



UNIVERSIDADE FEDERAL DO PARÁ  
CAMPUS UNIVERSITÁRIO DE TUCURUÍ  
FACULDADE DE ENGENHARIA ELÉTRICA

KEVIN MARTINS MEDEIROS

**MODELOS DE PREVISÃO DE VAZÃO AFLUENTE DA  
UHE-TUCURUÍ: UMA ABORDAGEM COM REDES NEURASIS LSTM  
E CNN**

TUCURUÍ/PA  
2023

KEVIN MARTINS MEDEIROS

**MODELOS DE PREVISÃO DE VAZÃO AFLUENTE DA  
UHE-TUCURUÍ: UMA ABORDAGEM COM REDES NEURAIS LSTM  
E CNN**

Trabalho de Conclusão de Curso, apresentado como requisito parcial para a obtenção de grau de Bacharel em Engenharia Elétrica, do Campus Universitário de Tucuruí pela Universidade Federal do Pará.

Orientador: Prof. Dr. Raphael Barros Teixeira

TUCURUÍ/PA  
2023

KEVIN MARTINS MEDEIROS

**MODELOS DE PREVISÃO DE VAZÃO AFLUENTE DA  
UHE-TUCURUÍ: UMA ABORDAGEM COM REDES NEURAS LSTM  
E CNN**

Trabalho de Conclusão de Curso, apresentado como requisito parcial para a obtenção de grau de Bacharel em Engenharia Elétrica, do Campus Universitário de Tucuruí pela Universidade Federal do Pará.

DATA DE APROVAÇÃO: 06/12/2023

CONCEITO: EXCELENTE

---

Prof. Dr. Raphael Barros Teixeira  
Orientador - FEE/CAMTUC/UFPA

---

Prof. Dr. Cleison Daniel Silva  
Membro - FEE/CAMTUC/UFPA

---

Prof. Eng<sup>o</sup>. Wanderley Pereira dos Santos  
Membro - IFPA/Campus Tucuruí

TUCURUÍ/PA  
2023

Dedico aos meus pais, Daniane e Manoel, e a toda a minha família, os pilares do meu sucesso e a razão do meu sorriso.

## AGRADECIMENTOS

Começo meus agradecimentos com um coração transbordante de gratidão. Em primeiro lugar, agradeço a Deus, que me presenteou com a dádiva da vida e me guiou ao longo dessa jornada, principalmente em tempos desafiadores como a pandemia. Acredito que sem sua presença, nada do que alcancei seria possível. Sou profundamente grato por fazer parte de uma família incrível, que tem sido meu porto seguro.

Meus pais, Manoel Medeiros e Daniane Martins, merecem um lugar especial em meus agradecimentos. Eles foram as pessoas que mais amei em minha vida e os pilares que me proporcionaram educação, o maior tesouro que alguém pode oferecer. Meu pai, que infelizmente nos deixou em 2016, sempre lutou para garantir a melhor educação para mim. Suas histórias e ensinamentos estão gravados em meu coração. Minha mãe, uma mulher guerreira, assumiu o papel de pai e mãe após a partida do meu pai, abdicando de muitas coisas em sua vida para que meu irmão e eu pudéssemos seguir nossos objetivos e frequentar a faculdade em Tucuruí, mesmo a gente sendo de Cametá. Grande parte do que sou hoje é resultado de suas lutas diárias.

Meu irmão Rodrigo merece um agradecimento especial por ter sido meu companheiro de jornada. Suas palavras de encorajamento, apoio constante e trocas de aprendizado enriqueceram significativamente minha experiência acadêmica. Ele esteve ao meu lado nos desafios e conquistas, e sua presença foi fundamental para o meu crescimento. E ao Raylando, seu suporte e ajuda à nossa família nos últimos anos foram inestimáveis. Minha gratidão se estende a toda a minha família e aos meus avós, em especial ao meu avô Manoel, que nos deixou na primeira semana em que comecei a desenvolver este TCC. Dedicar uma parte deste trabalho a ele é uma homenagem de gratidão.

Aos meus estimados professores, desejo expressar minha mais profunda gratidão. Cada um de vocês desempenharam um papel fundamental em minha jornada acadêmica, e é impossível subestimar a influência que tiveram em minha formação. Quero destacar, em particular, o professor Raphael Teixeira, meu orientador, que merece um reconhecimento especial por sua dedicação incansável e orientação constante. Mesmo com uma extensa lista de orientandos, ele aceitou o desafio de guiar-me nessa jornada. Seus conselhos e apoio foram cruciais para o sucesso deste trabalho.

Além disso, gostaria de ressaltar os demais professores com quem tive a honra de aprender ao longo dos anos: Jéferson, André, Andrecia, Washington, Ewerton, Cleison, Bayma, Luis Paulo e todos os outros que contribuíram para a minha formação como engenheiro eletricitista. Suas aulas inspiradoras e as valiosas trocas de conhecimento moldaram o profissional que me tornei, e por isso, sou eternamente grato.

Aos amigos que fiz durante a graduação, meu sincero agradecimento. Cada um de vocês deixou uma marca indelével em minha jornada. Em especial, quero agradecer às pessoas com as quais tive a oportunidade de colaborar em trabalhos em equipe. Alessandro Araújo, Daniel Aviz, Luis Eduardo, Gilzi Rodrigues, Jaciane Bastos, Camila Negrão, Matheus Gama, Cascio Batista, André Aranha, Edson Davi e Dario Panagio, nossa parceria tornou o aprendizado mais valioso e enriquecedor.

O Movimento Empresa Júnior foi uma parte essencial da minha formação acadêmica. Minha paixão por seu propósito me inspirou e me abriu portas para oportunidades

e desafios incríveis. Minha EJ, a Esquadro, desempenhou um papel fundamental nessa jornada. Uma vez esquadrito, sempre esquadrito. A experiência na Esquadro me conectou a pessoas extraordinárias e me proporcionou lições valiosas sobre liderança, trabalho em equipe e responsabilidade. Minha participação na Federação Paraense das Empresas Juniores do Pará, a Pororoca, foi um capítulo memorável e repleto de aprendizado. Foi um período incrível em que conheci pessoas incríveis e líderes que me inspiraram muito e contribuíram para meu desenvolvimento. Afinal açaí com granola e banana “NÃO” “NÓS TOMAMOS AÇAÍ COM METAS”

Por fim, expresso minha sincera gratidão à Suzano e a toda a equipe com a qual trabalhei durante meu estágio em Belém. Minha experiência lá foi transformadora, e aprendi muito mais do que aspectos técnicos. Conectei-me com histórias inspiradoras de jovens profissionais que moldaram meu crescimento. Agradeço especialmente a Izaias, Karol, Kleyton, Francisco, Robson, Aldemir, Cláudio, Santiago, Ademir Pereira, Koji, Darci, Marcelle e a toda a equipe operacional.

*“O Senhor é o meu pastor, nada me faltará.”  
(Salmo 23)*

## RESUMO

Este trabalho apresenta um estudo abrangente sobre a previsão de vazão afluentes da Usina Hidrelétrica de Tucuruí, situada na bacia do Tocantins-Araguaia. A pesquisa abrange cinco cenários distintos, variando a arquitetura dos modelos de previsão, incorporando Redes Neurais Recorrentes de Longa Memória de Curto Prazo (LSTM) e Redes Neurais Convolucionais (CNN). A implementação, conduzida em Python com o auxílio de bibliotecas como Pandas e NumPy, faz uso de um conjunto de dados históricos de vazões afluentes fornecidos pelo Operador Nacional do Sistema Elétrico (ONS) das Usinas de Tucuruí, Estreito e Lajeado. Os resultados obtidos foram avaliados minuciosamente por meio de análises aprofundadas, métricas de regressão e representações gráficas, demonstrando a eficácia dessas abordagens na previsão da vazão afluente diária da UHE-Tucuruí em horizontes temporais que variam de 1 a 7 dias. Além das contribuições metodológicas, este estudo proporciona insights cruciais que têm o potencial de elevar a precisão da previsão hidrológica, um campo de extrema importância na gestão de recursos hídricos e energia.

**Palavras-chave:** Previsão de Vazão, Redes Neurais, LSTM, CNN, UHE-Tucuruí.

## ABSTRACT

This paper presents a comprehensive study on the prediction of influent flow at the Tucuruí Hydroelectric Power Plant, located in the Tocantins-Araguaia basin. The research encompasses five distinct scenarios, varying the architecture of prediction models by incorporating Long Short-Term Memory Recurrent Neural Networks (LSTM) and Convolutional Neural Networks (CNN). The implementation, conducted in Python with the assistance of libraries such as Pandas and NumPy, utilizes historical data of influent flows provided by the National Electric System Operator (ONS) from the Tucuruí, Estreito, and Lajeado power plants. The results obtained were meticulously evaluated through in-depth analyses, regression metrics, and graphical representations, unequivocally demonstrating the effectiveness of these approaches in predicting the daily influent flow at the UHE-Tucuruí over temporal horizons ranging from 1 to 7 days. In addition to its methodological contributions, this study provides crucial insights that have the potential to enhance the accuracy of hydrological forecasting, a field of utmost importance in the management of water resources and energy.

**Keywords:** Flow Prediction, Neural Networks, LSTM, CNN, UHE-Tucuruí.

## LISTA DE FIGURAS

Figura 1 – Localização das UHE da Bacia Hidrográfica Tocantins-Araguaia. . . . .	21
Figura 2 – Diagrama das usinas hidrelétricas da Bacia Hidrográfica Tocantins-Araguaia. . . . .	22
Figura 3 – Vazão afluente na UHE de Serra da Mesa. . . . .	23
Figura 4 – Vazão afluente na UHE de Cana Brava. . . . .	24
Figura 5 – Vazão afluente na UHE de São Salvador. . . . .	24
Figura 6 – Vazão afluente na UHE de Peixe Angical. . . . .	25
Figura 7 – Contribuição das Usinas na Vazão Total. . . . .	26
Figura 8 – Comportamento da Vazão Afluente na UHE Lajeado. . . . .	27
Figura 9 – Comportamento da Vazão Afluente na UHE Estreito. . . . .	29
Figura 10 – Comportamento da Vazão Afluente na UHE Tucuruí. . . . .	30
Figura 11 – Vazão afluente das UHE's em 3D. . . . .	31
Figura 12 – Neurônio Artificial. . . . .	34
Figura 13 – Organização em camadas de uma Rede Neural. . . . .	35
Figura 14 – Estrutura de uma LSTM. . . . .	37
Figura 15 – Exemplo de uma arquitetura CNN. . . . .	40
Figura 16 – Deslizamento do Kernel na CNN 1D sobre uma Série Temporal. . . . .	41
Figura 17 – Exemplo de operação convolucional 1D. . . . .	41
Figura 18 – Deslizamento do Kernel na CNN 2D sobre uma Imagem Bidimensional. . . . .	42
Figura 19 – Representação de uma Estrutura da Unidade de Memória CNN-LSTM. . . . .	45
Figura 20 – Dados de identificação e validação . . . . .	61
Figura 21 – Gráficos de perda do Modelo LSTM. . . . .	66
Figura 22 – Gráficos de perda do Modelo CNN1D. . . . .	67
Figura 23 – Gráficos de perda do Modelo CNN2D. . . . .	67
Figura 24 – Gráficos de perda do Modelo LSTM-CNN1D. . . . .	68
Figura 25 – Gráficos de perda do Modelo LSTM-CNN2D. . . . .	68
Figura 26 – LSTM - Comparação entre Valores Reais e Previsões. . . . .	71
Figura 27 – CNN1D - Comparação entre Valores Reais e Previsões. . . . .	72
Figura 28 – CNN2D - Comparação entre Valores Reais e Previsões. . . . .	73
Figura 29 – LSTM-CNN1D - Comparação entre Valores Reais e Previsões. . . . .	74
Figura 30 – LSTM-CNN2D - Comparação entre Valores Reais e Previsões. . . . .	75
Figura 31 – MAE ao longo de 7 dias . . . . .	77
Figura 32 – MSE ao longo de 7 dias . . . . .	78
Figura 33 – $R^2$ ao longo de 7 dias . . . . .	79

## LISTA DE TABELAS

Tabela 1 – Usinas Hidrelétricas na Bacia do Rio Tocantins, Potências Instaladas e Ano de Fundação . . . . .	21
Tabela 2 – Dados da vazão média e porcentagem de contribuição das UHE's durante o período . . . . .	25
Tabela 3 – Resumo do Modelo LSTM . . . . .	51
Tabela 4 – Resumo do Modelo CNN1D . . . . .	53
Tabela 5 – Resumo do Modelo CNN2D . . . . .	54
Tabela 6 – Resumo do Modelo LSTM-CNN1D . . . . .	56
Tabela 7 – Resumo do Modelo LSTM-CNN2D . . . . .	58
Tabela 8 – Resumo do Tempo de Treinamento . . . . .	63
Tabela 9 – MAE ao longo de 7 dias . . . . .	78
Tabela 10 – MSE ao longo de 7 dias . . . . .	79
Tabela 11 – $R^2$ ao longo de 7 dias . . . . .	80

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
<b>1.1</b>	<b>Justificativa</b>	<b>14</b>
<b>1.2</b>	<b>Metodologia</b>	<b>15</b>
<b>1.3</b>	<b>Objetivos</b>	<b>16</b>
1.3.1	Objetivo geral	16
1.3.2	Objetivos específicos	16
<b>1.4</b>	<b>Estrutura do trabalho</b>	<b>17</b>
<b>2</b>	<b>BACIA HIDROGRÁFICA TOCANTINS-ARAGUAIA E USINAS HIDRELÉTRICAS</b>	<b>19</b>
<b>2.1</b>	<b>Características da Bacia Hidrográfica Tocantins-Araguaia</b>	<b>19</b>
2.1.1	Rio Tocantins: Um Pilar da Bacia	19
2.1.2	O Rio Araguaia: Um Complemento Fundamental	20
<b>2.2</b>	<b>Usinas Hidrelétricas na Bacia do Rio Tocantins</b>	<b>20</b>
<b>2.3</b>	<b>Vazões Afuentes nas Usinas Hidrelétricas na Bacia do Rio Tocantins</b>	<b>22</b>
<b>2.4</b>	<b>Usina Hidrelétrica de Lajeado</b>	<b>27</b>
<b>2.5</b>	<b>Usina Hidrelétrica de Estreito</b>	<b>28</b>
<b>2.6</b>	<b>Usina Hidrelétrica de Tucuruí</b>	<b>29</b>
<b>2.7</b>	<b>Revisão da literatura</b>	<b>32</b>
<b>3</b>	<b>MODELOS DE APRENDIZADO DE MÁQUINA PARA PREVISÃO DE SÉRIES TEMPORAIS</b>	<b>33</b>
<b>3.1</b>	<b>Redes Neurais Artificiais - RNAs</b>	<b>33</b>
3.1.1	Redes Neurais Artificiais em Hidrologia	35
<b>3.2</b>	<b>Redes Neurais Recorrentes e sua Aplicação em Hidrologia</b>	<b>36</b>
3.2.1	Memórias de Longo e Curto Prazo - LSTM	37
<b>3.3</b>	<b>Redes Neurais Convolucionais - CNNs</b>	<b>39</b>
3.3.1	Arquitetura e Funcionamento das CNNs	39
3.3.2	Tipos de Redes Neurais Convolucionais	40
3.3.2.1	CNN Unidimensional (CNN1D)	40
3.3.2.2	CNN Bidimensional (CNN2D)	41
3.3.2.3	CNN Tridimensional (CNN3D)	43
3.3.3	Velocidade de Processamento: Comparação entre CNNs e LSTMs	43
<b>3.4</b>	<b>Combinação de Redes Neurais Recorrentes (RNNs) e Redes Neurais Convolucionais (CNNs)</b>	<b>43</b>
3.4.1	Estrutura e Funcionamento da CNN-LSTM	44
3.4.2	Vantagens sobre Abordagens Tradicionais	45
<b>4</b>	<b>DESENVOLVIMENTO COMPUTACIONAL DOS MODELOS DE PREVISÃO DE VAZÃO AFLUENTE</b>	<b>46</b>
<b>4.1</b>	<b>Ambiente Computacional e Bibliotecas Utilizadas</b>	<b>46</b>
4.1.1	Bibliotecas Importadas	46
4.1.2	Justificativas para a Escolha das Bibliotecas	47
4.1.3	Configurações Adicionais	47
<b>4.2</b>	<b>Carregamento dos Dados</b>	<b>47</b>

4.2.1	Procedimento de Carregamento . . . . .	48
4.2.2	Seleção de Dados Relevantes . . . . .	48
<b>4.3</b>	<b>Função Split_Sequences . . . . .</b>	<b>48</b>
4.3.1	Explicação dessa Função . . . . .	49
<b>4.4</b>	<b>Normalização dos Dados . . . . .</b>	<b>49</b>
<b>4.5</b>	<b>Estruturação dos Modelos . . . . .</b>	<b>50</b>
4.5.1	Modelo 1: LSTM . . . . .	51
4.5.2	Modelo 2: CNN1D . . . . .	52
4.5.3	Modelo 3: CNN2D . . . . .	54
4.5.4	Modelo 4: LSTM-CNN1D . . . . .	55
4.5.5	Modelo 5: LSTM-CNN2D . . . . .	57
4.5.5.1	Função mse_ponderado . . . . .	59
<b>4.6</b>	<b>Estruturação e Organização dos Dados para Treinamento . . . . .</b>	<b>60</b>
4.6.1	Divisão dos Dados . . . . .	60
4.6.2	Gráficos de identificação e validação . . . . .	60
4.6.3	Geração do Conjunto de Dados . . . . .	61
4.6.4	Organização dos Dados para Treinamento . . . . .	62
<b>4.7</b>	<b>Treinamento dos Modelos . . . . .</b>	<b>62</b>
4.7.1	Diferenças entre os Treinamentos . . . . .	63
4.7.2	Tempo de Treinamento . . . . .	63
<b>4.8</b>	<b>Gráficos de Perda durante o Treinamento . . . . .</b>	<b>64</b>
<b>4.9</b>	<b>Validação dos Modelos . . . . .</b>	<b>69</b>
4.9.1	Preparação dos Dados de Validação . . . . .	69
4.9.2	Criação do Conjunto de Validação . . . . .	69
<b>4.10</b>	<b>Previsões . . . . .</b>	<b>70</b>
<b>4.11</b>	<b>Resultados . . . . .</b>	<b>76</b>
4.11.1	Gráficos e Tabelas dos Resultados . . . . .	77
<b>4.12</b>	<b>Análise dos Resultados . . . . .</b>	<b>80</b>
<b>5</b>	<b>CONCLUSÃO . . . . .</b>	<b>83</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>85</b>

## 1 INTRODUÇÃO

As vazões afluentes, também conhecidas como vazões de entrada, representam o fluxo de água que chega a uma área específica de uma bacia hidrográfica em um determinado período, geralmente expresso em termos de volume de água por unidade de tempo. A previsão dessas vazões desempenha um papel fundamental no planejamento e na gestão dos recursos hídricos, especialmente nas usinas hidrelétricas, onde a disponibilidade de água é essencial para a geração de energia elétrica (SALCEDO-SANZ; HERMS; PASTOR-SÁNCHEZ, 2018).

A previsão de vazão afluente é uma técnica crucial na hidrologia, visando estimar a quantidade de água que fluirá em um ponto específico de uma bacia hidrográfica em um período futuro. Essa estimativa é de extrema relevância para o planejamento e a operação de usinas hidrelétricas, permitindo antecipar as condições hidrológicas futuras e otimizar a geração de energia elétrica, além da gestão dos recursos hídricos (HERRERA; JÓDAR; GIRÁLDEZ, 2010). Essa capacidade de prever com precisão as vazões futuras é crucial para garantir a eficiência, a segurança e a sustentabilidade do sistema energético.

Nos últimos anos, avanços nas técnicas de aprendizado de máquina têm oferecido novas abordagens para a previsão de séries temporais, incluindo vazões de rios. Entre essas técnicas, destacam-se as Redes Neurais Artificiais (RNAs), que se destacam por sua habilidade em modelar relações complexas e não lineares em dados hidrológicos (SALCEDO-SANZ; HERMS; PASTOR-SÁNCHEZ, 2018). Inspiradas no sistema nervoso central de organismos superiores, essas redes têm a capacidade de identificar regularidades e padrões nos dados por meio de treinamento e realizar generalizações com base no conhecimento adquirido (HAYKIN, 2001).

No âmbito das RNAs, duas arquiteturas têm sido amplamente exploradas para a previsão de séries temporais: as *Long Short-Term Memory* (LSTM), ou Redes Neurais Recorrentes de Longa Memória de Curto Prazo, e as *Convolutional Neural Networks* (CNN), ou Redes Neurais Convolucionais. As redes LSTM são capazes de lidar com dependências temporais de longo prazo, capturando informações passadas relevantes para a previsão futura (YANG et al., 2017). Por sua vez, as redes CNN são eficientes na extração de características espaciais e temporais das séries temporais, o que as torna adequadas para a análise de padrões complexos (YAO et al., 2018).

Em um contexto específico, as usinas hidrelétricas situadas na bacia do Tocantins-Araguaia, como das Usinas de Tucuruí, Estreito e Lajeado, dependem diretamente do regime de vazão dos rios para a produção de energia elétrica. Assim, torna-se crucial a capacidade de prever com precisão as vazões futuras (PAPACHARALAMPOUS; MAKROPOULOS; DIAKAKIS, 2019). Os dados de recursos hídricos são coletados periodicamente, registrando sequências temporais em pontos igualmente espaçados ao longo do tempo, e os modelos de Redes Neurais Recorrentes (RNN) são frequentemente aplicados a esses dados (KWON et al., 2023).

Diversos estudos têm explorado o uso de RNAs, para a previsão de vazões em usinas hidrelétricas. (BELOTTI, 2019) realizou um estudo sobre a previsão de vazões afluentes utilizando redes neurais artificiais e *ensembles*. Eles demonstraram a eficácia dessas técnicas na melhoria das previsões hidrológicas. Outros estudos, como o de (GÓMEZ-

GONZÁLEZ et al., 2020) e (BRUNNER; ZOISS; SCHAEFLI, 2017), também exploraram o uso de redes LSTM para a simulação de vazão em rios.

Destaca-se também o estudo conduzido por (SANTOS, 2022), que aplicou LSTMs na previsão diária de vazão na Usina Hidrelétrica de Tucuruí, utilizando dados históricos de Tucuruí e Estreito. Este trabalho serviu como ponto de partida para nossa pesquisa, que representa um avanço significativo. Nesta continuidade, em nosso estudo ampliou-se a base de dados de 01 de janeiro de 1999 até 01 junho de 2023 e incluíram-se novas usinas na análise, considerando aquelas com contribuição mínima de 10% na vazão total e dados atualizados, proporcionando uma visão mais abrangente da bacia do Tocantins-Araguaia.

A pesquisa também inovou ao explorar novos modelos, incorporando arquiteturas convolucionais unidimensionais e bidimensionais. Essa abordagem híbrida, que combina Redes Neurais Recorrentes e Redes Neurais Convolucionais, resultou em modelos mais flexíveis para lidar com as complexas relações espaciais e temporais presentes nos dados de vazão dos reservatórios. A inclusão de uma revisão teórica das CNNs, o aprimoramento de hiperparâmetros e a aplicação de uma nova função de perda ponderada também contribuíram para melhorias substanciais nos modelos.

Outro aspecto importante é a utilização de técnicas de pré-processamento e seleção de variáveis para otimizar a entrada dos dados no modelo de previsão. Isso contribuirá para melhorar a precisão e a confiabilidade das previsões, ao considerar apenas as variáveis mais relevantes para o problema em questão.

O estudo também introduziu novas métricas de avaliação durante o período, proporcionando uma análise detalhada da precisão das previsões em relação aos dados reais de vazão dos reservatórios. Em síntese, esta pesquisa não apenas amplia e aprimora trabalhos anteriores, mas também traz contribuições inovadoras em metodologia, modelos e avaliação.

A expectativa é que este estudo contribua significativamente para o aprimoramento da previsão de vazões afluentes em usinas hidrelétricas na região, fornecendo informações cruciais para o planejamento da operação desses empreendimentos. A avaliação comparativa entre as redes LSTM e CNN, quando combinadas em um único modelo, permitirá a identificação e exploração das interações entre as camadas, entendendo como a informação extraída pela CNN é processada e utilizada pela LSTM, potencialmente resultando em previsões mais precisas. A combinação das camadas visa oferecer uma representação mais rica dos dados e uma melhor captura dos padrões relevantes.

## 1.1 Justificativa

A previsão de vazão afluente desempenha um papel crucial na gestão e operação de usinas hidrelétricas, fornecendo informações fundamentais para o planejamento da geração de energia e decisões relacionadas aos recursos hídricos. Com o avanço das técnicas de aprendizado de máquina, as Redes Neurais Artificiais têm se destacado como uma abordagem promissora para a previsão de séries temporais hidrológicas. Nesse contexto, as LSTM e as CNN têm demonstrado relevância para a tarefa de previsão de vazões em rios.

Este estudo se justifica pela necessidade de aprimorar as previsões de vazão afluente em usinas hidrelétricas na bacia do Tocantins-Araguaia. A pesquisa não se restringe à aplicação do modelo LSTM, mas estende-se a quatro outros modelos: CNN1D

(Redes Neurais Convolucionais unidimensionais), CNN2D (Redes Neurais Convolucionais bidimensionais), LSTM-CNN1D (uma combinação de LSTM e CNN1D), LSTM-CNN2D (uma fusão de LSTM e CNN2D). Essa abordagem multifacetada visa explorar a eficácia dessas arquiteturas de maneira isolada e, mais inovadoramente, em combinação híbrida, proporcionando ao modelo uma flexibilidade para lidar com as complexas relações espaciais e temporais nos dados de vazão dos reservatórios.

A análise se estende além do âmbito regional, ao abordar a região da bacia do Tocantins-Araguaia e focar na Usina Hidrelétrica de Tucuruí, este estudo contribuirá com informações específicas para a gestão sustentável dos recursos hídricos e a eficiência da geração de energia elétrica na região. A inovação deste estudo não se restringe apenas à aplicação e avaliação de modelos. A apresentação teórica das Redes Neurais Convolucionais, o aprimoramento de hiperparâmetros e a introdução de uma nova função de perda destacam a busca por melhorias substanciais na eficácia dos modelos. A aplicação de técnicas de pré-processamento e seleção de variáveis visa otimizar a entrada de dados nos modelos, contribuindo para uma previsão mais precisa e confiável.

Assim, este estudo visa não só avançar no entendimento da aplicação das RNAs, mas também aprimorar as estratégias de gestão de recursos hídricos e operação de usinas hidrelétricas, contribuindo para o desenvolvimento de práticas mais robustas e adaptáveis, essenciais em um contexto global de mudanças climáticas e demandas crescentes por energia sustentável.

## 1.2 Metodologia

A metodologia adotada neste estudo visa alcançar uma análise abrangente da previsão de vazão afluente, considerando as particularidades da bacia do Tocantins-Araguaia. O estudo é estruturado em cinco cenários distintos, cada um explorando diferentes arquiteturas de modelos de aprendizado de máquina. A abordagem multifacetada inclui a aplicação de modelos auto regressivos, destacando-se os seguintes cenários:

- **Modelo LSTM (Redes Neurais Recorrentes):** Este cenário consiste na implementação de um modelo baseado em Redes Neurais Recorrentes de Longa Memória de Curto Prazo (LSTM). Essa arquitetura é conhecida por sua capacidade de lidar com dependências temporais de longo prazo nos dados hidrológicos.
- **Modelo CNN1D (Redes Neurais Convolucionais Unidimensionais):** Exploramos um modelo baseado em Redes Neurais Convolucionais unidimensionais para capturar características temporais complexas nas séries temporais hidrológicas.
- **Modelo CNN2D (Redes Neurais Convolucionais Bidimensionais):** Este cenário envolve a aplicação de Redes Neurais Convolucionais bidimensionais, visando extrair padrões espaciais e temporais simultaneamente.
- **Modelo LSTM-CNN1D (Híbrido LSTM e CNN1D):** Integramos as vantagens dos modelos LSTM e CNN1D para criar uma arquitetura híbrida. Essa abordagem visa combinar a capacidade de capturar dependências temporais de longo prazo com a eficiência na extração de características temporais.
- **Modelo LSTM-CNN2D (Híbrido LSTM e CNN2D):** Exploramos uma abordagem similar ao cenário anterior, mas integrando as Redes Neurais Convolucionais bidimensionais. Isso possibilita uma análise mais profunda das relações espaciais e temporais nos dados de vazão.

A implementação dos modelos será realizada utilizando a linguagem Python, aproveitando bibliotecas essenciais como Pandas e NumPy. A escolha dessa linguagem e das bibliotecas mencionadas é respaldada pela ampla aceitação na comunidade de ciência de dados e aprendizado de máquina, além da facilidade de implementação de modelos complexos.

Para a implementação, utilizaremos dados históricos de vazão afluyente disponibilizados pelo Operador Nacional de Sistema Elétrico (ONS) das Usinas Tucuruí, Estreito e Lajeado. Sendo as entradas as duas últimas e a saída predita em Tucuruí. Esses dados em seguida são submetidos a processos de pré-processamento, incluindo normalização, tratamento de outliers e seleção criteriosa de variáveis relevantes.

Os modelos são treinados com base nos dados históricos das UHEs de Tucuruí, Estreito e Lajeado de um período de **01 de janeiro de 1999 a 01 de junho de 2023**, em seguida divididos em conjuntos de treinamento e validação para evitar overfitting. Após a implementação dos modelos, serão realizados testes e análises para avaliar seu desempenho na previsão de vazões afluentes.

Para avaliar o desempenho dos modelos em cada cenário, foram utilizadas métricas padrão, como Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE) e Coeficiente de Determinação ( $R^2$ ). Essas métricas oferecem uma visão abrangente do quão bem os modelos estão performando em termos de precisão.

Um aspecto importante desta metodologia é a avaliação temporal dos modelos durante o período de 1 a 7 dias. Essa análise detalhada permite uma compreensão mais profunda do comportamento dos modelos em curtos intervalos de tempo.

Ao final, será realizada uma análise comparativa entre os cenários, identificando quais arquiteturas de modelos apresentam o melhor desempenho em diferentes contextos. Essa comparação é essencial para fornecer insights valiosos para a escolha da melhor abordagem na tarefa de previsão de vazões em cenários similares.

## 1.3 Objetivos

### 1.3.1 Objetivo geral

O objetivo geral deste estudo é desenvolver e comparar modelos de previsão de vazão afluyente para a Usina Hidrelétrica de Tucuruí, situada na região da bacia do Tocantins-Araguaia. O foco principal recai na utilização de Redes Neurais Recorrentes de Longa Memória de Curto Prazo (LSTM) e Redes Neurais Convolucionais (CNN) em diferentes configurações. O propósito fundamental é aprimorar as previsões de vazão e fornecer informações robustas e confiáveis para o planejamento e operação desta importante infraestrutura.

### 1.3.2 Objetivos específicos

Para atingir o objetivo geral proposto, os objetivos específicos deste trabalho são:

- **Levantamento Bibliográfico:** Realizar um levantamento bibliográfico sobre técnicas de previsão de vazões afluentes em usinas hidrelétricas, com ênfase no uso de LSTMs

e CNNs na área hidrológica.

- **Análise de Dados:** Coletar e analisar dados hidrológicos das usinas Tucuruí, Estreito e Lajeado, para construir um conjunto de dados representativo para o treinamento e avaliação do modelo de previsão.
- **Desenvolvimento de Modelos:** Desenvolver modelos de previsão de vazões afluentes utilizando as redes LSTM e CNN, explorando a interação entre as camadas e a sinergia entre as capacidades de capturar dependências temporais de longo prazo e extrair características espaciais e temporais relevantes.
- **Experimentação e Avaliação:** Realizar experimentos e avaliar o desempenho do modelo proposto, comparando-o com o uso isolado das redes LSTM e CNN e elas ao serem combinadas.
- **Análise Temporal de Curto Prazo:** Realizar uma análise temporal específica, em previsões de 1 a 7 dias à frente. Essa análise detalhada contribuirá para uma compreensão mais refinada da eficácia de cada modelo em intervalos de tempo mais curtos.
- **Exploração de Arquiteturas Híbridas:** Investigar o desempenho de modelos híbridos, como LSTM-CNN1D e LSTM-CNN2D, visando compreender a complementaridade entre Redes Neurais Recorrentes e Convolucionais na previsão de vazão. Essa análise ajudará a identificar como essas arquiteturas trabalham em conjunto para melhorar a precisão das previsões.
- **Otimização de Dados:** Aplicar técnicas de pré-processamento e seleção de variáveis para otimizar a entrada dos dados no modelo de previsão, considerando apenas as variáveis mais relevantes para o problema em questão.
- **Contribuição para o Conhecimento:** Contribuir para o avanço do conhecimento na área de previsão de vazões em usinas hidrelétricas, fornecendo sugestões e diretrizes para aprimorar as estratégias de gestão e planejamento da operação desses empreendimentos na região.

Com a realização desses objetivos, espera-se que este trabalho contribua para o desenvolvimento de novos modelos para previsão de vazões afluentes em usinas hidrelétricas, fornecendo informações valiosas para o planejamento da operação desses empreendimentos e contribuindo para a sustentabilidade do sistema energético na região.

#### 1.4 Estrutura do trabalho

Este trabalho é organizado em cinco seções principais, cada uma contribuindo para a compreensão abrangente da previsão de vazão afluentes da UHE-Tucuruí, localizado na bacia do Tocantins-Araguaia.

- **Capítulo 1: Introdução**

É apresentada uma introdução abrangente, contextualizando o trabalho na área de previsão hidrológica. São fornecidas a justificativa para a pesquisa, a metodologia adotada, os objetivos gerais e específicos, delineando o escopo e a contribuição esperada deste estudo para o campo.

- **Capítulo 2: Revisão Bibliográfica**

É dedicado à revisão bibliográfica, fornecendo uma compreensão aprofundada das características distintivas da Bacia Hidrográfica Tocantins-Araguaia. Destaca-se uma análise detalhada das principais Usinas Hidrelétricas (UHEs) ao longo do Rio Tocantins, explorando dados históricos da vazão afluente diária. Essa seção visa

estabelecer uma base sólida para a compreensão da dinâmica hidrológica dessas usinas e seu impacto na previsão de vazões afluentes.

- **Capítulo 3: Conceitos Teóricos**

Apresenta conceitos teóricos relacionados aos modelos de aprendizado de máquina utilizados neste estudo para previsão de séries temporais hidrológicas. Destacam-se as motivações por trás da escolha de diferentes arquiteturas, desde Redes Neurais Recorrentes, especialmente os modelos LSTM, até modelos híbridos inovadores que combinam elementos de Redes Neurais Convolucionais e LSTMs. Cada modelo é discutido em detalhes, proporcionando uma compreensão abrangente das estratégias de aprendizado de máquina empregadas na previsão de vazões.

- **Capítulo 4: Resultados e Discussões**

Nele os códigos e resultados dos experimentos são apresentados e discutidos de forma detalhada. São verificados o desempenho e a eficácia de cada modelo na previsão de vazões afluentes, com uma análise específica voltada para diferentes horizontes temporais. Gráficos e métricas são utilizados para facilitar a interpretação e comparação dos resultados.

- **Capítulo 5: Conclusões e Sugestões**

Reúne as conclusões derivadas dos resultados e das discussões precedentes. Além disso, são apresentadas sugestões para trabalhos futuros, apontando direções promissoras para pesquisas subsequentes na área de previsão de vazões em usinas hidrelétricas.

## 2 BACIA HIDROGRÁFICA TOCANTINS-ARAGUAIA E USINAS HIDRELÉTRICAS

Neste capítulo, serão apresentados os conceitos fundamentais relacionados a uma Bacia Hidrográfica, com ênfase nas características distintivas da Bacia Hidrográfica Tocantins-Araguaia. O principal objetivo é fornecer uma análise detalhada das principais Usinas Hidrelétricas localizadas ao longo do Rio Tocantins. Além disso, será conduzida uma análise dos dados históricos da vazão afluyente diária de cada uma dessas UHEs, com especial destaque para os reservatórios que desempenham um papel significativo no contexto deste trabalho.

Esta investigação busca compreender a dinâmica hidrológica dessas usinas e como elas influenciam a previsão de vazões afluentes, contribuindo para uma compreensão mais abrangente das complexas interações entre os aspectos hidrológicos e as operações desses empreendimentos. Essa contextualização é essencial para embasar a análise das séries temporais de vazão e a implementação dos modelos de previsão, proporcionando uma base teórica sólida para o desenvolvimento computacional e a interpretação dos resultados.

### 2.1 Características da Bacia Hidrográfica Tocantins-Araguaia

A Bacia Hidrográfica Tocantins-Araguaia é uma das mais significativas do Brasil, destacando-se por sua vasta extensão, abrangendo aproximadamente 967.059 km<sup>2</sup>. Essa imensa área territorial estende-se principalmente pelos estados de Tocantins, Pará, Maranhão, Goiás e Mato Grosso, além do Distrito Federal (BRASIL, 2018). É relevante mencionar que a Bacia Tocantins-Araguaia é a maior bacia hidrográfica inteiramente situada em território brasileiro.

#### 2.1.1 Rio Tocantins: Um Pilar da Bacia

O Rio Tocantins, o principal curso d'água que cruza a Bacia Hidrográfica Tocantins-Araguaia, possui uma extensão de 2.416 km, configurando-se como o segundo maior rio totalmente brasileiro. Sua nascente se encontra no estado de Goiás, resultante da confluência dos rios das Almas e Maranhão. O Rio Tocantins percorre territórios dos estados do Tocantins e Maranhão até atingir sua foz na Baía do Marajó, situada no norte do Pará. Além disso, seu afluyente mais significativo é o Rio Araguaia, com o qual se une na região conhecida como Bico do Papagaio, no extremo norte do Tocantins (VIEIRA, 2018).

O Rio Tocantins possui um elevado potencial para geração de energia hidrelétrica, fato que levou à construção de diversas usinas hidrelétricas ao longo de seu curso, sendo a Usina Hidrelétrica de Tucuruí a mais emblemática. Além de sua importância energética, o Rio Tocantins desempenha um papel vital no abastecimento de água para a população local, bem como na atividade pesqueira, agricultura e economia regional, servindo também como importante via de navegação (BRASIL, 2018).

### 2.1.2 O Rio Araguaia: Um Complemento Fundamental

O Rio Araguaia, com uma extensão de 2.115 km, é outro rio relevante na Bacia Tocantins-Araguaia. Ele atravessa os estados de Mato Grosso, Goiás, Tocantins e Pará, nascendo na Serra dos Caiapós a uma altitude de 850 metros. Seu encontro com o Rio Tocantins ocorre próximo ao Bico do Papagaio. Vale ressaltar que o Rio Araguaia abriga a maior ilha fluvial do mundo, a Ilha do Bananal (ANA, 2020).

As águas do Rio Araguaia são essenciais para o abastecimento das comunidades ribeirinhas e de municípios circunvizinhos, além de serem um recurso vital para o desenvolvimento do turismo, sobretudo nas ilhas de areia. Sua grande importância ecológica é evidenciada pela diversidade de espécies de peixes e pela rica biodiversidade de flora e fauna que caracterizam as áreas banhadas por ele. Além disso, o Rio Araguaia atravessa dois dos maiores biomas brasileiros, o Cerrado e a Amazônia (RIBEIRO et al., 2021).

A Bacia do Tocantins-Araguaia, devido ao seu expressivo potencial energético, ao abastecimento de água à população e ao suporte aos ecossistemas, desempenha um papel central tanto na economia regional quanto na manutenção da biodiversidade. Sua preservação e uso sustentável são temas cruciais para o desenvolvimento da região (MMA, 2006).

## 2.2 Usinas Hidrelétricas na Bacia do Rio Tocantins

As UHEs localizadas na Bacia do Rio Tocantins desempenham um papel essencial na geração de energia elétrica no Brasil e têm um impacto significativo no desenvolvimento regional. Estes empreendimentos são fundamentais para a matriz energética brasileira, fornecendo eletricidade para diversas regiões do país.

Na Figura 1, observar-se a representação da Bacia do Rio Tocantins e suas principais UHEs, com destaque para as que serão abordadas neste trabalho, as quais desempenham um papel fundamental na infraestrutura de geração de energia elétrica do Brasil. Essas usinas são construídas em rios, aproveitando o potencial energético das águas para a conversão em eletricidade, empregando tecnologia limpa e renovável (SMITH, 2017).

Dentre as Usinas situadas na Bacia do Rio Tocantins, destacam-se algumas das maiores em termos de capacidade instalada, como Serra da Mesa, Cana Brava, São Salvador, Peixe Angical, Lajeado, Estreito e Tucuruí. Cada uma dessas usinas possui sua própria história de construção e contribui de forma significativa para a oferta de eletricidade no país (SILVA; SANTOS, 2020).

Historicamente, a construção das hidrelétricas na Bacia do Tocantins visou atender à crescente demanda por energia elétrica no Brasil. Elas desempenham um papel estratégico na estabilização do sistema elétrico, contribuindo para o fornecimento de eletricidade nas regiões Norte, Nordeste e outras partes do país (PEREIRA et al., 2018).

O funcionamento dessas UHEs é baseado na captação da água do rio por meio de barragens, formando reservatórios e liberando controladamente a água para acionar as turbinas, responsáveis por gerar eletricidade. Esse processo é crucial para garantir o fornecimento contínuo de energia elétrica para indústrias, residências e serviços públicos (PAULA et al., 2019).

Figura 1 – Localização das UHE da Bacia Hidrográfica Tocantins-Araguaia.



Fonte: Adaptado de (EARTH, 2020)

A capacidade de geração de energia das UHEs na Bacia do Rio Tocantins varia consideravelmente. A tabela 1 a seguir apresenta algumas dessas Usinas, juntamente com suas respectivas potências instaladas:

Tabela 1 – Usinas Hidrelétricas na Bacia do Rio Tocantins, Potências Instaladas e Ano de Fundação

Usina Hidrelétrica	Estado	Potência Instalada (MW)	Ano de Fundação
Serra da Mesa	Goiás	1.275	1994
Cana Brava	Goiás	465	2002
São Salvador	Goiás	243	2008
Peixe Angical	Tocantins	452	2006
Lajeado	Tocantins/Maranhão	902	2001
Estreito	Tocantins/Maranhão	1.087	2012
Tucuruí	Pará	8.365	1984

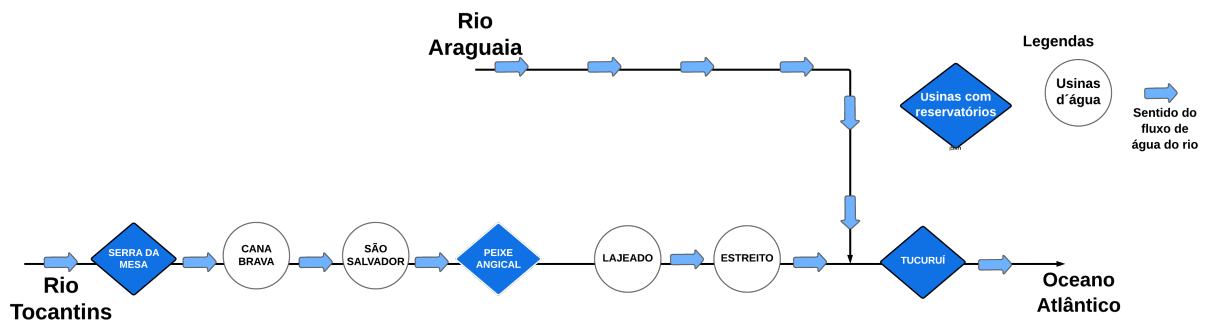
Fonte: Adaptado de (ANA, 2020).

A primeira usina a entrar em operação na cascata do Tocantins foi Tucuruí, em

1984. Em 1998, Serra da Mesa foi inaugurada. Em seguida, entraram em operação Lajeado (2001), Cana Brava (2002), Peixe Angical (2006), São Salvador (2009) e, finalmente, Estreito (2011). Essas usinas, com diferentes capacidades de geração, desempenham um papel crucial no fornecimento de energia elétrica para várias regiões do Brasil (ANA, 2020).

Figura 2 – Diagrama das usinas hidrelétricas da Bacia Hidrográfica Tocantins-Araguaia.

### **Diagrama esquemático de hidrelétricas da bacia hidrográfica do Rio Tocantins**



Fonte: Adaptado de (ANA, 2020).

Na Figura 2, é possível observar as usinas hidrelétricas da cascata do rio Tocantins. Dentre essas usinas, somente Serra da Mesa, Peixe Angical e Tucuruí possuem reservatórios com capacidade de regularização de vazões. Destaca-se a Serra da Mesa, que é o maior reservatório do Brasil em termos de volume de água, com 54,4 bilhões de m<sup>3</sup>. Além disso, Tucuruí possui a segunda maior capacidade instalada totalmente nacional, com 8.365 MW (ELETRICIDADE, 2015).

### **2.3 Vazões Afluentes nas Usinas Hidrelétricas na Bacia do Rio Tocantins**

A análise das vazões afluentes é de extrema importância para o funcionamento adequado das UHEs localizadas na Bacia do Rio Tocantins. Neste trabalho, serão apresentados aspectos fundamentais sobre as vazões afluentes a essas usinas, considerando sua relevância na geração de energia elétrica e na gestão dos recursos hídricos na região.

A previsão e análise das vazões afluentes são cruciais para o planejamento e a operação eficiente das UHEs na Bacia do Rio Tocantins. Segundo (SILVA et al., 2019), essas usinas dependem diretamente das vazões dos rios para a geração de energia elétrica. Uma análise adequada das vazões permite antecipar variações sazonais e eventuais eventos climáticos extremos que podem afetar a disponibilidade de água para geração.

Segundo (BALBINOT et al., 2008), a Bacia do Rio Tocantins é caracterizada por um regime de chuvas sazonal, com uma estação seca e outra chuvosa. A variabilidade climática, incluindo fenômenos como El Niño e La Niña, tem um impacto direto nas vazões afluentes das usinas hidrelétricas na Bacia do Rio Tocantins. Durante eventos de El Niño, observa-se uma tendência a condições mais secas na região, resultando em vazões afluentes mais baixas. Por outro lado, eventos de La Niña frequentemente levam a um aumento nas chuvas e, conseqüentemente, a vazões mais altas.

O monitoramento contínuo das vazões afluentes é realizado pela Agência Nacional de Águas (ANA) e outras entidades. De acordo com (SILVA *et al.*, 2019), a ANA coleta dados hidrometeorológicos, como níveis de água e pluviometria, para alimentar modelos de previsão de vazões, permitindo um planejamento mais preciso.

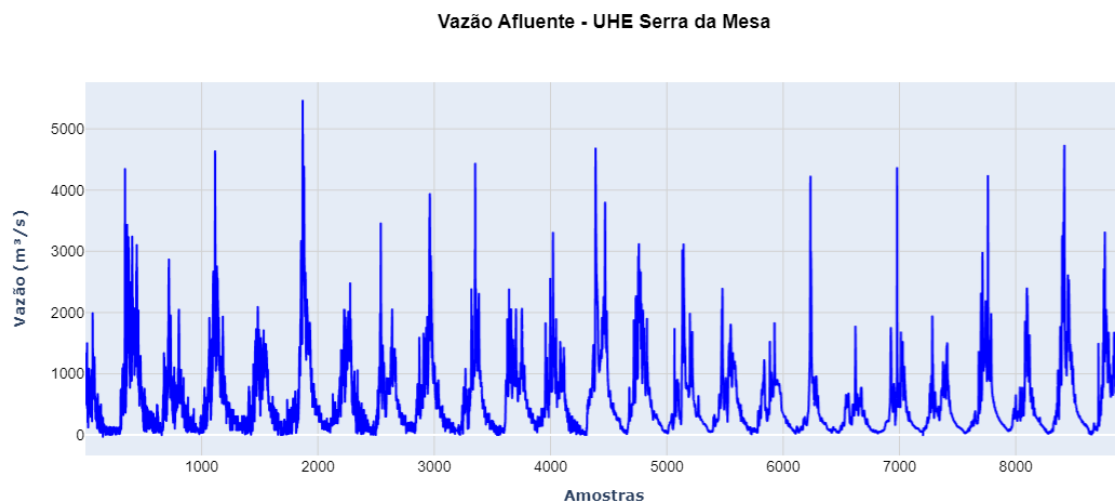
As usinas instaladas ao longo do Rio Tocantins realizam medições contínuas da vazão afluente, estabelecendo pontos de coleta de dados. O acesso a esses dados tem sido facilitado devido à disponibilidade do repositório do ONS (Operador Nacional do Sistema Elétrico), acessível por meio da ANA.

Conforme ilustrado na Figura 2, há um total de sete UHEs conectadas em cascata, com seis delas localizadas a montante de Tucuruí. Dessas, apenas Estreito e Lajeado foram consideradas para contribuir com seus dados no treinamento dos modelos, juntamente com os dados de Tucuruí.

Dessa forma, inicialmente, nas Figuras 3, 4, 5 e 6, apresentaremos o comportamento das vazões afluentes diárias de cada um dos reservatórios das UHEs que não foram considerados em nosso estudo. Isso abrangerá o período selecionado para o treinamento dos modelos neste trabalho, que compreende de 01/01/1999 a 01/06/2023, resultando em um total de 8.918 amostras de cada reservatório. Também será explicado o por que esses reservatórios não foram incluídos em nossa análise.

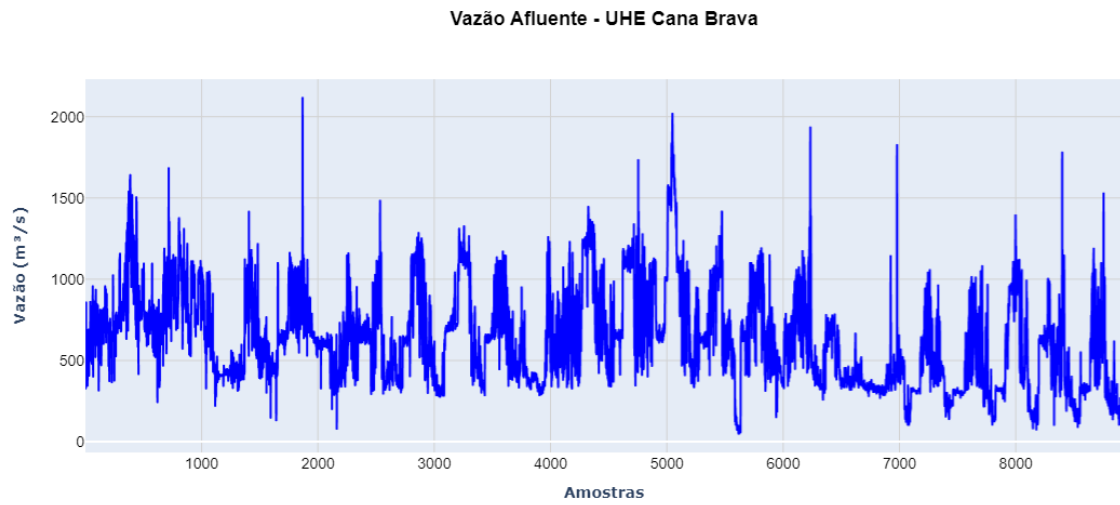
A seleção das UHEs que se mostraram mais relevantes para este estudo foi realizada mediante uma avaliação criteriosa de cada reservatório. Nesse processo, levamos em consideração diversos parâmetros, incluindo a magnitude das vazões, a integridade dos dados (considerando a presença consistente de amostras ao longo de todo o período de treinamento), bem como a minimização de ruídos nos registros. Essas UHEs selecionadas serão abordadas com mais detalhes nas próximas seções deste trabalho.

Figura 3 – Vazão afluente na UHE de Serra da Mesa.



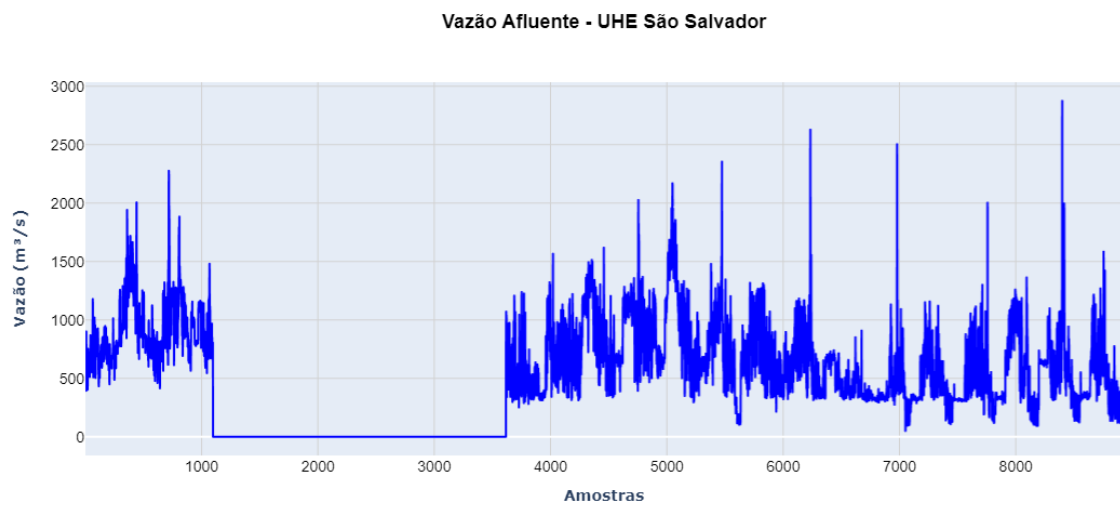
Fonte: Autoria própria.

Figura 4 – Vazão afluyente na UHE de Cana Brava.



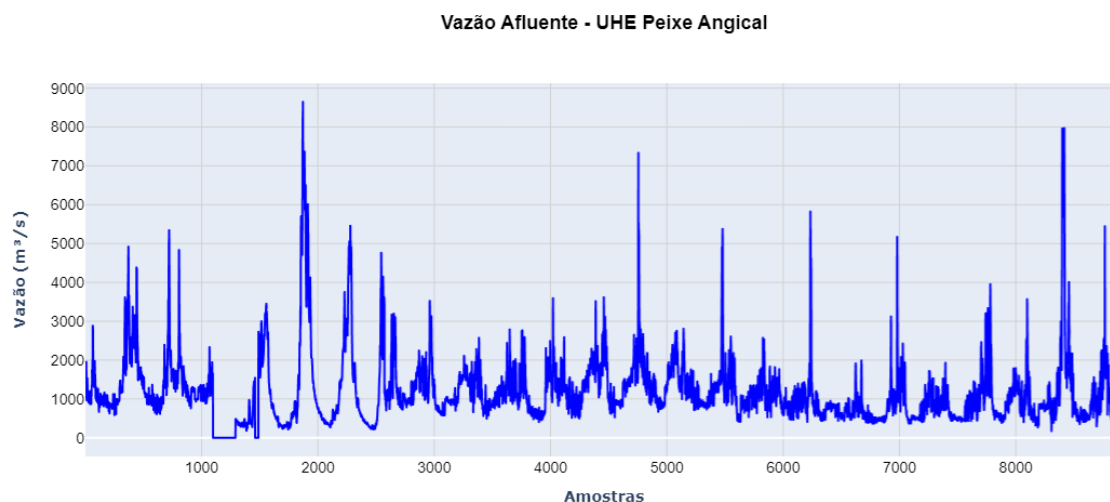
Fonte: Autoria própria.

Figura 5 – Vazão afluyente na UHE de São Salvador.



Fonte: Autoria própria.

Figura 6 – Vazão afluyente na UHE de Peixe Angical.



Fonte: Autoria própria.

Para selecionar as Usinas Hidrelétricas a serem consideradas neste estudo, implementamos um critério inicial com base na dimensão da vazão afluyente, utilizando a Tabela 2, que apresenta as vazões médias calculadas a partir dos conjuntos de dados de cada reservatório obtidos por meio da plataforma do Operador Nacional do Sistema Elétrico durante o período de interesse desta pesquisa. Posteriormente, na Figura 7 e Tabela 2, mostra a porcentagem de contribuição de cada UHE em relação à vazão total no período avaliado.

Para serem relevantes para nosso trabalho, usinas com uma contribuição superior a 10% da vazão total foram selecionadas, uma vez que desempenham um papel crucial na geração de eletricidade. Outras usinas com contribuições inferiores a esse valor não foram incluídas devido à disponibilidade limitada de dados e à necessidade de se concentrar nas mais relevantes para esta análise

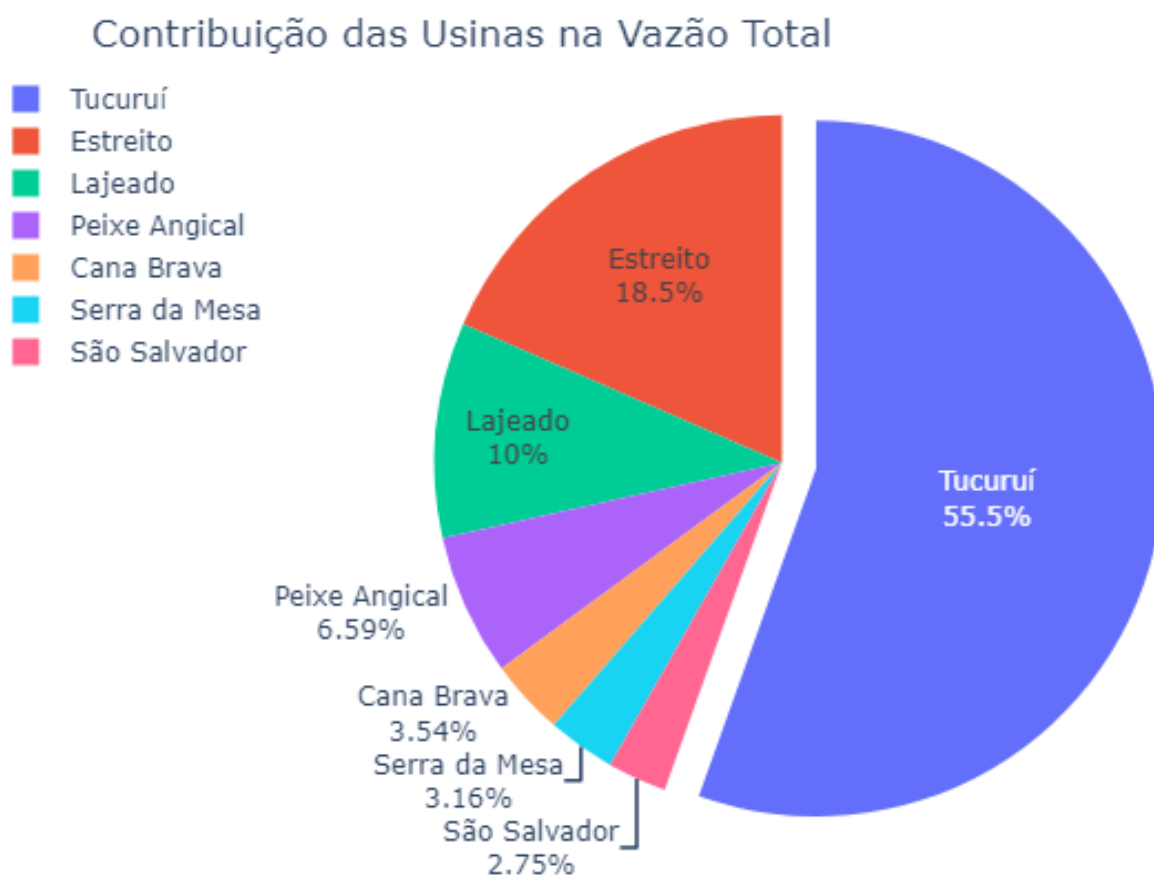
Tabela 2 – Dados da vazão média e porcentagem de contribuição das UHE's durante o período

Usina	Vazão Média (m <sup>3</sup> /s)	Porcentagem de Contribuição (%)
TUCURUÍ	10009.879682	55.480164
ESTREITO	3332.744562	18.471872
LAJEADO	1805.081857	10.004739
PEIXE ANGICAL	1189.838529	6.594728
SÃO SALVADOR	497.008410	2.754689
CANA BRAVA	638.374636	3.538217
SERRA DA MESA	569.339874	3.155589

Fonte: Autoria própria.

De acordo com esse critério, as UHEs que não atenderam a essa condição foram as seguintes: Serra da Mesa, com uma vazão média de 569,33 m<sup>3</sup>/s e contribuição de

Figura 7 – Contribuição das Usinas na Vazão Total.



Fonte: Autoria própria.

3,16%; Cana Brava, com 638,37 m<sup>3</sup>/s e 3,54% de contribuição; São Salvador, com 497 m<sup>3</sup>/s e 2,75% de contribuição; e Peixe Angical, com 1189,83 m<sup>3</sup>/s e 6,59% de contribuição. Todas essas vazões médias foram calculadas com base nas amostras disponíveis durante o intervalo determinado para este trabalho. Por outro lado, as UHEs que atenderam a esse critério de relevância foram: Lajeado, com 1805,08 m<sup>3</sup>/s; Estreito, com 3332,74 m<sup>3</sup>/s; e Tucuruí, com 10009,87 m<sup>3</sup>/s. Cada uma dessas UHEs contribuiu com pelo menos 10% da vazão total, conforme mostrado no gráfico da Figura 7.

Para compreender o comportamento de cada um desses reservatórios, apresentamos seus dados em um gráfico 3D, conforme ilustrado na Figura 11. Além disso, também consideramos outros critérios, como a disponibilidade completa de dados e a minimização de ruídos nos registros das vazões. No entanto, observamos falhas significativas nesses aspectos em UHEs como Cana Brava, São Salvador e Peixe Angical, conforme demonstrado nas Figuras 4, 5 e 6. Essas falhas poderiam potencialmente afetar a qualidade e a confiabilidade dos resultados deste estudo.

Outro fator relevante a ser considerado é a localização geográfica das UHEs. Algumas delas estão mais distantes de Tucuruí em comparação com Estreito e Lajeado, o que pode influenciar na dinâmica das vazões entre esses reservatórios. Essas variações na localização geográfica também foram levadas em conta na seleção para este estudo.

É importante destacar que as próprias UHEs podem influenciar nas vazões afluentes. Conforme a (ANEEL, 2021), a operação dessas usinas, com a abertura e fechamento das

comportas dos reservatórios, pode afetar as vazões rio abaixo. Essa dinâmica é considerada na gestão dos recursos hídricos, visando a minimizar impactos ambientais e sociais.

## 2.4 Usina Hidrelétrica de Lajeado


A Usina Hidrelétrica de Lajeado, situada na Bacia do Rio Tocantins, desempenha um papel de destaque na geração de energia elétrica no Brasil. Neste aspecto, exploraremos sua história, funcionamento e importância na matriz energética nacional.

A história da Hidrelétrica de Lajeado remonta ao final dos anos 1980, quando foi concebida como parte do ambicioso projeto de aproveitamento hidrelétrico do Rio Tocantins. A construção desta usina ocorreu durante a década de 1990, e ela finalmente iniciou suas operações comerciais em 2001. Esse empreendimento foi planejado com o objetivo de explorar o vasto potencial energético da região e contribuir substancialmente para o fornecimento de eletricidade em todo o território brasileiro ([ANEEL, 2021](#)).

Lajeado possui uma capacidade instalada de aproximadamente 902 megawatts (MW), o que a classifica como uma usina de médio porte em comparação com outras instalações na vasta Bacia do Rio Tocantins. Seu funcionamento é baseado em um reservatório que regula o fluxo do rio. A água do rio é direcionada por condutos forçados até as turbinas, onde a energia hidráulica é eficientemente transformada em eletricidade. O complexo compreende uma barragem, uma casa de força, um vertedouro e sistemas de transmissão de energia, consolidando sua capacidade de geração ([ELETRICIDADE, 2015](#)).

A Usina Hidrelétrica de Lajeado assume um papel de destaque no cenário nacional de geração de energia elétrica. Sua produção de eletricidade contribui significativamente para o suprimento energético em várias regiões do Brasil. Além disso, essa usina aproveita a energia hidrelétrica, uma fonte limpa e renovável, minimizando assim os impactos ambientais em comparação com outras modalidades de geração de eletricidade ([ANEEL, 2021](#)).

Figura 8 – Comportamento da Vazão Afluente na UHE Lajeado.



Fonte: Autoria própria.

Neste contexto, na Figura 8, apresenta-se o comportamento das vazões afluentes diárias registradas no reservatório da UHE Lajeado durante o período de treinamento dos modelos deste estudo, que compreende o intervalo de 01/01/1999 a 01/06/2023. Isso resultou em um total de 8.918 amostras do comportamento das vazões desse reservatório. Além disso, a vazão média de Lajeado foi calculada com base nas amostras disponíveis ao longo do período estabelecido para este trabalho, totalizando uma média de 1805,08 metros cúbicos por segundo ( $\text{m}^3/\text{s}$ ), representando 10% de contribuição total no período.

## 2.5 Usina Hidrelétrica de Estreito


A Usina Hidrelétrica de Estreito, localizada na Bacia do Rio Tocantins, representa uma das instalações de geração de energia elétrica mais significativas do Brasil. Nesta seção, exploraremos sua história, funcionamento e o impacto de sua produção no fornecimento de eletricidade para a região.

A construção da Hidrelétrica de Estreito teve início no início dos anos 2000, e sua operação comercial foi efetivada em 2012. Este empreendimento é o resultado de uma colaboração entre empresas nacionais e internacionais e representa um grande avanço no aproveitamento do potencial hidrelétrico da Bacia do Rio Tocantins (EPE, 2021).

Estreito possui uma capacidade instalada de aproximadamente 1.087 megawatts (MW), conferindo-lhe um papel de destaque na geração de energia elétrica na região. Seu funcionamento é baseado em um vasto reservatório que controla o fluxo do Rio Tocantins. A água do rio é direcionada para turbinas que convertem eficazmente a energia hidráulica em eletricidade. O complexo inclui estruturas fundamentais, tais como uma barragem, casa de força, vertedouro e sistemas de transmissão de energia (ELETRICIDADE, 2015).

A Usina de Estreito desempenha um papel crucial no fornecimento de energia elétrica para a região em que está situada, beneficiando estados como Maranhão, Tocantins e Pará. Além de suprir as necessidades energéticas desses estados, a usina também desempenha um papel significativo no desenvolvimento econômico e industrial da área, gerando empregos e promovendo o crescimento da infraestrutura local. Sua capacidade de geração de eletricidade é essencial para atender à crescente demanda energética da região.

Figura 9 – Comportamento da Vazão Afluente na UHE Estreito.



Fonte: Autoria própria.

Nesse aspecto, na Figura 9, apresentamos o comportamento das vazões afluentes diárias registradas no reservatório da UHE de Estreito durante o período de treinamento dos modelos neste estudo. Isso resultou em um total de 8.918 amostras que representam o comportamento das vazões desse reservatório. Adicionalmente, calculamos a vazão média dessa Usina com base nas amostras disponíveis ao longo do período estipulado para este trabalho, totalizando uma média de 3332.74 metros cúbicos por segundo ( $m^3/s$ ). Essa contribuição representa 18,5% do total de vazão da usina em relação à vazão total da Bacia.

## 2.6 Usina Hidrelétrica de Tucuruí

A Usina Hidrelétrica de Tucuruí, além de ser a peça central do nosso estudo, é uma das maiores e mais importantes usinas hidrelétricas do Brasil. Sua história e contribuição para o abastecimento de energia elétrica no país são de relevância inquestionável.

A construção da Hidrelétrica de Tucuruí teve início na década de 1970 e foi concluída na década seguinte, marcando um marco histórico no desenvolvimento da região amazônica e na matriz energética brasileira. O projeto foi concebido para aproveitar o vasto potencial hidrelétrico da região, contribuindo assim para a diversificação das fontes de energia (ELETRICIDADE, 2015).

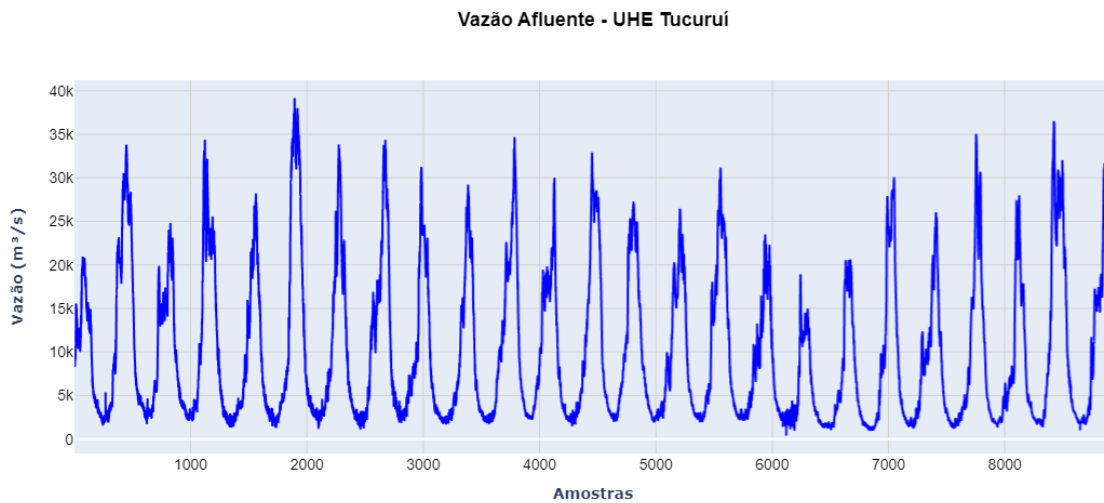
Tucuruí ostenta uma capacidade instalada significativa, com um total de aproximadamente 8.365 megawatts (MW). Sua operação baseia-se na formação de um grande reservatório, que regula o fluxo do Rio Tocantins, permitindo o controle das vazões afluentes. A água do rio é captada e direcionada para turbinas, onde a energia mecânica é transformada em eletricidade. O complexo inclui subestações e linhas de transmissão que possibilitam a distribuição da energia gerada para diversas regiões do país (JURÍDICO, 2020).

Além de sua importância na geração de energia elétrica, a Usina de Tucuruí

desempenha um papel fundamental no gerenciamento dos recursos hídricos da Bacia do Tocantins. Isso inclui a regulação das vazões e o controle de enchentes na região (SILVA; SANTOS, 2020).

A Usina Hidrelétrica de Tucuruí é uma das principais fornecedoras de energia elétrica para o Norte do Brasil, desempenhando um papel substancial no desenvolvimento econômico e industrial da região. Além disso, sua capacidade de geração desempenha um papel estratégico na segurança energética do país, garantindo o fornecimento de eletricidade mesmo em períodos de alta demanda (SILVA; SANTOS, 2020).

Figura 10 – Comportamento da Vazão Afluente na UHE Tucuruí.

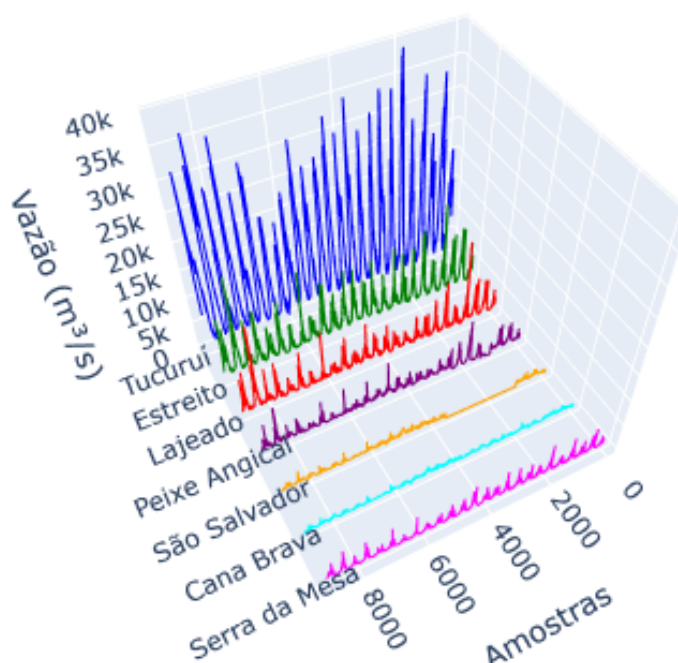


Fonte: Autoria própria.

Nesse sentido, na Figura 10, apresentamos o comportamento das vazões afluentes diárias registradas no reservatório da UHE Tucuruí durante o período de treinamento dos modelos deste estudo. Isso resultou em um conjunto de amostras que representam o comportamento das vazões desse reservatório. Além disso, calculamos a vazão média dessa Usina com base nas amostras disponíveis ao longo do período estipulado para este trabalho, totalizando uma média de 10.009,87 metros cúbicos por segundo ( $m^3/s$ ), representando 55,5% da contribuição total em relação à Bacia.

Figura 11 – Vazão afluyente das UHE's em 3D.

### Vazão Afluyente nas Usinas (3D)



Fonte: Autoria própria.

Conforme demonstrado em um gráfico 3D na Figura 11, a vazão de Tucuruí representa mais da metade da soma das demais vazões das UHEs da Bacia do Rio Tocantins. Isso se deve em grande parte à contribuição do Rio Araguaia, que desagua no Rio Tocantins na região do Bico de Papagaio, situado a jusante de Estreito e a montante de Tucuruí. Isso cria uma interconexão hidrológica fundamental entre esses rios e suas respectivas bacias. A contribuição do Rio Araguaia é valiosa para a operação da Usina de Tucuruí por várias razões:

- **Aumento da Vazão Afluyente:** O Rio Araguaia, com suas próprias vazões, contribui para aumentar a vazão afluyente que chega à Usina de Tucuruí. Isso é especialmente importante em épocas de seca, quando o volume de água no Rio Tocantins pode diminuir significativamente. A vazão do Araguaia ajuda a manter níveis adequados de água no reservatório de Tucuruí, garantindo a continuidade da geração de energia.
- **Regulação de Vazões:** A presença do Rio Araguaia permite uma maior flexibilidade na regulação das vazões em Tucuruí. Isso significa que a usina pode ajustar a quantidade de água que passa pelas turbinas de acordo com as demandas de geração de energia e as necessidades de controle de vazões do Rio Tocantins. Essa flexibilidade é crucial para otimizar a operação da usina.
- **Redução de Impactos Ambientais:** A disponibilidade da vazão do Araguaia também pode ajudar a reduzir os impactos ambientais da operação de Tucuruí. Ao manter vazões mínimas no Rio Tocantins, a usina pode preservar os ecossistemas aquáticos e terrestres a jusante, além de minimizar o risco de eventos como secas prolongadas ou inundações.

- **Melhoria na Precisão das Previsões:** Para o estudo em questão, a consideração da vazão do Rio Araguaia como parte do sistema hidrológico é essencial. A interação entre as vazões do Tocantins e do Araguaia pode afetar significativamente as condições de fluxo em Tucuruí. Isso torna as previsões mais precisas, uma vez que incorporam uma gama mais ampla de variáveis hidrológicas.

Portanto, a influência do Rio Araguaia na Usina de Tucuruí não se limita à geração de energia; ela desempenha um papel fundamental na gestão dos recursos hídricos da região. Essa interdependência é de importância crítica para a compreensão e previsão do comportamento das vazões em Tucuruí, destacando-a como uma componente essencial deste estudo. Vale ressaltar que, embora não tenhamos obtido dados suficientes do Araguaia para esta pesquisa, essa lacuna abre perspectivas para estudos futuros.

## 2.7 Revisão da literatura

Neste capítulo, analisamos a Bacia Hidrográfica Tocantins-Araguaia e suas usinas hidrelétricas, destacando a importância crucial da previsão de vazões para a operação eficiente desses empreendimentos.

A Bacia desempenha um papel de destaque no contexto hidrográfico, abrangendo uma vasta área que se estende por diversos estados, como o Pará, Tocantins, Goiás e Maranhão. Seu notável potencial energético tem sido objeto de estudo (VIEIRA, 2018).

A hidrologia da bacia é marcada por vazões sazonais diretamente relacionadas a fatores climáticos, como chuvas e secas. Essa sazonalidade desempenha um papel crucial no planejamento e operação das usinas hidrelétricas na região (BRITO et al., 2018). Estudos conduzidos por (MEDEIROS et al., 2019) demonstram como a variabilidade climática exerce uma influência direta sobre as vazões afluentes, tornando a previsão dessas vazões um desafio significativo.

As usinas hidrelétricas na Bacia desempenham um papel vital na matriz energética do Brasil. Tome-se como exemplo a Usina Hidrelétrica de Tucuruí, uma das maiores do país, com uma potência instalada de 8.365 MW (ANEEL, 2021). Essas usinas contribuem de maneira substancial para a geração de energia elétrica, desempenhando um papel crucial no abastecimento de eletricidade em várias regiões do país (FERREIRA et al., 2018).

Para operar eficientemente essas usinas, é essencial obter previsões precisas das vazões afluentes. Estudos recentes, como o de (SILVA et al., 2019), têm investigado métodos de previsão, incluindo modelos baseados em séries temporais de vazão e dados meteorológicos. A precisão dessas previsões é fundamental para o planejamento da operação das usinas, otimizando a gestão dos recursos hídricos e a geração de energia (LIMA et al., 2020).

Além disso, destacamos a importância da incorporação de técnicas de aprendizado de máquina, especialmente redes neurais artificiais, como uma abordagem promissora para a previsão de vazões na Bacia Tocantins-Araguaia, devido à sua capacidade de lidar com a complexidade das séries temporais fluviais.

Portanto, este capítulo estabelece uma base sólida para a compreensão dos desafios e oportunidades na gestão de vazões na região, os quais serão explorados em detalhes nos próximos capítulos deste estudo.

### 3 MODELOS DE APRENDIZADO DE MÁQUINA PARA PREVISÃO DE SÉRIES TEMPORAIS

Este capítulo detalha a metodologia adotada para a aplicação de técnicas de Aprendizado de Máquina (AM) na previsão de séries temporais. A pesquisa envolve uma análise comparativa de cinco arquiteturas de modelos, cada uma desenvolvida para prever variáveis específicas ao longo do tempo. A seleção desses modelos é diversificada, abrangendo desde as conhecidas Redes Neurais Recorrentes, notadamente os modelos LSTM, até arquiteturas híbridas que incorporam elementos tanto de Redes Neurais Convolucionais quanto de LSTMs combinadas.

Para fundamentar essa escolha, é essencial discutir as motivações por trás da preferência por redes recorrentes na modelagem dinâmica não linear. Cada arquitetura será apresentada, discutida e definida, destacando os elementos fundamentais que as tornam adequadas para a modelagem de séries temporais. Além disso, é crucial destacar que cada modelo considera o conceito de auto-regressão. Isso implica que cada instância é treinada para aprender e utilizar informações passadas da série temporal como insumos para suas previsões futuras.

Ao longo deste capítulo, será possível compreender não apenas os detalhes técnicos de cada modelo, mas também a lógica subjacente à escolha dessas arquiteturas específicas. Isso proporcionará uma visão aprofundada das estratégias de Aprendizado de Máquina aplicadas à previsão de séries temporais no contexto deste estudo.

#### 3.1 Redes Neurais Artificiais - RNAs

As Redes Neurais Artificiais desempenham um papel fundamental no campo do Aprendizado de Máquina, sendo intrinsecamente inspiradas no funcionamento complexo do sistema nervoso humano. Conforme definido por (RUMELHART; MCCLELLAND; PDP, 1986), elas são “sistemas compostos por unidades simples de processamento, que adquirem conhecimento através da experiência e têm a capacidade de generalização.”


Os neurônios artificiais, componentes essenciais dessas redes, são organizados em camadas, formando uma estrutura que aprende com dados e executa tarefas complexas. A estrutura fundamental envolve unidades de processamento conectadas por canais de comunicação, cada um associado a pesos específicos. A inteligência emerge das interações entre essas unidades.

Essencialmente, elas são modelos não-lineares que fornecem saídas tipicamente contínuas. A operação de uma unidade de processamento, conforme proposto inicialmente por (MCCULLOCH; PITTS, 1943), segue uma sequência lógica. A Figura 12 ilustra o funcionamento de um neurônio artificial.

As Redes Neurais Artificiais representam estruturas computacionais inspiradas no funcionamento do cérebro humano, projetadas para realizar tarefas de aprendizado e reconhecimento de padrões. No contexto de uma RNA, o processo de funcionamento pode ser desdobrado da seguinte forma:

- **Sinais de entrada {  $X_1, X_2, \dots, X_n$  }:** Representam os estímulos externos, geralmente normalizados para otimizar a eficiência computacional dos algoritmos de

Figura 12 – Neurônio Artificial.



Fonte: (SILVA; SPOTTI; FLAUZINO, 2016).

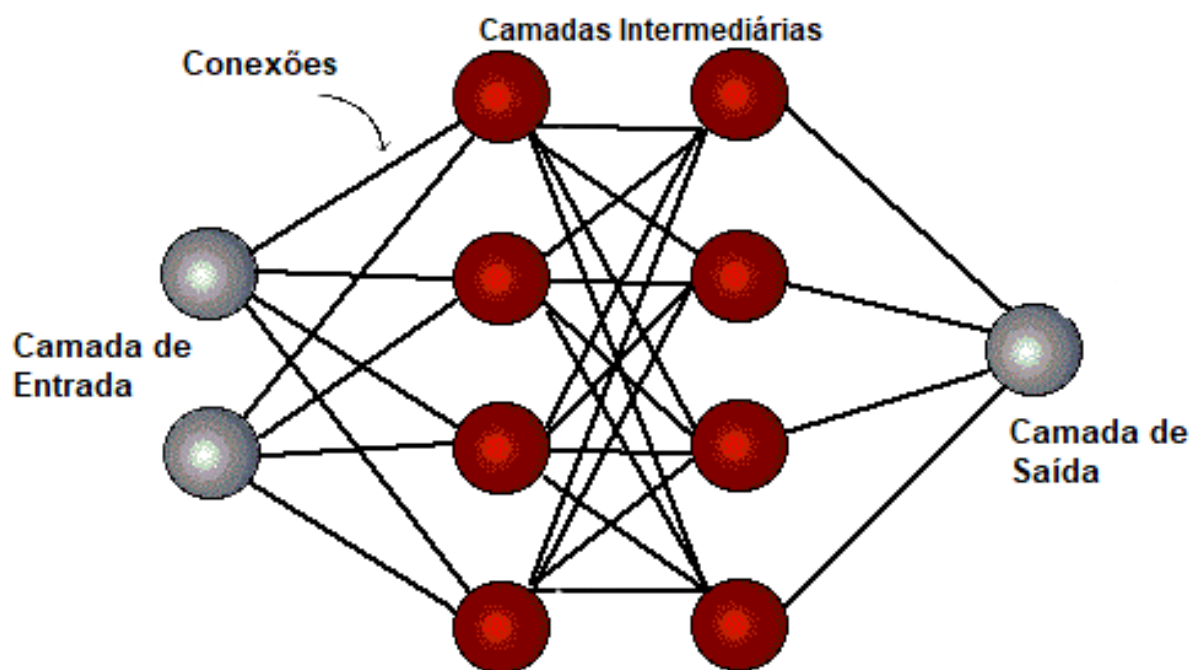
aprendizagem.

- **Pesos sinápticos**  $\{ W_1, W_2, \dots, W_n \}$ : São valores atribuídos para ponderar a contribuição de cada sinal de entrada na rede. Esses pesos são ajustados durante o processo de treinamento.
- **Combinador linear**  $\{ \Sigma \}$ : Agrega os sinais de entrada ponderados pelos respectivos pesos sinápticos, gerando um potencial de ativação.
- **Limiar de ativação**  $\{ \Theta \}$ : Estabelece o patamar necessário para que o resultado do combinador linear alcance um valor que desencadeie a ativação do neurônio.
- **Potencial de ativação**  $\{ u \}$ : É o resultado da diferença entre o valor produzido pelo combinador linear e o limiar de ativação. Se o valor for positivo ( $u \geq 0$ ), o neurônio gera um potencial excitatório; caso contrário, o potencial será inibitório.
- **Função de ativação**  $\{ g \}$ : Tem como função restringir a saída do neurônio a um determinado intervalo de valores. Diferentes funções de ativação, como a sigmoide ou a tangente hiperbólica, podem ser empregadas.
- **Sinal de saída**  $\{ y \}$ : Representa o valor final de saída do neurônio, podendo ser utilizado como entrada para outros neurônios interconectados sequencialmente.

A maioria dos modelos de redes neurais incorpora alguma regra de treinamento, que ajusta os pesos das conexões com base nos padrões apresentados. Em resumo, elas aprendem por meio de exemplos, adaptando-se para melhor se ajustar aos dados e realizar tarefas específicas. Esse processo de aprendizado é essencial para a capacidade em generalizar e lidar com dados não vistos durante o treinamento.

As arquiteturas neurais geralmente são organizadas em camadas: a camada de entrada, que apresenta padrões à rede; as camadas intermediárias ou escondidas, que realizam a maior parte do processamento; e a camada de saída, que apresenta o resultado final. A Figura 13 ilustra esse arranjo, onde a camada de entrada recebe os padrões, as camadas intermediárias realizam o processamento e a camada de saída apresenta o resultado. A topologia da rede, as características dos nós e as regras de treinamento são determinantes na especificação de uma RNA.

Figura 13 – Organização em camadas de uma Rede Neural.



Fonte: (ICMC.USP, 2021).

A aprendizagem profunda é um algoritmo computacional crucial para a análise de dados, amplamente utilizado em diversos campos devido às suas capacidades superiores de previsão e classificação (LECUN; BENGIO; HINTON, 2015). As principais técnicas de aprendizagem profunda frequentemente utilizadas são redes neurais recorrentes para dados de sequência e redes neurais convolucionais para imagens (ALZUBAIDI et al., 2021). Essas técnicas avançadas têm sido adotadas em áreas ambientais, como gestão de desastres, sistemas de gestão de recursos hídricos e problemas de poluição atmosférica (SUN; SCANLON, 2019).

### 3.1.1 Redes Neurais Artificiais em Hidrologia

Na área da hidrologia, a aplicação de modelos hidrológicos baseados em física e Redes Neurais Artificiais ou RNAs tem sido extensivamente explorada no processamento de dados hidrológicos. Modelos físicos demandam uma grande quantidade de dados para construir um modelo hidrogeológico e dependem de previsões precisas de precipitação futura, apresentando desafios em áreas com poucos dados e menor sensibilidade a anomalias climáticas (HA; LIU; MU, 2021).

Por outro lado, as RNAs, notadamente modelos de memória de longo e curto prazo (LSTM), têm se destacado na previsão de séries temporais. Essas estruturas, amplamente aplicadas em campos como processamento de linguagem natural e reconhecimento de imagem (WU et al., 2017) (CHO et al., 2014), superam algumas limitações dos modelos hidrológicos tradicionais. Elas oferecem vantagens, como a exigência de dados, a capacidade de previsão em diversas escalas de tempo e maior eficácia na captura de padrões complexos, incluindo eventos discrepantes (TAORMINA; CHAU, 2015).

Além disso, as RNAs podem ser integradas a métodos estatísticos, como a média móvel (MA) e a análise de espectro singular (SSA), para aprimorar a previsão de dados hidrológicos. O pré-processamento, incluindo técnicas como MA, SSA e decomposição em modo empírico, contribui para o aprendizado de padrões pelos modelos RNA, aumentando sua capacidade de generalização (WU; CHAU, 2013) (LIU et al., 2020).

No entanto, é importante destacar que treinar modelos de aprendizagem de máquina diretamente com dados originais pode resultar em imprecisões nos resultados. Estratégias que exploram a combinação inteligente de pré-processamento e algoritmos de aprendizagem profunda são promissoras para melhorar a precisão na previsão do fluxo de rios, eventos climáticos e vazões afluentes, como no El Niño e na UHE-Tucuruí (WANG; MU; LIU, 2021) (SANTOS, 2022).

Recentemente, o foco da pesquisa em RNAs concentrou-se na otimização da estrutura dos modelos para explorar conexões implícitas nos dados e descobrir padrões com horizontes de tempo mais longos. Métodos inovadores, como LSTM, CNNs, CNN-LSTM, Unidade Recorrente Controlada (GRU), estruturas bidimensionais e codificador-decodificador, surgiram para aprimorar o processamento de séries temporais. Essas abordagens representam avanços significativos na capacidade de prever eventos hidrológicos complexos e destacam a evolução contínua das RNAs no contexto da hidrologia.

Nos próximos segmentos, aprofundaremos a exploração de duas variantes específicas de RNAs que são fundamentais para nossa análise: Redes Neurais Recorrentes e Redes Neurais Convolucionais.

### 3.2 Redes Neurais Recorrentes e sua Aplicação em Hidrologia

As Redes Neurais Recorrentes representam uma classe especial de RNAs projetadas para processar dados sequenciais, tornando-as particularmente adequadas para a modelagem de séries temporais. Ao contrário das RNAs de alimentação direta, essas redes possuem conexões retroativas em sua estrutura, permitindo que informações anteriores sejam incorporadas ao processamento atual (KWON; CHA; PARK, 2023).

Essa capacidade de manter uma “memória” das entradas passadas é crucial na previsão de séries temporais, uma vez que os padrões temporais frequentemente dependem de eventos anteriores. As RNNs alcançam isso por meio de loops em sua arquitetura, que permitem que informações sejam transmitidas de um passo de tempo para o próximo.

No entanto, as RNNs tradicionais podem sofrer do problema de desvanecimento do gradiente. Isso ocorre quando os gradientes usados para treinar a rede diminuem exponencialmente à medida que informações mais antigas são propagadas para trás no tempo. Esse problema limita a capacidade de aprender dependências de longo prazo em dados sequenciais. (GHIMIRE; YASEEN; FAROOQUE, 2021).

O progresso das RNNs na modelagem de séries temporais tem sido notável. No entanto, para enfrentar o desafio da memória de curto prazo, arquiteturas mais avançadas, como as LSTM, foram desenvolvidas. Essas arquiteturas, que serão detalhadas na seção seguinte, buscam superar as limitações das RNNs tradicionais, possibilitando uma aprendizagem mais eficiente e a captura de relações temporais complexas. Conseqüentemente, variáveis hidrológicas, como precipitação, vazão, demanda hídrica e nível de água, frequentemente são previstas utilizando modelos RNN (HAUSWIRTH et al., 2021).

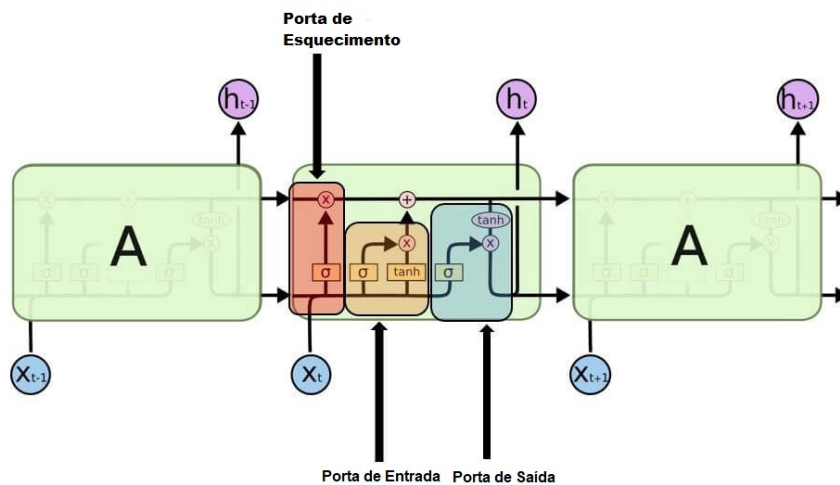
### 3.2.1 Memórias de Longo e Curto Prazo - LSTM

As LSTMs representam uma extensão crucial das Redes Neurais Recorrentes, projetadas para resolver o problema da “memória de curto prazo”. Propostas por Hochreiter e Schmidhuber em 1997 (HOCHREITER; SCHMIDHUBER, 1997), essas arquiteturas introduzem unidades especiais chamadas “células de memória” que têm a capacidade de reter informações por longos períodos, possibilitando a aprendizagem eficaz de padrões temporais complexos (GREFF et al., 2017).

Para superar as limitações das RNNs tradicionais, as Redes Neurais Recorrentes de Memória de Longo Prazo foram desenvolvidas. Sendo elas um tipo especializado de RNN que foi projetado para aprender e lembrar informações de longo prazo, tornando-as especialmente eficazes na modelagem de séries temporais.

As LSTMs são um componente essencial das RNNs, projetadas para superar as limitações de memória de curto prazo encontradas em RNNs convencionais. A estrutura de uma unidade LSTM, apresentada na Figura 14, é composta por uma célula, uma porta de entrada, uma porta de esquecimento e uma porta de saída.

Figura 14 – Estrutura de uma LSTM.



Fonte: Adaptado de (ANALYTICSVIDHYA, 2022)

A célula funciona como uma unidade de armazenamento de informações, enquanto as portas regulam o fluxo de dados. Três portas principais desempenham papéis cruciais no controle do fluxo de informações dentro da célula:

#### 1. Porta de Entrada:

- **Função:** Esta porta controla quanto da nova informação deve ser adicionado à célula de memória.
- **Operação:** Utiliza a função sigmoide para decidir entre permitir a passagem dos valores 0 ou 1. A função tanh pondera os dados de entrada, atribuindo-lhes importância em uma escala de -1 a 1.

- **Equações:**

$$i_t = \sigma(W_{ii} \cdot X_t + b_{ii} + W_{hi} \cdot h_{t-1} + b_{hi}) \quad (3.1)$$

$$\tilde{C}_t = \tanh(W_{ic} \cdot X_t + b_{ic} + W_{hc} \cdot h_{t-1} + b_{hc}) \quad (3.2)$$

## 2. Porta de Esquecimento:

- **Função:** Esta porta controla o quanto da informação anterior da célula de memória deve ser esquecido e quanto da nova informação deve ser armazenado.
- **Operação:** Utiliza uma função sigmoide para analisar o estado anterior da célula ( $h_{t-1}$ ) e a entrada de conteúdo ( $X_t$ ), gerando um valor entre 0 (omitir) e 1 (manter).
- **Equação:**

$$f_t = \sigma(W_{if} \cdot X_t + b_{if} + W_{hf} \cdot h_{t-1} + b_{hf}) \quad (3.3)$$

## 3. Porta de Saída:

- **Função:** Esta porta controla quanto da informação da célula de memória deve ser exposta como saída da LSTM.
- **Operação:** A função sigmoide decide entre permitir a passagem dos valores 0 ou 1, enquanto a função tanh pondera a relevância dos valores em uma escala de -1 a 1.
- **Equações:**

$$o_t = \sigma(W_{io} \cdot X_t + b_{io} + W_{ho} \cdot h_{t-1} + b_{ho}) \quad (3.4)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (3.5)$$

Essas equações ilustram como as portas de uma LSTM controlam o fluxo de informações, permitindo que a célula retenha e acesse dados de acordo com os requisitos da tarefa em questão. Essa capacidade de manter informações relevantes por intervalos de tempo arbitrários torna especialmente adequadas para lidar com sequências temporais de duração variável.

Na aplicação prática, é empregada em várias áreas, incluindo processamento de linguagem natural, onde sua capacidade de construir memória de longo prazo a partir de processos de curto prazo é particularmente valiosa. Ela proporciona contextos significativos para avaliação de palavras ou fonemas em relação ao conjunto, contribuindo para a filtragem e categorização eficientes de dados. O conceito de LSTM representa uma ideia consolidada e amplamente adotada no desenvolvimento de redes neurais recorrentes para uma variedade de tarefas.

Em contextos hidrológicos, onde a precisão na previsão de eventos climáticos é fundamental, as RNNs, especialmente as LSTMs, se destacam. Sua capacidade de capturar padrões complexos e de lidar eficientemente com a natureza sequencial dos dados hidrológicos as torna ferramentas inestimáveis para prever com precisão a vazão dos rios e eventos climáticos extremos (GHIMIRE; YASEEN; FAROOQUE, 2021).

Diversos estudos notáveis foram conduzidos recentemente sobre as aplicações das LSTMs na previsão de vazões, incluindo:

- **Kelantan, Malásia:** (FU et al., 2020) utilizaram o modelo LSTM para prever vazões em um estudo que abrangeu cinco décadas de dados de precipitação e vazão no rio Kelantan, no nordeste da Malásia, demonstrando a eficácia dessa abordagem em cenários de longo prazo.
- **Comparação de Desempenho:** (RAHIMZAD et al., 2021) conduziram uma análise comparativa de modelos, destacando que o LSTM superou métodos tradicionais de

aprendizado de máquina, incluindo regressão linear e perceptron multicamadas, em previsões de vazão baseadas em dados de precipitação.

- **China:** (WANG et al., 2022) coletaram dados de vazão e precipitação em sete bacias hidrográficas na China, empregando o modelo GRU para a previsão de vazões. Uma abordagem híbrida, que combinou LSTM e GRU, foi sugerida para melhorar a capacidade de previsão.
  - **Integração de Métodos:** Em uma abordagem integrativa, (AHMED et al., 2021) acoplaram LSTM e GRU ao algoritmo de seleção de recursos Boruta (BRF), resultando em previsões aprimoradas de fluxo usando dados meteorológicos.
  - **Consideração de Barragens:** O estudo de (OUYANG et al., 2021) enfatizou a importância de considerar a influência de barragens na previsão de fluxo. Ao avaliar 3.557 bacias nos Estados Unidos, destacaram a necessidade de tratar adequadamente a presença de barragens nos modelos LSTM para otimizar a precisão das previsões.
- Previsão de Vazão Afluente com LSTM:** (SANTOS, 2022) conduz um estudo que aplica Redes Neurais Recorrentes LSTM na previsão diária de vazão na Usina Hidrelétrica de Tucuruí, utilizando dados históricos tanto da própria Usina quanto da Usina de Estreito. O trabalho ressalta a necessidade crucial de incorporar a presença de outros dados para aprimorar a precisão das previsões.

Em relação à conexão entre precipitação e escoamento, é comum utilizar dados históricos como entrada para modelos de aprendizagem profunda. No entanto, essa abordagem pode ser inadequada em regiões com infraestruturas artificiais significativas, como barragens e açudes, que provocam alterações substanciais nos padrões de fluxo, independentemente das condições climáticas (WILLIAMS GP & WOLMAN, 1984).

### 3.3 Redes Neurais Convolucionais - CNNs

As CNNs oferecem uma abordagem única para prever séries temporais, especialmente no contexto da hidrologia. Enquanto as RNNs se destacam na captura de dependências temporais de longo prazo, as CNNs são especializadas em reconhecer padrões espaciais em dados sequenciais.


#### 3.3.1 Arquitetura e Funcionamento das CNNs

As CNNs baseiam-se no conceito de convolução, um processo pelo qual filtros deslizam sobre os dados de entrada, extraindo características locais. Essa capacidade é particularmente útil para dados espacialmente caracterizados, como os encontrados em previsões hidrológicas. A arquitetura típica das CNNs inclui camadas de convolução, camadas de pooling e camadas totalmente conectadas, como mostrado na Figura 15

- **Convolução:** A convolução permite que a rede identifique padrões espaciais, como características geográficas em mapas de precipitação ou características hidrográficas.
- **Pooling:** As camadas de pooling reduzem a dimensionalidade, preservando as características essenciais e tornando a rede mais eficiente.
- **Totalmente Conectada ou Flattening:** As camadas totalmente conectadas integram as informações extraídas para gerar a saída final da rede.

Uma integração notável é a combinação com Modelos Recorrentes. A abordagem híbrida que mescla CNNs com modelos recorrentes, como LSTM ou GRU, tem se mostrado

Figura 15 – Exemplo de uma arquitetura CNN.



Fonte: (INTERVIEWBIT, 2022).

eficaz. Essa fusão permite a captura de informações tanto espaciais quanto temporais, enriquecendo a compreensão do sistema hidrológico (AHMED et al., 2021), algo explorado em detalhes neste trabalho.

É importante destacar também o kernel, sendo o cérebro de um sistema operacional e em redes neurais refere-se a uma pequena matriz usada na operação de convolução. Durante essa operação, o kernel desliza sobre os dados de entrada, realizando operações locais para extrair padrões relevantes. Os pesos e o tamanho do kernel são ajustáveis, permitindo que a rede neural aprenda diferentes características nos dados durante o treinamento. Em resumo, o kernel é essencial para a capacidade da rede neural de reconhecer e aprender padrões nos dados.

### 3.3.2 Tipos de Redes Neurais Convolucionais

As CNNs representam uma classe poderosa de arquiteturas adaptadas para diversas tipologias de dados e aplicações. Neste contexto, destacamos três variantes fundamentais: CNN Unidimensional (CNN1D), CNN Bidimensional (CNN2D), e CNN Tridimensional (CNN3D).


#### 3.3.2.1 CNN Unidimensional (CNN1D)

Este modelo é especialmente indicado para análise de dados unidimensionais, como séries temporais. Nas CNNs 1D, os kernels de convolução movem-se ao longo de uma única direção, resultando em dados de entrada e saída bidimensionais (SHEN et al., 2021). Reconhecida por sua capacidade robusta de extração de recursos, destaca-se na identificação automática de características não lineares nos dados brutos. A combinação de camadas convolucionais e de pooling contribui para essa extração, enquanto o aprendizado adaptativo de recursos ocorre na camada totalmente conectada, eliminando a necessidade de extração manual de características e tornando o processo mais eficiente (YAO et al., 2021).

O diferencial dessa arquitetura é sua habilidade em operar por meio do deslizamento do kernel em uma única dimensão, tornando-a ideal para a análise de séries temporais. Em cenários como a interpretação de dados de um acelerômetro, onde a primeira dimensão representa o tempo e a segunda dimensão é composta pelos valores de aceleração em diferentes eixos, a CNN1D destaca-se na identificação de padrões temporais significativos.

Em termos mais práticos, é possível imaginar dados de séries temporais como aqueles provenientes de um acelerômetro, nele o kernel desliza apenas na dimensão temporal. Cada passo do kernel abrange uma janela de tempo, permitindo a extração de padrões temporais específicos. A Figura 16 ilustra visualmente esse deslizamento unidimensional do kernel.

Figura 16 – Deslizamento do Kernel na CNN 1D sobre uma Série Temporal.




Fonte: Adaptado de (VERMA, 2019).

A CNN1D encontra aplicações valiosas em dados sequenciais, como séries temporais de sensores, dados de áudio e texto, onde a identificação de padrões em uma única dimensão temporal é essencial.

A figura 17 ilustra a operação de convolução unidimensional, onde os diferentes mapas de recursos após a convolução são representados. As conexões coloridas mostram os links entre a camada de entrada e a camada convolutiva, e cada conexão é ponderada. Essa estrutura permite uma operação de convolução eficaz com um número menor de pesos em comparação com arquiteturas totalmente conectadas e isso aumenta sua velocidade de processamento.

Figura 17 – Exemplo de operação convolucional 1D.



Fonte: Adaptado de (GHIMIRE; YASEEN; FAROOQUE, 2021).

### 3.3.2.2 CNN Bidimensional (CNN2D)

A arquitetura da Rede Convolutiva Bidimensional desempenha um papel fundamental em tarefas de processamento de imagem, desempenhando um papel crucial na


extração de padrões visuais complexos. O termo 2D refere-se à capacidade do kernel de deslizar ao longo de duas dimensões nos dados, geralmente correspondentes à altura e largura da imagem (ZHAO et al., 2021). Esta capacidade única torna a CNN2D altamente eficiente na captura de informações locais em imagens, sendo essencial para a extração de características espaciais.

Ao operar por meio do deslizamento do kernel sobre a imagem, a CNN2D realiza convoluções em duas dimensões, o que a torna particularmente robusta na detecção de bordas, distribuição de cores e outros padrões visuais. Essa capacidade de discernimento espacial é uma característica distintiva que a diferencia de outras redes neurais, tornando-a especialmente eficaz em tarefas de classificação de imagens.

Para ilustrar o processo de convolução, é possível imaginar um pequeno kernel, como um filtro 3x3, movendo-se pela imagem. A Figura 18 oferece uma representação visual desse deslizamento sobre uma imagem bidimensional. A cada passo, o kernel realiza uma multiplicação elemento a elemento com a região da imagem que está cobrindo, gerando valores que compõem a camada convolucional de saída. Esse processo é repetido em toda a extensão da imagem, capturando eficientemente padrões locais e construindo representações hierárquicas.

A natureza tridimensional dos dados manipulados pela CNN2D contribui significativamente para sua eficácia na detecção de bordas, distribuição de cores e outras características espaciais em imagens. Além de seu sucesso em tarefas de classificação, destaca-se em contextos que demandam compreensão espacial, tornando-a uma escolha versátil e robusta. Sua capacidade de generalização a padrões complexos a torna promissora em aplicações diversas, inclusive na área de previsão de vazões, onde a interpretação eficaz de informações espaciais é fundamental.

Figura 18 – Deslizamento do Kernel na CNN 2D sobre uma Imagem Bidimensional.



Fonte: Adaptado de (VERMA, 2019).

Na previsão de vazões diárias ao longo do tempo em usinas hidrelétricas, a CNN2D destaca-se ao analisar mapas hidrográficos, onde cada pixel representa a vazão diária em uma determinada localidade. Ao aplicar o deslizamento do kernel sobre essas imagens bidimensionais, a CNN2D extrai padrões espaciais e temporais, permitindo a aprendizagem automática de complexas interações entre diferentes pontos do mapa. Essa abordagem aprimora a interpretação das variáveis hidrológicas, resultando em modelos de previsão de vazões mais eficazes e precisos para usinas hidrelétricas.

### 3.3.2.3 CNN Tridimensional (CNN3D)

Esse modelo leva a convolução para três dimensões, tornando-o adequado para dados tridimensionais, visto que os núcleos de convolução se movem em 3 direções e os dados de entrada e saída do CNN3D são quadrimencionais como dados de ressonância magnética (MRI) e tomografias computadorizadas (TC) (RAO; LIU, 2020). Esses dados são comuns em aplicações de diagnóstico médico. O CNN3D permite a classificação de dados médicos e a extração de características relevantes desses dados e não foi utilizado neste estudo.

### 3.3.3 Velocidade de Processamento: Comparação entre CNNs e LSTMs

Além das notáveis capacidades na extração de características espaciais, as Redes Neurais Convolucionais também apresentam uma vantagem significativa em termos de velocidade de processamento quando comparadas aos modelos baseados em Redes Neurais Recorrentes, como as LSTMs. Devido à sua arquitetura eficiente e à natureza paralela das operações de convolução, as convolucionais geralmente demonstram uma velocidade de treinamento mais rápida e isso foi observado em nosso estudo.

Enquanto as LSTMs, devido à sua estrutura sequencial e dependência temporal, podem exigir mais tempo para convergir durante o treinamento, as CNNs lidam de maneira mais eficaz com grandes conjuntos de dados, resultando em tempos de treinamento mais curtos. Essa característica faz das CNNs uma escolha atrativa em cenários em que a eficiência computacional e a velocidade de processamento são críticas para a aplicação desejada (HA; LIU; MU, 2021).

## 3.4 Combinação de Redes Neurais Recorrentes (RNNs) e Redes Neurais Convolucionais (CNNs)

Na busca contínua por avanços na modelagem de séries temporais, a combinação de Redes Neurais Recorrentes, em particular as LSTMs, com Redes Neurais Convolucionais tem emergido como uma estratégia promissora. Essa fusão arquitetural visa capitalizar a habilidade das CNNs na extração de padrões espaciais, aliada à capacidade de memória de longo prazo das LSTMs para lidar com dependências temporais.

### 3.4.1 Estrutura e Funcionamento da CNN-LSTM

A arquitetura da CNN-LSTM apresenta uma inovação marcante na previsão de dados hidrológicos. Proposta inicialmente por (SHI; AL., 2015), essa abordagem se destaca por sua capacidade de lidar efetivamente com séries temporais espaço-temporais, tornando-a particularmente relevante para aplicações em hidrologia.

A CNN-LSTM mantém a formulação fundamental da LSTM tradicional, incorporando operações de convolução em vez de conexões totalmente conectadas. Consiste em células LSTM, cada uma associada a uma camada convolucional. De acordo com o artigo (SHI; AL., 2015), essas células processam informações, enquanto as camadas convolucionais extraem padrões espaciais.

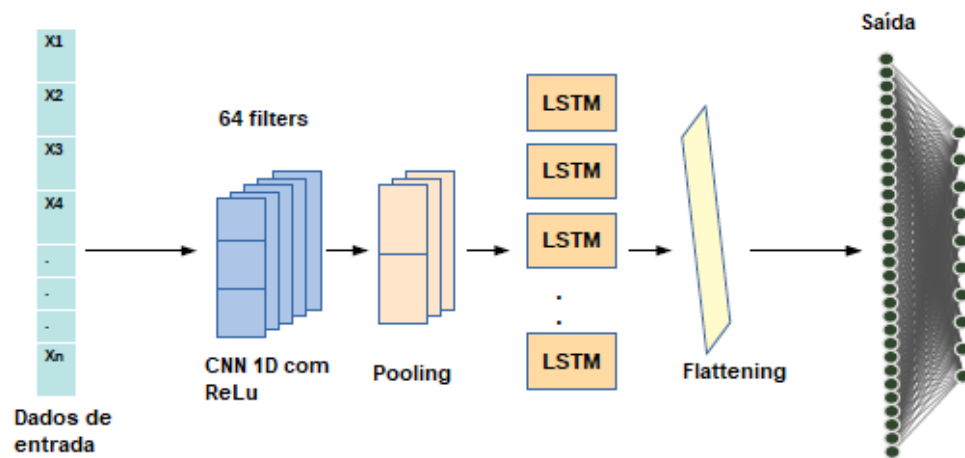
- **Convolução Espacial:**
  - A entrada, representando dados espaço-temporais, passa por camadas convolucionais para identificar padrões espaciais.
  - Essa operação permite que a rede extraia características espaciais importantes nas séries temporais, vital para previsões precisas em hidrologia.
- **Células LSTM:**
  - Cada célula LSTM recebe as características extraídas pela convolução espacial.
  - A estrutura LSTM permite a aprendizagem de dependências temporais de longo alcance, sendo crucial para a compreensão de padrões em séries temporais hidrológicas.
- **Saída Integrada:**
  - As saídas das células LSTM são integradas para formar a saída final da CNN-LSTM.
  - Essa saída combinada representa uma compreensão aprimorada das relações espaço-temporais nos dados hidrológicos.

A CNN-LSTM é adaptável a diferentes tipos de dados hidrológicos, sejam eles unidimensionais ou bidimensionais. Por exemplo, ao tratar dados de vazão, a rede pode agrupar séries temporais em diferentes períodos, tratando-as como dados bidimensionais com dois canais na rede.

A Figura 19, esquematiza a estrutura simples de uma unidade de memória na CNN-LSTM para reconhecimento de atividade humana, destacando a interconexão entre a convolução e as células LSTM, além das camadas intermediárias. Isso evidencia como a convolução contribui para uma representação mais rica dos dados espaço-temporais.

Desenvolvida inicialmente para processar imagens de ondas de radar, a CNN-LSTM tem sido adaptada para lidar com séries temporais hidrológicas unidimensionais e bidimensionais. Nessa abordagem, em nosso estudo os dados de vazão são tratados como séries temporais agrupadas em períodos. Os dados agrupados são, então, tratados como dados unidimensionais ou bidimensionais, com dois canais alimentados na rede. Essa transformação permite que o kernel convolucional extraia informações espaciais das séries temporais, contribuindo para uma previsão mais precisa.

Figura 19 – Representação de uma Estrutura da Unidade de Memória CNN-LSTM.



Fonte: Adaptado de (ALI et al., ).

### 3.4.2 Vantagens sobre Abordagens Tradicionais

Comparativamente a modelos tradicionais, a CNN-LSTM destaca-se pela capacidade de perceber características com variação espacial significativa, crucial para dados hidrológicos complexos. A eficácia na obtenção de relações espaço-temporais a torna uma escolha preferencial, especialmente quando a correlação entre variáveis hidrológicas varia ao longo do tempo.

A aplicação da CNN-LSTM em dados hidrológicos unidimensionais, bidimensionais e a consideração de diferentes períodos na agregação das séries temporais indicam sua flexibilidade e adaptabilidade, abrindo caminho para uma previsão mais precisa e contextualizada das variáveis hidrológicas.

## 4 DESENVOLVIMENTO COMPUTACIONAL DOS MODELOS DE PREVISÃO DE VAZÃO AFLUENTE

Neste capítulo, é detalhado a implementação prática dos modelos de previsão de vazão afluyente da UHE-Tucuruí na linguagem de programação Python. A metodologia adotada compreende a criação e treinamento de cinco modelos distintos, cada um projetado para explorar diferentes arquiteturas e abordagens. A implementação baseia-se em bibliotecas fundamentais, como Pandas e NumPy, e as redes neurais são construídas utilizando TensorFlow e Keras.

A seção inicial deste capítulo contextualiza o ambiente computacional e justifica a escolha da linguagem Python para o desenvolvimento dos modelos. Aborda-se a relevância das bibliotecas utilizadas e como essas ferramentas proporcionam uma base sólida para a implementação eficiente dos algoritmos de aprendizado de máquina. Além disso, são apresentadas as etapas essenciais do processo de codificação, desde o carregamento dos dados até a validação dos modelos, fornecendo uma visão geral do fluxo de trabalho.

Este capítulo não apenas descreve o código, mas também oferece *insights* sobre as decisões, escolhas de parâmetros e estratégias para garantir que os modelos sejam robustos e capazes de lidar com as complexidades dos dados hidrológicos. A estruturação das seções subsequentes visa fornecer uma compreensão clara de como cada modelo é construído e treinado, enriquecendo a análise com comentários sobre boas práticas de programação e considerações específicas de cada arquitetura.

O código Python referente a cada modelo e as funções específicas, como `split_sequence`, serão apresentados em seções subsequentes, proporcionando uma abordagem passo a passo para a compreensão detalhada de cada implementação. Este capítulo não apenas documenta o código-fonte, mas também oferece uma narrativa coerente para compreender não apenas o “como” da implementação, mas também o “porquê” por trás de cada escolha e estratégia adotada.

### 4.1 Ambiente Computacional e Bibliotecas Utilizadas

O desenvolvimento dos modelos de previsão de vazão afluyente para a UHE-Tucuruí foi realizado em um ambiente computacional robusto, utilizando a linguagem de programação Python e várias bibliotecas especializadas. A escolha do Python para este projeto é justificada pela sua ampla aceitação na comunidade de ciência de dados e aprendizado de máquina, oferecendo eficiência e versatilidade. As bibliotecas utilizadas foram organizadas para facilitar a importação e o gerenciamento de dados, a implementação de modelos de aprendizado de máquina e a avaliação de desempenho.

#### 4.1.1 Bibliotecas Importadas

```

1 from keras.models import Sequential, Model
2 from keras.layers import LSTM, Dense, Conv1D, MaxPooling1D, Dropout, Conv2D,
3 Flatten, Reshape

```

```

4 from keras.optimizers import Adam
5 from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score

```

#### 4.1.2 Justificativas para a Escolha das Bibliotecas

As bibliotecas utilizadas e suas justificativas de escolhas foram guiadas pelos seguintes aspectos:

1. **Pandas e NumPy:** Utilizadas para a manipulação eficiente de dados, permitindo o carregamento, organização e análise dos conjuntos de dados de vazão afluentes.
2. **Matplotlib:** Essencial para a visualização de dados e resultados, fornecendo gráficos que facilitam a interpretação dos resultados obtidos pelos modelos.
3. **Keras (parte do TensorFlow):** Uma poderosa biblioteca para a construção e treinamento de modelos de aprendizado profundo. A escolha de Keras facilita a implementação de arquiteturas de redes neurais, incluindo LSTM, CNN1D, CNN2D, LSTM-CNN1D e LSTM-CNN2D, sendo usada em destaque neste último para a criação de uma nova função de perda.
4. **Scikit-learn:** Oferece métricas de avaliação de desempenho, como MAE, MSE e  $R^2$ , fundamentais para analisar quão bem os modelos estão realizando as previsões.

#### 4.1.3 Configurações Adicionais

- **Otimizador Adam:** Escolhido para ajustar os pesos do modelo durante o treinamento, otimizando a taxa de aprendizado de forma adaptativa.
- **Estrutura de Rede Neural:** Composta por camadas LSTM, Conv1D, MaxPooling1D, Dropout, Conv2D, Flatten e Reshape, refletindo a diversidade de arquiteturas exploradas neste estudo.

Esse ambiente computacional e seleção de bibliotecas proporcionaram uma base sólida para a implementação dos modelos, combinando eficiência, flexibilidade e ferramentas especializadas para o desenvolvimento e avaliação dos modelos de previsão de vazão afluentes.

## 4.2 Carregamento dos Dados

Para a condução deste estudo, foram essenciais os dados históricos de vazão afluentes das Usinas Tucuruí, Estreito e Lajeado. Esses dados foram disponibilizados pelo Operador Nacional de Sistema Elétrico ((ONS), ) por meio de seu site, abrangendo o extenso período de **01 de janeiro de 1999 a 01 de junho de 2023**. Esse intervalo totaliza 26.754 pontos de dados, com 8.918 amostras para cada uma das usinas, sendo Tucuruí, Estreito e Lajeado.

A escolha dessas usinas específicas se deu pela disponibilidade abrangente de dados. A totalidade das informações necessárias estava acessível, facilitando uma análise abrangente e detalhada.

#### 4.2.1 Procedimento de Carregamento

O arquivo contendo os dados brutos foi carregado utilizando a biblioteca Pandas em Python. O código para esta operação foi o seguinte:

```

1 # Carregando os dados do arquivo
2 arquivo = '/content/drive/MyDrive/TCC_Kevin/DadosBrutos/DadosReservatorios.xlsx'
3 #arquivo = 'DadosReservatorios.xlsx'
4
5 Dados = pd.read_excel(arquivo)

```

#### 4.2.2 Seleção de Dados Relevantes

A tabela de dados bruta continha outras informações, mas para este estudo, apenas o tempo (t) e as vazões das Usinas de Tucuruí (y), Estreito (x) e Lajeado (z) foram considerados. Os *arrays* correspondentes foram definidos da seguinte forma:

```

1 # Aqui iniciamos pegando os dados que importam
2 t = Dados['AMOSTRA'].values
3 yd = Dados['TUCURUÍ'].values
4 xd = Dados['ESTREITO'].values
5 zd = Dados['LAJEADO'].values

```

Essas variáveis agora contêm os dados temporais (t) e as vazões correspondentes das Usinas Tucuruí, Estreito e Lajeado. Esse processo de carregamento e seleção é crucial para a preparação dos dados antes de sua aplicação nos modelos de aprendizado de máquina.

### 4.3 Função `Split_Sequences`

Para viabilizar a entrada de dados nos modelos de aprendizado de máquina, uma função específica, denominada `split_sequences`, foi desenvolvida. Esta função é fundamental para criar padrões de entrada e saída apropriados para o treinamento dos modelos. Assim, tem a finalidade de dividir as sequências temporais em sub-sequências, facilitando a preparação dos dados para o treinamento dos modelos preditivos.

```

1 # Aqui definimos a função split_sequences() uma vez.
2 # Em seguida é só chamá-la sempre que precisar.
3
4 def split_sequences(sequences, n_steps_in, n_steps_out):
5     X, y = list(), list()
6     for i in range(len(sequences)):
7         # encontrar o final deste padrão
8         end_ix = i + n_steps_in

```

```

9     out_end_ix = end_ix + n_steps_out-1
10    # verificar se estamos além do conjunto de dados
11    if out_end_ix > len(sequences):
12        break
13    # reunir as partes de entrada e saída do padrão
14    seq_x = sequences[i:end_ix, :-1] # Entrada: Tucuruí e Estreito
15    seq_z = sequences[i:end_ix, -1] # Entrada: Lajeado
16    seq_y = sequences[end_ix-1:out_end_ix, -1] # Saída: Tucuruí
17    X.append(np.column_stack((seq_x, seq_z))) # Entradas:Tuc., Estreito e Lajeado
18    y.append(seq_y)
19    return np.array(X), np.array(y)

```

### 4.3.1 Explicação dessa Função

A função `split_sequences` recebe três parâmetros:

- `sequences`: representa a sequência multivariada que será dividida em amostras.
- `n_steps_in`: é o número de passos temporais a serem considerados como entrada (*lookback*), que nesse caso o `nsi` foi igual a 30 .
- `n_steps_out`: é o número de passos temporais a serem previstos como saída, que nesse caso o `nso` foi igual a 7.

A função utiliza índices para extrair as partes relevantes da sequência, levando em consideração o número de passos definidos. Assim, essa função percorre a sequência e para cada ponto, extrai a entrada (Tucuruí e Estreito) e a saída (Tucuruí) de acordo com o número de passos definidos. A entrada é então combinada, incluindo a vazão de Lajeado, e as amostras são acumuladas em listas separadas para `X` (entrada) e `y` (saída).

Essa função proporciona a estruturação adequada dos dados para o treinamento dos modelos, tornando-se uma etapa crítica na preparação dos dados para a modelagem.

## 4.4 Normalização dos Dados

A normalização dos dados desempenha um papel crucial na etapa de preparação dos dados para a modelagem da previsão de vazões afluente da UHE-Tucuruí. Essa técnica é essencial para colocar os dados em uma escala comparável, promovendo um desempenho mais eficiente dos modelos. Nesse contexto, o processo de normalização é aplicado:

```

1  ymax = np.max(yd)
2  y = yd/ymax
3  x = xd/ymax
4  z = zd/ymax

```

Cada etapa desse processo possui um significado específico:

- `ymax = np.max(yd)`: Encontra o valor máximo das vazões de Tucuruí (`yd`).

- $y = yd/ymax$ : Divide os valores das vazões de Tucuruí ( $yd$ ) pelo valor máximo ( $ymax$ ), normalizando os dados no intervalo de 0 a 1.
- $x = xd/ymax$ : Divide os valores das vazões de Estreito ( $xd$ ) pelo valor máximo ( $ymax$ ), normalizando os dados no intervalo de 0 a 1.
- $z = zd/ymax$ : Divide os valores das vazões de Lajeado ( $zd$ ) pelo valor máximo ( $ymax$ ), normalizando os dados no intervalo de 0 a 1.

Assim, a normalização dos dados é um processo importante, pois garante que todas as características tenham um impacto igual na modelagem. Isso ajuda a evitar problemas de escala que poderiam afetar o treinamento do modelo, permitindo que ele aprenda de maneira eficaz e produza resultados mais precisos.

## 4.5 Estruturação dos Modelos

Neste contexto, será delineada a estruturação dos cinco modelos distintos desenvolvidos para a previsão de vazão afluyente da UHE-Tucuruí. Cada modelo é detalhado com sua arquitetura específica, todos implementados com a biblioteca Keras em Python.

Durante o processo de treinamento de todos os modelos e sua consolidação em um único arquivo, é gerado um conjunto de resultados que pode ser observado na coluna Configurações nas próximas tabelas. Nessa coluna, as informações sobre as dimensões das saídas de cada camada são apresentadas de forma detalhada. É importante destacar, o termo None que é utilizado para representar que as dimensões da saída podem variar de acordo com as características dos dados de entrada. Esse aspecto denota uma notável flexibilidade em relação ao tamanho da saída, o que é essencial para a adaptação do modelo a diferentes cenários.

Outro aspecto relevante que encontramos nesse conjunto de resultados é a seção Parâmetros. Esta seção indica o número de parâmetros ajustáveis contidos em cada camada do modelo. Os parâmetros são valores que o modelo pode ajustar durante o processo de treinamento, e desempenham um papel crucial na capacidade da rede neural em aprender e se adaptar aos dados. Portanto, uma análise minuciosa dos parâmetros é fundamental para avaliar o desempenho geral do modelo.

Além disso, na linha Total de Parâmetros, encontramos a quantidade total de parâmetros no modelo. Além disso, essa quantidade é expressa em kilobytes (KB), que é uma unidade de medida para dados digitais. Essa representação em KB fornece uma ideia clara do tamanho do modelo e dos recursos computacionais necessários para a sua implementação. Portanto, é uma informação relevante para avaliar a viabilidade prática do modelo em diferentes contextos.

É importante destacar que as camadas com um valor de 0 para parâmetros, como o MaxPooling e a camada Flatten, desempenham funções essenciais na arquitetura da rede neural sem introduzir parâmetros treináveis. A camada MaxPooling realiza uma operação de redução espacial, preservando apenas o valor máximo em uma janela deslizante, sem a necessidade de aprender pesos ou vieses. Da mesma forma, a camada Flatten tem a função de reformatar os dados, convertendo-os em um vetor unidimensional, mas sem contribuir com elementos de aprendizado, pois não realiza cálculos com parâmetros ajustáveis. Essa característica é crucial para entender a estrutura da rede, destacando camadas que desempenham operações específicas sem a necessidade de adaptação durante o treinamento.

### 4.5.1 Modelo 1: LSTM

O primeiro modelo é uma Rede Neural Recorrente baseada na arquitetura LSTM. A LSTM é conhecida por sua capacidade de capturar relações de longo prazo em sequências temporais. A arquitetura consiste em uma camada LSTM seguida por uma camada densa e uma camada de saída linear. O modelo é compilado com o otimizador Adam e a função de perda Mean Squared Error (MSE).

```

1  # Arquitetura do modelo
2  model = Sequential()
3
4  # Uma camada LSTM
5  model.add(LSTM(64, activation='relu', input_shape=(nsi, nf)))
6
7  # Uma camada densa com ativação ReLU
8  model.add(Dense(50, activation='relu'))
9
10 # Camada de saída com ativação linear
11 model.add(Dense(nso, activation='linear'))
12
13 # Compilando o modelo com otimizador Adam e função de perda MSE
14 model.compile(optimizer=Adam(learning_rate=0.001), loss='mse')
```

Tabela 3 – Resumo do Modelo LSTM

Camada (Layer)	Configurações
lstm (LSTM)	Saída: (None, 64), Parâmetros: 17,664
dense (Dense)	Saída: (None, 50), Parâmetros: 3,250
dense_1 (Dense)	Saída: (None, 7), Parâmetros: 357
<b>Total de Parâmetros</b>	21,271 (83.09 KB)
<b>Treináveis</b>	21,271 (83.09 KB)
<b>Não Treináveis</b>	0 (0.00 Byte)

Fonte: Autoria própria.

A estrutura do modelo compreende três camadas principais:

#### 1. Camada LSTM:

- **Configuração:** 64 unidades com função de ativação ReLU.
- Esta camada LSTM, composta por 17,664 parâmetros ajustáveis, é projetada para aprender padrões temporais complexos inerentes aos dados de vazão. A escolha da função de ativação ReLU visa introduzir não linearidades, permitindo ao modelo capturar relações mais complexas nos dados.

#### 2. Camada Densa Intermediária:

- **Configuração:** 50 unidades com ativação ReLU.
- Composta por 3,250 parâmetros ajustáveis, essa camada desempenha um papel fundamental na redução da dimensionalidade dos dados antes de atingirem

a última camada. Sua ativação ReLU adiciona não linearidades essenciais ao processo.

### 3. Camada de Saída Linear:

- **Configuração:** 7 unidades com ativação linear.
- Responsável pela produção das saídas finais, essa camada emprega a função de perda Mean Squared Error (MSE) e o otimizador Adam durante o treinamento. Seus 357 parâmetros são ajustados para otimizar a correspondência entre as previsões do modelo e os valores reais de vazão.

A análise detalhada dos parâmetros evidencia a complexidade e a capacidade de adaptação da camada LSTM, enquanto as camadas subsequentes contribuem para a modelagem eficiente dos dados. O total de 21,271 parâmetros ajustáveis destaca a riqueza da capacidade de aprendizado do modelo. A alocação desses parâmetros permite ao modelo não apenas compreender os padrões específicos nos dados de entrada, mas também ajustar-se de maneira dinâmica às nuances das séries temporais hidroelétricas.

Em termos de eficiência computacional, o modelo LSTM ocupa 83.09 KB, uma informação crucial para avaliar sua viabilidade prática em diferentes contextos. A totalidade dos parâmetros é treinável, garantindo uma adaptação contínua do modelo aos dados. Essa abordagem, combinada com a escolha cuidadosa das funções de ativação, otimizadores e métricas de avaliação, fundamenta a robustez e eficácia do modelo LSTM na tarefa desafiadora de prever a vazão afluente.

#### 4.5.2 Modelo 2: CNN1D

O segundo modelo utiliza uma camada de convolução 1D para extrair características relevantes de dados sequenciais, seguida por uma camada de pooling e uma camada densa. A camada de saída é linear, e o modelo é compilado com o otimizador Adam e a função de perda MSE.

```

1  # Arquitetura do modelo
2  model = Sequential()
3
4  # Uma camada de convolução 1D
5  model.add(Conv1D(filters=64, kernel_size=3, activation='relu', input_shape=(nsi, nf)))
6
7  # Uma camada de pooling (agrupamento)
8  model.add(MaxPooling1D(pool_size=2))
9
10 # Achatamento dos dados
11 model.add(Flatten())
12
13 # Uma camada densa com ativação ReLU
14 model.add(Dense(50, activation='relu'))
15
16 # Camada de saída com ativação linear
17 model.add(Dense(nso, activation='linear'))
18
19 # Compilando o modelo com otimizador Adam e função de perda MSE

```

```
20 model.compile(optimizer='adam', loss='mse')
```

Tabela 4 – Resumo do Modelo CNN1D

Camada (Layer)	Configurações
conv1d (Conv1D)	Saída: (None, 28, 64), Parâmetros: 832
max_pooling1d (MaxPooling1D)	Saída: (None, 14, 64), Parâmetros: 0
flatten (Flatten)	Saída: (None, 896), Parâmetros: 0
dense (Dense)	Saída: (None, 50), Parâmetros: 44,850
dense_1 (Dense)	Saída: (None, 7), Parâmetros: 357
<b>Total de Parâmetros</b>	46,039 (179.84 KB)
<b>Treináveis</b>	46,039 (179.84 KB)
<b>Não Treináveis</b>	0 (0.00 Byte)

Fonte: Autoria própria.

#### 1. Conv1D (Camada de Convolução 1D):

- **Configuração:** 64 unidades com função de ativação ReLU.
- Esta camada de convolução 1D possui 832 parâmetros ajustáveis, projetados para extrair características importantes dos dados sequenciais. A saída da camada tem dimensões (None, 28, 64).
  - **(None):** Número dinâmico de amostras processadas em cada lote durante o treinamento.
  - **(28):** Comprimento da dimensão sequencial na saída.
  - **(64):** Número de filtros na camada, representando a quantidade de características distintas que a camada está tentando aprender.

#### 2. MaxPooling1D (Camada de Max Pooling 1D):

- **Configuração:** Pooling de tamanho 2.
- Esta camada de max pooling não possui parâmetros treináveis (0 parâmetros). A saída da camada tem uma forma de (None, 14, 64).

#### 3. Flatten (Camada de Flatten):

- **Configuração:** Achatamento dos dados.
- Esta camada de flatten não possui parâmetros treináveis (0 parâmetros). A saída da camada tem uma forma de (None, 896).

#### 4. Camada Densa (Dense):

- **Configuração:** 50 unidades com ativação ReLU.
- A camada densa tem 44,850 parâmetros ajustáveis e é utilizada para reduzir a dimensionalidade dos dados antes de atingirem a última camada.

#### 5. Camada Densa Final:

- **Configuração:** 7 unidades com ativação linear.
- A última camada densa tem 357 parâmetros e produz a saída final do modelo. Com 7 unidades, corresponde ao número de saídas que está prevendo (nso=7).

No contexto específico do modelo CNN1D, observa-se que a camada de convolução 1D utiliza None em suas dimensões de saída. Essa característica é particularmente significativa, indicando que a saída da camada convolucional 1D será bidimensional, adaptando-se dinamicamente ao comprimento da sequência de entrada. Essa adaptação é fundamental

para lidar com dados de séries temporais de comprimentos variáveis, conferindo ao modelo a capacidade de processar diferentes comprimentos de sequência de maneira eficaz.

O total de 46,039 parâmetros ajustáveis destaca a notável capacidade de aprendizado do modelo. No âmbito da eficiência computacional, é importante observar que o modelo CNN1D requer 179.84 KB e todos os parâmetros são treináveis.

### 4.5.3 Modelo 3: CNN2D

O terceiro modelo é uma Rede Neural Convolutiva 2D (CNN2D). Consiste em uma camada de convolução 2D, seguida por uma camada de *max pooling*, uma camada de *flatten* e duas camadas densas, todas com ativação *ReLU*. A camada de saída é linear, e o modelo é compilado com o otimizador *Adam* e a função de perda MSE.

```

1 # Arquitetura do modelo
2 model = Sequential()
3
4 # Uma camada de convolução 2D
5 model.add(Conv2D(filters=64, kernel_size=(3, 3), activation='relu', input_shape=(nsi, nf, 1)))
6
7 # Uma camada de pooling (agrupamento)
8 model.add(MaxPooling2D(pool_size=(2, 2)))
9
10 # Achatamento dos dados
11 model.add(Flatten())
12
13 # Uma camada densa com ativação ReLU
14 model.add(Dense(50, activation='relu'))
15
16 # Camada de saída com ativação linear
17 model.add(Dense(nso, activation='linear'))
18
19 # Compilando o modelo com otimizador Adam e função de perda MSE
20 model.compile(optimizer='adam', loss='mse')

```

Tabela 5 – Resumo do Modelo CNN2D

Camada (Layer)	Configurações
conv2d (Conv2D)	Saída: (None, 28, 2, 64), Parâmetros: 640
max_pooling2d (MaxPooling2D)	Saída: (None, 14, 1, 64), Parâmetros: 0
flatten (Flatten)	Saída: (None, 896), Parâmetros: 0
dense (Dense)	Saída: (None, 50), Parâmetros: 44,850
dense_1 (Dense)	Saída: (None, 7), Parâmetros: 357
<b>Total de Parâmetros</b>	45,847 (179.09 KB)
<b>Treináveis</b>	45,847 (179.09 KB)
<b>Não Treináveis</b>	0 (0.00 Byte)

Fonte: Autoria própria.

### 1. Conv2D (Camada de Convolução 2D):

- **Configuração:** 64 unidades com função de ativação ReLU.
- Esta camada de convolução 2D, composta por 640 parâmetros ajustáveis, é projetada para extrair características importantes dos dados sequenciais. A saída da camada tem uma forma de (None, 28, 2, 64).
  - **(None):** Representa o número de amostras processadas em cada lote, adaptando-se dinamicamente durante o treinamento.
  - **(28):** Indica o comprimento da dimensão sequencial na saída.
  - **(2):** Refere-se à profundidade, indicando o número de canais produzidos pela camada de convolução.
  - **(64):** Representa o número de filtros na camada, ou seja, a quantidade de características distintas que a camada está tentando aprender.

### 2. MaxPooling2D (Camada de Max Pooling 2D):

- **Configuração:** Pooling de tamanho 2.
- Esta camada de max pooling não possui parâmetros treináveis (0 parâmetros). A saída da camada tem uma forma de (None, 14, 1, 64).

### 3. Flatten (Camada de Flatten):

- **Configuração:** Achatamento dos dados.
- Esta camada de flatten não possui parâmetros treináveis (0 parâmetros). A saída da camada tem uma forma de (None, 896).

### 4. Camada Densa (Dense):

- **Configuração:** 50 unidades com ativação ReLU.
- A camada densa tem 44,850 parâmetros ajustáveis e é utilizada para reduzir a dimensionalidade dos dados antes de atingirem a última camada.

### 5. Camada Densa Final:

- **Configuração:** 7 unidades com ativação linear.
- A última camada densa tem 357 parâmetros e produz a saída final do modelo. Com 7 unidades, corresponde ao número de saídas que está prevendo (nso=7).

O total de 45,847 parâmetros ajustáveis destaca a riqueza e sofisticação da capacidade de aprendizado desse modelo. No âmbito da eficiência computacional, é relevante notar que o modelo CNN2D ocupa 179.09 KB, uma informação crucial para avaliar sua viabilidade prática em diferentes cenários de aplicação. Todos os parâmetros são treináveis, assegurando uma adaptação contínua e flexível do modelo aos padrões identificados nos dados.

#### 4.5.4 Modelo 4: LSTM-CNN1D

O quarto modelo combina uma camada de convolução 1D com uma camada LSTM. A convolução permite a extração de características espaciais, enquanto a LSTM captura padrões temporais de longo prazo. O modelo é compilado com o otimizador Adam e a função de perda MSE.

```

1 # Arquitetura do modelo
2 model = Sequential()
3
4 # Uma camada de convolução
5 model.add(Conv1D(filters=64, kernel_size=3, activation='relu', input_shape=(nsi, nf)))

```

```

6
7 # Uma camada de pooling
8 model.add(MaxPooling1D(pool_size=2))
9
10 # Uma camada LSTM
11 model.add(LSTM(64, activation='relu'))
12
13 # Uma camada densa com ativação ReLU
14 model.add(Dense(50, activation='relu'))
15
16 # Camada de saída com ativação linear
17 model.add(Dense(nso, activation='linear'))
18
19 # Compilando o modelo com otimizador Adam e função de perda MSE
20 model.compile(optimizer=Adam(learning_rate=0.001), loss='mse')

```

Tabela 6 – Resumo do Modelo LSTM-CNN1D

Camada (Layer)	Configurações
conv1d_1 (Conv1D)	Saída: (None, 28, 64), Parâmetros: 832
max_pooling1d_1 (MaxPooling1D)	Saída: (None, 14, 64), Parâmetros: 0
lstm_1 (LSTM)	Saída: (None, 64), Parâmetros: 33,024
dense_2 (Dense)	Saída: (None, 50), Parâmetros: 3,250
dense_3 (Dense)	Saída: (None, 7), Parâmetros: 357
<b>Total de Parâmetros</b>	37,463 (146.34 KB)
<b>Treináveis</b>	37,463 (146.34 KB)
<b>Não Treináveis</b>	0 (0.00 Byte)

Fonte: Autoria própria.

#### 1. Conv1D (Camada de Convolução 1D):

- **Configuração:** 64 unidades com função de ativação ReLU.
- Esta camada de convolução 1D, composta por 832 parâmetros ajustáveis, é projetada para extrair características relevantes dos dados sequenciais. A saída da camada tem uma forma de (None, 28, 64).

#### 2. MaxPooling1D (Camada de Max Pooling 1D):

- **Configuração:** Pooling de tamanho 2.
- Esta camada de max pooling não possui parâmetros treináveis (0 parâmetros). A saída da camada tem uma forma de (None, 14, 64).

#### 3. LSTM (Camada Recorrente de Memória de Longo Prazo):

- **Configuração:** 64 unidades com função de ativação ReLU.
- Esta camada LSTM tem 33,024 parâmetros ajustáveis e é utilizada para capturar padrões temporais de longo prazo. A saída da camada tem uma forma de (None, 64).

#### 4. Camada Densa (Dense):

- **Configuração:** 50 unidades com ativação ReLU.
- A camada densa tem 3,250 parâmetros ajustáveis e é utilizada para reduzir a dimensionalidade dos dados antes de atingirem a última camada.

## 5. Camada Densa Final:

- **Configuração:** 7 unidades com ativação linear.
- A última camada densa tem 357 parâmetros e produz a saída final do modelo. Com 7 unidades, corresponde ao número de saídas que está prevendo (nso=7).

A análise detalhada dos parâmetros destaca a complexidade intrínseca e a notável capacidade de adaptação das camadas de convolução 1D e LSTM, sendo as subsequentes contribuintes essenciais para a eficaz modelagem dos dados. Com um total de 37,463 parâmetros ajustáveis, o modelo LSTM-CNN1D exibe uma riqueza notável em sua capacidade de aprendizado. A distribuição estratégica desses parâmetros possibilita que o modelo compreenda não apenas os padrões específicos nos dados de entrada, mas também se ajuste dinamicamente às nuances complexas das séries temporais hidroelétricas.

No que diz respeito à eficiência computacional, destaca-se que o modelo LSTM-CNN1D ocupa 146.34 KB, uma informação vital para avaliar sua viabilidade prática em diversos contextos de aplicação. Todos os parâmetros são treináveis, garantindo uma contínua e adaptativa conformação do modelo aos dados. Esta abordagem, aliada à criteriosa escolha de funções de ativação, otimizadores e métricas de avaliação, fundamenta a robustez e eficácia do modelo LSTM-CNN1D diante da desafiadora tarefa de prever a vazão afluyente.

### 4.5.5 Modelo 5: LSTM-CNN2D

O quinto modelo combina uma camada de convolução 2D com uma camada LSTM. Após a convolução e o achatamento, há uma camada densa e a camada de saída. Além disso, este modelo introduz uma função de perda personalizada, `mse_ponderado`, que atribui diferentes importâncias às diferentes saídas do modelo.

```

1  # Arquitetura do modelo
2  model = Sequential()
3
4  # Uma camada de convolução 2D
5  model.add(Conv2D(filters=64, kernel_size=(3, 3), activation='relu', input_shape=(nsi, nf, 1)))
6
7  # Achatamento dos dados
8  model.add(Flatten())
9
10 # Uma camada densa com ativação ReLU
11 model.add(Dense(nsi * 64, activation='relu'))
12
13 # Uma camada de Reshape para converter a saída
14 model.add(Reshape((nsi, 64)))
15
16 # Uma camada LSTM
17 model.add(LSTM(64, activation='relu'))
18
19 # Uma camada densa com ativação ReLU
20 model.add(Dense(50, activation='relu'))
21

```

```

22 # Camada de saída com ativação linear
23 model.add(Dense(nso, activation='linear'))
24
25 # Compilando o modelo com otimizador Adam e função de perda mse_ponderado
26 model.compile(optimizer=Adam(learning_rate=0.001), loss=mse_ponderado)

```

Tabela 7 – Resumo do Modelo LSTM-CNN2D

Camada (Layer)	Configurações
conv2d (Conv2D)	Saída: (None, 28, 2, 64), Parâmetros: 640
flatten (Flatten)	Saída: (None, 3584), Parâmetros: 0
dense (Dense)	Saída: (None, 1920), Parâmetros: 6,883,200
reshape (Reshape)	Saída: (None, 30, 64), Parâmetros: 0
lstm (LSTM)	Saída: (None, 64), Parâmetros: 33,024
dense_1 (Dense)	Saída: (None, 50), Parâmetros: 3,250
dense_2 (Dense)	Saída: (None, 7), Parâmetros: 357
<b>Total de Parâmetros</b>	6,920,471 (26.40 MB)
<b>Treináveis</b>	6,920,471 (26.40 MB)
<b>Não Treináveis</b>	0 (0.00 Byte)

Fonte: Autoria própria.

### 1. Conv2D (Camada de Convolução 2D):

- **Configuração:** 64 unidades com kernel de tamanho (3, 3) e função de ativação ReLU.
- Esta camada de convolução 2D tem 640 parâmetros.
- A saída da camada tem uma forma de (None, 28, 2, 64).

### 2. Flatten (Camada de Flattening):

- Esta camada de flattening não possui parâmetros treináveis (0 parâmetros).
- A saída da camada tem uma forma de (None, 3584).

### 3. Dense (Camada Densa):

- **Configuração:** 1920 unidades com função de ativação ReLU.
- A camada densa tem 6,883,200 parâmetros.

### 4. Reshape (Camada de Reshape):

- Esta camada de reshape não possui parâmetros treináveis (0 parâmetros).
- A saída da camada tem uma forma de (None, 30, 64).

### 5. LSTM (Camada Recorrente de Memória de Longo Prazo):

- **Configuração:** 64 unidades com função de ativação ReLU.
- Esta camada LSTM tem 33,024 parâmetros.
- A saída da camada tem uma forma de (None, 64).

### 6. Camada Densa (Dense):

- **Configuração:** 50 unidades com função de ativação ReLU.
- A camada densa tem 3,250 parâmetros.

### 7. Camada Densa Final:

- **Configuração:** 7 unidades com ativação linear.
- A última camada densa tem 357 parâmetros e produz a saída final do modelo. Com 7 unidades, corresponde ao número de saídas que está prevendo (nso=7).

### 8. Total de Parâmetros:

- O modelo LSTM-CNN2D tem um total de 6,920,471 parâmetros, com 26.40 MB de espaço necessário para armazená-los.

### 9. Treináveis e Não Treináveis:

- Todos os parâmetros são treináveis, o que significa que serão ajustados durante o treinamento para otimizar o desempenho do modelo. Não há parâmetros não treináveis neste modelo.

O total de 6,920,471 parâmetros ajustáveis destaca a excepcional riqueza na capacidade de aprendizado do modelo LSTM-CNN2D. A estratégica alocação desses parâmetros confere ao modelo a habilidade não apenas de compreender os padrões específicos presentes nos dados de entrada, mas também de ajustar-se dinamicamente às sutilezas das séries temporais hidroelétricas.

Quanto à eficiência computacional, é relevante salientar que o modelo LSTM-CNN2D ocupa 26.40 MB, uma informação de suma importância para a avaliação de sua viabilidade prática em diferentes contextos de aplicação. Todos os parâmetros são treináveis, assegurando uma contínua e adaptativa conformação do modelo aos dados.

#### 4.5.5.1 Função mse\_ponderado

A função de perda `mse_ponderado` foi criada para o Modelo 5 (LSTM-CNN2D). Essa função calcula o erro quadrático médio (MSE) ponderado, onde cada saída tem um peso correspondente. O vetor de pesos é criado como um vetor crescente, e o erro é multiplicado por esses pesos antes de calcular a média. Isso permite atribuir diferentes importâncias às diferentes saídas durante o treinamento.

$$\text{mse\_ponderado}(y_{\text{verdadeiro}}, y_{\text{predito}}) = \frac{1}{N} \sum_{i=1}^N \left( \sum_{j=1}^M w_j \cdot (y_{\text{verdadeiro},i,j} - y_{\text{predito},i,j})^2 \right) \quad (4.1)$$

Onde:

- $N$  é o número de amostras.
- $M$  é o número de saídas.
- $w_j$  é o peso atribuído à saída  $j$ , calculado como  $w_j = j$ .

```

1 # Função de perda mse_ponderado
2 import tensorflow as tf
3
4 def mse_ponderado(y_true, y_pred):
5     erro = tf.square(y_true - y_pred) # Calcula o erro quadrático
6     pesos = tf.range(1, tf.shape(erro)[1] + 1) # Cria vetor de pesos crescente
7     pesos = tf.cast(pesos, dtype=tf.float32) # Converte para float32
8     erro_ponderado = erro * pesos # Multiplica o erro pelo vetor de pesos
9     mse = tf.reduce_mean(erro_ponderado, axis=-1) # Calcula a média ao longo do último eixo
10    return mse

```

Essa nova função de perda foi testada em todos os modelos, no entanto, não

apresentou grandes avanços nos resultados. Em vista disso, optou-se por destacar sua inclusão e desempenho apenas no último modelo, o mais complexo, que é o Modelo 5 (LSTM-CNN2D).

## 4.6 Estruturação e Organização dos Dados para Treinamento

A estruturação e organização dos dados desempenham um papel crucial no treinamento eficaz do modelo de previsão de séries temporais. Neste contexto, foram adotadas as seguintes abordagens:

### 4.6.1 Divisão dos Dados

Considerando um conjunto de 7 saídas ( $nso=7$ ), ou seja até 7 dias a frente para prever, o conjunto total de dados ( $N$ ) foi dividido em dados de identificação (treinamento) e dados de validação. O percentual de dados de identificação ( $percIdent$ ) foi fixado em 80%. Dessa forma, foram criados conjuntos de índices para identificação ( $ti$ ) e validação ( $tv$ ), com os respectivos subconjuntos de dados de vazão para Tucuruí ( $yi$ ), Estreito ( $xi$ ), e Lajeado ( $zi$ ).

```

1  # Divisão dos Dados
2  nso = 7
3  percIdent = 0.8
4  N = len(y)
5  Ni = int(percIdent * N)
6  ti = np.arange(0, Ni)
7  tv = np.arange(Ni - nso, N - nso)
8  Nv = len(tv)
9
10 yi = y[ti]
11 yv = y[tv]
12
13 xi = x[ti]
14 xv = x[tv]
15
16 zi = z[ti]
17 zv = z[tv]
```

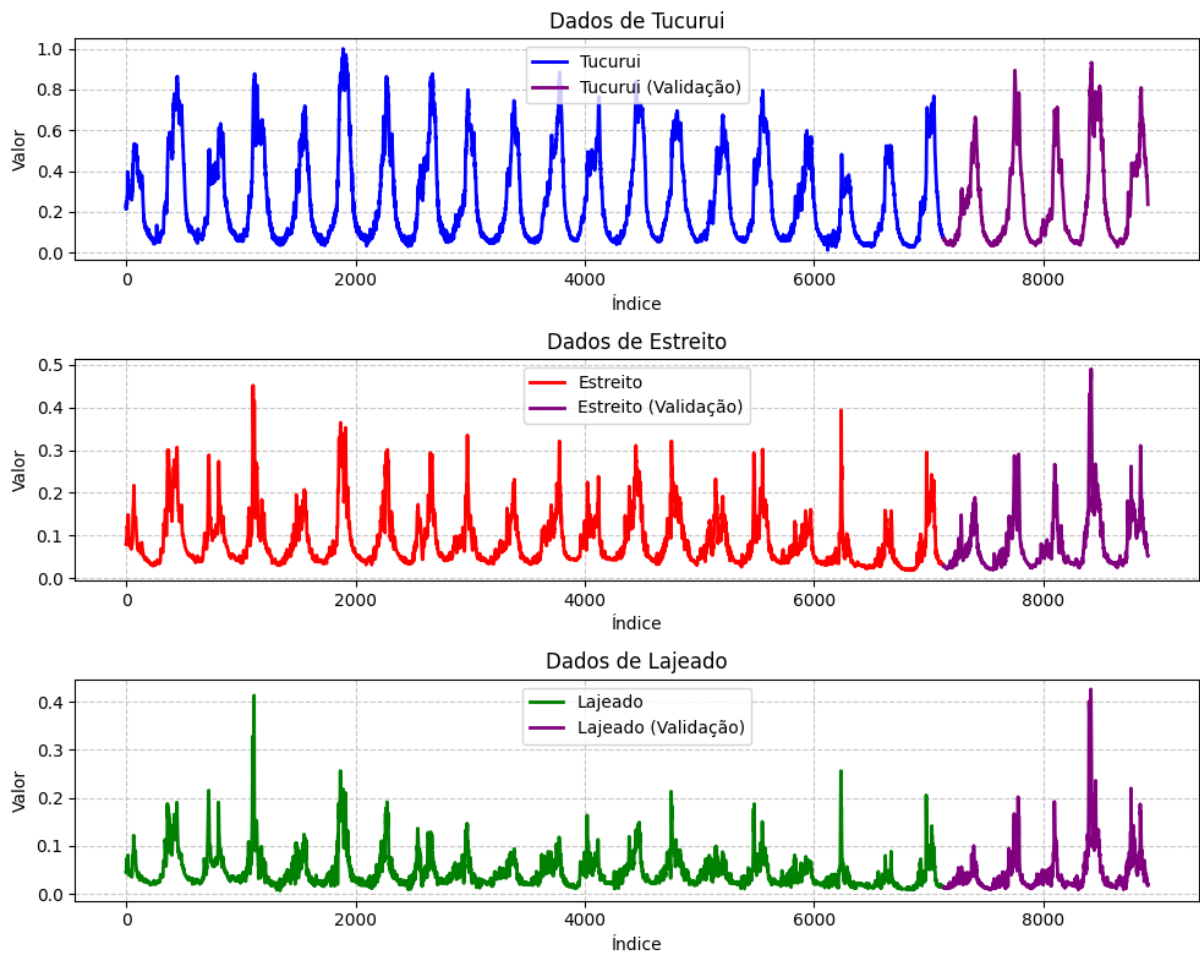
Essa divisão é fundamental, pois permite treinar o modelo com dados de treinamento e avaliá-lo com dados de validação. A inclusão de dados não utilizados no treinamento ajuda a avaliar a capacidade do modelo de generalização.

### 4.6.2 Gráficos de identificação e validação

A visualização temporal dos dados é essencial para identificar padrões e tendências. Foram criados gráficos que representam a distribuição temporal das vazões de Tucuruí, Estreito e Lajeado nos conjuntos de treinamento e validação. Essa análise gráfica fornece

informações valiosas para o treinamento e avaliação dos modelos.

Figura 20 – Dados de identificação e validação



Fonte: Autoria própria.

Para treinar os modelos de aprendizado de máquina, foi criado um conjunto de dados combinando diversas séries temporais. Este conjunto é essencial para preparar as entradas e saídas necessárias para o treinamento dos modelos preditivos.

#### 4.6.3 Geração do Conjunto de Dados

```

1 # Criando o dataset combinando as séries temporais
2 dataset = np.hstack((xi, yi, zi, yii))
3 nsi = 30
4 X_treino, y_treino = split_sequences(dataset, nsi, nso)
5 nf = X_treino.shape[2]

```

O código Python apresentado utiliza a função `split_sequences` para dividir as

sequências temporais em sub-sequências apropriadas para o treinamento. O número de passos temporais de entrada (*lookback*) foi definido como 30, e o número de passos temporais de saída como 7. O resultado é o conjunto de treinamento (`X_treino` e `y_treino`) pronto para ser utilizado nos modelos. O número de features no conjunto de treino é denotado por `nf`.

#### 4.6.4 Organização dos Dados para Treinamento

Os dados de entrada e saída foram organizados no formato adequado para alimentar o modelo. Para cada usina (Tucuruí, Estreito e Lajeado), os dados foram estruturados de acordo com as necessidades do modelo.

```

1 # Organização dos Dados de Treinamento
2 yii = y[ti + 1].reshape(Ni, 1)
3 yi = yi.reshape(Ni, 1)
4 xi = xi.reshape(Ni, 1)
5 zi = zi.reshape(Ni, 1)

```

Essa estruturação é crucial para garantir que os dados sejam apresentados da maneira adequada ao modelo durante o treinamento, facilitando a aprendizagem eficaz das relações temporais e espaciais para prever as vazões afluentes da UHE-Tucuruí.

## 4.7 Treinamento dos Modelos

O treinamento dos modelos é uma etapa crítica no desenvolvimento do sistema de previsão de vazão afluente da UHE-Tucuruí. Cada modelo possui características distintas que requerem diferentes números de épocas (`epochs`) para atingir estabilidade e maximizar o desempenho. Nesta seção, abordaremos o treinamento de cada modelo, destacando as diferenças entre eles e o tempo necessário para o treinamento.

Primeiro, foi criada uma função para medir o tempo de treinamento de cada modelo. Esta função registra o horário de início, treina o modelo e, em seguida, calcula o tempo decorrido. Isso permite determinar o tempo necessário para treinar cada modelo e é útil para avaliar o esforço computacional envolvido.

```

1 # Definindo o tempo inicial
2 tempo_inicial = time.time()
3
4 # Treinando o modelo
5 DadosTreino = model.fit(X_treino, y_treino, epochs=X,
6 batch_size=32, verbose=1, validation_split=0.2)
7
8 # Calculando o tempo decorrido em segundos
9 tempo_decorrido = time.time() - tempo_inicial
10
11 # Convertendo o tempo decorrido para minutos e segundos
12 minutos = int(tempo_decorrido // 60)

```

```

13 segundos = int(tempo_decorrido % 60)
14
15 # Imprimindo o tempo decorrido no formato desejado
16 print(f"Tempo de treinamento: {minutos}m{segundos}s")

```

#### 4.7.1 Diferenças entre os Treinamentos

Cada modelo neste estudo apresentou características distintas que influenciaram significativamente o processo de treinamento. Uma diferença notável é o número de épocas (epochs) que cada modelo requer para atingir estabilidade e desempenho ideal. As seguintes informações destacam as diferenças entre os modelos em termos de épocas de treinamento:

- **Modelo 1 – LSTM:** Treinado por 50 epochs.
- **Modelo 2 – CNN1D:** Treinado por 400 epochs.
- **Modelo 3 – CNN2D:** Treinado por 400 epochs.
- **Modelo 4 – LSTM-CNN1D:** Treinado por 500 epochs.
- **Modelo 5 – LSTM-CNN2D:** Treinado por 500 epochs.

O Modelo 1 - LSTM, por exemplo, mostrou resultados satisfatórios após 50 epochs, refletindo uma convergência mais rápida devido à natureza da camada LSTM.

Por outro lado, os Modelos 2 e 3 - CNN1D e CNN2D requereram treinamentos mais prolongados, com 400 epochs, para alcançar a estabilização de suas curvas de aprendizado. Isso destaca a complexidade adicional introduzida pelas arquiteturas de redes neurais convolucionais no processo de aprendizado.

Os Modelos 4 e 5 - LSTM-CNN1D e LSTM-CNN2D, os mais complexos da análise, demandaram extensos treinamentos, com 500 epochs, a fim de equilibrar eficazmente a complexidade da combinação entre camadas LSTM e convolucionais. A escolha desses números de epochs levou em consideração não apenas a estabilização dos modelos, mas também a otimização do desempenho em relação ao tempo de processamento.

A complexidade dos modelos também se manifestou no tempo de treinamento, uma métrica de grande relevância, especialmente em contextos práticos. A tabela a seguir resume os tempos de treinamento para cada modelo:

#### 4.7.2 Tempo de Treinamento

Tabela 8 – Resumo do Tempo de Treinamento

Modelo	Tempo de Treinamento
LSTM	3m23s
CNN1D	6m22s
CNN2D	6m18s
LSTM-CNN1D	24m26s
LSTM-CNN2D	1h53m46s

Fonte: Autoria própria.

Esses números representam os tempos gastos em treinamento, sendo que os três primeiros modelos, apesar de mais simples, já demandam uma quantidade considerável de tempo. À medida que a complexidade dos modelos aumenta, especialmente nos Modelos 4 e 5, o tempo de treinamento aumenta significativamente, exigindo recursos computacionais mais substanciais.

Essas informações sobre o número de epochs e o tempo de treinamento são fundamentais para compreender o esforço computacional necessário em relação ao desempenho de cada modelo. Tais considerações são cruciais para a seleção do modelo mais apropriado, levando em conta as limitações de recursos disponíveis e as necessidades de tempo em contextos práticos. Esta análise sublinha o fato de que a complexidade do modelo está intimamente relacionada à demanda computacional e ao tempo de treinamento.

## 4.8 Gráficos de Perda durante o Treinamento

A análise dos gráficos de perda durante o treinamento desempenha um papel fundamental na avaliação do desempenho e da estabilidade dos modelos de previsão de vazão. Nesta seção, apresentam-se os gráficos de perda para os modelos LSTM, CNN1D, CNN2D, LSTM-CNN1D e LSTM-CNN2D. A observação desses gráficos permite acompanhar o progresso do treinamento, verificar se a perda está consistentemente diminuindo e fazer ajustes no modelo ou no processo de treinamento, se necessário. Além disso, esses gráficos oferecem informações valiosas para avaliar a convergência e a estabilidade do treinamento.

```

1  # Plotando a perda do treinamento
2  plt.subplot(121)
3  plt.plot(DadosTreino.history['loss'], color='skyblue', linewidth=2)
4  plt.grid(True, linestyle='--', alpha=0.7)
5
6  plt.xlabel('Época', fontsize=12)
7  plt.ylabel('Perda', fontsize=12)
8  plt.title('Histórico de Perda do Treinamento', fontsize=14)
9
10 # Plotando o logaritmo da perda do treinamento
11 plt.subplot(122)
12 plt.plot(np.log(DadosTreino.history['loss']), color='lightcoral', linewidth=2)
13 plt.grid(True, linestyle='--', alpha=0.7)
14
15 plt.xlabel('Época', fontsize=12)
16 plt.ylabel('Logaritmo da Perda', fontsize=12)
17 plt.title('Histórico de Perda do Treinamento (Logaritmo)', fontsize=14)
18
19 # Adicionando legenda
20 plt.legend(['Perda', 'Logaritmo da Perda'], loc='upper right')
21
22 # Exibir os gráficos
23 plt.tight_layout()
24 plt.show()

```

Para a representação visual do treinamento, optou-se por exibir tanto o gráfico de perda convencional quanto o gráfico de logaritmo da perda. Essa escolha é comum em análises de treinamento de modelos, pois oferece várias vantagens cruciais para a compreensão do desempenho do modelo.

Primeiro, o gráfico de perda convencional pode ser sensível a pequenas flutuações, especialmente em modelos mais complexos e treinamentos prolongados. Essa sensibilidade pode dificultar a identificação de padrões significativos na variação natural da perda ao longo das épocas. Por outro lado, o gráfico do logaritmo da perda fornece uma representação mais suave, destacando tendências e tornando mais evidentes as mudanças importantes.

A transformação logarítmica é valiosa porque permite uma interpretação mais intuitiva das variações, especialmente quando se lida com uma ampla gama de valores de perda. Essa técnica facilita a identificação visual de estágios específicos do treinamento onde ajustes ou melhorias podem ser necessários.


Além disso, a análise comparativa entre os dois gráficos é simplificada, uma vez que eles são apresentados lado a lado. Essa abordagem oferece uma visão abrangente do comportamento do modelo ao longo do tempo, permitindo que nuances e tendências gerais sejam compreendidas de forma mais clara.

Para entender a dinâmica dos resultados, é crucial considerar a relação entre a complexidade dos modelos e o desempenho nos gráficos de perda. Notavelmente, observa-se que modelos mais complexos, como o LSTM-CNN2D, podem apresentar gráficos de perda com resultados piores em comparação com modelos menos complexos, como o LSTM ou CNN1D.

A crescente complexidade de um modelo envolve uma maior capacidade de aprendizado e adaptação aos dados. No entanto, em conjuntos de dados específicos ou tarefas de previsão, essa complexidade adicional pode resultar em overfitting, onde o modelo se ajusta demais aos dados de treinamento, perdendo a capacidade de generalização para novos dados. Isso é refletido nos gráficos de perda, onde o modelo complexo pode exibir uma diminuição inicial da perda de treinamento, mas posteriormente apresentar aumento da perda de validação, indicando uma performance inferior em dados não vistos.

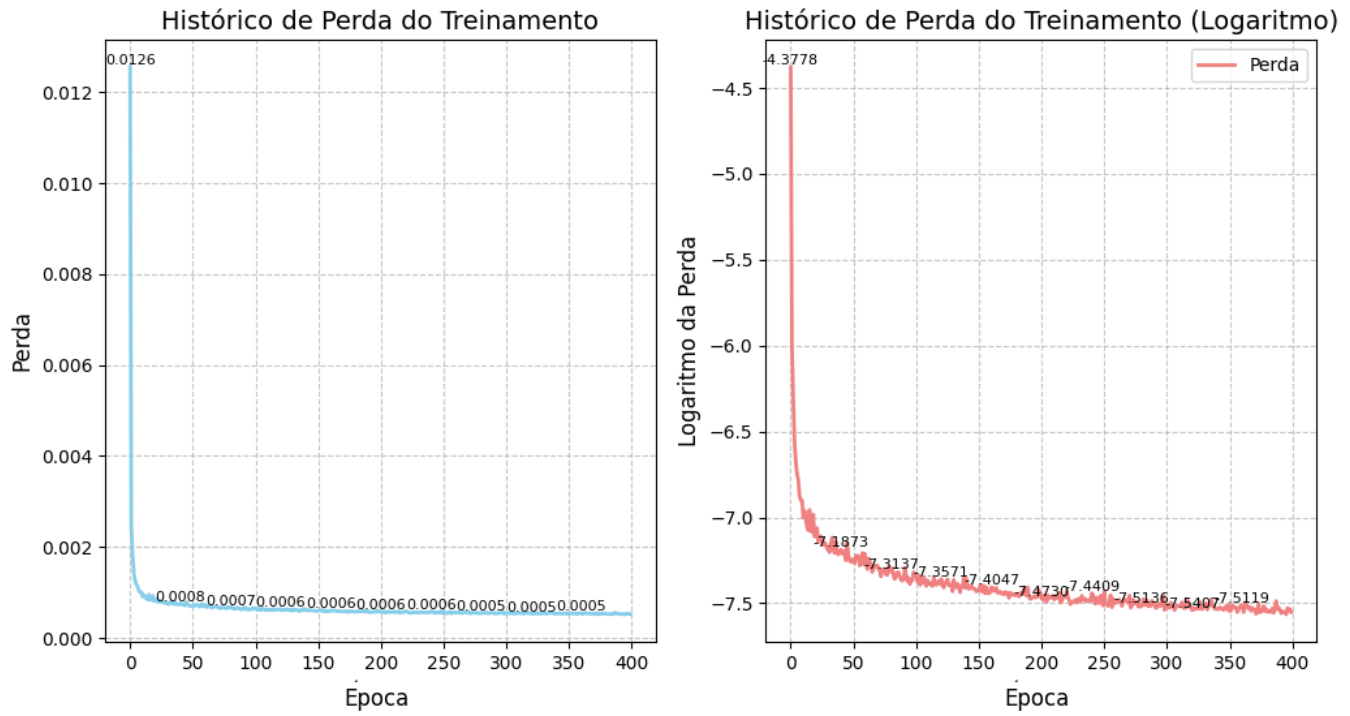
Essa observação destaca a importância de encontrar um equilíbrio entre a complexidade do modelo e a capacidade de generalização, ajustando hiperparâmetros e monitorando atentamente os gráficos de perda durante o treinamento. O entendimento dessa dinâmica contribui para uma escolha mais informada e eficiente de modelos em tarefas de previsão de vazão, considerando a relevância prática e a capacidade de generalização.

Figura 21 – Gráficos de perda do Modelo LSTM.



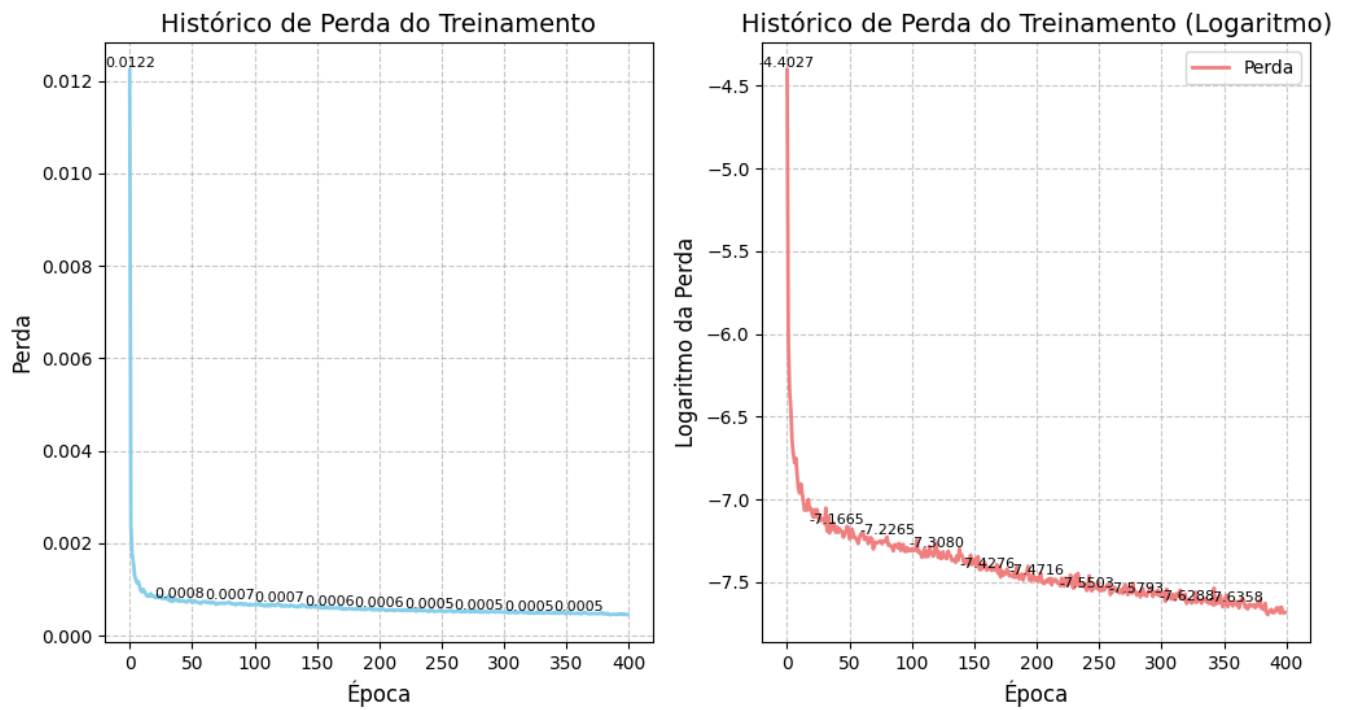
Fonte: Autoria própria.

Figura 22 – Gráficos de perda do Modelo CNN1D.




Fonte: Autoria própria.

Figura 23 – Gráficos de perda do Modelo CNN2D.




Fonte: Autoria própria.

Figura 24 – Gráficos de perda do Modelo LSTM-CNN1D.



Fonte: Autoria própria.

Figura 25 – Gráficos de perda do Modelo LSTM-CNN2D.



Fonte: Autoria própria.

## 4.9 Validação dos Modelos

A validação dos modelos desempenha um papel crucial na avaliação do desempenho fora do ambiente de treinamento, fornecendo informações sobre a capacidade de generalização dos modelos para dados não observados. Portanto, as etapas de preparação e criação do conjunto de validação, bem como a divisão dos dados para avaliação, são essenciais.

```

1 # Dados de validação
2 yvv = y[tv + 1].reshape(Nv, 1)
3 yv = yv.reshape(Nv, 1)
4 xv = xv.reshape(Nv, 1)
5 zv = zv.reshape(Nv, 1)
6
7 # Criação do conjunto de validação
8 dataset_val = np.hstack((xv, yv, zv, yvv))
9 X_teste, y_teste = split_sequences(dataset_val, nsi, nso)

```

### 4.9.1 Preparação dos Dados de Validação

A preparação dos dados de validação envolve as seguintes etapas:

- `yvv = y[tv + 1].reshape(Nv, 1)`: Obtém as sequências temporais de saída do reservatório Tucuruí para o conjunto de validação.
- `yv = yv.reshape(Nv, 1)`: Redimensiona as sequências temporais de entrada do reservatório Tucuruí para o formato adequado.
- `xv = xv.reshape(Nv, 1)`: Redimensiona as sequências temporais de entrada do reservatório Estreito para o formato adequado.
- `zv = zv.reshape(Nv, 1)`: Redimensiona as sequências temporais de entrada do reservatório Lajeado para o formato adequado.

### 4.9.2 Criação do Conjunto de Validação

Para criar o conjunto de validação, as seguintes etapas são executadas:

- `dataset_val = np.hstack((xv, yv, zv, yvv))`: Cria um conjunto de validação combinando as sequências temporais de entrada e saída dos reservatórios Tucuruí, Estreito e Lajeado.
- `X_teste, y_teste = split_sequences(dataset_val, nsi, nso)`: Utiliza a função `split_sequences` para dividir o conjunto de validação em amostras com um determinado número de passos anteriores (`nsi`) e um número de passos futuros (`nso`) para cada amostra. Isso cria os conjuntos de entrada (`X_teste`) e saída (`y_teste`) para o teste do modelo.

Essa estratégia de validação é crucial para verificar como o modelo se comporta em dados não utilizados durante o treinamento, permitindo uma avaliação robusta do desempenho e da capacidade de generalização dos modelos de previsão de vazão.

## 4.10 Previsões

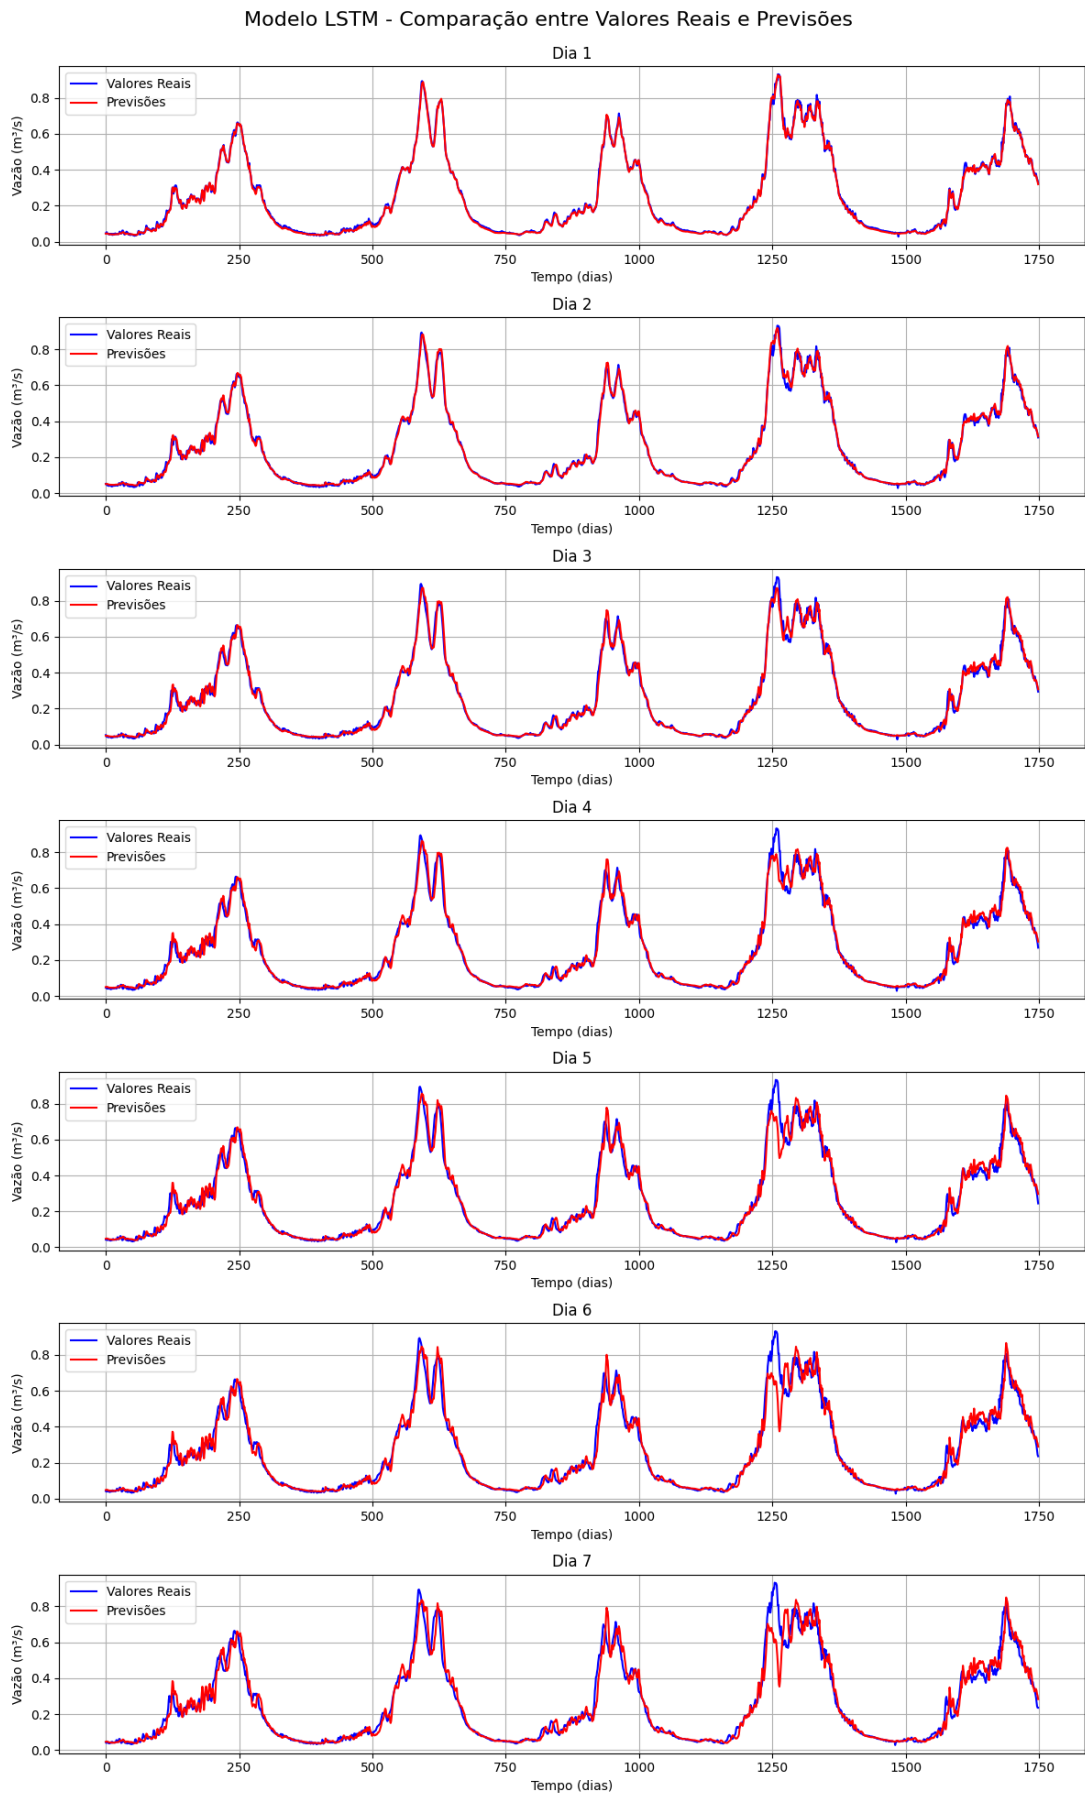
As previsões do modelo representam um aspecto crucial para avaliar sua capacidade de antecipar com precisão as vazões dos reservatórios. Abaixo estão detalhadas as etapas de realização das previsões e a visualização comparativa do desempenho para cada modelo.

```
1 # Realizando previsões
2 yp = model.predict(X_teste)
```

As previsões (`yp`) são obtidas aplicando o modelo aos dados de entrada de teste (`X_teste`), proporcionando uma visão do desempenho do modelo em cenários não vistos durante o treinamento.

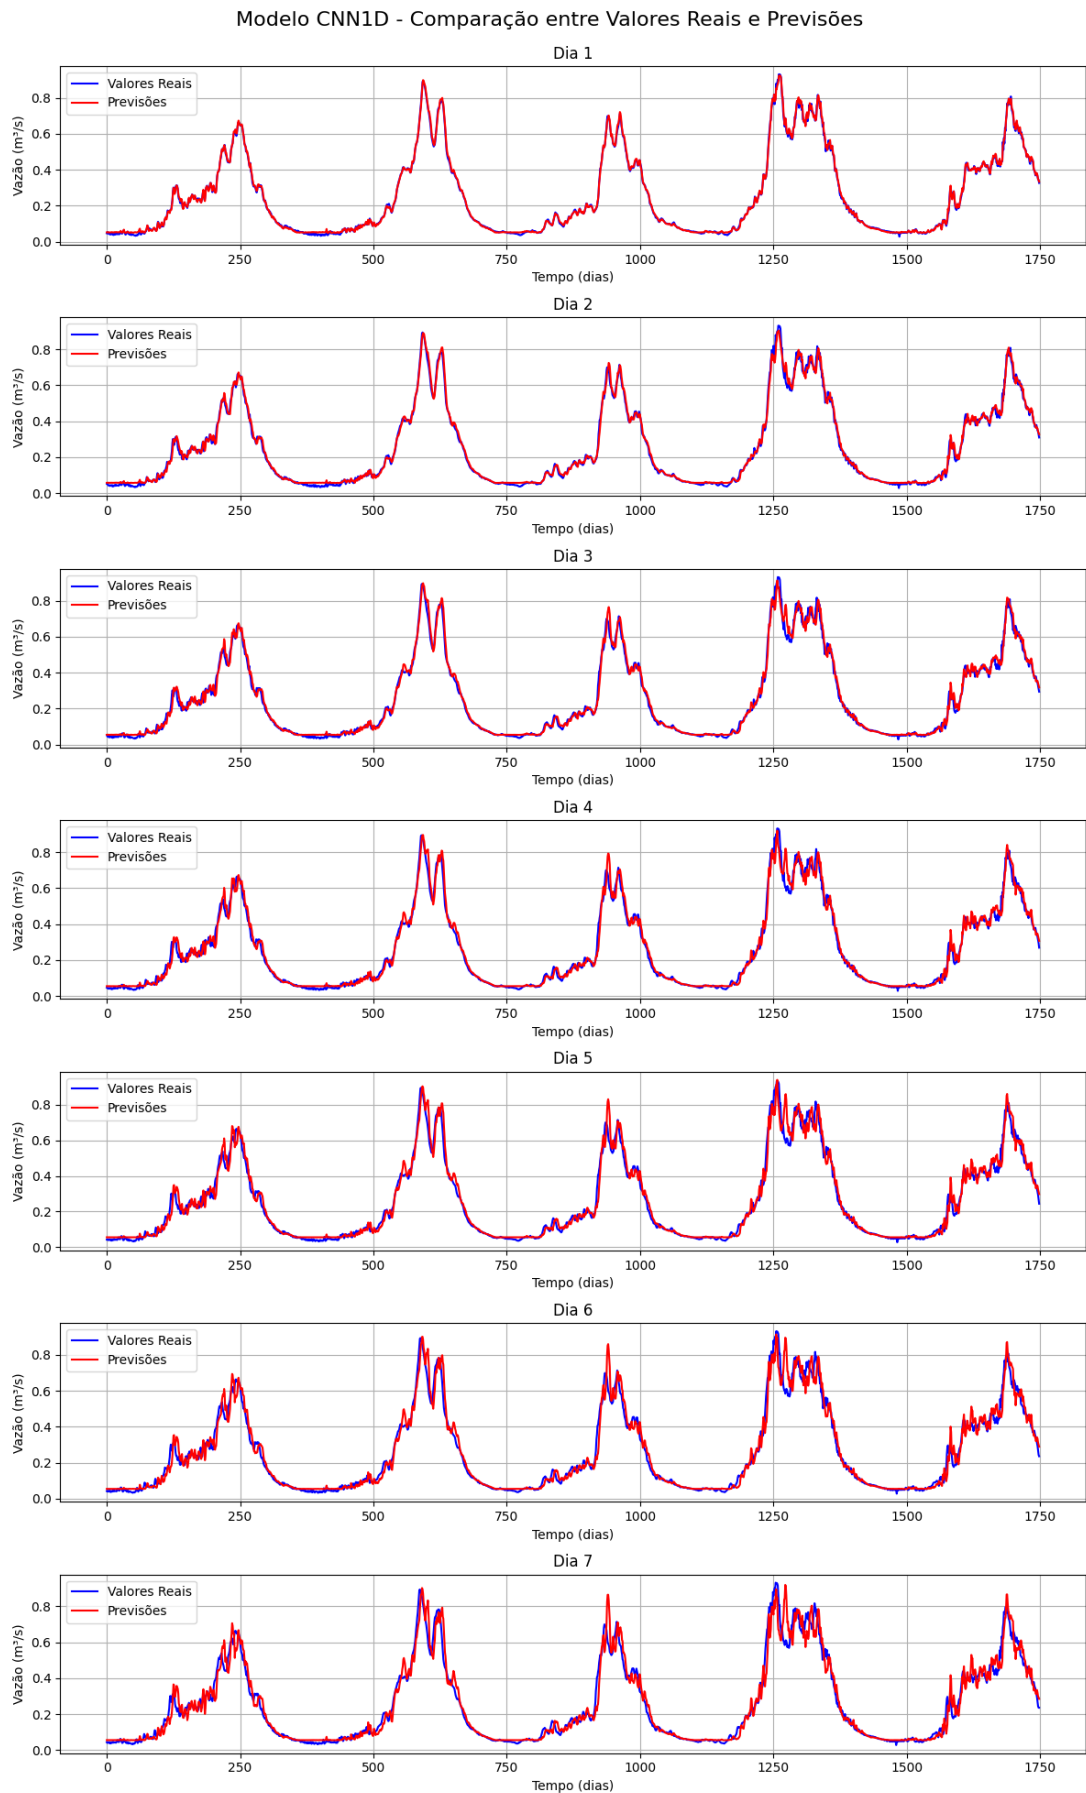
Para avaliar o desempenho, são gerados gráficos com subgráficos separados para cada dia futuro. Cada subgráfico exibe as previsões do modelo (representadas pela linha vermelha) em comparação com os valores reais correspondentes (linha azul) para horizontes temporais de 1 a 7 dias à frente.

Figura 26 – LSTM - Comparação entre Valores Reais e Previsões.



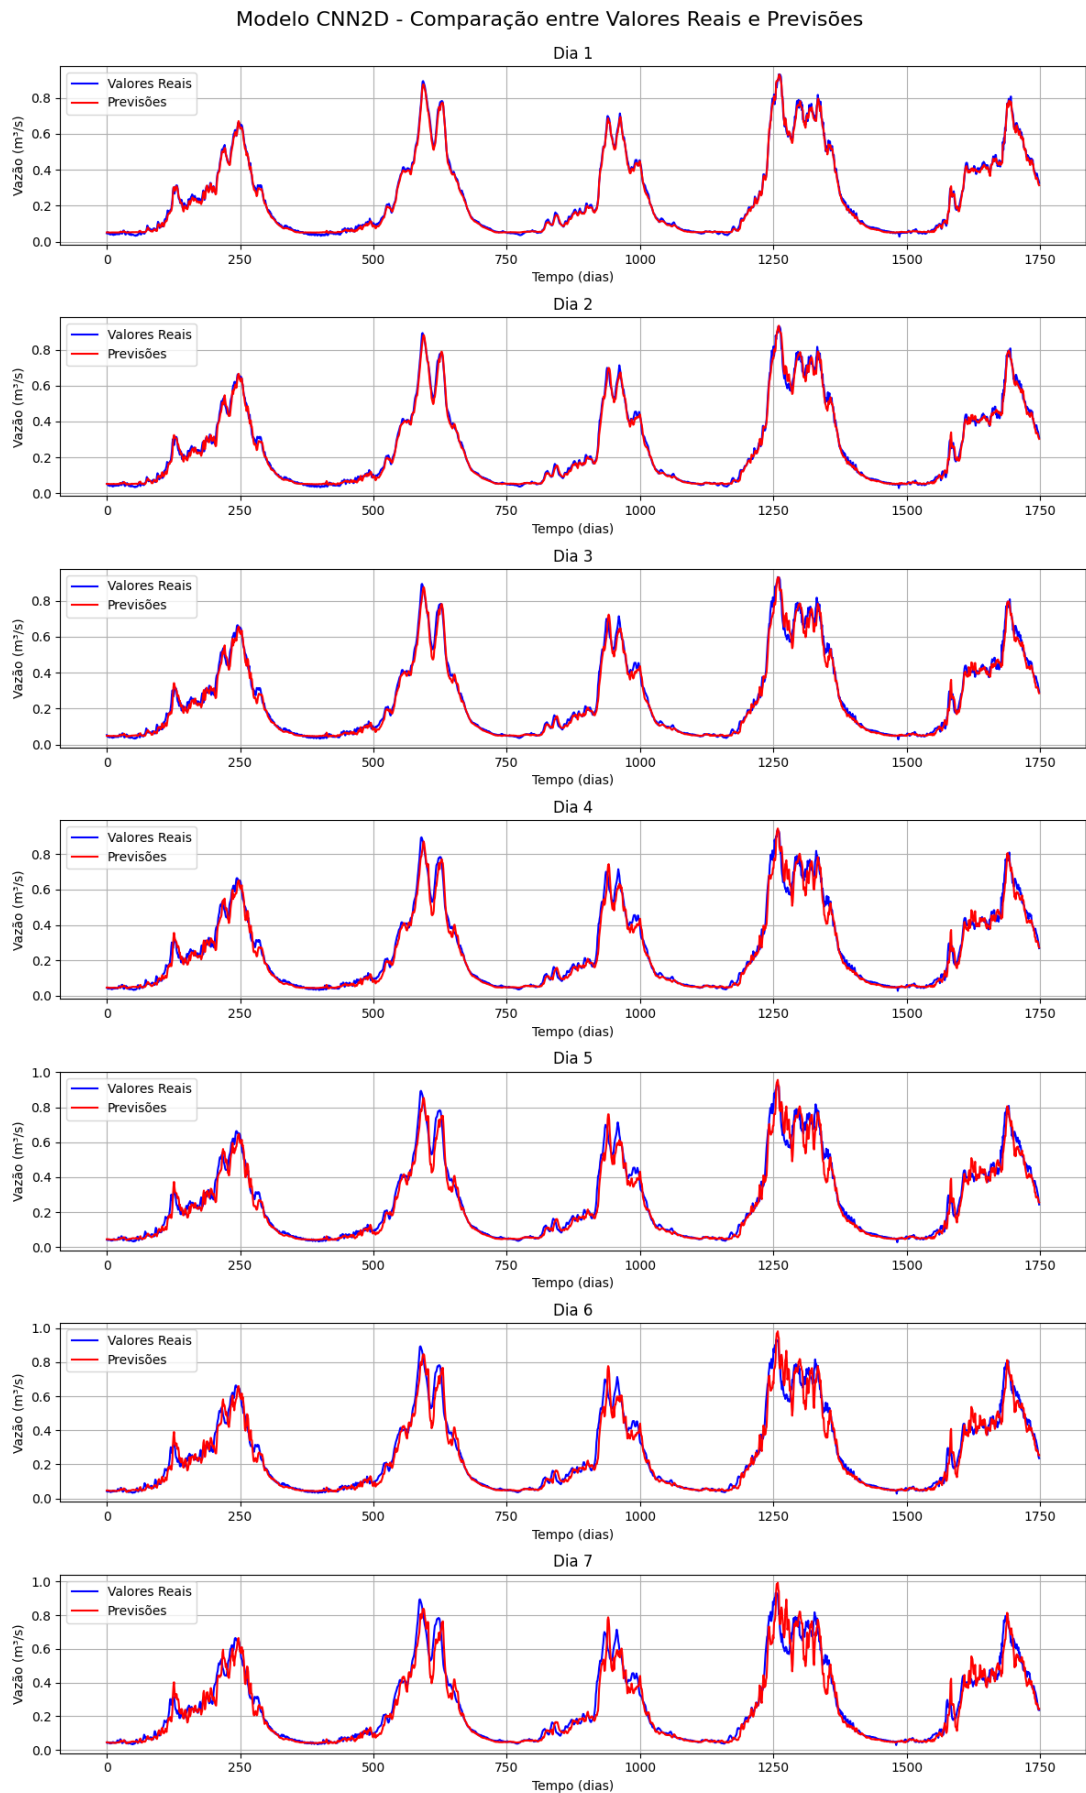
Fonte: Autoria própria.

Figura 27 – CNN1D - Comparação entre Valores Reais e Previsões.



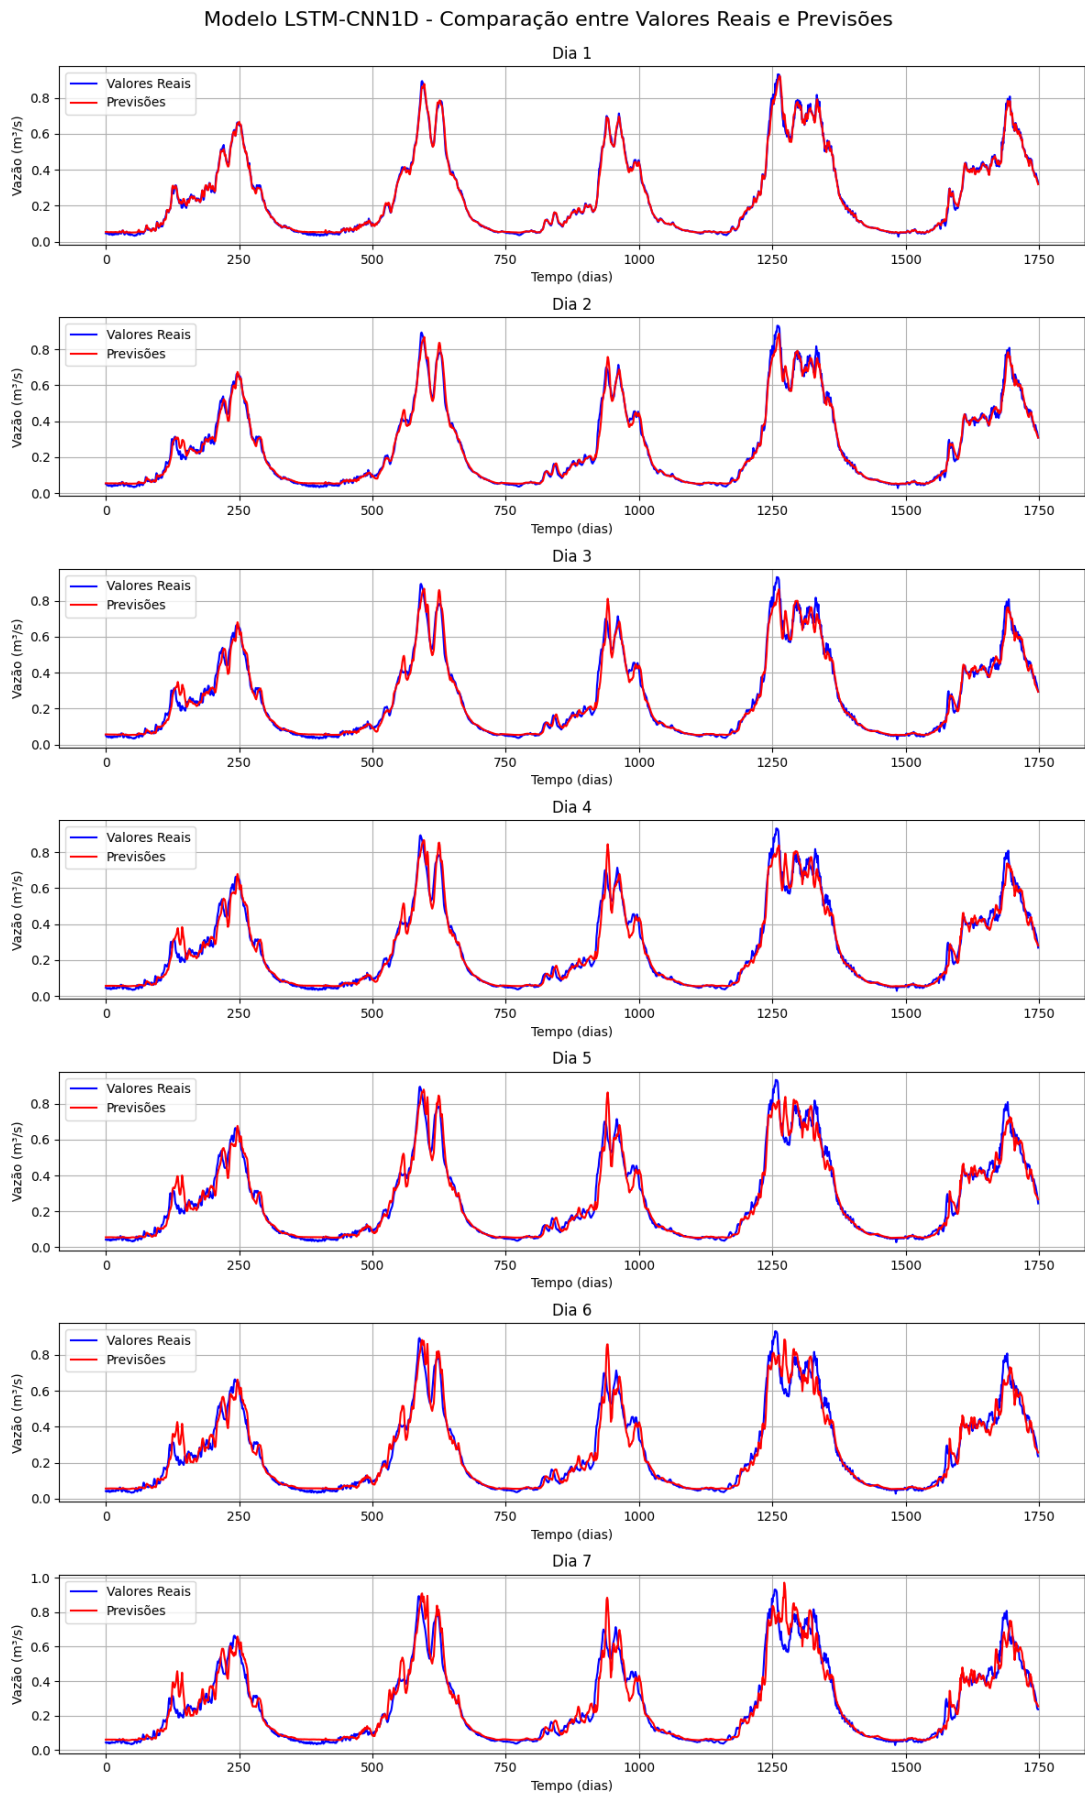
Fonte: Autoria própria.

Figura 28 – CNN2D - Comparação entre Valores Reais e Previsões.



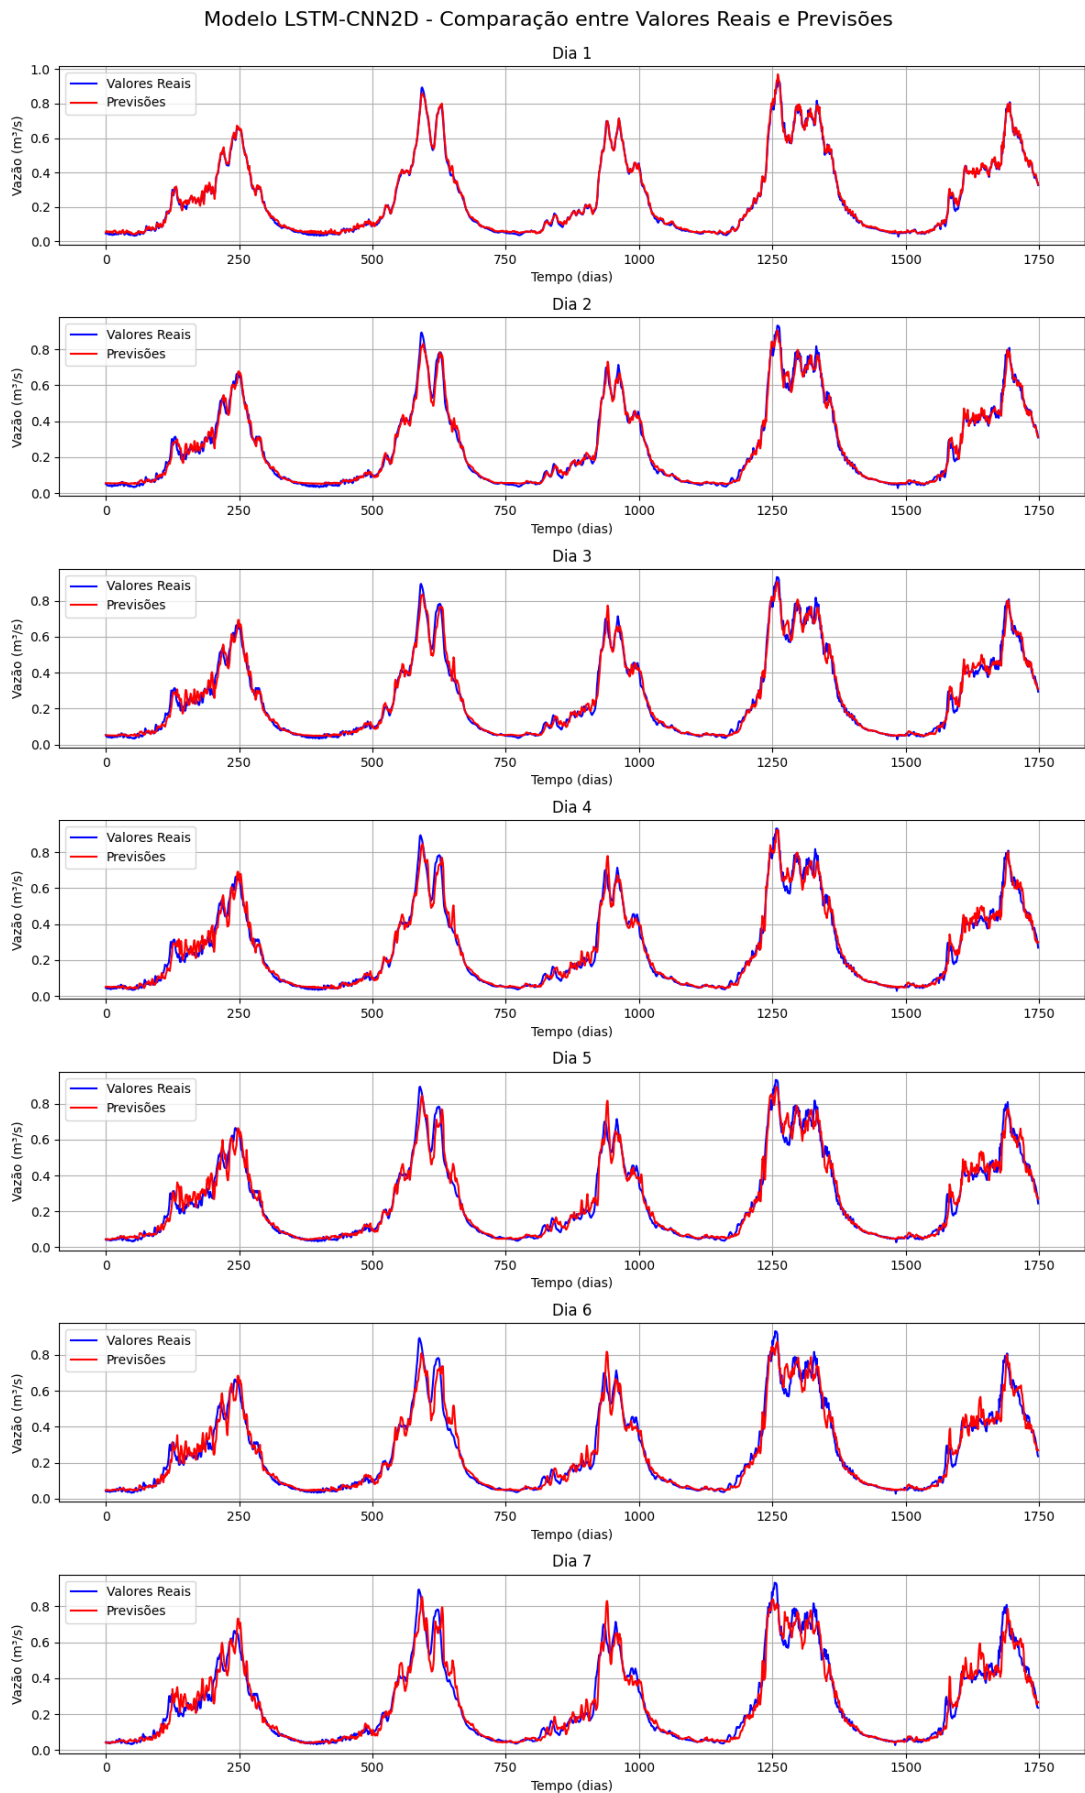
Fonte: Autoria própria.

Figura 29 – LSTM-CNN1D - Comparação entre Valores Reais e Previsões.



Fonte: Autoria própria.

Figura 30 – LSTM-CNN2D - Comparação entre Valores Reais e Previsões.



Fonte: Autoria própria.

Esses gráficos permitem uma análise visual imediata da precisão das previsões em diferentes horizontes temporais, destacando a capacidade de cada modelo em antecipar as variações nas vazões dos reservatórios. Esse processo é essencial para a escolha do modelo mais eficaz e adequado às características específicas dos dados de vazão da UHE-Tucuruí.

#### 4.11 Resultados

A avaliação dos modelos é conduzida por meio de métricas de regressão essenciais para compreender o desempenho em diferentes horizontes temporais. As métricas utilizadas incluem:

1. **MAE (Erro Absoluto Médio):** O MAE representa a média absoluta das diferenças entre os valores reais ( $y_i$ ) e os valores previstos ( $\hat{y}_i$ ). Quanto **menor o valor do MAE**, melhor o desempenho do modelo em termos de precisão.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.2)$$

onde  $n$  é o número de observações.

2. **MSE (Erro Quadrático Médio):** O MSE representa a média dos quadrados das diferenças entre os valores reais ( $y_i$ ) e os valores previstos ( $\hat{y}_i$ ). Quanto **menor o valor do MSE**, melhor o desempenho do modelo em termos de precisão.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.3)$$

onde  $n$  é o número de observações.

3. **R<sup>2</sup> (Coeficiente de Determinação):** O R<sup>2</sup> mede a proporção da variabilidade dos valores reais ( $y_i$ ) que é explicada pelo modelo. **O valor do R<sup>2</sup> varia de 0 a 1**, onde 1 indica um ajuste perfeito do modelo aos dados.

$$R^2 = 1 - \frac{MSE}{\text{Var}(y_i)} \quad (4.4)$$

onde  $\text{Var}(y_i)$  é a variância dos valores reais ( $y_i$ ).

```

1 # Calculando as métricas MAE, MSE, R2 em cada dia
2 efficiency_values = []
3 for n in range(nso):
4     y_true = y_teste[:, n]
5     y_pred = yp[:, n]
6
7     mae = np.mean(np.abs(y_true - y_pred))
8     mse = np.mean(np.square(y_true - y_pred))
9     r2 = r2_score(y_true, y_pred)
10
11     print(f"Dia {n+1}:")
12     print(f"MAE: {mae:.5f}")

```

```

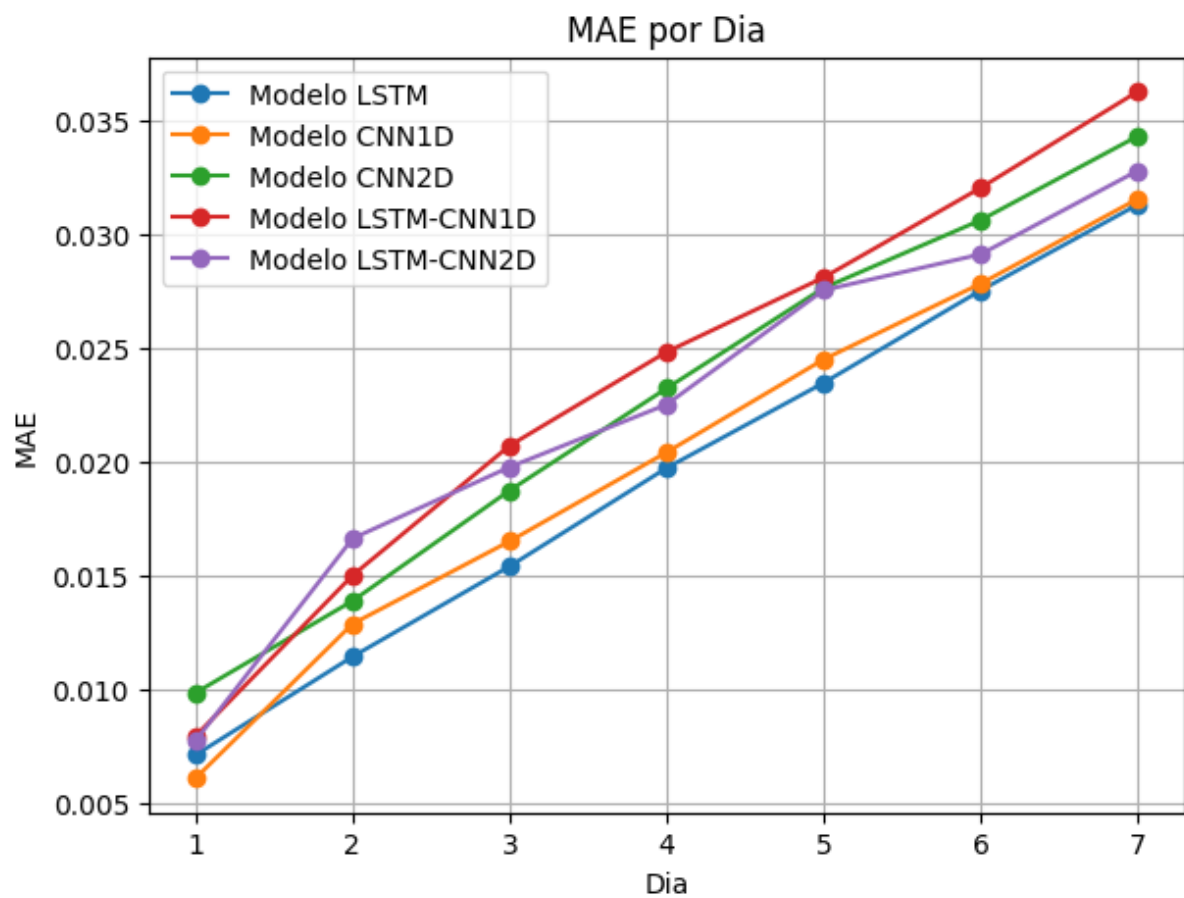
13 print(f"MSE: {mse:.5f}")
14 print(f"R²: {r2:.7f}")
15 print()

```

#### 4.11.1 Gráficos e Tabelas dos Resultados

Para proporcionar uma compreensão visual e comparativa das métricas em um horizonte de 1 a 7 dias, serão apresentados gráficos e tabelas para MAE, MSE e  $R^2$ .

Figura 31 – MAE ao longo de 7 dias



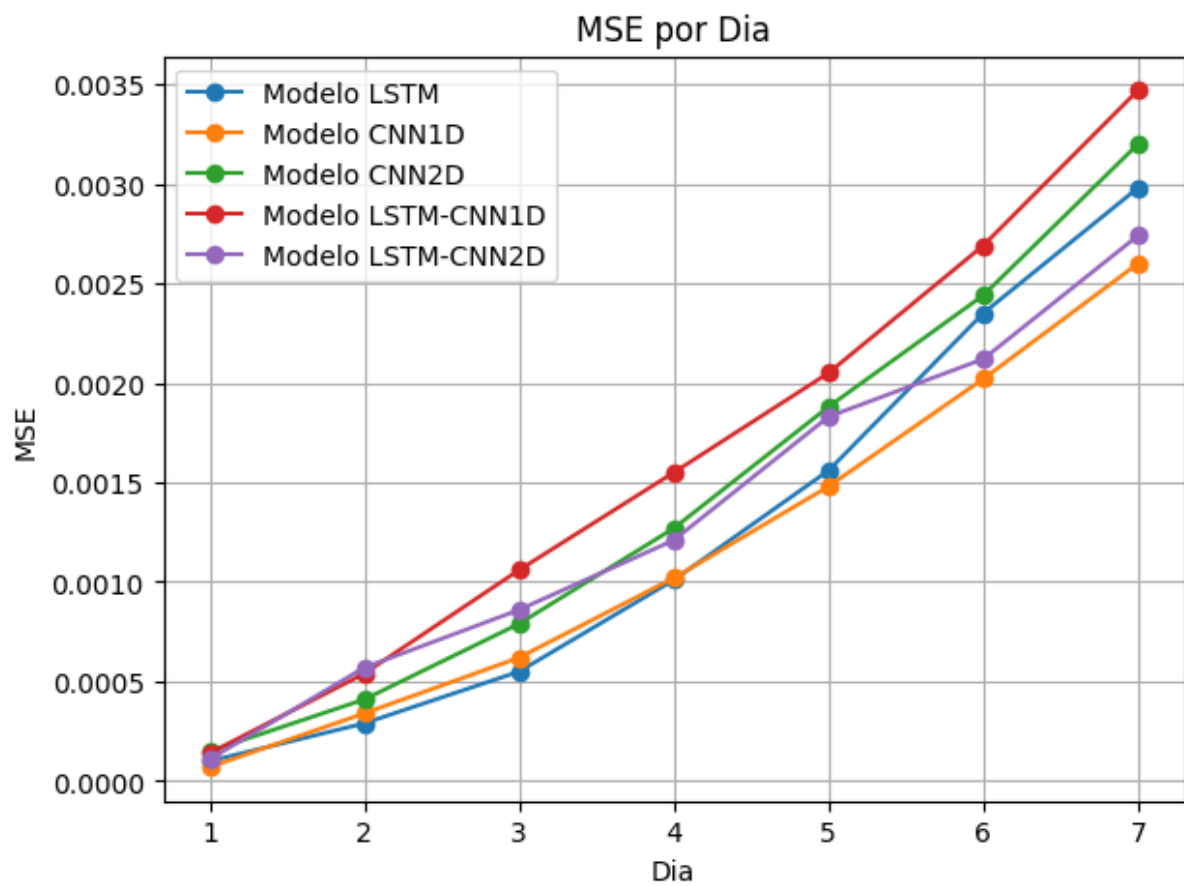
Fonte: Autoria própria.

Tabela 9 – MAE ao longo de 7 dias

Dia	LSTM	CNN1D	CNN2D	LSTM-CNN1D	LSTM-CNN2D
1	0.00709	0.00607	0.00982	0.00792	0.00772
2	0.01141	0.01285	0.01386	0.01498	0.01660
3	0.01538	0.01648	0.01871	0.02068	0.01974
4	0.01970	0.02039	0.02320	0.02480	0.02249
5	0.02344	0.02447	0.02761	0.02807	0.02751
6	0.02750	0.02780	0.03059	0.03201	0.02909
7	0.03127	0.03152	0.03428	0.03624	0.03276

Fonte: Autoria própria.

Figura 32 – MSE ao longo de 7 dias

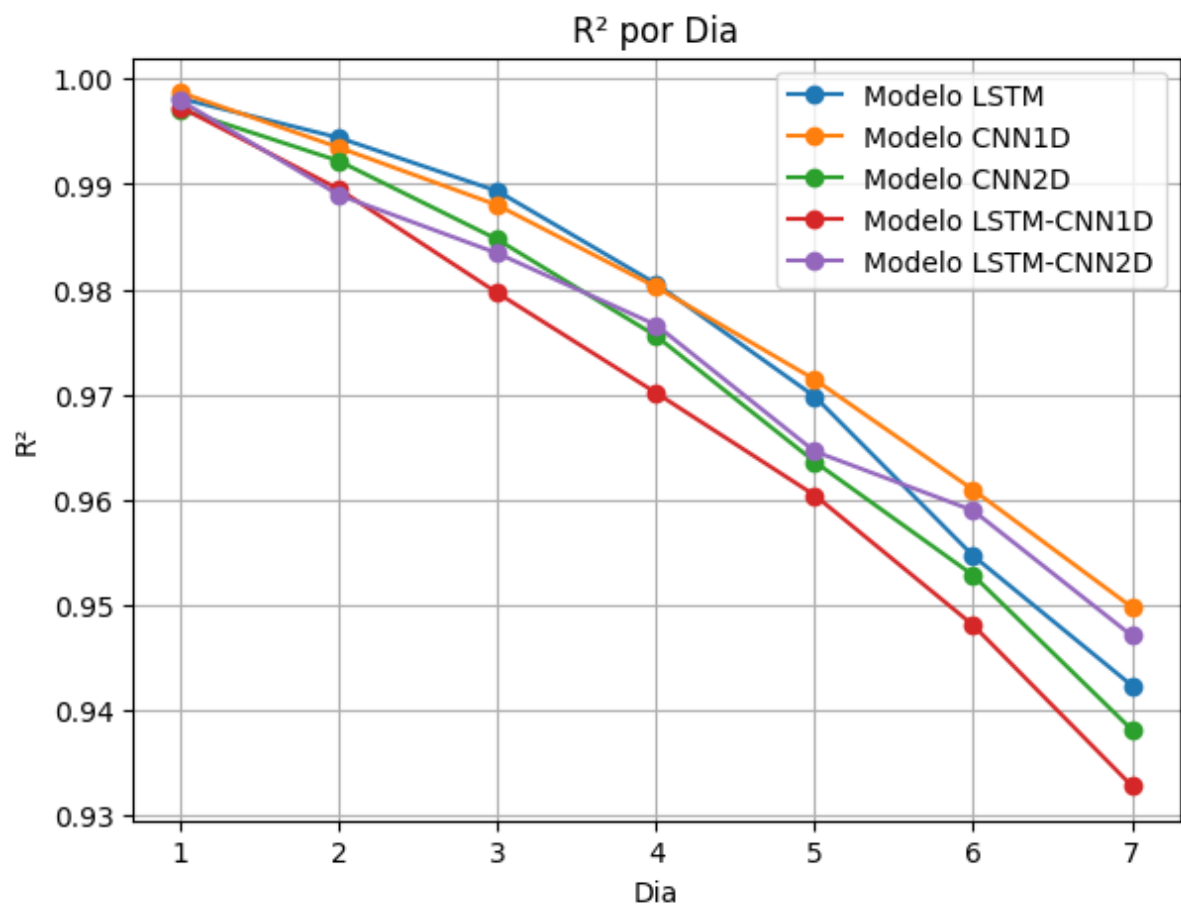


Fonte: Autoria própria.

Tabela 10 – MSE ao longo de 7 dias

Dia	LSTM	CNN1D	CNN2D	LSTM-CNN1D	LSTM-CNN2D
1	0.00010	0.00007	0.00015	0.00014	0.00011
2	0.00029	0.00034	0.00041	0.00054	0.00057
3	0.00055	0.00062	0.00079	0.00106	0.00086
4	0.00101	0.00102	0.00127	0.00155	0.00121
5	0.00156	0.00148	0.00188	0.00205	0.00183
6	0.00235	0.00202	0.00244	0.00269	0.00212
7	0.00298	0.00260	0.00320	0.00347	0.00274

Fonte: Autoria própria.

Figura 33 –  $R^2$  ao longo de 7 dias

Fonte: Autoria própria.

Tabela 11 –  $R^2$  ao longo de 7 dias

Dia	LSTM	CNN1D	CNN2D	LSTM-CNN1D	LSTM-CNN2D
1	0.99813	0.99870	0.99710	0.99731	0.99793
2	0.99440	0.99347	0.99219	0.98951	0.98896
3	0.98933	0.98799	0.98473	0.97965	0.98342
4	0.98053	0.98022	0.97557	0.97017	0.97662
5	0.96983	0.97144	0.96363	0.96045	0.96461
6	0.95469	0.96095	0.95284	0.94810	0.95899
7	0.94238	0.94982	0.93818	0.93285	0.94711

Fonte: Autoria própria.

Esses elementos gráficos e tabelares fornecerão uma visão abrangente do desempenho dos modelos em diferentes horizontes temporais, facilitando a escolha do modelo mais eficaz para a previsão de vazão nos reservatórios. Isso permitirá uma análise precisa do desempenho de cada modelo em cenários de previsão de curto e longo prazo.

#### 4.12 Análise dos Resultados

Na análise dos resultados, observou-se distintas performances entre os modelos implementados, revelando nuances importantes na capacidade de previsão para séries temporais específicas. A abordagem adotada neste estudo buscou não apenas compreender os resultados quantitativos, mas também discernir o porquê por trás das escolhas metodológicas e suas implicações.

Para avaliar o desempenho dos modelos em relação às três métricas de regressão, foi optado por utilizar o  $R^2$  que é Coeficiente de Determinação, para uma análise mais profunda. Esta métrica foi escolhida devido à sua capacidade de indicar a proximidade dos resultados em relação a 1, sendo que valores mais próximos de 1 indicam resultados superiores. O  $R^2$  oferece uma medida eficaz para a qualidade das previsões, permitindo uma análise abrangente da capacidade de cada modelo em explicar a variação nas vazões diárias ao longo do tempo em usinas hidrelétricas. Assim podemos destacar os seguintes resultados:

- **Modelo com Melhor Desempenho no Primeiro Dia:**

- O modelo com o  $R^2$  mais alto no primeiro dia é o Modelo CNN1D com um valor de 0.99870. Este modelo supera os demais no início da análise, indicando uma capacidade inicial superior em explicar a variação nas vazões diárias. Esse fenômeno pode ser associado à sua habilidade de resposta rápida a flutuações nos dados, revelando-se especialmente eficaz na detecção de padrões imediatos. No entanto, vale ressaltar que, apesar das diferenças, as métricas dos demais modelos foram bem próximas, mostrando a viabilidade de todas as abordagens neste cenário.

- **Estabilidade ao Longo do Tempo:**

- Para avaliar a estabilidade ao longo do tempo, calculamos a média do  $R^2$  para cada modelo. Essa média considera todos os dias da semana, proporcionando uma visão geral do desempenho consistente. Os resultados são os seguintes:

$$\begin{aligned} \text{Média do } R^2 \text{ para LSTM} &= \frac{0.99813 + \dots + 0.94238}{7} \approx 0.97694 \\ \text{Média do } R^2 \text{ para CNN1D} &= \frac{0.99870 + \dots + 0.94982}{7} \approx 0.97420 \\ \text{Média do } R^2 \text{ para CNN2D} &= \frac{0.99710 + \dots + 0.93818}{7} \approx 0.96661 \\ \text{Média do } R^2 \text{ para LSTM-CNN1D} &= \frac{0.99731 + \dots + 0.93285}{7} \approx 0.96535 \\ \text{Média do } R^2 \text{ para LSTM-CNN2D} &= \frac{0.99793 + \dots + 0.94711}{7} \approx 0.97017 \end{aligned}$$

Com base nas médias, observa-se que o Modelo LSTM tem a média mais alta, indicando uma estabilidade consistente ao longo dos dias. Essa consistência aponta para a robustez do modelo, evidenciando sua habilidade de generalização em diferentes contextos temporais. Nesse caso, as métricas mantiveram-se consistentes, sugerindo que a escolha do Modelo LSTM pode ser favorável em cenários onde a estabilidade e a capacidade de manter um desempenho constante são prioridades. Essa robustez é crucial em ambientes hidrológicos dinâmicos, onde as condições podem variar consideravelmente ao longo do tempo.

- **Melhor Desempenho no Sétimo Dia:**

- O modelo com o  $R^2$  mais alto no sétimo dia é o Modelo CNN1D com um valor de 0.94982. Este modelo supera os demais no final da análise, indicando um desempenho superior neste ponto específico. Este modelo, singularmente, demonstra uma capacidade excepcional de compreender padrões complexos em sequências temporais mais extensas, evidenciando uma melhoria progressiva ao longo do horizonte temporal. Novamente, é importante mencionar que, embora o CNN1D tenha se destacado no sétimo dia, os outros modelos também apresentaram resultados competitivos.

É fundamental ressaltar que a análise do desempenho dos modelos pode ser estendida à consideração das métricas MAE que é Erro Médio Absoluto e MSE o Erro Quadrático Médio, ambas refletindo a precisão do modelo. Valores menores para essas métricas indicam um melhor ajuste do modelo aos dados observados. Nota-se que os resultados obtidos foram satisfatórios, atingindo valores na ordem de 0.00 em todos os cenários, com uma tendência geral de decaimento ao longo dos sete dias.

Ao observar as tabelas, que apresentam os valores de MAE e MSE para cada modelo nos diferentes dias, percebe-se a consistência nos baixos valores alcançados. Isso sugere que todos os modelos demonstraram uma capacidade robusta de previsão, minimizando tanto os erros absolutos quanto os quadráticos. Destaca-se que, em todos os casos, os modelos mantiveram uma performance consistente, mesmo considerando as variações ao longo dos dias.

Nos gráficos de erro, torna-se evidente que os modelos híbridos, resultantes da combinação de diferentes arquiteturas, apresentam potencial para aprimoramentos à medida que o número de épocas aumenta. Contudo, é importante notar que esses modelos, embora eficazes, carregam consigo uma considerável carga computacional, demandando mais tempo de processamento.

Essa maior complexidade muitas vezes resulta em execuções prolongadas, excedendo uma hora, o que, por sua vez, pode acarretar desconexões do ambiente. Essas desconexões podem ocorrer devido à exigência computacional intensiva ou a flutuações na conectividade da internet. Este desafio compromete a consistência e registro dos resultados, sugerindo, assim, oportunidades de refinamento em futuros estudos. A otimização da eficiência computacional e a mitigação de possíveis interrupções emergem como áreas promissoras para avançar nas investigações subsequentes.

Ao longo deste trabalho, a narrativa vai além de resultados numéricos, introduzindo justificativas claras para cada observação. As escolhas metodológicas foram explicadas não apenas em termos de métricas de desempenho, mas também em relação à compreensão de como cada modelo lida com diferentes aspectos das séries temporais.

Portanto, esse estudo não é apenas uma avaliação estática, mas um guia para futuras implementações, proporcionando uma escolha informada de modelos com base nas necessidades específicas da aplicação. A compreensão aprofundada de cada modelo não só enriquece a análise, mas também estabelece um fundamento sólido para contínuas melhorias e adaptações, destacando a viabilidade de todos os modelos e fornecendo uma visão abrangente para escolhas futuras.

## 5 CONCLUSÃO

Após uma análise minuciosa e abrangente dos modelos de previsão de séries temporais, visando estimar a vazão afluyente da Usina de Tucuruí e utilizando dados tanto desta usina quanto de outras situadas na mesma bacia, como Estreito e Lajeado, este estudo conclui que a integração de técnicas avançadas de aprendizado de máquina com informações hidroelétricas apresenta-se como uma abordagem altamente promissora para uma previsão precisa em um contexto tão intrincado. Ao mergulhar no cenário prático, esta pesquisa proporcionou um entendimento profundo do desempenho desses modelos, destacando sua aplicabilidade e relevância no âmbito da gestão hídrica e energética.

A implementação prática desses modelos, com o uso de bibliotecas como Pandas, NumPy, Matplotlib e Keras, permitiu uma análise sólida dos dados históricos fornecidos pelo Operador Nacional do Sistema Elétrico (ONS). O foco na disponibilidade de dados extensivos de 1999 a junho de 2023 possibilitou uma investigação abrangente.

O método adotado, desde a estruturação dos dados até a avaliação das métricas de desempenho, proporcionou uma compreensão aprofundada do comportamento de cada modelo. A análise meticulosa dessas métricas revelou que todos os modelos alcançaram resultados satisfatórios, enquanto a inspeção detalhada dos gráficos de perda indicou áreas potenciais para melhorias nos modelos híbridos. A escolha cuidadosa das arquiteturas, incluindo LSTM, CNN1D, CNN2D, LSTM-CNN1D e LSTM-CNN2D, permitiu uma análise holística dos aspectos temporais dos dados.

Apesar dessas conquistas, esta pesquisa também apresenta limitações inerentes à dependência de dados específicos das usinas estudadas e do período abordado. Futuros trabalhos podem explorar diversas direções:

1. **Adaptação a Diferentes Contextos Hidroelétricos:** Investigar a aplicabilidade dos modelos desenvolvidos em diferentes contextos hidroelétricos, considerando variações nas características das usinas e padrões climáticos.
2. **Inclusão de Dados Climáticos:** Incorporar dados climáticos, como índices de precipitação, para entender melhor a influência de fatores externos nas vazões afluentes.
3. **Otimização de Hiperparâmetros:** Realizar uma busca mais extensiva de hiperparâmetros para otimizar ainda mais o desempenho dos modelos, considerando diferentes configurações de camadas e funções de ativação.
4. **Estudo de Generalização:** Avaliar a capacidade de generalização dos modelos em cenários de curto e longo prazo, explorando a robustez dos resultados em diferentes horizontes temporais.
5. **Consideração de Eventos Excepcionais:** Investigar como os modelos respondem a eventos excepcionais, como secas prolongadas ou períodos de chuvas intensas, para melhorar a capacidade de antecipação em situações críticas.
6. **Influência da Bacia do Araguaia:** Explorar a influência dos dados da Bacia do Araguaia nos modelos desenvolvidos para a Bacia do Tocantins. Considerar como a interconexão entre diferentes bacias hidrográficas pode impactar as vazões afluentes das usinas, promovendo uma análise mais abrangente e integrada.
7. **Eficiência Computacional:** Os modelos híbridos, embora promissores, demandam execuções prolongadas, muitas vezes excedendo uma hora. Esta complexidade computacional pode levar a desconexões do ambiente, impactando a consistência dos

resultados. Futuras pesquisas podem focar na otimização da eficiência computacional, explorando estratégias para reduzir o tempo de processamento, como técnicas de paralelização e otimização de algoritmos.

A análise dessas áreas pode aprimorar não apenas a aplicação dos modelos em contextos específicos, mas também contribuir para o desenvolvimento de metodologias mais robustas para previsão de séries temporais em geral. Em síntese, este trabalho não apenas oferece uma implementação técnica, mas também fornece uma narrativa compreensível sobre as escolhas feitas, os desafios encontrados e os resultados obtidos. Está assim, alinhado ao propósito acadêmico de contribuir para o corpo de conhecimento existente, ao mesmo tempo que oferece direcionamento prático para aplicações futuras.

## REFERÊNCIAS

- AHMED, A. M. et al. Modelo híbrido de aprendizagem profunda com algoritmo otimizador de floresta boruta-random para previsão de vazão com índices de modo climático, precipitação e periodicidade. **J. Hidrol. (Amst)**, v. 599, 2021. Citado 2 vezes nas páginas 39 e 40.
- ALI, H. R.; LONGZHI, Y.; LOK, W. W.; WEI, B. **Joint Learning of Temporal Models to Handle Imbalanced Data for Human Activity Recognition**. Acesso em 05/10/2023. Disponível em: <[https://www.researchgate.net/figure/Architecture-of-the-Hybrid-1D-CNN-LSTM-model-for-human-activity-recognition\\_fig4\\_34334155](https://www.researchgate.net/figure/Architecture-of-the-Hybrid-1D-CNN-LSTM-model-for-human-activity-recognition_fig4_34334155)>. Citado na página 45.
- ALZUBAIDI, L. et al. Revisão de aprendizagem profunda: conceitos, arquiteturas cnn, desafios, aplicações, direções futuras. **J. Big Data**, v. 8, 2021. Citado na página 35.
- ANA, A. N. d. e. S. B. **RELATÓRIO DE ANÁLISE DE IMPACTO REGULATÓRIO N 1/2020/CORSH/SOE**. 2020. <[https://participacao-social.ana.gov.br/api/files/Relatorio\\_de\\_AIR\\_sistema\\_Hidrico\\_do\\_Rio\\_Tocantins\\_1607537134591.pdf](https://participacao-social.ana.gov.br/api/files/Relatorio_de_AIR_sistema_Hidrico_do_Rio_Tocantins_1607537134591.pdf)>. Acessado em : 21/09/2023. Citado 3 vezes nas páginas 20, 21 e 22.
- ANALYTICSVIDHYA. **An Overview on Long Short Term Memory (LSTM)**. 2022. Acesso em 05/10/2023. Disponível em: <<https://www.analyticsvidhya.com/blog/2022/03/an-overview-on-long-short-term-memory-lstm/>>. Citado na página 37.
- ANEEL. **Lista de usinas cadastradas - Aneel**. 2021. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>>. Citado 3 vezes nas páginas 26, 27 e 32.
- BALBINOT, R.; OLIVEIRA, N. K. d.; VANZETTO, S. C.; PEDROSO, K.; VALÉRIO, F. O papel da floresta no ciclo hidrológico em bacias hidrográficas. **Ambiência**, v. 4, n. 1, p. 131–149, 2008. Citado na página 22.
- BELOTTI, J. T. **Previsão de vazões afluentes utilizando redes neurais artificiais e ensembles**. Dissertação (Mestrado em Ciência da Computação), Ponta Grossa, 2019. Acesso em: 15/09/2023. Disponível em: <<https://repositorio.utfpr.edu.br/jspui/handle/1/4037>>. Citado na página 13.
- BRASIL. **Atlas da bacia hidrográfica do rio Tocantins-Araguaia**. Goiânia: SEMA, 2018. Disponível em: <<http://www.semاد.go.gov.br/index.php/publicacoes/category/149-atlas-das-bacias-hidrograficas?download=612:atlas-da-bacia-hidrografica-do-rio-tocantins-araguaia>>. Citado na página 19.
- BRITO, D. F. et al. Variabilidade sazonal das vazões afluentes e o controle do nível d'água da uhe tucuruí. **Revista Brasileira de Recursos Hídricos**, v. 23, p. e12, 2018. Citado na página 32.
- BRUNNER, M. I.; ZOISS, R.; SCHAEFLI, B. Long short-term memory networks for the simulation of discharge in river networks. **Journal of Hydrology**, v. 550, p. 430–442, 2017. Citado na página 14.

CHO, K. et al. Aprendendo representações de frases usando codificador-decodificador rnn para tradução automática estatística. In: . [S.l.: s.n.], 2014. Pré-impressão do arXiv arXiv:1406.1078. Citado na página 35.

EARTH, G. **UHEs presentes no rio tocantins**. 2020. Acessado em: 21/09/2023. Disponível em: <<https://earth.google.com/web/@-8.90525607,-47.87818391,481.1262763a,1822082.74287879d,35y,8.78725064h,0t,0r>>. Citado na página 21.

ELETRICIDADE, M. D. **Memória da eletricidade**. 2015. Disponível em: <<http://www.memoriadaeletricidade.com.br/Default.asp>>. Citado 4 vezes nas páginas 22, 27, 28 e 29.

EPE. **Usina Hidrelétrica Estreito**. 2021. Disponível em: <<https://www.epe.gov.br/pt/areas-de-atuacao/gestao-de-empresendimentos/empresendimentos-hidreletricos/usina-hidreletrica-estreito>>. Citado na página 28.

FERREIRA, R. R. et al. Energia elétrica e desenvolvimento: o papel das hidrelétricas no brasil. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**, v. 22, n. 2, p. 245–254, 2018. Citado na página 32.

FU, M. et al. Modelo de inteligência de dados de aprendizagem profunda baseado em escala de janela de previsão ajustada: aplicação em simulação diária de fluxo. **Acesso IEEE**, v. 8, p. 32632–32651, 2020. Citado na página 38.

GHIMIRE, S.; YASEEN, Z.; FAROOQUE, A. e. a. Predição de fluxo de fluxo usando uma metodologia integrada baseada em redes neurais convolucionais e redes de memória de longo e curto prazo. **Sci Rep**, v. 11, p. 17497, 2021. Citado 3 vezes nas páginas 36, 38 e 41.

GÓMEZ-GONZÁLEZ, A. E.; MENDOZA-RAMOS, A.; RAMÍREZ-BARRETO, J. M.; MARTÍNEZ-CASTRO, D. Convolutional neural networks for time series forecasting: A systematic literature review. **Mathematics**, v. 8, n. 5, p. 734, 2020. Citado na página 14.

GREFF, K.; SRIVASTAVA, R.; KOUTNÍK, J.; STEUNEBRINK, B.; SCHMIDHUBER, J. Lstm: A search space odyssey. **IEEE Trans. on Neural Networks and Learning Systems**, v. 28, n. 10, p. 2222–2232, 2017. Citado na página 37.

HA, S.; LIU, D.; MU, L. Previsão do fluxo do rio yangtze com base na rede neural de aprendizagem profunda com el niño – oscilação sul. **Sci Rep**, v. 11, p. 11738, 2021. Citado 2 vezes nas páginas 35 e 43.

HAUSWIRTH, S.; BIERKENS, M.; BEIJK, V.; WANDERS, N. O potencial das abordagens baseadas em dados para quantificar extremos hidrológicos. **Av. Recurso Hídrico**, v. 155, 2021. Citado na página 36.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. [S.l.]: Bookman Editora, 2. ed. Porto Alegre, 2001. ISBN 8577800865, 9788577800865. Citado na página 13.

HERRERA, M.; JÓDAR, J.; GIRÁLDEZ, J. V. Reservoir inflow forecasting using neural networks: Alternative input variables. **Hydrological Sciences Journal**, v. 55, n. 7, p. 1095–1110, 2010. Citado na página 13.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, 1997. Citado na página 37.

ICMC.USP, N. do S. **Redes Neurais Artificiais**. 2021. Acesso em 05/10/2023. Disponível em: <<https://sites.icmc.usp.br/andre/research/neural/>>. Citado na página 35.

INTERVIEWBIT. **CNN Architecture – Detailed Explanation**. 2022. Acesso em 05/10/2023. Disponível em: <<https://www.interviewbit.com/blog/cnn-architecture/#:~:text=A%20convolutional%20neural%20network%20is,of%20data%20automatically%20and%20adaptively.>> Citado na página 40.

JURÍDICO. **A Usina Hidrelétrica de Tucuruí e os Instrumentos Jurídicos de Gestão de Riscos e Danos Ambientais**. 2020. Acesso em 21/09/2023. Disponível em: <<https://ambitojuridico.com.br/cadernos/direito-ambiental/a-usinahidreletrica-de-tucuru-para-e-os-instrumentos-juridicos-de-gestao-de-riscos-e-danos-ambientais>>. Citado na página 29.

KWON, Y.; CHA, Y.; PARK, Y.; ALL. Assessing the impacts of dam/weir operation on streamflow predictions using lstm across south korea. **Scientific Reports**, v. 13, p. 9296, 2023. Disponível em: <<https://doi.org/10.1038/s41598-023-36439-z>>. Citado na página 13.

KWON, Y.; CHA, Y.; PARK, Y. e. a. Avaliando os impactos da operação de barragens/açudes nas previsões de vazão usando lstm na coreia do sul. **Sci Rep**, v. 13, p. 9296, 2023. Citado na página 36.

LECUN, Y.; BENGIO, Y.; HINTON, G. Aprendizagem profunda. **Nature**, v. 521, p. 436–444, 2015. Citado na página 35.

LIMA, T. J. S. et al. Avaliação da previsão de vazões em curto prazo para a usina hidrelétrica de tucuruí. **Revista Brasileira de Geografia Física**, v. 13, n. 2, p. 451–464, 2020. Citado na página 32.

LIU, D. et al. Previsão de vazão usando rede neural de aprendizado profundo: estudo de caso do rio yangtze. **Acesso IEEE**, v. 8, p. 90069–90086, 2020. Citado na página 36.

MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, 1943. Citado na página 33.

MEDEIROS, P. R. et al. Influência dos fenômenos climáticos na variabilidade das vazões na bacia do rio tocantins. **Revista Brasileira de Meteorologia**, v. 34, n. 1, p. 57–66, 2019. Citado na página 32.

MMA. **Caderno setorial de recursos hídricos**. [S.l.: s.n.], 2006. Citado na página 20.

(ONS), O. N. de S. E. **Operador Nacional de Sistema Elétrico (ONS)**. <[https://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/dados\\_hidrologicos\\_vazoes.aspx](https://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/dados_hidrologicos_vazoes.aspx)>. Acesso em 06/10/2023. Citado na página 47.

OUYANG, W. et al. Modelagem de vazões em escala continental de bacias com reservatórios: Rumo a uma estratégia coerente baseada em aprendizado profundo. **J. Hidrol. (Amst)**, v. 599, p. 126455, 2021. Citado na página 39.

PAPACHARALAMPOUS, G.; MAKROPOULOS, C.; DIAKAKIS, M. Short-term reservoir inflow forecasting in ungauged basins using artificial neural networks. **Water**, v. 11, n. 5, p. 980, 2019. Citado na página 13.

PAULA, R. D. et al. Sustainable management of hydropower plants: A review. **Energies**, v. 12, n. 10, p. 1946, 2019. Citado na página 20.

PEREIRA, L. G. et al. The hydroelectric complex of the tocantins river basin: Environmental challenges and vulnerability. **Water**, v. 10, n. 5, p. 563, 2018. Citado na página 20.

RAHIMZAD, M. et al. Comparação de desempenho de um modelo de aprendizado profundo baseado em lstm versus algoritmos convencionais de aprendizado de máquina para previsão de fluxo de fluxo. **Recurso Hídrico. Gerenciar**, v. 35, p. 4167–4187, 2021. Citado na página 38.

RAO, C.; LIU, Y. Three-dimensional convolutional neural network (3d-cnn) for homogenization of heterogeneous materials. **Computational Materials Science**, v. 184, p. 109850, 2020. Citado na página 43.

RIBEIRO, M.; BORTOLIN, T. A.; MENDES, L. A.; RITA, L. S. Análise de séries hidrológicas na bacia hidrográfica afluyente à usina hidrelétrica castro alves, rs. **Revista Brasileira de Geografia Física**, v. 14, p. 1–2, 2021. Citado na página 20.

RUMELHART, D. E.; MCCLELLAND, J. L.; PDP o G. On learning the past tenses of english verbs. In: MCCLELLAND, J. L.; RUMELHART, D. E. (Ed.). **Parallel Distributed Processing**. Cambridge, MA: MIT Press, 1986. v. 2, p. 216–271. Citado na página 33.

SALCEDO-SANZ, S.; HERMS, J. Álvarez; PASTOR-SÁNCHEZ, J. River flow forecasting using hybrid neural networks with seasonal time series decomposition. **Water**, v. 10, n. 3, p. 324, 2018. Citado na página 13.

SANTOS, A. L. L. **Previsão de vazão afluyente da UHE-Tucuruí por redes neurais recorrentes LSTM**. Trabalho de Conclusão de Curso, Tucuruí, 2022. Acesso em: 03/10/2023. Disponível em: <<https://bdm.ufpa.br:8443/jspui/handle/prefix/4578>>. Citado 3 vezes nas páginas 14, 36 e 39.

SHEN, X.; NI, Z.; LIU, L.; YANG, J.; AHMED, K. Wipass: Smartphone keystroke recognition based on 1d-cnn using wifi signals. **Pervasive Mobile Computing**, v. 73, p. 101393, 2021. Citado na página 40.

SHI, X.; AL. et. Rede convolucional lstm: uma abordagem de aprendizado de máquina para previsão de precipitação. **Cornell University**, 2015. Computer Vision and Pattern Recognition. Citado na página 44.

SILVA, A. M.; SANTOS, R. V. Análise econômica das usinas hidrelétricas da bacia do rio tocantins. **Revista Brasileira de Energia**, v. 29, n. 2, p. 193–209, 2020. Citado 2 vezes nas páginas 20 e 30.

SILVA, I. N. da; SPOTTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas. Fundamentos Teóricos e Aspectos Práticos**. 2. ed. [S.l.]: Artliber, 2016. 431 p. Capa comum. ISBN 8588098873. Citado na página 34.

SILVA, M. S. et al. Influência das mudanças climáticas na vazão do rio tocantins: Estudo de caso na uhe tucuruí. **Anais do XIII Simpósio Brasileiro de Climatologia Geográfica**, v. 13, n. 2, p. 256–267, 2019. Citado 3 vezes nas páginas 22, 23 e 32.

- SMITH, J. Hydropower basics. 2017. Citado na página 20.
- SUN, A. Y.; SCANLON, B. R. Como o big data e o aprendizado de máquina podem beneficiar o meio ambiente e a gestão da água: um levantamento de métodos, aplicações, direções futuras. **Environmental Research Letters**, v. 14, 2019. Citado na página 35.
- TAORMINA, R.; CHAU, K. Previsão de intervalo baseada em ann de descargas de vazão usando o método lube e mofips. **Eng. Apl. Artefato. Intel.**, v. 45, p. 429–440, 2015. Citado na página 35.
- VERMA, S. **Understanding 1D and 3D Convolution Neural Network | Keras**. 2019. Acesso em 10/11/2023. Disponível em: <<https://towardsdatascience.com/understanding-1d-and-3d-convolution-neural-network-keras-9d8f76e29610>>. Citado 2 vezes nas páginas 41 e 42.
- VIEIRA, J. D. S. Caracterização da bacia hidrográfica do rio araguaia: uma contribuição para a gestão dos recursos hídricos. **Revista de Gestão, Inovação e Sustentabilidade**, v. 5, n. 3, p. 92–110, 2018. Citado 2 vezes nas páginas 19 e 32.
- WANG, Q.; ZHENG, Y.; YUE, Q.; LIU, Y.; YU, J. Impacto das características regionais no desempenho da unidade recorrente fechada na previsão de vazões. **Abastecimento de Água**, 2022. <https://doi.org/10.2166/ws.2022.041>. Citado na página 39.
- WANG, S.; MU, L.; LIU, D. Uma abordagem híbrida para previsão de el nio baseada na decomposição de modo empírico e codificador-decodificador lstm convolucional. **Computação. Geociências.**, v. 149, n. 2, p. 104695, 2021. Citado na página 36.
- WILLIAMS GP & WOLMAN, M. Efeitos a jusante de barragens em rios aluviais. **Artigo Profissional 1286 do US Geological Survey**, 1984. Citado na página 39.
- WU, C.; CHAU, K. Predição de séries temporais de precipitação usando métodos modulares de soft computing. **Eng. Apl. Artefato. Intel.**, v. 26, n. 3, p. 997–1007, 2013. Citado na página 36.
- WU, Y. et al. Sistema de tradução automática neural do google: preenchendo a lacuna entre a tradução humana e a automática. In: **Anais da conferência IEEE sobre visão computacional e reconhecimento de padrões**. [S.l.: s.n.], 2017. Citado na página 35.
- YANG, W. et al. River flow prediction based on lstm (long short term memory) recurrent neural network. **Hydrology Research**, v. 49, n. 3, p. 784–800, 2017. Citado na página 13.
- YAO, D.; LI, B.; LIU, H.; YANG, J.; JIA, L. Remaining useful life prediction of roller bearings based on enhanced 1d-cnn and simple recurrent unit. **Measurement**, v. 175, p. 109166, 2021. Citado na página 40.
- YAO, H. et al. Convolutional neural networks for time series classification. **Journal of Systems Engineering and Electronics**, v. 29, n. 4, p. 678–686, 2018. Citado na página 13.
- ZHAO, Z. et al. Combining a parallel 2d-cnn with a dilated self-attention residual network for discrete speech emotion recognition based on etc. **Neural Networks**, v. 141, p. 52–60, 2021. Citado na página 42.