, que tem início no sábado e término na sexta-feira. Conforme ilustrado na Figura 3, o ONS adota este esquema de elaboração das previsões de vazões para o PMO e suas revisões.

Figura 3 - Cronograma do Programa Mensal da Operação.



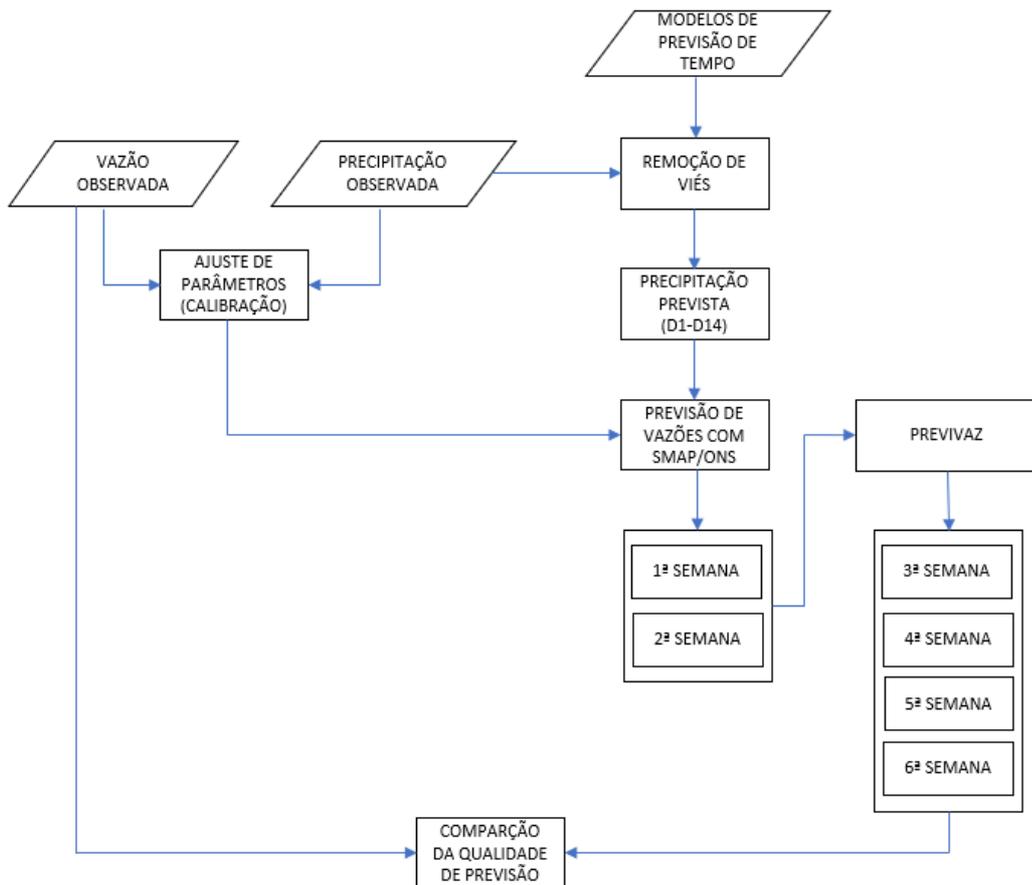
Fonte: adaptado de GT-SMAP (2022).

O planejamento da operação de curto prazo no âmbito do PMO, sob responsabilidade do ONS, consiste na definição de metas semanais de geração para cada usina do SIN. Nesse processo, as vazões afluentes aos aproveitamentos hidroelétricos são consideradas parte estocástica e parte determinística. Para o primeiro mês, são utilizadas previsões de afluências semanais, enquanto a partir do segundo mês, são adotados cenários sintéticos de vazões mensais. É importante ressaltar que o planejamento de curto prazo atualmente abrange um horizonte de até dois meses.

O modelo GEVAZP é uma ferramenta utilizada pelo ONS para gerar os cenários do segundo mês, que são alimentados na cadeia de modelos Decomp-Newave para cálculo do PLD. Os modelos Newave e Decomp são dois modelos

matemáticos utilizados no planejamento e operação de sistemas hidrotérmicos de energia elétrica, sendo o NEWAVE responsável por otimizar a operação do sistema elétrico a médio prazo no horizonte de até 5 anos, e o DECOMP para o curto prazo, com horizonte de 2 meses e intervalos semanais (SILVA, 2008). Para isso, é utilizada a informação do PMO e de cada revisão, sendo que as previsões para as duas primeiras semanas operativas são obtidas pela média da previsão diária do modelo chuva-vazão SMAP no horizonte de 14 dias. Já para as semanas posteriores, são utilizados os resultados do modelo estocástico PREVIVAZ. Como resultado, para cada revisão é gerado um arquivo com seis colunas, conhecido como PREVS, cada uma representando uma semana. A Figura 4 apresenta um fluxograma da metodologia atualmente adotada pelo ONS.

Figura 4 - Metodologia de previsão de vazão aplicada pelo ONS.



Fonte: adaptado de GT-SMAP (2022).

Além do SMAP, a metodologia CPINS é empregada somente nos reservatórios da bacia do Rio São Francisco entre Três Marias/Queimado e Sobradinho, enquanto nas demais bacias dos rios Tocantins, Paranaíba, Paraná, Paranapanema, Grande, Tietê, Iguaçu, Uruguai, Jacuí, Capivari, Itajaí e parte das bacias dos rios Madeira e São Francisco é utilizada a metodologia descrita na Figura 4. Os demais postos seguem a técnica de regressão linear para estimar a vazão afluente nos postos que não possuem medições fluviométricas. Para os postos que não dispõem de medições fluviométricas, a vazão afluente é estimada por meio de regressão linear em relação à vazão prevista nos postos base, que possuem equipamentos específicos para medição de vazão e chuvas. A lista completa dos postos e modelos aplicados em cada bacia hidrográfica está disponível no "Relatório de Previsão de Vazão do PMO", disponibilizado no Anexo A deste documento.

2.2 MODELOS DE PREVISÃO DE VAZÃO

A seção a seguir descreve a metodologia matemática nos modelos de previsão de vazão semanal utilizados atualmente no PMO do ONS. Como descrito anteriormente, os resultados do modelo chuva-vazão juntamente com o modelo PREVIVAZ irão compor o arquivo de vazões PREVS que alimenta a cadeia de modelos NEWAVE-DECOMP para prospecção do PLD semanalmente.

2.2.1 Modelo SMAP

O SMAP é um modelo chuva-vazão proposto por Lopes et al. (1982), o qual tem como objetivo simular o ciclo hidrológico por meio da representação de reservatórios. Esse modelo é amplamente utilizado pelo NOS para estabelecer o planejamento da operação no curto prazo a partir da previsão da vazão natural afluente em cada aproveitamento hidrelétrico do SIN (LOPES et al., 1982). Segundo Nunes et al. (2014), a aplicação do SMAP é importante para a gestão dos recursos hídricos e para a otimização da produção de energia elétrica no Brasil. Dessa forma, a utilização desse modelo tem contribuído significativamente para a tomada de decisões estratégicas e operacionais no setor elétrico brasileiro.

2.2.1.1 Parâmetros de entrada do modelo SMAP

De acordo com o manual de metodologia do modelo SMAP disponibilizado pelo ONS, os dados de entrada do modelo no modo operacional são os totais diários de precipitação previstos e observados, os totais diários de evapotranspiração potencial (Ep_t), e as vazões médias diárias observadas ($Qobs_t$) do período de assimilação de dados (ONS, 2017). Para as precipitações observadas o modelo então calcula um total diário de precipitação média da bacia $Pb_{(t)}$ ponderando o peso de cada estação pluviométrica a partir da seguinte expressão:

$$Pb_{(t)} = P1_{(t)}ke_1 + P2_{(t)}ke_2 + \dots + Pn_{(t)}ke_n \quad (1)$$

onde $Pb(t)$ é a precipitação média observada na bacia, no instante de tempo t (mm/day); $P1_{(t)}, P2_{(t)}, \dots, Pn_{(t)}$ é a precipitação observada nos postos pluviométricos considerados na bacia; e ke_1, ke_2, \dots, ke_n são os coeficientes de representação espacial de cada posto pluviométrico, considerando

$$ke_1 + ke_2 + ke_3 + \dots + ke_n = 1 \quad (2)$$

Após isso o aplicativo calcula a precipitação considerada como representativa do dia t ($Pd(t)$), sendo ela composta por uma ponderação de $Pb(t)$ de diferentes tempos, conforme equação seguir:

$$Pd(t) = [Pb_{(t-n)}kt_{(-n)} + \dots + Pb_{(t)}kt_{(0)} + Pb_{(t+1)}kt_{(+1)} + Pb_{(t+2)}kt_{(+2)}] \quad (3)$$

onde $kt_{-n}, \dots, kt_0, kt_{+1}, kt_{+2}$ são os coeficientes de representação temporal e n é o número de dias no passado que serão considerados na ponderação.

Finalmente o valor de $Pd_{(t)}$ é multiplicado pelo fator $Pcof$, que ajusta o volume de precipitação na bacia para garantir o equilíbrio hídrico da bacia, obtendo a precipitação média na bacia $P_{(t)}$, a ser considerada pelo modelo no instante de tempo t (mm/day).

$$P_{recp(t)} = Pd_{(t)} \cdot Pcof \quad (4)$$

onde $Pcof$ é o coeficiente de ajuste da precipitação.

A evapotranspiração potencial fornecida ($Epf(t)$) muitas vezes é estimada a partir de equações empíricas ou medidas em locais distantes e ajustadas para a bacia de interesse. Dessa forma, também com vistas à garantia do balanço hídrico da bacia, é necessário ajustar a evapotranspiração potencial ($Ep(t)$) com as seguintes equações:

$$Ep(t) = Epf(t) \cdot Ecof \quad (5)$$

$$Emarg = Epf(t) \cdot Ecof2 \quad (6)$$

Onde $Ep(t)$ evapotranspiração potencial (mm / dia); $Epf(t)$ evapotranspiração potencial diária estimada para a bacia (mm / dia); $Ecof$ coeficiente de ajuste da evapotranspiração potencial média da bacia; $Emarg$ evaporação da planície de inundação (mm / dia); e $Ecof2$ coeficiente de ajuste da evapotranspiração potencial da evaporação da planície de inundação. A Tabela 1 resume as principais variáveis de entrada, parâmetros e saída do modelo SMAP.

Tabela 1 – Parâmetros do modelo SMAP

Parâmetro	Descrição
<i>Eb(0)</i>	Escoamento básico inicial
<i>Tu(0)</i>	Teor de umidade do solo inicial
<i>Sup(0)</i>	Escoamento superficial inicial
<i>K1t</i>	Constante de recessão do escoamento para planícies (dia)
<i>K2t</i>	Constante de recessão do primeiro escoamento superficial (dia)
<i>K3t</i>	Constante de recessão do escoamento da superfície/planícies (dia)
<i>K2t2</i>	Constante de recessão do segundo escoamento superficial (dia)
<i>Kkt</i>	Constante de recessão do escoamento básico (dia)
<i>Cap</i>	Capacidade de campo (%)
<i>Ai</i>	Abstração inicial (mm)
<i>Str</i>	Capacidade de saturação do solo (mm)
<i>Crec</i>	Parâmetro de recarga subterrânea (%)
<i>Ecof</i>	Coeficiente de ajuste da evapotranspiração da bacia

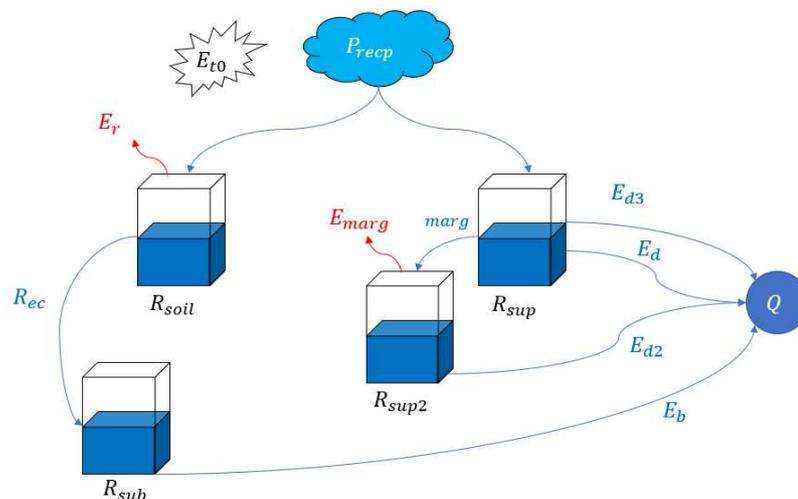
<i>Ecof2</i>	Coefficiente de ajuste da evapotranspiração de planície de inundação
<i>H1</i>	Altura representativa para início do segundo escoamento superficial (mm)
<i>H</i>	Altura representativa para transbordamento para planícies (mm)
<i>Pcof</i>	Coefficiente de ajuste da precipitação

Fonte: adaptado de Maciel, M.G. et al (2020).

2.2.1.2 Equações de estado e balanço hídrico

O funcionamento do modelo SMAP baseia-se na separação da vazão em dois tipos de escoamento: escoamento superficial e escoamento subterrâneo. Para isso, é utilizada as equações de estado e balanço hídrico. No modelo, cada tipo de escoamento é armazenado em reservatórios fictícios que descrevem a forma e a duração dos escoamentos. Originalmente, o modelo diário era composto por três reservatórios que modelavam a distribuição da água em diferentes posições do solo. Entretanto, o ONS aprimorou o modelo na última década, adicionando um quarto tanque que representa a água acumulada em planícies. Este novo modelo é amplamente utilizado em bacias brasileiras e tem contribuído significativamente para o planejamento da operação do sistema elétrico brasileiro (MACIEL, 2020). Figura 5 apresenta um diagrama esquemático dos principais processos simulados e variáveis utilizadas pelo modelo.

Figura 5 - Esquemático do modelo SMAP.



Fonte: adaptado de MACIEL, 2020.

O modelo utilizado para simular o escoamento hidrológico é composto por diversos reservatórios fictícios, responsáveis por descrever a forma e a duração dos escoamentos. A parcela do escoamento superficial (E_s) é transferida para o reservatório de superfície (R_{sup}), onde são calculados os escoamentos superficiais (E_d e E_d3) e a transferência de água (M_{arg}) para o reservatório de planície (R_{sup2}). Este último tem como função representar o amortecimento dos canais de drenagem e, nele, é calculado o escoamento superficial de planície (E_d2) e uma parcela de evaporação (E_{marg}). Por outro lado, a parcela que infiltra é a diferença entre a precipitação e o escoamento superficial ($P - E_s$). Ela é transferida para o reservatório de solo (R_{solo}), onde é extraída a parcela de evapotranspiração real (E_r) e também a transferência para o reservatório subterrâneo (R_{sub}) através da recarga do aquífero (Rec), desde que não tenha sido atingido o limite da capacidade de campo do solo ($Capc$). No reservatório R_{sub} , é calculado o escoamento subterrâneo (E_b), que representa a parcela de água que se infiltra no solo e recarrega os aquíferos subterrâneos (ROCHA, 2017).

As condições iniciais dos reservatórios devem ser definidas para ser possível determinar a dinâmica do sistema. Essas condições são definidas com base nos valores do escoamento básico $E_b(0)$, do teor de umidade $Tu(0)$, e do escoamento superficial $Sup(0)$, utilizados para serem obtidos os estados iniciais dos reservatórios R_{soil} , R_{sub} e R_{sup} conforme equações definidas a seguir.

$$R_{soil}(0) = \frac{Tu(0) \cdot 100}{Str} \quad (7)$$

$$R_{sub}(0) = \frac{Eb(0)}{(1 - 0,5^{\frac{1}{kk_E}}) \cdot AD} \cdot 86.4 \quad (8)$$

$$R_{sup}(0) = \frac{Sup(0)}{(1 - 0,5^{\frac{1}{k^2_E}}) \cdot AD} \cdot 86.4 \quad (9)$$

$$R_{sup2}(0) = 0 \quad (10)$$

Onde Str é a capacidade de saturação do solo e deve ser calibrado e AD é a área de drenagem da região.

Uma vez definidos todos os parâmetros descritos, inicia-se o processo iterativo de definição de vazões e estados do reservatório a cada dia considerado. O primeiro parâmetro a ser definido é o teor de umidade $Tu(t)$ em função do estado do reservatório R_{soil} , conforme equação:

$$Tu(t) = \frac{R_{soil}(t)}{Str} \quad (11)$$

Em seguida é obtido o escoamento superficial do dia t ($Es(t)$) que será zero, caso a precipitação observada no dia t seja inferior ou igual a abstração do solo Ai . Caso contrário $Es(t)$ é obtido pela equação:

$$Es(t) = \frac{(Precp(t) - Ai)^2}{Precp(t) - Ai + Str - R_{soil}(t)} \quad (12)$$

A evapotranspiração real $Er(t)$ é igual a evapotranspiração potencial $Epr(t)$, caso a diferença $Precp(t) - Es(t)$ seja superior a evapotranspiração potencial $Epr(t)$. Caso contrário, $Er(t)$ será determinada conforme equação:

$$Er(t) = Precp(t) - Es(t) + [Epr(t) - Precp(t) + Es(t)] \cdot Tu(t) \quad (13)$$

A recarga subterrânea $Rec(t)$ é um escoamento que modela a água sendo absorvida pelo solo deslocando-se para regiões subterrâneas, representadas pelo reservatório subterrâneo R_{sub} . Caso o estado do reservatório do solo $R_{soil}(t)$ seja inferior ao produto entre as constantes de capacidade de campo $Capc$ e a saturação do solo Str , $Rec(t)$ será zero. Caso seja superior ao produto dessas constantes, $Rec(t)$ é obtido pela equação:

$$Rec(t) = Crec \cdot Tu(t) \cdot (R_{soil}(t) - Capc \cdot Str) \quad (14)$$

onde $Crec$ é uma constante de recarga subterrânea (%), devendo ser calibrada.

O excesso de água que fica armazenado nas margens é representado pelo reservatório R_{sup2} sendo caracterizado como um extravasamento do reservatório R_{sup} . Para o cálculo desse extravasamento $Marg(t)$, deve-se verificar se $R_{sup}(t)$ é inferior a altura $H1$ do reservatório R_{sup} . Em caso positivo, não há extravasamento e $Marg(t)$ é definido em zero. Caso contrário será calculado conforme equação:

$$Marg(t) = (R_{sub}(t) - H1) \cdot (1 - 0,5^{\frac{1}{k1t}}) \quad (15)$$

Onde a altura do reservatório $H1$ deve ser calibrada.

Uma vez definidos os estados dos reservatórios e os parâmetros característicos da bacia no instante t , são calculados os escoamentos provenientes de cada reservatório que compõem a vazão calculada pelo modelo. O escoamento $Ed(t)$ está relacionado ao reservatório $Rsup$ e é obtido através da equação:

$$Ed(t) = \min [Rsup(t) - Marg(t), H] \cdot (1 - 0,5^{\frac{1}{k_2 t}}) \quad (16)$$

Onde H representa a altura mínima do reservatório $Rsup$ para que o escoamento superficial no instante de tempo t seja diferente de zero.

O escoamento $Ed3(t)$ representa um escoamento existente quando o reservatório de superfície $Rsup(t)$ é superior a H . Dessa maneira, caso $Rsup(t)$ seja inferior a H , não haverá escoamento e $Ed3(t)$ é obtido conforme equação:

$$Ed3(t) = [Rsup(t) - H - Marg(t)] \cdot (1 - 0,5^{\frac{1}{k_2 t_2}}) \quad (17)$$

Os escoamentos $Ed2(t)$ e $Eb(t)$, dos reservatórios $Rsup2$ and $Rsub$, respectivamente, podem ser obtidos através das equações:

$$Ed2(t) = Rsup2(t) \cdot (1 - 0,5^{\frac{1}{k_3 t}}) \quad (18)$$

$$Eb(t) = Rsub(t) \cdot (1 - 0,5^{\frac{1}{k_4 t}}) \quad (19)$$

Por fim, a vazão natural $Q(t)$ é calculada no instante t através da equação:

$$Q(t) = \frac{Ed(t) + Ed2(t) + Ed3(t) + Eb(t)}{86,4} \cdot AD \quad (20)$$

onde a constante 86,4 é aplicada como fator de conversão.

Uma vez obtida a vazão, uma última etapa consiste no cálculo dos estados dos reservatórios para a próxima iteração, conforme equações:

$$Rsoil(t + 1) = \min [Rsoil(t) + Precp(t) - Es(t) - Er(t) Rec(t), Str] \quad (21)$$

$$R_{sub}(t + 1) = R_{sub}(t) + Rec(t) - Eb(t) \quad (22)$$

$$R_{sup}(t + 1) = R_{sup}(t) + Es(t) - Marg(t) - Ed(t) - Ed3(t) + \max(0, R_{soil}(t) + Precp(t) - Es(t) - Er(t) - Rec(t) - Str) \quad (23)$$

$$R_{sup2}(t + 1) = \max(R_{sup2}(t) + Marg(t) - Ed2(t) - Emarg(t), 0)$$

1.1.1 Previvaz

O PREVIVAZ é um modelo hidrológico estocástico de séries temporais univariado com base na série histórica de vazões para estimar seus parâmetros e realizar a previsão das vazões para até seis semanas à frente. O modelo foi desenvolvido pelo Centro de Pesquisas de Energia Elétrica (CEPEL), com o objetivo de obter as previsões de afluências semanais em conjunto com o modelo SMAP, até seis semanas à frente, para serem utilizadas no primeiro mês do planejamento de curto prazo (PMO) e suas revisões semanais.

O modelo consiste em aplicar a série histórica de vazões médias para cada aproveitamento hidrelétrico e então avaliar entre 140 alternativas de modelagem incluindo modelos lineares auto-regressivos, tanto periódicos quanto não-periódicos (MACEIRA et al, 1999). No processo de planejamento de curto prazo do ONS, o modelo PREVIVAZ é aplicado a partir da terceira semana prevista em todos os aproveitamentos hidrelétricos. A Tabela 2 lista as alternativas de modelagem estocástica consideradas pelo modelo PREVIVAZ.

Tabela 2 - Alternativas de modelagem estocásticas do modelo PREVIVAZ.

Modelo	Característica	Método de estimação
CONSTANTE	Previsão pela media anual	Momentos
SAZONAL	Previsão pela media da semana	Momentos
AR(p) (p≤4)	Estrutura de correlação estacionária	Momentos
ARMA(p,1) (p≤3)	Estrutura de correlação estacionária	Momentos

PAR(p)-G1 ($p \leq 4$)	Estrutura de correlação sazonal semestral	Momentos
PAR(p)-G2 ($p \leq 4$)	Estrutura de correlação sazonal trimestral	Momentos
PAR(p)-G3 ($p \leq 4$)	Estrutura de correlação sazonal mensal	Momentos
PAR(p)-G4 ($p \leq 4$)	Estrutura de correlação sazonal semanal	Momentos
PAR(p)-RO ($p \leq 4$)	Estrutura de correlação sazonal	Regressão à origem
PARMA(p,1)-G1 ($p \leq 3$)	Estrutura de correlação sazonal semestral	Momentos
PARMA(p,1)-G2 ($p \leq 3$)	Estrutura de correlação sazonal trimestral	Momentos
PARMA(p,1)-G3 ($p \leq 3$)	Estrutura de correlação sazonal mensal	Momentos
PARMA(p,1)-G4 ($p \leq 3$)	Estrutura de correlação sazonal semanal	Momentos
PARMA(p,1)-RO ($p \leq 3$)	Estrutura de correlação sazonal	Regressão à origem
PARMA(p,1)-R ($p \leq 3$)	Estrutura de correlação sazonal	Regressão

Fonte: CEPEL, 2015.

O procedimento adotado na escolha da alternativa de modelagem considera a primeira metade da série histórica para estimar os parâmetros de todas as alternativas listadas na Tabela 2. O erro médio quadrático é então calculado com base na segunda metade da série histórica. Similarmente, com base na segunda metade da série histórica, são então estimados os parâmetros de todas as alternativas consideradas. Novamente, o erro médio quadrático é calculado com base na primeira metade da série histórica. A alternativa que possui o menor o erro médio quadrático é adotada como modelo para realizar a previsão das vazões semanais que completam o arquivo PREVS. Os parâmetros da alternativa utilizada no modelo são então estimados levando em consideração a série histórica completa (CEPEL, 2015).

O modelo apresenta algumas limitações quanto seus resultados dados sua formulação simplificada, podendo ser ainda considerado como satisfatório, segundo Colonesse et al (2015), que cita a importância do modelo para o planejamento da operação do sistema energético brasileiro, considerando sua facilidade e baixo custo. Para os autores, a aplicação do modelo pode ser inadequada nos casos em que as bacias possuem regimes hidrológicos com grande variabilidade. Como solução, identificou-se a necessidade de incorporar a informação de precipitação, atualmente realizada com a aplicação do modelo SMAP para as duas primeiras semanas previstas em cada revisão semanal pelo ONS. Ainda assim, as previsões publicadas pelo ONS a partir da terceira semana realizadas pelo PREVIVAZ incorporam erros em sua estrutura, uma vez que as previsões de precipitação de modelos atmosféricos possuem incerteza para horizontes superiores a alguns dias.

3 MODELAGEM DE SÉRIES TEMPORAIS VIA REDES NEURAIIS

A modelagem de series temporais são de extrema importância em uma gama de problemas reais com dependência na componente temporal. A literatura mostra grande esforço em diferentes campos de pesquisa no desenvolvimento de modelos especializados com capacidade de identificar padrões e tendências que possam ser empregados para realizar previsões. Nesse contexto, modelos de *Deep Learning* tem se tornado popular na solução de problemas em diversas aplicações, incluindo previsão de séries temporais. Uma das maiores vantagens em relação aos modelos estatísticos clássicos, é o potencial dos modelos *Deep Learning* capturarem relações complexas de não-linearidade entre as variáveis (LARA-BENITEZ et al, 2021).

Entre os modelos utilizados na modelagem de séries temporais destaca-se o modelo *Multilayer Perceptron* (MLP), com uma arquitetura clássica entre os modelos de redes neurais. A estrutura de um MLP consiste basicamente em camadas de entrada, camadas escondidas e saída. Apesar de ser uma abordagem aplicável em muitos problemas, modelos MLP apresentam algumas limitações quando se trata da identificação de padrões em séries temporais, uma vez que tratam os dados de entrada de maneira independente (TAO et al, 2019).

Nesse contexto, modelos mais especializados como LSTM e TCN podem ter maior desempenho para previsões que redes neurais de propagação direta, como MLP. Tais modelos podem conseguir de maneira mais eficiente capturar a dinâmica dos padrões temporais das variáveis, sendo possível codificar a dimensão temporal (LIN et al, 2021).

O modelo LSTM faz parte de uma classe de rede neural conhecida chamada de *recurrent neural network* (RNN), desenvolvida para modelar a dependência temporal de longo prazo em problemas relacionados a séries temporais (OMRAN et al 2021). Esse modelo foi inicialmente proposto por Hochreiter and Schmidhuber para solucionar problemas inerentes a gradientes pequenos (LI et al, 2022). A arquitetura de LSTMs consiste em um conjunto de células de memória, que retêm e manipulam informações por meio de *gates* e controlam a passagem de informações entre as células. Os principais componentes da arquitetura incluem um *Input Gate* responsável por adicionar informações ao estado da célula de memória, *Output Gate* responsável por extrair as informações úteis do estado da célula de memória atual, direcionando-

as para a célula de memória seguinte, e *Forget Gate* que decide quais informações devem ser descartadas, ou seja, esquecidas pela célula de memória (LI et al 2020).

As Redes Convolucionais Temporais, ou TCN do inglês *Temporal Convolutional Neural Network* são compostas por blocos residuais contendo estruturas de camadas convolucionais causais e dilatadas. Proposta por Bai et al. (2018), o modelo TCN apresenta como principais características, (1) convoluções causais na arquitetura afim de evitar o vazamento de informações do futuro para o passado, e (2) saída com o mesmo comprimento da entrada, como nas redes recorrentes (HEWAGE et al, 2020). As camadas convolucionais causais evitam que o modelo viole a ordem em que os dados são modelados. Já as camadas de convolução dilatadas permitem uma cobertura maior do campo receptivo, permitindo a aplicação do filtro convolucional sobre um comprimento maior da série temporal (LUCAS, 2019). Entre as vantagens em relação ao modelo RNN destaca-se os gradientes mais estáveis, maior campo receptivo e paralelismo. Tais características permitem o processamento completo de sequências longas de dados, melhor controle sobre a memória do modelo evitando os problemas relacionados a gradientes muito grandes ou muito pequenos.

3.1 TREINAMENTO E OTIMIZAÇÃO DE REDES NEURAIIS

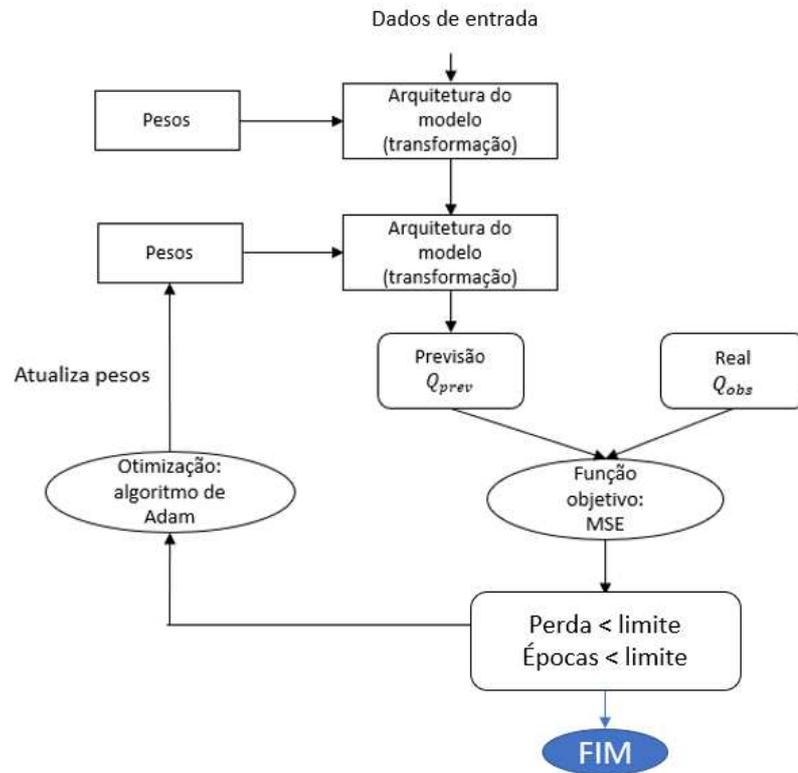
Em uma rede neural, o aprendizado de máquina é baseado no mapeamento entre variáveis de entrada e o valor esperado por meio de uma sequência de transformações, realizadas sobre os dados através das várias camadas. Essa tarefa é realizada por meio da função de perda, que tem como objetivo reduzir a diferença entre o valor desejado e o valor atual através da atualização dos pesos (CHOLLET, 2018). Essa característica se torna ainda mais relevante quando se trata de problemas complexos onde os dados não podem ser modelados para capturar padrões por meio de funções lineares. Previsão de dados sequenciais como séries temporais, por exemplo, são problemas que podem apresentar características não-lineares (LARA-BENITEZ, 2021). Nesse caso, a modelagem por meio de funções lineares seria limitada. Assim, as funções de ativação tornam possível a propagação posterior de informações, realizando a transformação não-linear nos pesos, sendo capaz de aprender e executar tarefas mais complexa.

A escolha da função de ativação apropriada é crucial para evitar problemas relacionados aos gradientes, além de manter boa performance durante o processo de otimização dos parâmetros da rede (ZHANG, 2021). A função ReLU, do inglês *rectified linear unit*, é uma opção bastante popular, devido sua estabilidade. Seu funcionamento se baseia na retenção de somente valores positivos, enquanto descarta todos os valores negativos (GERON, 2017).

Outro elemento fundamental no treinamento de redes neurais está relacionado a função custo ou perda, que calcula quão longe o valor previsto está do valor observado. Em problemas de regressão, como o visto em previsão de séries temporais, a função perda comumente adotada é a do erro quadrático médio, do inglês *mean-squared error* (MSE). Uma das vantagens relacionadas ao uso dessa função é devido a sua sensibilidade à *outliers*, penalizando erros maiores de maneira mais significativa, devido ao fator quadrático da função (CHOLLET, 2018).

Durante o treinamento do modelo, o processo de otimização ajusta cada peso para minimizar a diferença entre o valor previsto e o valor observado. Assim, quanto menor é o resultado da função perda de uma rede neural, mais próxima ela está de convergir. Dessa maneira, o processo de aprendizado pode ser determinado como a redução da função perda, ajustando os parâmetros da rede, que tipicamente são inicializados de forma aleatória. Cada ciclo de propagação dos pesos e ajuste do erro é chamado de época, ou seja, uma iteração. Esse processo de sistematicamente atualizar os pesos da rede neural, reduz eventualmente o valor da função perda, resultando nos parâmetros finais que minimizam a função perda (Figura 7). Como critério de parada podem ser utilizado o erro calculado pela função perda em relação ao limite pré-estabelecido pelo usuário, ou definindo um número de épocas máximo para o treinamento (ZHANG et al, 2021).

Figura 6 – Processo geral de treinamento de uma rede neural.



Fonte: adaptado de Chollet, F. (2018).

Há uma variedade de algoritmos de otimização amplamente utilizados no processo de treinamento de modelos de aprendizado de máquina, como o método do gradiente descendente e gradiente descendente estocástico. Entretanto, esses algoritmos apresentam algumas limitações relacionadas a oscilação frequente dos gradientes calculados durante o processo de treinamento, exigindo assim métodos de otimização alternativos. Uma das formas de solução para esse problema surgiu com a introdução de *adaptive learning rates*, ou taxas de aprendizado adaptativas. A ideia por trás desses algoritmos, como Adaptive gradients (Adagrad), RMS propagation (RMSprop) e adaptive moment estimation (ADAM), é a utilização de um passo que atualiza durante a otimização, ao invés de um valor pré-definido (GERON, 2017). O Adagrad atualiza a taxa de aprendizado de forma independente para cada parâmetro, o que significa que parâmetros frequentemente atualizados têm sua taxa de aprendizado reduzida, enquanto parâmetros menos frequentemente atualizados têm sua taxa de aprendizado aumentada. Já o RMSprop também considera a frequência de atualização de cada parâmetro, mas utiliza uma média móvel exponencial quadrática dos gradientes para adaptar a taxa de aprendizado. Por fim, o

algoritmo Adam combina as abordagens do Adagrad e do RMSprop, adicionando um momento que controla a direção do movimento ao longo dos gradientes. Isso permite que o Adam seja eficiente tanto em termos de memória quanto de computação e resulte em uma convergência mais rápida e estável durante o treinamento (BRANCO et al, 2022).

Dentre os algoritmos com essa mesma proposta, o algoritmo Adam mostrou boa robustez, sendo aplicável em uma variedade de problemas de otimização não-convexos, exigindo pouca memória de processamento. O algoritmo proposto por KINGMA e BA (2014), faz uso das vantagens de outros dois métodos de otimização populares, combinando a habilidade do algoritmo AdaGrad de lidar com gradientes esparsos com a habilidade do algoritmo RMSProp de lidar com funções não estacionárias. (KINGMA e BA, 2014).

3.2 SÉRIES TEMPORAIS

A previsão de séries temporais pode ser modelada como problemas de regressão, onde a variável prevista passos à frente pode ser estimada com base em dados históricos. Modelos como TFT, LSTM e TCN utilizam covariáveis temporais como informação adicional e contexto sobre passado até o tempo atual ou futuro, para a previsão da série temporal. A documentação sobre covariáveis da biblioteca Darts, utilizada na implementação dos modelos, possui os detalhes sobre a implementação dos modelos na seção *Torch Forecasting Models and Covariates*.

Atributos temporais são poderosas ferramentas, uma vez que conhecidos de antemão, ajudando o modelo a capturar tendências e padrões temporais entre as variáveis modeladas e a variável prevista. As covariáveis tomam como referência o ponto, nesse caso o dia, a partir do qual deseja-se realizar a previsão. Assim, as covariáveis de passado (*past_covariates*) são registros históricos, como vazão observada, enquanto as covariáveis de futuro (*future_covariates*) são registros conhecidos de dados futuros, ou seja, precipitação prevista.

Neste trabalho, no experimento de previsão foi realizado considerando o registro histórico da precipitação como série de precipitação observada (*past_covariate*) anterior ao dia da previsão e como a série de precipitação prevista (*future_covariate*) a partir do dia de referência da previsão, durante o treinamento dos modelos. Alguns modelos na biblioteca utilizada suportam apenas *past_covariates*,

apenas *future_covariates*, ou ambos os atributos temporais. O Quadro 1 apresenta os modelos e suas respectivas covariáveis disponíveis.

Quadro 1. Covariáveis por modelo.

Modelo	Covariável
LSTM	<i>future_covariate</i>
TCN	<i>past_covariate</i>
TFT	<i>future_covariate e past_covariate</i>

Fonte: elaborado pelo autor.

3.2.1 Criação de amostras temporais via amostragem

O aprendizado supervisionado é uma abordagem do aprendizado de máquina que consiste em relacionar entrada e saída do modelo com base em dados rotulados. Durante o treinamento, amostras de dados previamente agrupados são alimentados ao modelo juntamente com o valor de saída real esperado para a previsão. Com base no mapeamento entre entradas e saída prevista pelo modelo e saída real desejada, o modelo é capaz de ajustar os parâmetros de maneira a minimizar a função custo. (GUNNARSON e FRANC, 2021).

Previsão de series temporais é um problema que se enquadra nessa topologia de aprendizado supervisionado, podendo ser modelado como um problema de regressão, onde séries históricas são alimentadas para gerar previsão de séries futuras. Séries temporais são basicamente uma sequência de observações ordenadas cronologicamente e registradas em intervalos fixos de tempo (GORODETSKAYA et al, 2018). Para que o modelo entenda as relações temporais entre as covariáveis e a saída desejada, a técnica de amostragem é aplicada sobre a série original de dados. A criação das amostras é baseada em um esquema de janela móvel, onde o total de amostras criadas é calculado com base nos parâmetros que definem as covariáveis, como o *input_chunk_length* para *past_covariates* e *future_covariates*, e *output_chunk_length* para o horizonte de previsão desejado.

Considerando um simples cenário, apenas para ilustrar o processo, em que o modelo é alimentado com dados observados de precipitação de duas estações pluviométricas, portanto, as covariáveis *past_covariates*. O modelo utiliza dados

observados de 2 dias, ou seja, *input_chunk_length* igual a 2, para realizar previsões de vazão natural 2 dias a frente, ou seja, *output_chunk_length* igual a 2. O conjunto de dados possui registro de precipitação para ambas as estações pluviométricas e a vazão, variável de saída do modelo, com um histórico de 100. O conjunto de dados que ilustra esse cenário é exemplificado na Tabela 3, onde a primeira coluna apresenta o índice relativo ao dia do registro, seguido das colunas de precipitação para as estações pluviométricas 1 e 2 e a vazão observada.

Tabela 3 – Exemplo de estrutura de dados para amostragem.

<i>Time index</i>	<i>Prec 1</i>	<i>Prec 2</i>	<i>Flow</i>
1	$P_{1,1}$	$P_{2,1}$	Q_1
2	$P_{1,2}$	$P_{2,2}$	Q_2
3	$P_{1,3}$	$P_{2,3}$	Q_3
4	$P_{1,4}$	$P_{2,4}$	Q_4
5	$P_{1,5}$	$P_{2,5}$	Q_5
...
$N = 100$	$P_{1,100}$	$P_{2,100}$	Q_{100}

Fonte: elaborado pelo autor.

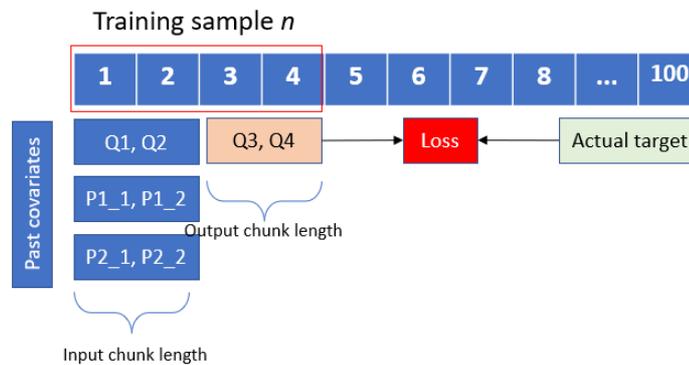
O total de amostras gerados é calculado com base no parâmetro *input_chunk_length* (k), o horizonte de previsão, representado pelo parâmetro *output_chunk_length* (T_{max}) e o número total de dias do conjunto de dados (N). No cenário hipotético exemplificado, o conjunto de dados possui 100 dias de registro de precipitação e vazão, com uma janela de amostragem de dois dias anterior do ponto de referência de previsão, $k = 2$, para realizar uma previsão com horizonte de dois dias a frente, $T_{max} = 2$. A partir dessas definições, o total de amostras gerados (M) pode ser obtido conforme equação a seguir:

$$M = N - (k + T_{max}) + 1 \quad (24)$$

No cenário considerado, a quantidade total de amostras, ou seja, pares entrada- saída (X, Y), que alimentarão o modelo durante o treinamento é 97 amostras,

representada como $S_1: X_1 = \{P_{1,1}, P_{1,2}, P_{2,1}, P_{2,2}, Q_1, Q_2\}$, $Y_1 = \{Q_3, Q_4\}$. A Figura 9 ilustra o processo de amostragem descrito no cenário exemplificado.

Figura 7 - Processo de amostragem de dados temporais.

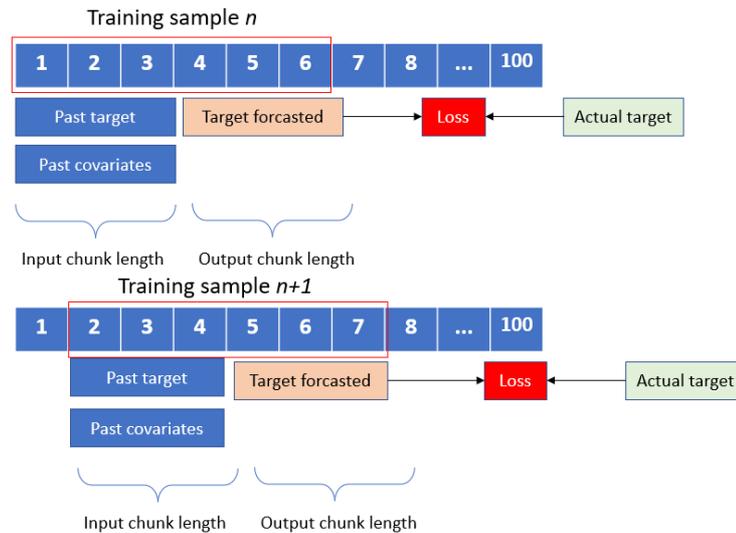


Fonte: elaborado pelo autor.

3.2.2 Treinamento

Durante o treinamento, o modelo processa cada amostra em sequência, conservando a dependência temporal dos registros. Utilizando as informações contidas nas covariáveis (*past_covariates* e *future_covariates*), o modelo realiza a previsão da variável de saída (*target forecast*). A função custo (*loss*) compara os valores da série prevista com o a série observado (*actual target*) de maneira a minimizar o erro. A Figura 10, ilustra o processo de treinamento com variáveis temporais.

Figura 8. Processo de treinamento com variáveis temporais.



Fonte: elaborado pelo autor.

3.3 TEMPORAL FUSION TRANSFORMER

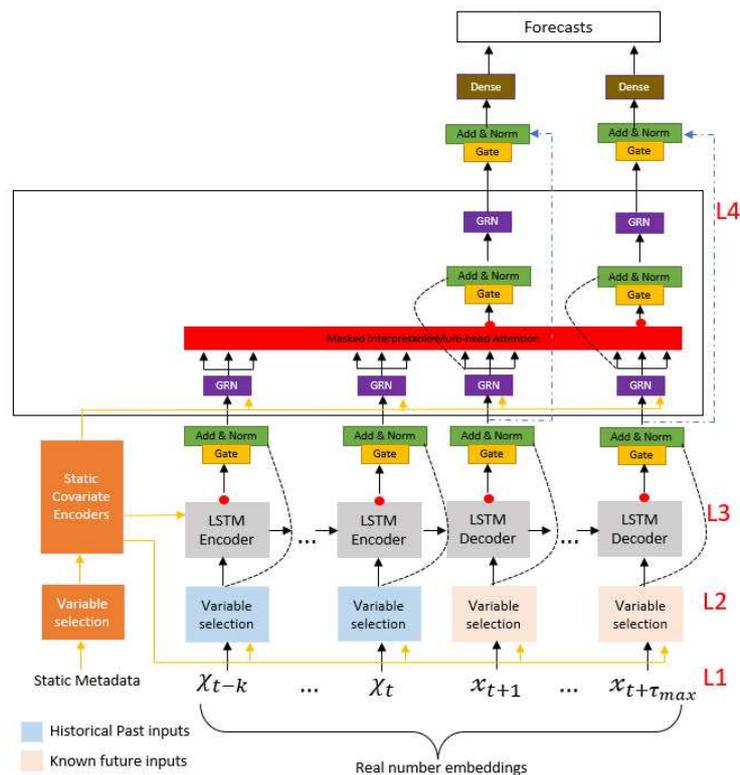
A qualidade das previsões hidrológicas afeta o desempenho da operação do sistema, o que tem gerado grandes esforços do ONS nos últimos anos no aperfeiçoamento metodológico para a obtenção dos cenários hidrológicos de previsão de aflúências com objetivo de promover melhoria do processo de planejamento e programação da operação (RAMOS et al, 2017). Nesse contexto, o desenvolvimento de metodologias voltadas a aplicação de redes neurais artificiais, especialmente arquiteturas de redes profundas como LSTM, tem ganhado espaço na literatura como solução para análise de séries temporais devido à sua capacidade de tratar relações de entrada-saída de dados não-lineares e capacidade de generalização, sendo capaz de identificar e assimilar as características como sazonalidade, periodicidade, tendência.

Recentemente, LIM et al (2020) propuseram *Temporal Fusion Transformer* (TFT), uma nova arquitetura de rede neural para previsão de alto desempenho de múltiplos dias a frente. Para obter melhorias significativas sobre a performance em relação aos demais modelos de referência no estado da arte, os autores introduziram algumas mudanças relevantes, incorporando a arquitetura (1) covariáveis (*time covariates*) estatísticas extraídas a partir do uso do módulo de seleção de variáveis, usadas em diversos pontos do modelo para relacionar os recursos estáticos com a codificação de vetores de contexto para a dinâmica temporal, (2) mecanismos de

portão (*gating mechanism*) para ignorar quaisquer componentes irrelevantes para a arquitetura por meio do contexto externo fornecido pelas estatísticas dos dados, (3) processamento local através de módulos *Encoder-Decoder-LSTM* para captura de dependências temporais de curto prazo e (4) blocos de auto-atenção (*self-attention*) para captura de dependências temporais de longo prazo (MGHAZLI et al, 2021).

Os autores CIVITARESE et al (2021) descrevem os principais componentes da arquitetura do modelo em quatro níveis. O nível L1 representa a entrada e codificação das covariáveis, o nível L2 consiste no módulo de seleção de variáveis, o nível L3 possui o módulo encondere-decoder-LSTM e o nível L4 consiste no bloco de auto-atenção. A Figura 11 mostra a arquitetura do modelo TFT e seus módulos de processamento separados nos níveis descritos.

Figura 9 - Arquitetura do modelo TFT.



Fonte: adaptado de Lim, B. et al (2020).

Com base nessas características, o modelo TFT foi desenvolvido para construir de maneira eficiente a representação de cada variável de entrada (covariáveis temporais para dados observados e conhecidos no futuro). Tais recursos mostraram em diversos testes alto desempenho nas previsões em diferentes aplicações,

auxiliando na identificação de variáveis relevantes, padrões temporais persistentes e eventos significantes (LIM et al, 2020).

3.3.1 Entradas do modelo

Em relação as variáveis de entrada, o modelo TFT aceita séries históricas, futuras e estáticas para realizar as previsões. As séries históricas representam dados observados, como vazões e precipitação registrados no passado. As séries históricas futuras, são entendidas pelo modelo como conhecido no futuro, embora não realizado, como é o caso quando se utiliza série de precipitação prevista como variável de previsão. As variáveis estáticas, por sua vez, não se alteram com o tempo (GUNNARSSON e FRANC, 2021).

Primeiramente, as covariáveis de entrada são transformadas em vetores de dimensão d_{model} , conhecido como a dimensão de estado do modelo TFT. O valor desse parâmetro da arquitetura é configurado pelo usuário durante a definição do modelo. As variáveis contínuas são simplesmente escalares em \mathbb{R} e, nesse caso, os valores são utilizados em uma função que realiza a vetorização por meio de uma transformação linear conforme equação:

$$\xi^{(j)} = x_j w_j + b_j \quad (25)$$

Onde $x_j \in \mathbb{R}$ é o valor da variável j , e $w_j \in \mathbb{R}^{d_{model}}$ e $b_j \in \mathbb{R}^{d_{model}}$ correspondem aos pesos e vieses para a variável j , respectivamente. A saída $\xi^{(j)} \in \mathbb{R}^{d_{model}}$ é uma representação vetorial da variável j na dimensão de estado do modelo TFT. Os parâmetros são inicializados aleatoriamente.

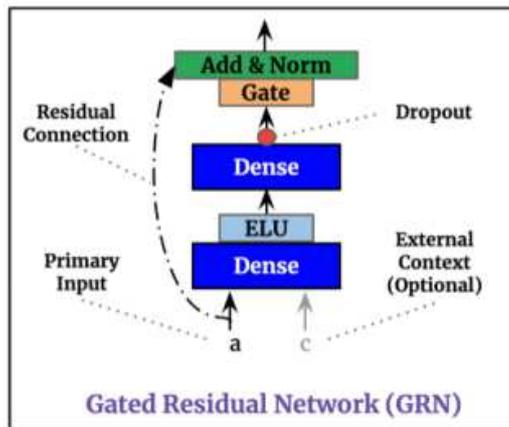
Essa transformação dimensional de cada variável em um vetor com a dimensão de estado do modelo TFT d_{model} é realizada para cada passo temporal, tanto para séries históricas quanto para séries futuras.

3.3.2 Gating mechanisms

O mecanismo de portão, do inglês *gating mechanism*, é empregado por um *gated residual network* (GRN), elemento fundamental no módulo de seleção de

variáveis que permite o modelo aplicar processamento não-linear entre as variáveis de entrada e saída (WU et al, 2022). A Figura 12 ilustra os principais componentes internos da arquitetura do bloco GRN, incluindo camadas densas de redes neurais seguido de uma função *dropout* e uma unidade de processamento *Gated Linear Units* (GLUs) responsável por filtrar qualquer informação irrelevante (GUNNARSSON e FRANC, 2021). É indicado na arquitetura uma conexão residual que desvia das operações de processamento do bloco GRN. Esse artifício é comumente aplicado em muitos modelos de aprendizado profundo para evitar problemas relacionados a dissipação de gradientes, do inglês *vanishing gradients*, onde os gradientes se tornam muito pequenos e a rede neural perde sua capacidade de aprender.

Figura 10. Arquitetura de um bloco GRN.



Fonte: Lim, B. et al (2020).

Um GRN pode ser modelado conforme as equações:

$$GRN_{\omega}(a, c) = LayerNorm(a, GLU_{\omega}(\eta_1)) \quad (26)$$

$$\eta_1 = W_{1,\omega}\eta_2 + b_{1,\omega} \quad (27)$$

$$\eta_2 = ELU(W_{2,\omega}a + W_{3,\omega}c + b_{2,\omega}) \quad (28)$$

Onde a é a variável de entrada e c é uma variável opcional que corresponde ao vetor de contexto estático. ELU é a função de ativação *Exponential Linear Unit*, $\eta_2 \in \mathbb{R}^{d_{model}}$ e $\eta_1 \in \mathbb{R}^{d_{model}}$ são camadas intermediárias, $LayerNorm$ é usada para de normalização padrão de dados, e ω corresponde ao índice que indica as variáveis em que os pesos e vieses são compartilhados. Quando o valor resultante da operação

$W_{2,\omega}a + W_{3,\omega}c + b_{2,\omega} \gg 0$, a função *ELU* funciona como uma função identidade e quando a operação $W_{2,\omega}a + W_{3,\omega}c + b_{2,\omega} \ll 0$, a função *ELU* gera uma saída com valor constante, resultando em uma camada com comportamento linear.

As unidades de processamento *Gated Linear Units (GLUs)* são implementadas na arquitetura do modelo para permitir maior flexibilidade para suprimir qualquer parte da arquitetura que não seja necessária, a depender do conjunto de dados alimentados. Tomando a variável $\gamma \in \mathbb{R}^{d_{model}}$ como entrada, a função *GLU* pode ser modelada conforme a equação a seguir:

$$GLU_{\omega}(\gamma) = \sigma(W_{4,\omega}\gamma + b_{4,\omega}) \odot (W_{5,\omega}\gamma + b_{5,\omega}) \quad (29)$$

onde o operador $\sigma(\cdot)$ representa a função de ativação Sigmoid, $W(\cdot) \in \mathbb{R}^{d_{model} \times d_{model}}$, $b(\cdot) \in \mathbb{R}^{d_{model}}$ são tensores contendo os pesos e vieses, e o operador \odot representa o produto escalar de Hadamard, atribuindo valores a zero para variáveis que carregam informações irrelevantes.

3.3.3 Variable selection

O módulo de seleção de variáveis é aplicado sobre as variáveis de entrada previamente transformadas (vetorização) com objetivo de dar mais ênfase sobre os elementos úteis na realização de previsões precisas, enquanto descartando informações irrelevantes. O módulo recebe como entrada um conjunto de valores $\xi^{(1)}, \dots, \xi^{(m_{\chi})}$ onde m_{χ} é o número de variáveis por tipo de entrada χ representando série histórica, futura ou estática. Internamente, o módulo é composto por uma série de blocos de processamento GRN para transformação das variáveis de entrada $\xi_t^{(j)} \in \mathbb{R}^{d_{model}}$.

$$\tilde{\xi}_t^{(j)} = GRN_{\tilde{\xi}^{(j)}}(\xi_t^{(j)}) \quad (30)$$

Paralelamente, um outro bloco GRN seguido de uma camada que aplica a função de ativação *Softmax* responsável por computar os pesos a partir da

representação tensorial das variáveis no passo de tempo t $\Xi_t = \left[\xi_t^{(1)T}, \dots, \xi_t^{(m_\chi)T} \right]^T$.

O processo de obtenção dos pesos pode ser expresso pela equação:

$$v_{\chi_t} = \text{Softmax}(\text{GRN}_{v_\chi}(\Xi_t, c_s)) \quad (31)$$

Onde $v_{\chi_t} \in \mathbb{R}^{m_\chi}$ é o tensor que armazena os pesos da seleção de e c_s é uma variável opcional obtida através de um codificador de covariável estativo.

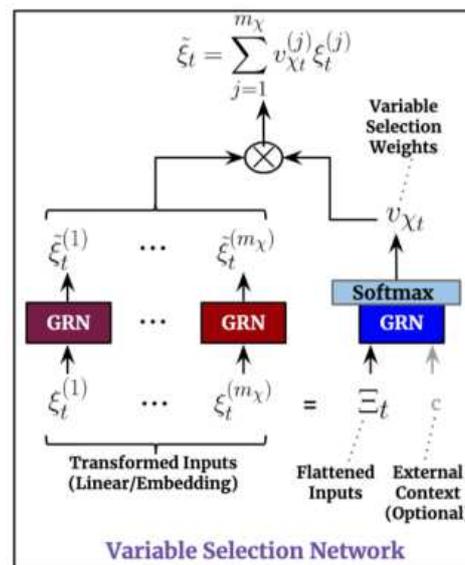
A principal saída do processamento para seleção de variáveis é um tensor $\tilde{\xi}_t \in \mathbb{R}^{d_{model}}$ resultante da combinação da média ponderada entre as variáveis e os pesos calculados (GUNNARSSON e FRANCO, 2021).

$$\tilde{\xi}_t = \sum_{j=1}^{m_\chi} v_{\chi_t}^{(j)} \xi_t^{(j)} \quad (32)$$

Onde $v_{\chi_t}^{(j)}$ representa o elemento j -th do tensor v_{χ_t} .

A Figura 13 ilustra os principais componentes internos da arquitetura do módulo de seleção de variáveis.

Figura 11 - Bloco de seleção de variáveis.



Fonte: Lim, B. et al, (2020).

3.3.4 Sequence-to-sequence: bloco LSTM

O processamento temporal por meio dos módulos *encoder-decoder-LSTM* são responsáveis por identificar as dependências de curto prazo. Na arquitetura do modelo TFT mostrado na Figura 11, os blocos LSTM são aplicados após o módulo de seleção de variáveis, sendo utilizado com função *encoder* para processar variáveis históricas $\tilde{\xi}_{t-k:t}$ e a função *decoder* para processar as variáveis futuras $\tilde{\xi}_{t+1:t+\tau_{max}}$. As saídas são posteriormente processadas por unidades de processamento GLU antes de serem alimentadas no bloco *Temporal Fusion Decoder* onde é aplicado a auto-atenção para processamento das dependências de longo prazo.

A arquitetura também dispõe de uma conexão residual que contorna os blocos LSTM e conecta o módulo de deleção de variáveis diretamente a unidade de processamento GLU, modelado conforme equação:

$$\tilde{\phi}(t, n) = \text{LayerNorm}(\tilde{\xi}_{t+n} + \text{GLU}_{\tilde{\phi}}(\phi(t, n))) \quad (33)$$

Onde $n \in [-k, \tau_{max}]$ representa um índice posicional.

3.3.5 Interpretable multi-head attention

LIM et al (2020) empregam o mecanismo de auto atenção no modelo TFT, com objetivo de capturar relações de longo prazo através de diferentes passos temporais. De maneira geral, mecanismos de atenção ponderam o tensor *Values* $\mathbf{V} \in \mathbb{R}^{N \times d_v}$ baseado na combinação entre o tensor *Keys* $\mathbf{K} \in \mathbb{R}^{N \times d_{attn}}$ e o tensor *Queries* $\mathbf{Q} \in \mathbb{R}^{N \times d_{attn}}$ conforme equação:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = A(\mathbf{Q}, \mathbf{K})\mathbf{V} \quad (34)$$

onde A é uma função de normalização definida como produto escalar entre *Queries* e *Keys*:

$$A(\mathbf{Q}, \mathbf{K}) = \text{Softmax}(\mathbf{Q}\mathbf{K}^T / \sqrt{d_{attn}}) \quad (35)$$

Com o objetivo de melhorar a capacidade de aprendizado do mecanismo de atenção padrão, os autores propuseram módulo um *multi-head attention* presente na arquitetura *Transformer*, empregando múltiplos blocos *head* de processamento como representação de diferentes sub-espacos:

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = [\mathbf{H}_1, \dots, \mathbf{H}_{m_H}] \mathbf{W}_H \quad (36)$$

$$\mathbf{H}_h = \text{Attention}(\mathbf{Q}\mathbf{W}_Q^{(h)}, \mathbf{K}\mathbf{W}_K^{(h)}, \mathbf{V}\mathbf{W}_V^{(h)}) \quad (37)$$

Onde $\mathbf{W}_K^{(h)} \in \mathbb{R}^{d_{model} \times d_{attn}}$, $\mathbf{W}_Q^{(h)} \in \mathbb{R}^{d_{model} \times d_{attn}}$, $\mathbf{W}_V^{(h)} \in \mathbb{R}^{d_{model} \times d_V}$ são tensores específicos contendo os parâmetros de pesos para as representações *Keys*, *Queries* e *Values*, respectivamente, e $\mathbf{W}_H \in \mathbb{R}^{(m_H \cdot d_V) \times d_{model}}$ é o tensor resultado da combinação linear entre as saídas concatenadas de todos os blocos *head*.

O módulo *multi-head attention* presente no modelo TFT foi adaptado pelos autores agregando todos os blocos *head* para que os valores em cada bloco *head* fossem compartilhados entre si, permitindo assim maior capacidade de identificar a relevância de cada variável para a previsão. Essa dinâmica é modelada conforme equações:

$$\text{InterpretableMultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \tilde{\mathbf{H}} \mathbf{W}_H \quad (38)$$

$$\tilde{\mathbf{H}} = \tilde{\mathbf{A}}(\mathbf{Q}, \mathbf{K}) \mathbf{V} \mathbf{W}_V \quad (39)$$

$$= \left\{ \frac{1}{H} \sum_{h=1}^{m_H} A(\mathbf{Q}\mathbf{W}_Q^{(h)}, \mathbf{K}\mathbf{W}_K^{(h)}) \right\} \mathbf{V} \mathbf{W}_V \quad (40)$$

$$= \frac{1}{H} \sum_{h=1}^{m_H} \text{Attention}(\mathbf{Q}\mathbf{W}_Q^{(h)}, \mathbf{K}\mathbf{W}_K^{(h)}, \mathbf{V}\mathbf{W}_V) \quad (41)$$

Onde $\mathbf{W}_V \in \mathbb{R}^{d_{model} \times d_V}$ são os valores dos pesos compartilhados através dos blocos *head*, e $\mathbf{W}_H \in \mathbb{R}^{d_{attn} \times d_{model}}$ corresponde ao mapeamento linear final (VASWANI et al, 2017).

4 METODOLOGIA

Nesta seção são descritos e analisados os dados obtidos de precipitação e vazão observada da UHE Tucuruí para a modelagem da vazão prevista.

4.1 PRECIPITAÇÃO OBSERVADA

Os dados de precipitações observadas utilizados nos experimentos computacionais foram coletados no portal de dados abertos do ONS, para o período compreendido entre 2006 e 2021. A precipitação observada disponibilizada tem como fontes de dados os registros estações meteorológicas do Instituto Nacional de Meteorologia (INMET), postos pluviométricos dos agentes de geração e estimativa da precipitação pelo satélite GOES-16 fornecida pela *National Aeronautics and Space Administration* (NASA).

O processo de combinação entre os dados observados nas estações meteorológicas e postos pluviométricos junto a estimativa de satélite é detalhada na Nota Técnica 0076-2020. Esse procedimento é adotado pelo ONS de forma a obter uma melhor representação da precipitação média das bacias de interesse para operação do SIN, dada as limitações na representação espacial da chuva em grande escala da precipitação observada coletada por meio de pluviômetros aliado a baixa densidade de estações pluviométricas nas bacias hidrográficas brasileiras (ONS, 2020). A tabela 4 resume as informações do banco de dados utilizado sobre os dados de precipitação.

Tabela 4 – Informações sobre o banco de dados utilizados sobre precipitação

Subsistema	Bacia	UHE	Código	Lat	Lon
Norte	Tocantins	275-Tucuruí	PSATUCR	-3,83	-49,65

Fonte: elaborado pelo autor.

4.2 VAZÕES OBSERVADAS

Os registros de vazões observadas por aproveitamento hidrelétrico foram obtidos na página de dados hidrológicos do portal de dados abertos do ONS para o período de análise compreendido entre 2006 e 2021. Os dados disponibilizados e utilizados atualmente nos processos do ONS são aplicados à metodologia de

reconstituição e tratamento das séries de vazões naturais, conforme descrito na Nota Técnica 0144-2018.

Segundo a definição adotada no setor elétrico, o termo vazão natural corresponde a vazão que ocorreria em uma seção do rio caso não houvesse ações antrópicas na sua bacia contribuinte. Similarmente, o termo vazão afluente caracteriza a vazão que chega a um aproveitamento hidroelétrico que é influenciada pelas obras de regularização e demais ações antrópicas porventura existentes na bacia hidrográfica (MALFATTI et al, 2018).

A implantação de reservatórios integrados a usinas hidroelétricas modifica a distribuição espacial e temporal das vazões. Logo, a vazão em um determinado instante em um ponto de controle de um curso d'água a jusante de um reservatório, normalmente, não é mais aquela que ocorreria caso a bacia contribuinte permanecesse em suas condições naturais. Dessa maneira, para resgatar as características de magnitude e variabilidade dessas séries, necessárias para o planejamento e operação do SIN, a reconstituição das vazões naturais torna-se primordial. De modo geral, as vazões naturais são calculadas a partir das séries de vazões observadas em estações fluviométricas e das vazões afluentes e defluentes nos locais de aproveitamentos, retirando-se os efeitos da operação dos reservatórios existentes a montante e incorporando as vazões relativas aos usos consuntivos e à evaporação líquida (ONS, 2018).

4.3 LOCAL DE ESTUDO

Para validar a aplicação do modelo proposto, foram consideradas duas bacias hidrográficas onde estão situadas as instalações do aproveitamento hidrelétrico UHE Tucuruí, com o objetivo de aplicar a metodologia de previsão de vazões naturais diárias. A seleção da usina foi baseada na sua importância para o SIN em relação a representatividade de energia natural afluente (ENA) no submercado Norte.

A ENA representa o volume de energia que pode ser produzido de acordo com o regime de chuvas e conseqüentemente preenchimento dos rios que pertencem à bacia em determinado local. Assim, quanto maior a ENA, maior a quantidade de energia possível de ser gerada pela usina hidrelétrica. A ENA é calculada pelo ONS a partir do produto das vazões naturais e das produtibilidades equivalentes ao armazenamento de 65% do volume útil dos reservatórios dos aproveitamentos

hidroelétricos, somadas para uma bacia ou subsistema. O valor da produtividade média está relacionado ao conjunto turbina-gerador, referente à queda obtida pela diferença entre o nível de montante e o nível médio do canal de fuga. A Tabela 5 apresenta a produtividade para UHE Tucuruí.

Tabela 5 - Produtibilidades

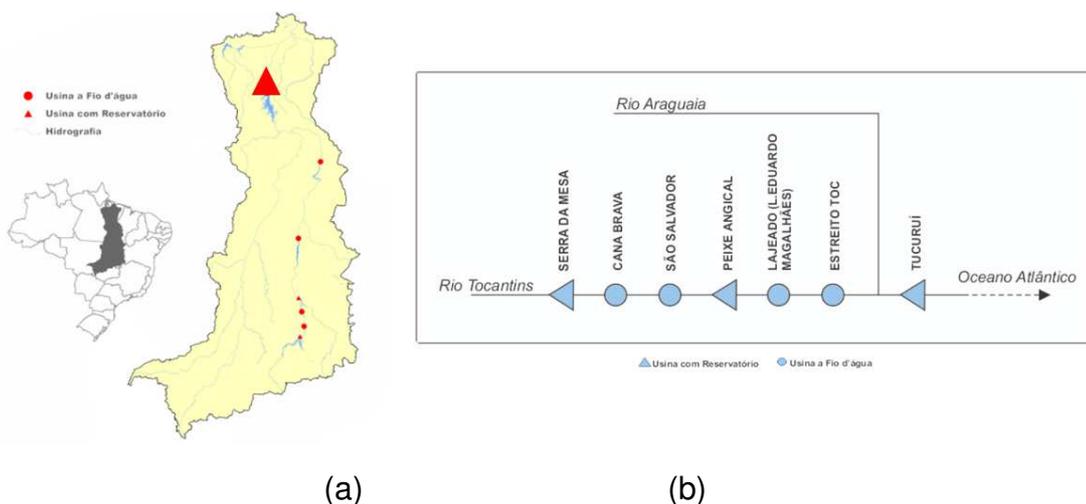
Subsistema	Bacia	UHE	Produtibilidade
Norte	Tocantins	275-Tucuruí	0,5496

Fonte: elaborado pelo autor.

4.3.1 Submercado Norte: 275-Tucuruí

A UHE Tucuruí, representado como posto 275 pelo ONS, está localizado na bacia do rio Tocantins (N). Construída no rio Tocantins, a geradora entrou em operação em 30 de dezembro de 1984, sob operação da Eletronorte, contando com potência total de 8.370 MW de energia. A Figura 14 mostra a área de drenagem da bacia e a localização da UHE Tucuruí à esquerda e o diagrama esquemático da cascata das usinas localizadas na bacia do Tocantins à direita.

Figura 12 - Localização UHE Tucuruí (a) e diagrama de usinas (b)

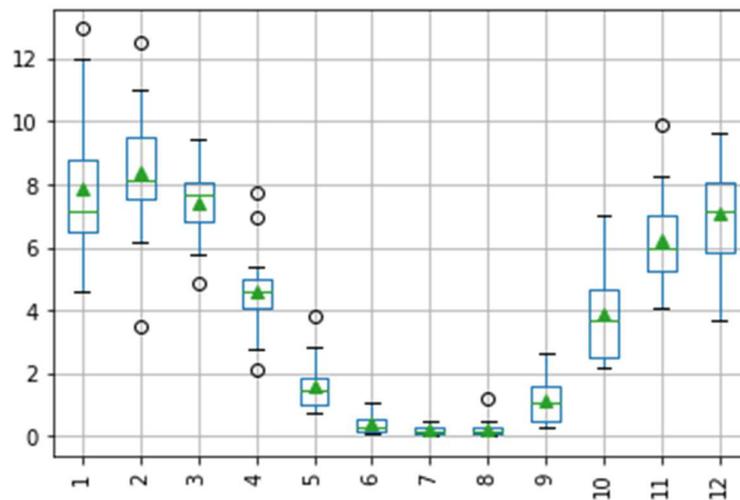


Fonte: Agência Nacional de Águas.

A região da bacia do rio Tocantins possui o clima Tropical, apresentando dois períodos climáticos bem definidos. O período chuvoso é caracterizado entre outubro e abril sendo responsável por 90% das precipitações que ocorrem no ano. O período

seco é marcado entre os meses de maio e setembro (LIMA e LOUREIRO, 2021). A Figura 15 mostra a característica da sazonalidade do regime de precipitação a partir dos dados compreendidos entre 2006 e 2022, representando a chuva média mensal. Como pode-se verificar a região apresenta um regime de precipitação bem definido ao longo do ano.

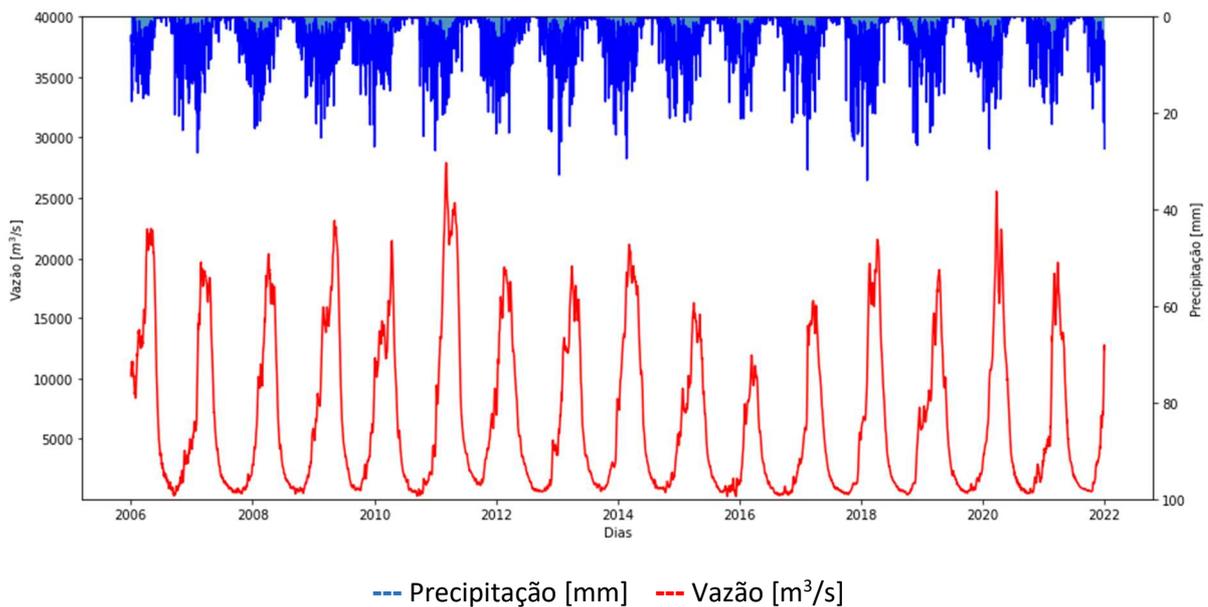
Figura 13 - Padrão de precipitação anual UHE Tucuruí.



Fonte: elaborado pelo autor.

O hidrograma para UHE Tucuruí, apresentado na Figura 16, mostra a relação entre os regimes de precipitação e vazão para o período entre 2006 e 2022.

Figura 14 - Hidrograma UHE Tucuruí.



Fonte: elaborado pelo autor.

A bacia do rio Tocantins tem hoje quase 90% do seu potencial hidrelétrico já aproveitado para geração de energia, dada a importância da sua posição geográfica entre as redes Norte e Nordeste e Sudeste do Brasil. Dentre as 8 usinas localizados ao longo do rio Tocantins, Tucuruí destaca-se por sua capacidade. A Tabela 6 resume os principais parâmetros estatísticos para as séries de precipitação e vazão no período compreendido entre 2006 e 2022 para o aproveitamento hidrelétrico de Tucuruí.

Tabela 6 - Resumo estatístico de precipitação e vazão para UHE Tucuruí.

	Precipitação	Vazão
Média	4,06	6461,96
Desvio padrão	4,98	6428,25
Mínimo	0,00	239,77
Percentil 25%	0,16	1232,99
Percentil 50%	2,11	3563,25
Percentil 75%	6,25	10887,43
Máximo	33,86	27919,93

Fonte: elaborado pelo autor.

4.4 INDICADORES DA QUALIDADE DA PREVISÃO DE VAZÃO

Uma avaliação dos indicadores mais comuns, mostra que um subconjunto deles pode ser considerado como bom indicador de curto prazo e outro de longo prazo. Indicadores que levam em consideração a média das observações podem ser considerados como adequados para uma avaliação de longo prazo, enquanto aqueles que estão voltados para a avaliação de cada ponto, podem ser considerados como adequados para uma avaliação de curto prazo. Para tanto, foi utilizado o indicador de “curto prazo”, Desvio Médio Percentual Absoluto – MAPE, e o indicador de longo prazo Coeficiente de Nash-Sutcliffe – NASH.

O MAPE é a média das diferenças absolutas entre os valores previstos e observados, expressa em porcentagem dos valores observados. Este indicador apresenta a vantagem de não ser influenciado pelo valor absoluto das vazões. Pode assumir valores no intervalo $[0, \infty)$, sendo $MAPE = 0$ o valor correspondente a previsões perfeitas no período (GT-SMAP, 2022).

$$MAPE(Q_{obs}, Q_{prev}) = 1/n \sum_{t=1}^n \left[\frac{|Q_{pred,t} - Q_{obs,t}|}{Q_{obs,t}} \right] \times 100 \quad (42)$$

O NASH é utilizado para avaliar o poder de predição dos modelos hidrológicos. Este indicador pode assumir valores no intervalo $(-\infty, 1]$, sendo $NASH = 1$ correspondente à previsão perfeita das vazões no período em foco. $NASH < 0$ mostra que utilizar as previsões do modelo é pior do que utilizar o valor médio das observações (GT-SMAP, 2022).

$$NASH(Q_{obs}, Q_{prev}) = 1 - \frac{\sum_{t=1}^n (Q_{obs,t} - Q_{prev,t})^2}{\sum_{t=1}^n (Q_{obs,t} - \bar{Q})^2} \quad (43)$$

onde $Q_{obs,t}$ é a vazão observada no intervalo de tempo t e $Q_{prev,t}$ é a vazão prevista no intervalo de tempo t . \bar{Q} representa a média das vazões observadas nos intervalos de tempo de 1 a n , conforme equação definida a seguir.

$$\bar{Q} = 1/n \sum_{t=1}^n Q_{obs,t} \quad (44)$$

5 RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados obtidos em relação a previsão de séries temporais.

5.1 EXPERIMENTOS COMPUTACIONAIS

Os experimentos computacionais foram implementados utilizando a linguagem de programação Python. Os modelos foram construídos utilizando a biblioteca Darts, uma biblioteca voltada para análise e modelagem de séries temporais baseada no framework Pytorch. A execução foi feita no Google colab, um serviço de nuvem gratuito hospedado pela Google.

A biblioteca permite fácil implementação das arquiteturas de deep learning sendo possível utilizar os métodos disponíveis em Pytorch, apenas inserindo os parâmetros da rede neural. Foram realizados 12 experimentos, variando as covariáveis para os modelos TFT, LSTM e TCN. Estes experimentos foram realizados para avaliar a influência no desempenho do modelo para a usina de Tucuruí. O Quadro 2 apresenta os experimentos propostos para comparar os modelos.

Quadro 2. Experimentos propostos.

Experimentos	Aproveitamento hidrelétrico	Modelo	Covariáveis
1	Tucuruí-275	LSTM	Precipitação observada
2			Vazão observada
3		TCN	Precipitação observada
4			Vazão observada
5		TFT	Precipitação observada e prevista
6			Vazão observada e precipitação prevista

Fonte: elaborado pelo autor.

Os modelos utilizaram como entrada precipitação observada e vazão observada 30 dias anterior ao ponto de previsão para prever em um horizonte de 14 dias a frente. Para o treinamento dos modelos propostos foi utilizado 80% dos dados observados, compreendendo o período entre 01/01/2006 e 18/10/2018. Para a validação das previsões, foi utilizado o restante dos dados observados, ou seja, 20%, compreendendo o período entre 19/10/2018 a 31/12/2021. Os modelos foram treinados para convergir em 100 épocas. As especificações da arquitetura de cada

modelo, de acordo com a nomenclatura da biblioteca Darts, são especificadas nas tabelas 7, 8 e 9, para o modelo TFT, LSTM e TCN, respectivamente. Foram utilizados os valores default para os parâmetros do modelo, conforme sugerido na documentação da biblioteca Darts para melhor desempenho das simulações.

Tabela 7. Especificações da arquitetura do modelo TFT

TFT	
Input_chunk_length	30
Output_chunk_length	14
Hidden_size	16
Lstm_layers	1
Num_attention_heads	4
dropout	0,2
Optimizer_kwargs	{"lr":0,001}
Loss_fn	MSELoss
epochs	100

Tabela 8. Especificações da arquitetura do modelo LSTM

LSTM	
Input_chunk_length	30
Output_chunk_length	14
N_rnn_layers	3
dropout	0,2
Optimizer_kwargs	{"lr":0,001}
Loss_fn	MSELoss
epochs	100

Tabela 9. especificações da arquitetura do modelo TCN

TCN	
Input_chunk_length	30
Output_chunk_length	14
Num_layers	3
Kernel_size	5
Num_filters	32
Dilation_base	2
dropout	0,2
Optimizer_kwargs	{"lr":0,001}
Loss_fn	MSELoss
epochs	100

De maneira a obter melhor desempenho e rápida convergência, foi utilizado os parâmetros do algoritmo de otimização Adam sugerido pelos autores, baseados em experimentos realizados em problemas de aprendizado de máquina. Para a taxa de aprendizagem foi utilizado $\alpha = 0.001$, taxa de decaimento exponencial $\beta_1 = 0.9$, $\beta_2 = 0.999$ e precisão $\epsilon = 10^{-8}$ (KINGMA e BA, 2017).

5.2 RESULTADOS

Para avaliar o desempenho das previsões feitas pelo modelo TFT, foram utilizados como referência os modelos LSTM, TCN populares na literatura e o modelo SMAP atualmente utilizado pelo ONS no PMO. A Tabela 10 apresenta os valores de MAPE e Nash para cada uma das variações de covariáveis nos modelos LSTM, TCN e TFT, além do tempo de execução de cada rodada referente a UHE Tucuruí. Para o modelo SMAP foram calculados apenas os valores MAPE e Nash em relação a vazão observada, uma vez que os dados da previsão desse modelo foram coletados diretamente da base de dados do ONS, sem a necessidade de executar o modelo SMAP.

Tabela 10 – MAPE e Nash para UHE Tucuruí – Tocantins (Norte).

Modelo	Covariáveis	MAPE	Nash	Tempo de execução (segundos)
LSTM	Precipitação	14,59	0,94	709
	Vazão	18,72	0,92	849
TCN	Precipitação	22,18	0,87	768
	Vazão	25,97	0,85	777
TFT	Precipitação	16,57	0,96	1492
	Vazão	17,18	0,94	1632
SMAP	-	13,39	0,94	-

Fonte: elaborado pelo autor.

Foi observado que em todos os modelos, a utilização da covariável de precipitação observada produz melhores previsões em relação a utilização da covariável de vazão observada. Dentre os modelos, o SMAP foi a proposta que apresentou menor erro nas previsões. Em relação aos modelos de *deep learning*, a arquitetura LSTM foi a que apresentou melhor desempenho de modo geral, considerando a média das previsões. O modelo TFT apresentou comportamento

médio similar ao analisar tanto o MAPE quanto Nash, porém um pouco inferior ao LSTM. Além disso, importante salientar o desempenho computacional para realizar o treinamento dos modelos TFT, que apresentaram tempo de execução duas vezes superior que aos demais modelos. O modelo TCN foi o modelo com pior erro nas previsões.

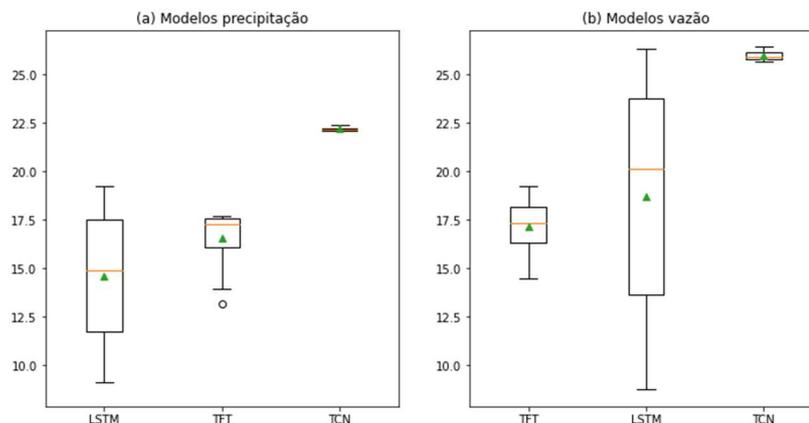
Uma análise mais detalhada das previsões ao longo do horizonte de 14 dias da uma nova perspectiva em relação ao desempenho dos modelos. A Figura 17 apresenta a comparação do MAPE entre os modelos TFT, LSTM e TCN para UHE Tucuruí treinados em relação à vazão observada e precipitação, para os períodos seco e úmido, entre os anos 2019 e 2020. À direita são apresentados os resultados para a modelagem utilizando a covariável de precipitação, enquanto na esquerda são apresentados os resultados para modelagem utilizando a covariável de vazão.

O gráfico de caixas da figura 17 compara o desempenho entre os modelos, com base no MAPE para as covariáveis de precipitação (figura 17 a) e vazão observada (figura 17 b). O modelo TCN apresentou o pior desempenho dentre os modelos comparados, entretanto resultou em baixa amplitude mostrando estabilidade na avaliação ao longo do horizonte de previsão.

Já o modelo LSTM mostrou melhor desempenho médio para a covariável de precipitação. No entanto, o modelo LSTM apresentou grande amplitude no MAPE entre o primeiro e último dia de previsão. Essa característica ficou mais acentuada para a covariável de vazão observada, onde a erro médio do modelo LSTM foi inferior ao modelo TFT.

O modelo TFT foi levemente inferior ao modelo LSTM para a covariável de precipitação, com uma distribuição positiva devido a estabilidade da precisão a partir do sétimo dia de previsão. Quando utilizado a covariável de vazão observada, o modelo TFT obteve o melhor desempenho em relação aos demais modelos, apresentando baixa dispersão do MAPE ao longo do horizonte, resultando em boa estabilidade de previsão.

Figura 15. Características de dispersão dos modelos para (a) covariável de precipitação e (b) covariável de vazão.



Fonte: elaborado pelo autor.

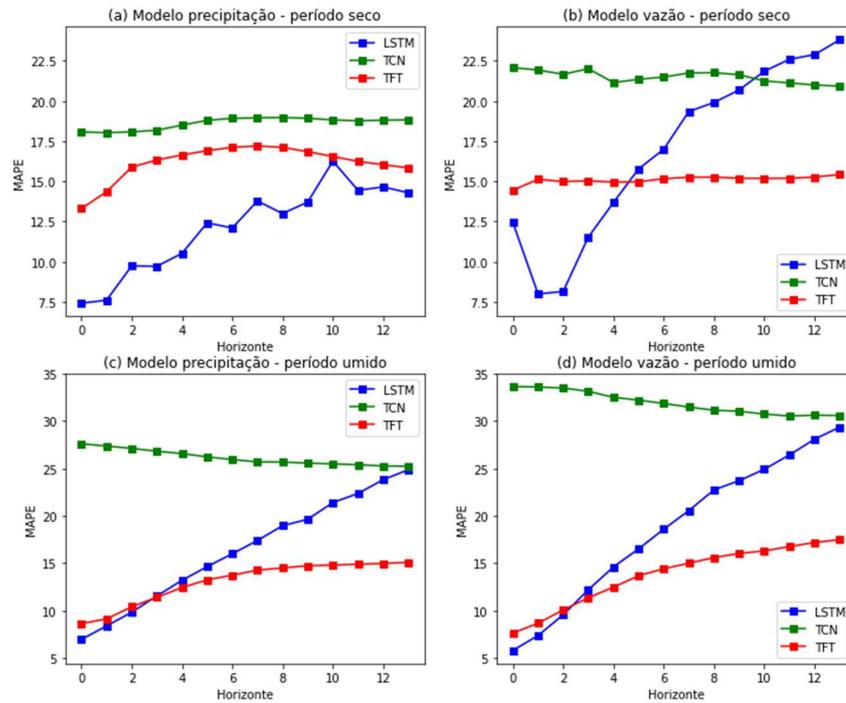
Os modelos que utilizaram a covariável de precipitação apresentam melhor desempenho ao longo do horizonte de previsão em relação aos modelos que utilizam covariável de vazão observada durante o período seco (Figura 18-a). O modelo TFT mostrou comportamento semelhante, apresentando uma leve melhora na estabilidade quando utilizando vazão observada como covariável (Figura 18-b).

O modelo LSTM mostrou maior variação no MAPE no decorrer do horizonte em relação aos demais modelos, sendo essa característica ainda mais expressiva quando o modelo utiliza covariável de vazão observada. A previsão do modelo LSTM fica inferior ao TFT a partir do sexto dia de previsão e inferior ao modelo TCN a partir do 11º dia de previsão (Figura 18-b).

Tanto os modelos TFT e TCN mostram boa estabilidade ao longo de todo o horizonte, não mostrando aumento do erro na previsão ao final do horizonte. Similarmente, no período úmido, os modelos apresentaram melhor desempenho quando utilizando covariáveis de precipitação em relação aos modelos que utilizaram a covariável de vazão observada. Nesse cenário, no entanto, o modelo LSTM fica com maior erro em relação ao modelo TFT a partir do terceiro dia (Figura 18-c).

Quando comparado os modelos em relação ao período de análise, o período úmido apresentou maior variação na previsão dos modelos entre o primeiro e último dia do horizonte, resultando em grande variação de MAPE. Além disso, o modelo TFT mostrou um leve aumento no erro de previsão ao final do horizonte, com o aumento do MAPE, quando comparado ao período seco (Figura 18-d).

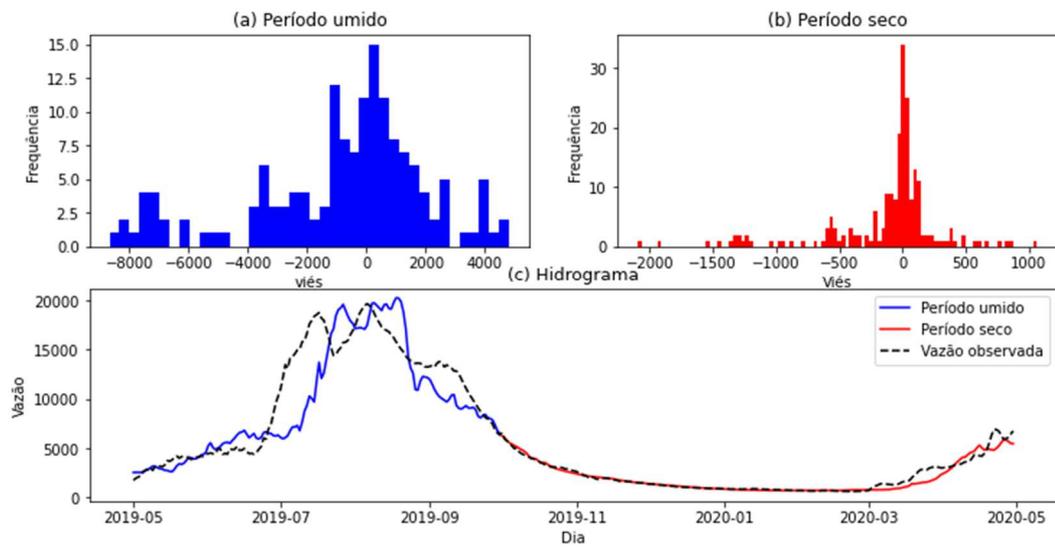
Figura 16. Desempenho ao longo do horizonte para UHE Tucuruí para o período seco: (a) Covariável precipitação e (b) covariável vazão observada. Período úmido: (c) Covariável precipitação e (d) covariável vazão observada.



Fonte: elaborado pelo autor.

A análise de viés auxilia a entender o comportamento da vazão prevista nos cenários de período úmido e seco. De maneira geral, todos os modelos apresentaram boa assertividade nas previsões durante o período seco, conforme apresentado nos hidrogramas do gráfico (c) das figuras 19 a 24. A distribuição do viés para o modelo LSTM utilizando covariável de precipitação no período úmido mostrou valores significativos de viés com vazão prevista subestimada em relação ao valor observado.

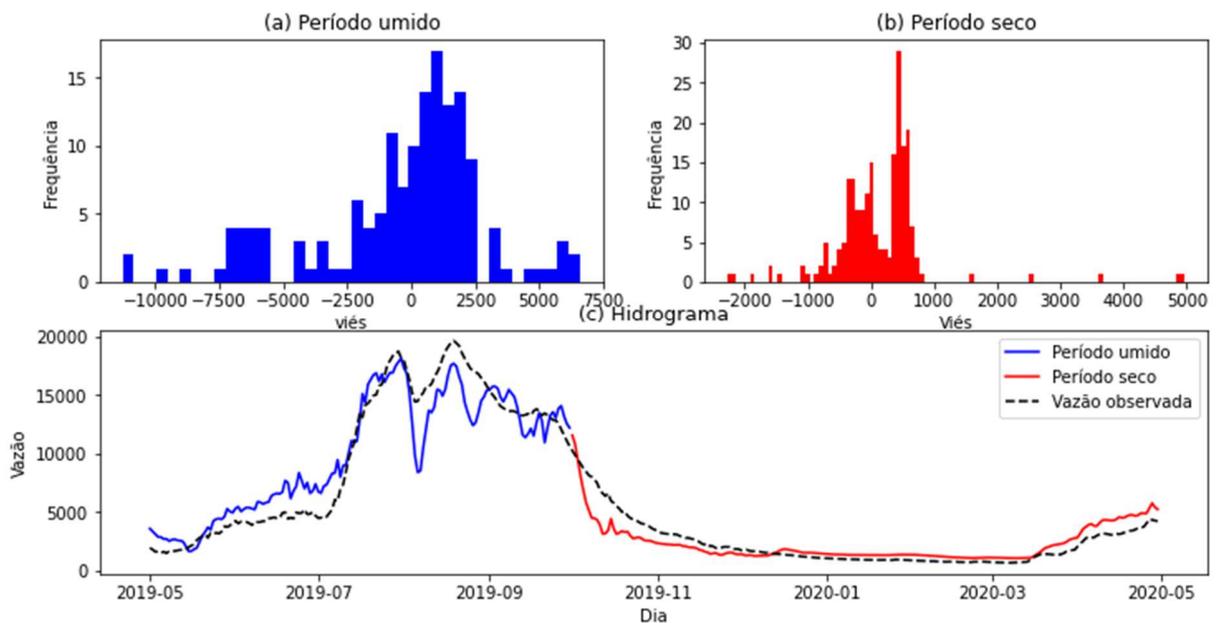
Figura 17. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo LSTM utilizando covariável de precipitação.



Fonte: elaborado pelo autor.

Quando o modelo LSTM considera apenas a covariável de vazão, eliminando a dependência da precipitação, o modelo resulta em uma previsão mais próxima da vazão observada. Chama atenção a alternância do viés no início e no final do período úmido, apresentando um comportamento de superestimativa no início do período e subestimativa entre a metade e o final deste período. Similarmente ao modelo LSTM com covariável de precipitação, o período seco mostrou boa assertividade na vazão prevista, no entanto com viés um pouco mais expressivo. Essa característica do viés da vazão prevista pelo modelo fica evidente na distribuição da Figura 20-b.

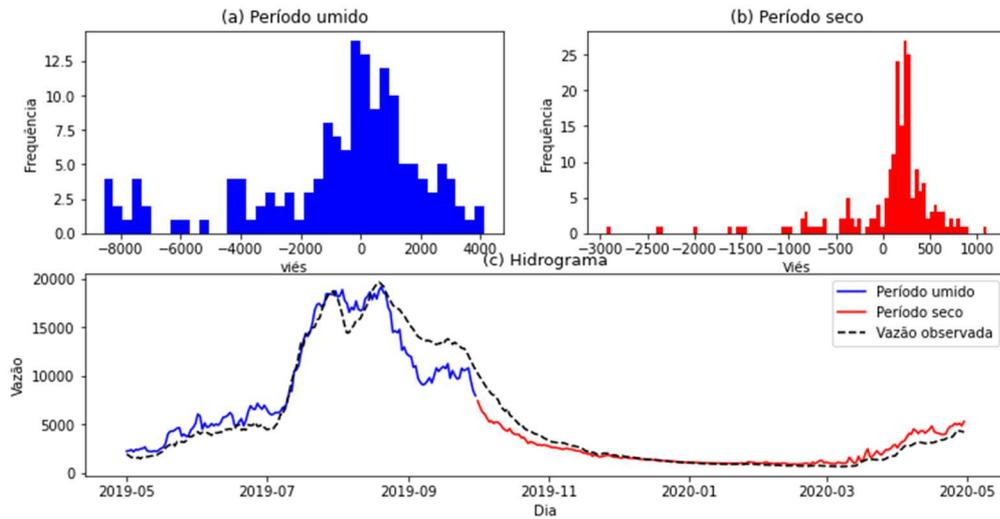
Figura 18. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo LSTM utilizando covariável de vazão.



Fonte: elaborado pelo autor.

O modelo TCN apresentou efetividade para o cálculo dos valores durante o período seco, apresentando comportamento similar aos demais modelos, mostrando uma tendência de subestimativa da vazão prevista no início do período seco e superestimativa no final deste período. O período úmido teve maior variação na previsão devido a maior sensibilidade e resposta a chuva, como já esperado, quando utilizado a covariável de precipitação nos modelos (Figura 21).

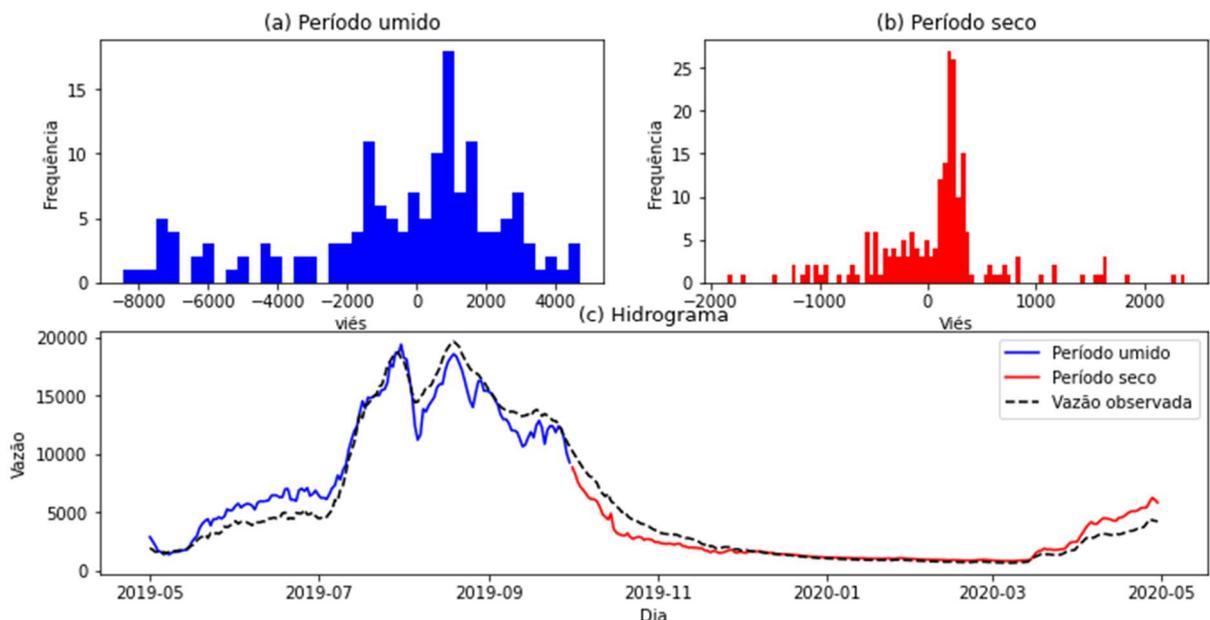
Figura 19. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo TCN utilizando covariável de precipitação.



Fonte: elaborado pelo autor.

Esse comportamento de variação entre vazão prevista e vazão verificada no período úmido é mais suave nos modelos que utilizaram a covariável de vazão observada (Figura 22). Os padrões de alternância de superestimativa e subestimativa das vazões previstas são observados novamente, conforme distribuição do viés.

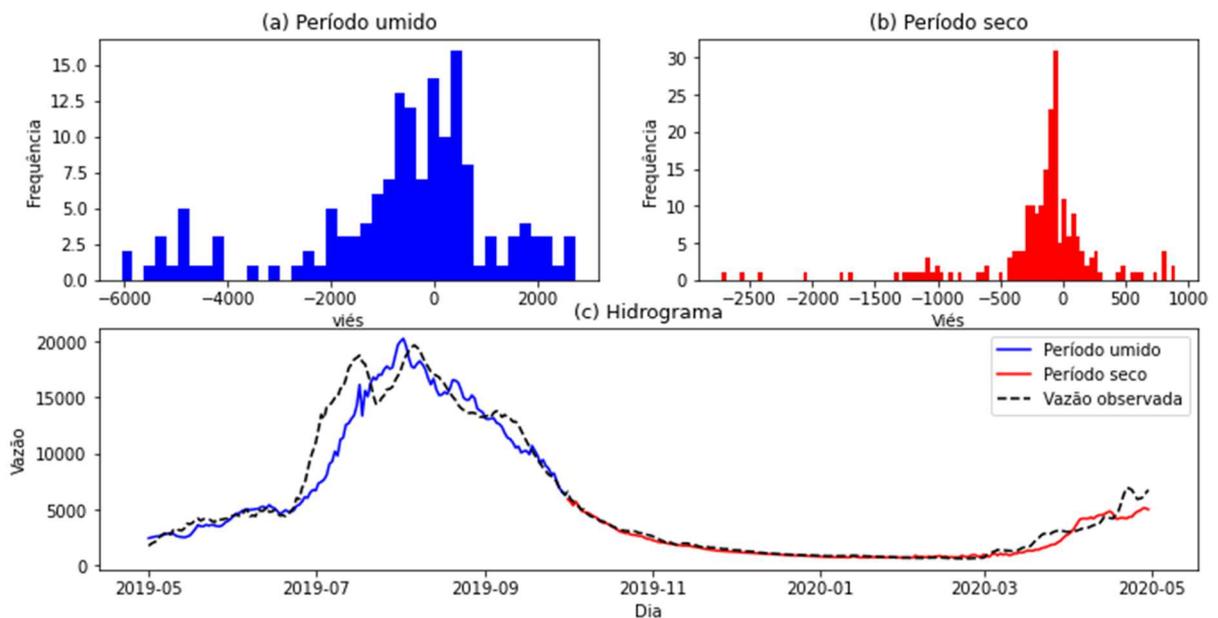
Figura 20. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo TCN utilizando covariável de vazão.



Fonte: elaborado pelo autor.

O modelo TFT apresentou boa aderência no início do período úmido, com uma leve subestimativa da vazão prevista conforme avançamos no período úmido, estabilizando entre o final do período úmido seguindo por todo o período seco com boa assertividade (Figura 23). Uma diferença do modelo TFT em relação aos demais modelos aqui, é a utilização de covariáveis futuras para precipitação além das covariáveis observadas de precipitação ou vazão.

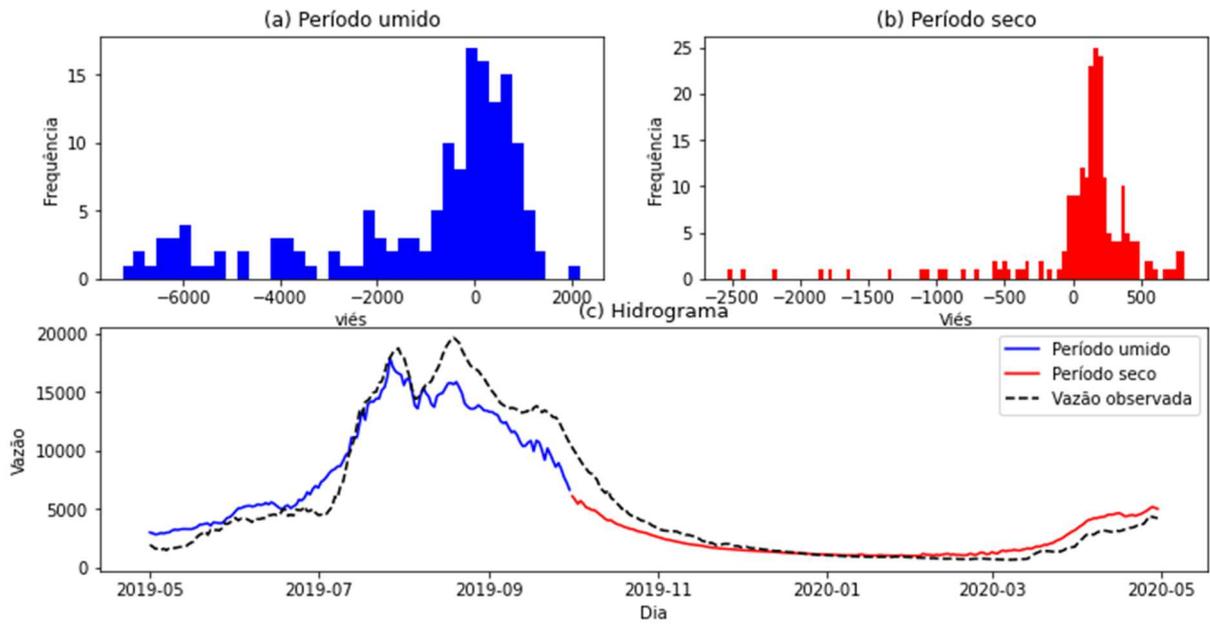
Figura 21. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo TFT utilizando covariável de precipitação.



Fonte: elaborado pelo autor.

Quando utilizado a covariável de vazão observada juntamente com a covariável futura de precipitação, o modelo mostrou maior descolamento entre as vazões previstas e observadas durante o período úmido de maneira mais significativa. No período seco nota-se maior aderência da série prevista em relação a série vazão observada, porém com viés maior no início e fim do período (Figura 24).

Figura 22. Distribuições do viés para o (a) período úmido e (b) período seco e (c) hidrograma de vazões para o modelo TFT utilizando covariável de vazão.



Fonte: elaborado pelo autor.

6 CONCLUSÕES

A previsão da disponibilidade de recursos hídricos é um estudo importante para diversos setores, incluindo o elétrico. Uma boa estimativa de vazões permite planejar a operação das UHEs do sistema elétrico interligado. Esse planejamento inclui a previsão de geração e vertimento a curto e longo prazo. Este trabalho propôs a aplicação de um modelo recente com características temporais que permite maior assertividade das previsões em relação a outros modelos vastamente utilizados para previsão.

Foi investigado o desempenho da TFT em comparação aos modelos LSTM, TCN e as previsões do modelo SMAP em relação as vazões observadas para um horizonte de 14 dias considerando a UHE Tucuruí na bacia do rio Tocantins, Região Norte do País. Para tal, foram realizados 6 experimentos variando a configuração de entrada durante o treinamento dos modelos, analisando o efeito da precipitação e vazão observada sobre a precisão das previsões em cada modelo. As previsões foram avaliadas com as métricas MAPE e Nash, comparando as previsões diárias com respectivo valor observado.

Verificou-se que a relação entre chuva e vazão é de suma importância para boas previsões, comparando os resultados dos mesmos modelos entre as duas localidades localizadas em bacias diferentes. As previsões mostraram boa assertividade no início do horizonte, diminuindo conforme avança para o final do horizonte. Apesar do modelo LSTM apresentar MAPE melhor que o modelo TFT, os experimentos mostraram que o modelo aumenta o erro de maneira considerável quando avança para o final da previsão. Esse comportamento é mais agravante quando aplicado a covariável de vazão. O mesmo padrão foi identificado para as duas usinas analisadas.

Após a análise dos resultados obtidos, pode-se afirmar que o modelo TFT apresentou um desempenho adequado na previsão de vazão para os próximos 14 dias. Além disso, constatou-se que este modelo apresentou assertividade comparável aos modelos LSTM e SMAP, porém com um melhor desempenho ao longo de todo o horizonte de previsão. Isso se deve, em grande parte, às características da sua arquitetura que são capazes de capturar padrões e relações de curto e longo prazo, proporcionando uma maior estabilidade e assertividade nas previsões até o final do horizonte. É importante ressaltar que, a partir do terceiro dia de previsão até o final do

horizonte, o modelo TFT apresentou um desempenho superior ao modelo LSTM, o que reforça a sua eficácia em relação aos modelos tradicionais utilizados na previsão de vazão

A análise de viés mostrou que os modelos se comportam melhor durante o período seco. No período úmido foi observado maior descolamento entre vazões prevista e observada, com um comportamento de alternância entre superestimativa no início do período e subestimativa ao final do período úmido. O modelo TFT apresenta um diferencial na modelagem ao utilizar covariável futura de precipitação, apresentando melhor assertividade ao longo dos períodos seco e úmido em relação aos demais modelos comparados.

Para trabalhos futuros é sugerido investigar o efeito dos parâmetros da arquitetura sobre o desempenho por meio do processo de *fine tuning*. Além disso, é importante explorar a característica de *variable importance* do modelo TFT por meio de experimentos com outras variáveis, como a precipitação e vazão de usinas a montante da usina avaliada. Outra característica que influencia as previsões é a correlação entre chuva e vazão. Dessa maneira é necessário aplicar o modelo TFT em outras bacias, como por exemplo, no submercado Sul, onde o regime climático não apresenta um padrão definido de chuva entre os períodos seco e úmido.

REFERÊNCIAS

LIM, B.; ARIK, S. O.; LOEFF, N.; PFISTER, T. Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting. arXiv preprint, 2020. Disponível em: <https://doi.org/10.48550/arXiv.1912.09363>.

CIVITARESE, D. S. et al. Extreme Precipitation Seasonal Forecast Using a Transformer Neural Network. arXiv preprint, 2021. Disponível em: <<https://doi.org/10.48550/arXiv.2107.06846>>

WU, B.; WANG, L.; ZENG, Y. Interpretable wind speed prediction with multivariate time series and temporal fusion transformers. *Energy*, v. 252, p. 123990, 2022. ISSN 0360-5442. Disponível em: <<https://doi.org/10.1016/j.energy.2022.123990>>

GUNNARSSON, A.; FRANC, C. Food Waste Reduction through Sales Forecasting using Temporal Fusion Transformers: A deep machine learning approach for predicting grocery sales. Master's thesis, Chalmers University of Technology, Sweden, 2021.

BAI, S.; KOLTER, J. Z.; KOLTUN, V. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling. arXiv preprint, 2018. Disponível em: <https://doi.org/10.48550/arXiv.1803.01271>.

HEWAGE, P. et al. Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station. *Soft Computing*, v. 24, p. 16453–16482, 2020. Disponível em: <https://doi.org/10.1007/s00500-020-04954-0>.

OMRAN, N. F. et al. Applying Deep Learning Methods on Time-Series Data for Forecasting COVID-19 in Egypt, Kuwait, and Saudi Arabia. *Complexity*, vol. 2021, Article ID 6686745, 13 pages, 2021. Disponível em: <https://doi.org/10.1155/2021/6686745>.

LI, P.; ZHANG, J.; KREBS, P. Prediction of Flow Based on a CNN-LSTM Combined Deep Learning Approach. *Water*, v. 14, p. 993, 2022. Disponível em: <https://doi.org/10.3390/w14060993>.

LI, T.; HUA, M.; WU, X. A Hybrid CNN-LSTM Model for Forecasting Particulate Matter (PM_{2.5}). *IEEE Access*, v. 8, p. 26933-26940, 2020. doi: 10.1109/ACCESS.2020.2971348.

LIN, Y.; KOPRINSKA, I.; RANA, M. Temporal Convolutional Attention Neural Networks for Time Series Forecasting. In: 2021 International Joint Conference on Neural Networks (IJCNN), p. 1-8, 2021. doi: 10.1109/IJCNN52387.2021.9534351.

LARA-BENITEZ, P.; CARRANZA-GARCIA, M.; RIQUELME, J. C. An experimental review on deep learning architectures for time series forecasting. *International Journal of Neural Systems*, v. 31, n. 03, p. 2130001, 2021. doi: 10.1142/S0129065721300011.

TAO, Q.; LIU, F.; LI, Y.; SIDOROV, D. Air Pollution Forecasting Using a Deep Learning Model Based on 1D Convnets and Bidirectional GRU. *IEEE Access*, v. 7, p. 76690-76698, 2019. doi: 10.1109/ACCESS.2019.2921578.

GORODETSKAYA, Y.; FONSECA, L. G.; RIBEIRO, C. B. M. Previsão de Vazão de Curto Prazo Utilizando Redes Neurais Artificiais. Estudo de Caso: Rio Paraíba do Sul. In: 3º Simpósio de Recursos Hídricos da Bacia do Rio Paraíba do Sul, 2018.

GUNNARSSON, A.; FRANC, C. Food Waste Reduction through Sales Forecasting using Temporal Fusion Transformers A deep machine learning approach for predicting grocery sales. 2021.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980 (v9), 2017. Disponível em: <https://doi.org/10.48550/arXiv.1412.6980>.

ZHANG, A.; LIPTON, Z. C.; LI, M.; SMOLA, A. J. Dive into Deep Learning. 2021.

GÉRON, A. Hands-On Machine Learning with Scikit-Learn and TensorFlow. O'Reilly, 2017.

CHOLLET, F. Deep learning with python. Manning Publications, 2018.

DARTS DOCUMENTATION. Torch Forecasting Models. Disponível em: https://unit8co.github.io/darts/userguide/torch_forecasting_models.html.

DARTS DOCUMENTATION. Covariates. Disponível em: <https://unit8co.github.io/darts/userguide/covariates.html>.

SCIKIT-LEARN 1.1.2 DOCUMENTATION. Metrics and scoring: quantifying the quality of predictions. Disponível em: https://scikit-learn.org/stable/modules/model_evaluation.html?highlight=mape.

RAMOS, K. M. et al. Previsão de vazões utilizando redes neurais para Sobradinho. In: XX Simpósio Brasileiro de Recursos Hídricos, 2017.

MGHAZLI, Y., ARAUJO, R. and SEIXAS, J. Previsão do mercado financeiro com redes neurais. In: CBIC - Congresso Brasileira de Inteligência Computacional, 2021. doi: 10.21528/CBIC2021-160

MACEIRA, M. E. P. et al. Periodic ARMA models applied to weekly streamflow forecasts. In: Proceedings of the 1999 IEEE Powertech, Budapest.

CEPEL. Programa de previsão de vazões semanais - previvaz: Manual do usuário. Rio de Janeiro, 2015.

BARINO, F. O.; SANTOS, A. B. Rede Neural Convolutacional 1D aplicada à previsão da vazão no Rio Madeira. In: SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS, 38., 2020, Florianópolis. Anais [...]. Florianópolis: SBrT, 2020.

FILHO, A. R. G. et al. Forecasting of water flow in a hydroelectric power plant using LSTM recurrent neural network. In: INTERNATIONAL CONFERENCE ON ELECTRICAL, COMMUNICATION AND COMPUTER ENGINEERING, 2nd, 2020, Istanbul. Proceedings [...]. Istanbul: IEEE, 2020.

MACIEL, G. M. et al. Daily Water Flow Forecasting via Coupling Between SMAP and Deep Learning. IEEE Access, v. 8, p. 204660-204675, 2020. DOI: 10.1109/ACCESS.2020.3036487.

MACEIRA, M. E. P.; TERRY, L. A.; COSTA, F. S.; DAMÁZIO, J. M.; MELO, A. C. G. Chain of optimization models for setting the energy dispatch and spot price in the Brazilian system. In: POWER SYSTEMS COMPUTATION CONFERENCE, 2002, Sevilla. Proceedings [...]. Sevilla: PSCC, 2002.

GT-SMAP. Uso do modelo SMAP/ONS em horizonte estendido no modelo Decomp. 2021.

SIGNORIELLO, G. A. Modelos Matemáticos para Previsão de Vazões Afluentes a Aproveitamentos Hidrelétricos. 2014. 145 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas, 2014.

NUNES, F. M. S. et al. Hydrological modelling using SMAP for estimating monthly streamflows in Piancó river basin. Revista Cerne, v. 9, n. 3, p. 289-295, 2014.

KUKI, C. A. C. et al. Estratégias de previsão de vazão para formação de preço de energia elétrica no curto prazo. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 52., 2020, João Pessoa. Anais eletrônicos [...]. João Pessoa: SOBRAPO, 2020.

COLONESE, J.P.; XAVIER, L.N.; ARAUJO, A.A.M. Análise de erros de previsão do modelo hidrológico Previzaz no âmbito do planejamento da operação do sistema elétrico brasileiro. In: XXI Simpósio Brasileiro de Recursos Hídricos, 2015, Brasília, DF.

SIGNORIELLO, G.A. Modelos matemáticos para previsão de vazões afluentes a aproveitamentos hidrelétricos. Dissertação de Mestrado. Universidade Estadual de Campinas, 2014.

BRAGA, R.S.; CATALDI, M.; OLIVEIRA, H.C. Metodologia para previsão de vazões na bacia do Rio Grande. In: XVIII Simpósio Brasileiro de Recursos Hídricos, 2014, Campo Grande, MS.

HU, Y.; YAN, L.; HANG, T.; FENG, J. Streamflow forecasting of small rivers based on LSTM. Disponível em: arXiv:2001.05681v1.

LIM, B.; ARIK, S.O.; LOEFF, N.; PFISTER, T. Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting. Elsevier, 2020.

CIVITARESE, D.S.; SZWARCMAN, D.; ZADROZNY, B.; WATSON, C. Extreme Precipitation Seasonal Forecast Using a Transformer Neural Network. In: Tackling Climate Change with Machine Learning workshop at ICML, 2021.

WU, B.; WANG, L.; ZENG, Y.-R. Interpretable wind speed prediction with multivariate time series and temporal fusion transformers. Energy, v. 246, 121174, 2022.

SAPPL, J.; HARDERS, M.; RAUCH, W. Predicting biogas production rates in anaerobic digesters with a temporal fusion transformer. Water Research, v. 202, 117416, 2021.

de FARIA, V. A. D. et al. An assessment of multi-layer perceptron networks for streamflow forecasting in large-scale interconnected hydrosystems. International Journal of Environmental Science and Technology, v. 19, n. 12, p. 5819-5838, dez. 2022. DOI: 10.1007/s13762-021-03565-y.

GUNNARSSON, A.; FRANC, C. Food Waste Reduction through Sales Forecasting using Temporal Fusion Transformers A deep machine learning approach for predicting grocery sales. Master's thesis (Computer Science) - Chalmers University of Technology, 2021.

LE, X.-H. et al. Comparison of Deep Learning Techniques for River Streamflow Forecasting. *IEEE Access*, v. 9, p. 71805-71820, 2021. DOI: 10.1109/ACCESS.2021.3077703.

SRIVASTAVA, A.; CANO, A. Analysis and forecasting of rivers pH level using Deep Learning. *Progress in Artificial Intelligence*, v. 10, n. 3, p. 200-211, 2021. DOI: 10.1007/s13748-021-00321-4.

BARINO, F. O.; SANTOS, A. B. Rede Neural Convolucional 1D aplicada à previsão da vazão no Rio Madeira. In: XXXVIII SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS, 2020, Florianópolis. Anais [...]. Florianópolis, 2020.

HU, Y. et al. Stream-Flow Forecasting of Small Rivers Based on LSTM. arXiv preprint arXiv:2001.05681, 2020. Disponível em: <https://arxiv.org/abs/2001.05681>.

MACIEL, G. M. et al. Daily Water Flow Forecasting via Coupling Between SMAP and Deep Learning. *IEEE Access*, vol. 8, pp. 204660-204675, 2020. DOI: 10.1109/ACCESS.2020.3036487.

LI, P.; ZHANG, J.; KREBS, P. Prediction of Flow Based on a CNN-LSTM Combined Deep Learning Approach. In: 2022 IEEE 4th Conference on Energy Internet and Energy System Integration (EI2), 2022. DOI: 10.1109/EI2.2022.00037.

SILVA, Thayse Cristina Trajano da. Cenários futuros de oferta e demanda de energia elétrica: simulações do possível racionamento até 2011. Dissertação (Mestrado em Engenharia Elétrica)– Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.

ROCHA, Vinícius Rogério da. Modelo hidrológico SMAP. Monolito Nimbus, 2017. Disponível em: <https://www.monolitonimbus.com.br/modelo-hidrologico-smap/>. Acesso em: 15 ago. 2022.

Branco, N. W., Cavalca, M. S. M., Stefenon, S. F., & Leithardt, V. R. Q. (2022). Wavelet LSTM for Fault Forecasting in Electrical Power Grids. *Sensors*, 22(21), 8323. <https://doi.org/10.3390/s22218323>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. In *Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017)* (pp. 5998-6008). Long Beach, CA: Curran Associates Inc.

MALFATTI, M. G. L.; CARDOSO, A. DE O.; HAMBURGER, D. S.. Modelo Empírico Linear para Previsão de Vazão de Rios na Usina Hidrelétrica de Itaipu – Bacia do Rio Paraná. *Revista Brasileira de Meteorologia*, v. 33, n. 2, p. 257–268, abr. 2018.

LIMA, S. S.; LOUREIRO, G. E. Rede hidrométrica na bacia hidrográfica Tocantins-Araguaia. *Revista Brasileira de Gestão Ambiental*, v. 15, n. 3, p. 78-90, 2021.

ANEXO A – LISTA DOS POSTOS E RESPECTIVOS MODELOS APLICADOS

EMPRESA	USINA	CÓDIGO	30/03	31/03	Modelo
CEMIG	CAMARGOS	001	148	146	SMAP
CEMIG	ITUTINGA	002	148	146	SMAP
FURNAS	FURNAS	006	935	938	SMAP
FURNAS	MASC. DE MORAES	007	1041	1090	SMAP
FURNAS	ESTREITO	008	1081	1111	SMAP
ENGIE	JAGUARA	009	1099	1120	SMAP
CEMIG	IGARAPAVA	010	1151	1154	SMAP
CEMIG	VOLTA GRANDE	011	1264	1247	SMAP
FURNAS	P COLOMBIA	012	1489	1464	SMAP
AES TIETE	CACONDE	014	090	095	SMAP
AES TIETE	EUC DA CUNHA	015	148	153	SMAP
AES TIETE	LIMOEIRO	016	149	154	SMAP
FURNAS	MARIMBONDO	017	2329	2317	SMAP
AES TIETE	AGUA VERMELHA	018	2702	2638	SMAP
FURNAS	BATALHA	022	069	068	SMAP
SEFAC	SERRA FAÇAO	251	109	111	SMAP
CEMIG	EMBORCACAO	024	317	318	SMAP
CEMIG	NOVA PONTE	025	289	285	SMAP
ENGIE	MIRANDA	206	292	296	SMAP
CEMIG	CAPIM BRANCO 1	207	292	296	SMAP
CEMIG	CAPIM BRANCO 2	028	292	297	SMAP
CORUMBA	CORUMBA IV	205	137	133	SMAP
CORUMBA_III	CORUMBA III	023	179	174	SMAP
FURNAS	CORUMBA I	209	541	529	SMAP
FURNAS	ITUMBIARA	031	1394	1365	SMAP
ENDESA	CACH DOURADA	032	1484	1453	SMAP
São Simão Energia	SÃO SIMÃO	033	2729	2645	SMAP
Rio Paraná	ILHA SOLTEIRA	034	6579	6365	SMAP
Rio Paranapanema	JURUMIRIM	047	245	260	SMAP
CBA	PIRAJU	048	245	262	SMAP
Rio Paranapanema	CHAVANTES	049	348	367	SMAP
Rio Paranapanema	LUCAS GARCEZ	050	488	504	SMAP
Rio Paranapanema	CANDAS 2	051	498	513	SMAP
Rio Paranapanema	CANDAS 1	052	520	534	SMAP
COPEL	MAUA	057	273	262	SMAP
Rio Paranapanema	CAPIVARA	061	1144	1151	SMAP
Rio Paranapanema	TAQUARUCU	062	1211	1209	SMAP
Rio Paranapanema	ROSANA	063	1361	1363	SMAP
COPEL	STA CLARA PR	071	069	068	SMAP
ELEJOR	FUNDÃO	072	072	071	SMAP
COPEL	JORDÃO NAT.	073	084	084	SMAP
COPEL	FOZ DO AREIA	074	436	458	SMAP
COPEL	SEGREDO NAT.	076	495	508	SMAP
ENGIE	SLT SANTIAGO	077	611	615	SMAP
ENGIE	SALTO OSORIO	078	631	625	SMAP
NEOENERGIA	BAIXO IGUAÇU	081	759	733	SMAP
ENGIE	ITA	092	439	439	SMAP
ENGIE	PASSO FUNDO	093	024	020	SMAP
FOZ CHAPECO	FOZ CHAPECO	094	541	523	SMAP
CERAN	MONTE CLARO	097	103	119	SMAP
CERAN	CASTRO ALVES	098	085	093	SMAP
ESFORA_ENERGETICA	ESFORA	099	066	065	SMAP
CESAP	SALTO PILAO	101	114	119	SMAP
IJUI	SÃO JOSÉ	102	052	105	SMAP
ELETROSUL	PASSO SÃO JOÃO	103	046	090	SMAP
CEEE	ERNESTINA	110	045	024	SMAP
CEEE	PASSO REAL	111	090	103	SMAP
CEEE	JACUI	112	087	104	SMAP
CEEE	ITAUBA	113	103	131	SMAP
CEEE	D.FRANCISCA	114	134	164	SMAP
COPEL	CAP.CACH.	115	019	019	SMAP
EMAE	PEDRAS	116	005	005	Regredido / Calculado
EMAE	GUARAPIRANGA	117	017	015	SMAP
EMAE	BILLINGS	118	021	019	SMAP
EMAE	BILLINGS + PEDRAS	119	026	023	SMAP
CESP	JAGUARI	120	034	033	SMAP
CESP	PARAIBUNA	121	053	052	SMAP
LIGHT	SANTA BRANCA	122	060	060	SMAP
FURNAS	FUNIL	123	217	222	SMAP
LIGHT	STA. CECILIA	125	328	317	SMAP
FURNAS	ANTA NAT.	129	580	583	SMAP
LIGHT	ILHA POMBO NAT.	130	644	641	SMAP
CEMIG	SALTO GRANDE	134	079	078	SMAP
ELETRA	BARRA BRAUNA	135	112	108	SMAP
BAGUARI	BAGUARI	141	382	389	SMAP

EMPRESA	USINA	CÓDIGO	30/03	31/03	Modelo
ENERGEST	MASCARENHAS	144	563	573	SMAP
ELETROGOES	RONDON II	145	130	122	SMAP
CEMIG	AIMORÉS	148	443	453	SMAP
CANDONGA	CANDONGA	149	102	102	SMAP
ELETROSUL	SÃO DOMINGOS	154	130	137	SMAP
RBE	RETIRO BAIXO	155	108	107	SMAP
CEMIG	TRES MARIAS	156	439	433	SMAP
CEMIG	QUEIMADO	158	034	033	SMAP
EMAE	PONTE NOVA	160	010	009	SMAP
EMAE	E. DE SOUZA	161	142	127	SMAP
EMAE	E. DE SOUZA - TRIBUT	164	104	093	Regredido / Calculado
CHESF	INCR. 3M/SBD	168	1052	1032	MPV
CHESF	SOBRADINHO	169	1834	1795	MPV / SMAP
CHESF	ITAPARICA	172	2032	1964	MPV
CHESF	MOXOTO	173	2032	1964	MPV
CHESF	PAULO AFONSO	175	2032	1964	MPV / Regredido ou Calculado
CHESF	COMPLEXO	176	2032	1964	MPV / Regredido ou Calculado
CHESF	XINGO	178	2093	2032	MPV
CEMIG	A. DIAS + SA CARVALHO	183	051	051	SMAP
IGE	ITAPEBI	188	082	081	SMAP
CHESF	B. ESPERANCA	190	599	549	SMAP
ENGIE	CANA BRAVA	191	1109	1112	SMAP
CEMIG	ROSAL	196	028	028	SMAP
PICADA	PICADA	197	044	044	SMAP
CEMIG	SOBRAGI	198	076	078	SMAP
LIGHT	TOCOS	201	026	026	SMAP
LIGHT	LAJES NAT.	202	012	012	SMAP
LIGHT	SANTANA	203	038	038	SMAP
ELETRONORTE	CACHOEIRA CALDEIRAO	204	1479	1420	SMAP
CEMIG	FUNIL-GRANDE	211	337	331	SMAP
BAESA	BARRA GRANDE	215	172	170	SMAP
EXPANSÃO	SÃO ROQUE	088	139	189	SMAP
GARIBALDI	GARIBALDI	089	161	181	SMAP
ENERCAN	CAMPOS NOVOS	216	177	199	SMAP
ENGIE	MACHADINHO	217	377	406	SMAP
MONEL	MONJOLINHO	220	036	036	SMAP
COPEL	SALTO CAXIAS	222	720	700	SMAP
SINOP	SINOP	227	1729	1740	SMAP
COPEL	COLIDER	228	1869	1894	SMAP
TELES PIRES	TELES PIRES	229	5367	5372	SMAP
ENERGEST	SÃO MANOEL	230	5388	5402	SMAP
AES TIETE	BARRA BONITA NAT.	237	442	546	SMAP
AES TIETE	BARIRI NAT.	238	543	575	SMAP
AES TIETE	IBITINGA NAT.	239	701	715	SMAP
AES TIETE	PROMISSAO NAT.	240	860	843	SMAP
CBA	SLT VERDINHO	241	172	170	SMAP
AES TIETE	N.AVANHANDAVA NAT.	242	869	909	SMAP
TJ03	TRES IRMAOS NAT.	243	815	835	SMAP
CESP	JUPIA NAT.	245	7874	7651	SMAP
CESP	P.PRIMAVERA NAT.	246	9863	9405	SMAP
GERDAU	CACU	247	164	160	SMAP
GERDAU	B. COQUEIROS	248	172	167	SMAP
CBA	OURINHOS	249	352	370	SMAP
BRASCAN_ENERG	ITUIQUIRA II	252	095	092	SMAP
ENGIE	SÃO SALVADOR	253	1283	1275	SMAP
VOTORANTIM	PEDRA DO CAVALO	254	031	027	SMAP
CEMIG	IRAPE	255	030	029	SMAP
ENERPEIXE	PEIXE ANGICAL	257	2712	2582	SMAP
BRASCAN_ENERG	ITUIQUIRA I	259	095	092	SMAP
FOZ_RIO_CLARO	FOZ DO RIO CLARO	261	187	183	SMAP
CEMIG	GUILMAN	262	050	050	SMAP
CEMIG	PORTO ESTRELA	263	078	078	SMAP
ITAIPI	ITAIPI NAT.	266	15230	14475	SMAP
AMAZONAS_ENERGIA	BALBINA	269	1233	1293	SMAP
FURNAS	SERRA DA MESA	270	952	938	SMAP
ENGIE	ESTREITO TOC	271	9377	9069	SMAP
INVESTCO	LAJEADO	273	4635	4313	SMAP
ELETRONORTE	TUCURUI	275	31452	31446	SMAP
ELETRONORTE	CURUA-UNA	277	559	594	SMAP
FURNAS	MANSO	278	252	229	SMAP
ELETRONORTE	SAMUEL	279	1458	1448	SMAP
ELETRONORTE	COARACY NUNES	280	1486	1429	SMAP
ENGIE	P.PEDRA	281	079	076	SMAP
CESC	SANTA CLARA - MG	283	028	028	SMAP

EMPRESA	USINA	CÓDIGO	30/03	31/03	Modelo
CERAN	14 DE JULHO	284	102	120	SMAP
ENERGIA GUST. DO BRASIL	JIRAU	285	34963	37634	SMAP
CEC	QUEBRA-QUEIXO	286	035	037	SMAP
SANTO_ANTONIO	SANTO ANTONIO	287	32365	36654	SMAP
ENERGEST	SANTO ANTONIO DO JARI	290	1993	2113	SMAP
APEDRA	DARDANELOS	291	764	750	SMAP
RVE	SALTO	294	159	153	SMAP
QGE	JAURU	295	091	087	SMAP
GRUPO_REDE	GUAPORÉ	296	044	042	SMAP
ELETRONORTE	FERREIRA GOMES	297	1500	1446	SMAP
NORTE ENERGIA	PIMENTAL	288	22215	23374	SMAP