



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

**Previsão de Vazão Afluente da UHE-Tucuruí por  
Redes Neurais Recorrentes LSTM**

AYLA LIS LOPES SANTOS

Tucuruí - PA  
2022



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

**Previsão de Vazão Afluente da UHE-Tucuruí por  
Redes Neurais Recorrentes LSTM**

AYLA LIS LOPES SANTOS

Trabalho de Conclusão de Curso apresentado do Colegiado da Faculdade de Engenharia Elétrica do Campus Universitário de Tucuruí da Universidade Federal do Pará como requisito para a obtenção do título de bacharel em engenharia elétrica.

**Orientador:** Prof. Dr. Raphael Barros Teixeira

Tucuruí - PA  
2022

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

**Previsão de Vazão Afluente da UHE-Tucuruí por  
Redes Neurais Recorrentes LSTM**

**AUTORA: AYL A LIS LOPES SANTOS**

TRABALHO DE CONCLUSÃO DE CURSO SUBMETIDO À BANCA EXAMINADORA DO COLEGIADO DA FACULDADE DE ENGENHARIA ELÉTRICA, DO CAMPUS UNIVERSITÁRIO DE TUCURUÍ, DA UNIVERSIDADE FEDERAL DO PARÁ, COMO REQUISITO PARA A OBTENÇÃO DO GRAU DE BACHAREL EM ENGENHARIA ELÉTRICA.

APROVADA EM 11/07/2022.

BANCA EXAMINADORA:



---

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



---

Prof. Dr. André Felipe Souza da Cruz  
Membro: UFPA - CAMTUC - FEE



---

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

Este trabalho é dedicado aos meus pais, Elizete e Roseano,  
os principais incentivadores e companheiros da minha vida.

# Agradecimentos

Primeiramente agradeço a Deus pela vida, e por todas as maravilhas que Ele tem me proporcionado.

A minha família por todo o apoio e incentivo, estando sempre presente nessa caminhada e me aconselhando a seguir em frente e lutar pelos meus sonhos, em especial gostaria de expressar a minha profunda gratidão a minha mãe Elizete Lopes, meu pai Roseano Rabelo, e meus irmãos Sara Lis e Davi Lopes.

Agradeço ao meu orientador Prof. Dr. Raphael Barros Teixeira por toda dedicação e confiança depositada no meu trabalho, e por todas as horas investidas e conhecimento repassados durante esse período. Sua contribuição foi de suma importância para a realização desta dissertação.

E, a todos os professores do curso de Engenharia Elétrica da UFPA que durante esses anos repassaram seu conhecimento.

Muito obrigado a todos os amigos e pessoas próximas que dividiram comigo momentos de felicidade, e que sempre estiveram presentes.

Essa gratidão estende-se a todos que contribuíram de forma direta ou indireta para a realização deste trabalho de conclusão de curso. Muito Obrigado!

# Resumo

A previsão de vazões afluentes aos reservatórios das usinas hidrelétricas é de grande importância na otimização do planejamento de operação, e tem como objetivo apresentar um cenário futuro que poderá impactar no processo de geração de energia através do aumento ou diminuição de vazão afluente prevista. Neste processo de previsão são geralmente utilizados modelos matemáticos computacionais baseados em redes neurais. Neste trabalho apresentamos um estudo da aplicação de Redes Neurais Recorrentes *Long Short-Term Memory* (LSTM) no problema de previsão de vazão afluente diária da Usina Hidrelétrica (UHE) de Tucuruí localizada na Bacia Hidrográfica Tocantins Araguaia, no horizonte de 1 até 7 dias à frente, considerando as séries históricas de dados medidos pela Agência Nacional de Águas (ANA) de UHE's localizadas à montante do seu reservatório. Os resultados obtidos através do treinamento do modelo, mostraram viabilidade de sua aplicação para previsão de vazão afluente diária por meio dos testes e análises realizadas ao longo do trabalho, onde o ajuste de cada cenário apresentado ficou em aproximadamente 91% ao ser realizada a comparação entre os valores computacionais, com a porção dos dados originais do conjunto separados para a validação.

**Palavras-chave:** previsão de vazões afluentes, redes neurais artificiais, redes neurais recorrentes, usinas hidrelétricas, LSTM.

## Resumo

The prediction of inflows to the reservoirs of hydroelectric plants is of great importance in optimizing the operation planning, and aims to present a future scenario that may impact the energy generation process by increasing or decreasing the expected inflow. In this forecasting process, computational mathematical models based on neural networks are generally used. In this work we present a study of the application of *Long Short-Term Memory* (LSTM) Recurrent Neural Networks in the problem of forecasting the daily inflow of the Tucuruí Hydroelectric Power Plant (UHE) located in the Tocantins Araguaia Hydrographic Basin, in the horizon of 1 to 7 days ahead, considering the historical series of data measured by the National Water Agency (ANA) of UHE's located upstream of its reservoir. The results obtained through the training of the model, showed the feasibility of its application to predict the daily inflow through the tests and analyzes carried out throughout the work, where the adjustment of each scenario presented was approximately 91% when the comparison was carried out. between the computational values, with the original data portion of the set set aside for validation.

**Key words:** prediction of inflows, artificial neural networks, recurrent neural networks, hydroelectric plants, LSTM.

# Lista de figuras

Figura 1 – Mapa da localização geográfica da BTA, de (ANA, 2020) . . . . .	7
Figura 2 – Usina Hidrelétrica de Tucuruí, de (SOUSA, 2019). . . . .	9
Figura 3 – Mapa da localização das usinas hidrelétricas na BTA, de (EARTH, 2020) . . . . .	10
Figura 4 – Diagrama com usinas hidrelétricas na BTA, de (ANA, 2021) . . . . .	10
Figura 5 – Característica de um reservatório típico, de (GUILHERME, 2020) . . . . .	11
Figura 6 – Característica de uma bacia hidrográfica, de (CONCEIÇÃO, 2014) . . . . .	12
Figura 7 – Vazão afluente na UHE de Serra da Mesa, Autoria própria. . . . .	14
Figura 8 – Vazão afluente na UHE Cana Brava, Autoria própria. . . . .	14
Figura 9 – Vazão afluente na UHE São Salvador, Autoria própria. . . . .	14
Figura 10 – Vazão afluente na UHE Peixe Angical, Autoria própria. . . . .	15
Figura 11 – Vazão afluente na UHE Lajeado, Autoria própria. . . . .	15
Figura 12 – Vazão afluente na UHE Estreito, Autoria própria. . . . .	15
Figura 13 – Vazão afluente na UHE Tucuruí, Autoria própria. . . . .	16
Figura 14 – Vazão afluente das UHE's, Autoria própria. . . . .	16
Figura 15 – Vazão afluente média das UHE's, Autoria própria. . . . .	17
Figura 16 – Estrutura genérica de um neurônio biológico, de (BOOK, 2019b) . . . . .	19
Figura 17 – Estrutura do modelo matemático de um neurônio artificial, da autora. . . . .	20
Figura 18 – Funções de ativação típicas de RNAs, Autoria própria. . . . .	21
Figura 19 – Marcos históricos do desenvolvimento das Redes Neurais, de (BOOK, 2019a). . . . .	21
Figura 20 – Arquitetura MLP com Duas Camadas Ocultas, da autora. . . . .	22
Figura 21 – Estrutura de uma RNA recorrente genérica, expressando os laços de realimentação e os operadores de atraso $z^{-1}$ . Adaptado de (HAYKIN, 2001). . . . .	23
Figura 22 – Estrutura de processamento e célula de uma RNA recorrente convencional, adaptado de (BRUNTON; NOACK; KOUMOUTSAKOS, 2019). . . . .	24
Figura 23 – Sequência de processamento de informação em uma camada LSTM, com destaque para a estrutura da célula e seus múltiplos canais fluxo de informação, de (BRUNTON; NOACK; KOUMOUTSAKOS, 2019). . . . .	25
Figura 24 – Atualização do Estado das células LSTM, de (JUNIOR, 2022). . . . .	25
Figura 25 – Processamento não-linear pelas funções de ativação $\sigma()$ na estrutura da LSTM. De (JUNIOR, 2022). . . . .	26
Figura 26 – Esquema Geral do Método de Pesquisa, da autora. . . . .	27
Figura 27 – Dados de Estreito normalizados e separados entre treinamento e validação. . . . .	28
Figura 28 – Dados de Tucuruí normalizados e separados entre treinamento e validação. . . . .	29
Figura 29 – Bloco entrada-saída da LSTM-1 . . . . .	30
Figura 30 – Curva do custo de treinamento para o modelo LSTM-1. . . . .	32
Figura 31 – Predição OSA para o modelo LSTM-1, confrontados com os dados de validação para a vazão afluente em Tucuruí . . . . .	32
Figura 32 – Simulação do Modelo 1, partindo de uma condição inicial na tentativa de reproduzir a série temporal. . . . .	33

Figura 33 – Curva do custo de treinamento para o modelo LSTM-2. . . . .	35
Figura 34 – Predição de um passo a frente do modelo LSTM-2. . . . .	35
Figura 35 – Simulação do modelo LSTM-2. . . . .	35
Figura 36 – Curva do custo de treinamento para o modelo LSTM-3. . . . .	36
Figura 37 – Curvas de resposta do modelo para $y(t + 1)$ , $y(t + 2)$ , $y(t + 3)$ e $y(t + 4)$ com o modelo LSTM-3. . . . .	37
Figura 38 – Curvas de resposta do modelo para $y(t + 5)$ , $y(t + 6)$ e $y(t + 7)$ com o modelo LSTM-3. . . . .	38
Figura 39 – Medida por NRMSE do ajuste para as curvas dos 7 dias a frente gerados pelo modelo confrontados com os dados reais. . . . .	38

# Sumário

	<b>Resumo</b> . . . . .	<b>v</b>
	<b>Abstract</b> . . . . .	<b>vi</b>
	<b>Lista de figuras</b> . . . . .	<b>vii</b>
	<b>Sumário</b> . . . . .	<b>ix</b>
<b>1</b>	<b>INTRODUÇÃO</b> . . . . .	<b>1</b>
1.1	Justificativa . . . . .	2
1.2	Objetivos . . . . .	3
1.2.1	Objetivo Geral . . . . .	3
1.2.2	Objetivos Específicos . . . . .	3
1.3	Metodologia . . . . .	3
1.4	Estrutura do Trabalho . . . . .	4
<b>2</b>	<b>A HIDROLOGIA DA BACIA ARAGUAIA TOCANTINS</b> . . . . .	<b>6</b>
2.1	Bacia Tocantins Araguaia . . . . .	6
2.1.1	Usinas Hidrelétricas na BTA . . . . .	8
2.2	A dinâmica de uma bacia hidrográfica . . . . .	11
2.3	Vazão Afluente em Usinas na BTA . . . . .	13
2.4	Revisão da literatura . . . . .	17
<b>3</b>	<b>REDES NEURAIIS ARTIFICIAIS RECORRENTES</b> . . . . .	<b>19</b>
3.1	Redes Neurais Artificiais . . . . .	19
3.1.1	Rede Perceptron de Múltiplas Camadas . . . . .	21
3.2	Redes neurais Recorrentes . . . . .	22
3.2.1	Redes Recorrentes LSTM . . . . .	24
<b>4</b>	<b>PREVISÃO DE VAZÃO NA BTA POR LSTM</b> . . . . .	<b>27</b>
4.1	Pré-processamento dos dados . . . . .	27
4.2	Modelo LSTM-1 . . . . .	29
4.2.1	Estrutura do modelo LSTM-1 . . . . .	30
4.2.2	Validação do modelo LSTM-1 . . . . .	32
4.3	Modelo LSTM-2 . . . . .	33
4.4	Modelo LSTM-3 . . . . .	35
<b>5</b>	<b>CONCLUSÃO</b> . . . . .	<b>39</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>41</b>

# 1 Introdução

O conhecimento das vazões naturais de bacias hidrográficas constitui uma informação relevante para o aproveitamento adequado da água em importantes atividades econômicas, sociais e ambientais, como: a agricultura, abastecimento, previsão de enchentes, manutenção da vida dos ecossistemas e geração de energia elétrica (LOPES *et al.*, 2020). Estas vazões são formadas pelo acúmulo das águas da chuva que escoam dos rios que compõem a bacia, sendo considerados eventos naturais, sem a intervenção humana. Ao longo do tempo diversos conhecimentos de hidrologia e modelagem de sistemas dinâmicos têm sido desenvolvidos na busca de se criar modelos matemáticos que possam prever o comportamento desta variável (SOUSA *et al.*, 2008; BRITO *et al.*, 2016) visando aproveitar esta informação antecipada para o devido aproveitamento e gestão dos processos dependentes das águas dos rios.

O ciclo hidrológico é um dos fenômenos que influenciam na vazão de uma Bacia Hidrográfica (BH), suas etapas são divididas em evaporação, condensação, precipitação, infiltração e transpiração, todas estas influenciadas por variáveis de diferentes naturezas como a radiação solar, a geologia da área da bacia, o ecossistema, o movimento da Terra, dentre muitas outras. Estas múltiplas variáveis concorrem de maneira não linear e aleatória, tornando este um sistema cuja modelagem é um desafio (BALBINOT *et al.*, 2008; MACHADO; PACHECO, 2010).

No Brasil, segundo um levantamento do MME (Ministério de Minas e Energia), cerca de 85% da energia elétrica produzida vem de fontes renováveis, sendo sua maioria produzida em usinas hidrelétricas (MONREAL *et al.*, ). O órgão nacional responsável pelo controle e sistematização da operação das instalações de geração, transmissão e planejamento de operações de energia elétrica é o Operador Nacional do Sistema Elétrico (ONS) (BRANDÃO, 2004), o qual dispõe de uma grande massa de dados de vazões dos reservatórios brasileiros registrada ao longo das últimas décadas. Estes dados têm sido aproveitados por pesquisadores e técnicos do setor de energia elétrica, que atuam na modelagem matemática das vazões afluentes (RIBEIRO *et al.*, 2021).

Os métodos utilizados no Brasil para monitorar o comportamento desse ativo com relação a geração de energia tem evoluído continuamente. Atualmente têm sido utilizado um conjunto de modelos matemáticos de previsão de afluências chamados PREVIVAZ e PREVIVAZH desenvolvidos pelo Centro de Pesquisa de Energia Elétrica - CEPTEL - da Eletrobras, sendo o primeiro voltado para previsão de médias semanais e o segundo para previsão de médias diárias de afluências (COLONESE, 2014; FERREIRA *et al.*, 2012). Estes modelos são amplamente utilizados nas usinas brasileiras de grande porte, como é o caso de Itaipu, Belo Monte e Tucuruí.

A criação destes modelos faz uso de um conjunto de técnicas de identificação de sistemas (OLIVEIRA, 2015; DEUS, 2010) onde as séries temporais de dados hidrológicos são utilizadas como fonte de informação para a determinação dos parâmetros das estruturas matemáticas dos modelos. Dado que o comportamento deste sistema é não linear, multivariável e aleatório, modelos analíticos, tipicamente buscados em identificação de sistemas, podem requerer uma estrutura matemática extensa e complexa, sem no entanto conduzir a resultados satisfatórios. Em busca de melhorar essa metodologia de previsão, atualmente vem sendo estudado técnicas do campo da Aprendizagem de Máquina (AM) para realizar tais modelagens (GORODESTSKAYA *et al.*, 2018; REIS, 2020), em particular as abordagens contemporâneas de aprendizagem profunda baseadas redes neurais artificiais (RNAs).

Este trabalho visa utilizar AM para a produção de um modelo dinâmico da vazão afluente do reservatório da Usina Hidrelétrica (UHE) de Tucuruí, localizada na Bacia Tocantins Araguaia (BTA). A proposta seguida fará uso de dados históricos medidos diariamente da vazão afluente de usinas da BTA, obtidos por meio da plataforma web da Agência Nacional de Águas (ANA) e do ONS. Busca-se então gerar modelos aptos para determinar o comportamento futuro de séries temporais da vazão afluentes na UHE Tucuruí.

O modelo pesquisado será baseado em RNAs Recorrentes (TOSCANO; CABRAL, 2006), pelo fato de que a arquitetura dessa RNA possuir uma estratégia de realimentação, fazendo com que o modelo possua memória, o que é necessário neste caso em que o sistema possui natureza dinâmica. O modelo buscado será validado confrontando a série temporal dos seus dados gerados com as medições reais de vazões do ONS.

A arquitetura escolhida para a modelagem é baseada nas RNA Recorrentes do tipo *Long Short-Term Memory* (LSTM). Atualmente essa estrutura tem sido muito empregada para diversas funções, seja para classificar, processar e prever séries temporais. O seu uso maciço se deve a sua capacidade de modelar sequências de dados, razão pela qual estas redes têm sido adotadas em modelagem de textos escritos, vídeos, sendo investigada na modelagem de sistemas dinâmicos não-lineares e despontando como uma forte candidata a oferecer soluções ao problema da vazão afluente em reservatórios (PEREIRA *et al.*, 2017; TOSCANO; CABRAL, 2006).

## 1.1 Justificativa

A proposta deste trabalho visa produzir um modelo computacional de previsão de afluência referente à UHE Tucuruí localizada na Bacia Tocantins Araguaia, tendo como proposta investigar a aplicação de métodos de aprendizagem de máquinas nesse processo de previsão, como uma alternativa aos modelos analíticos utilizados atualmente pelo Brasil.

A utilização de Redes Neurais Artificiais vem se expandindo para diversos cenários e aplicações, em especial para a previsão de vazão afluente vem se destacando a arquitetura de Rede Recorrente LSTM, isso por conta de ela conseguir capturar comportamentos dinâmicos de sistemas por incorporar memória na estrutura do modelo (LJUNG *et al.*, 2020; BROWNLEE, 2017).

Sabendo que, uma bacia hidrográfica disponibiliza um dos recursos primordiais para a sobrevivência dos seres vivos, estando, é necessário realizar o devido gerenciamento deste recurso de forma planejada e eficiente, seja relacionado as atividades no meio social, econômico e ambiental.

As empresas de geração hidrelétricas buscam por meio de modelos de previsão de vazão prever esse comportamento dinâmico para o seu funcionamento, podendo-se realizar planejamentos que buscam utilizar e gerenciar a água de forma correta, verificando os períodos que podem ter uma maior vazão, e outros uma menor vazão, dessa forma controlando o volume dos reservatórios disponíveis para a geração de energia e o nível de rios a jusante da hidrelétrica por meio das suas comportas, como é o caso típico da UHE Tucuruí.

Além da utilização de forma mais correta da água, outro fato importante é a comunidade e o meio ambiente que está presente no entorno dessas operações, sendo os mesmos impactados de acordo com as tomadas de decisões pelos processos de UHE's, podendo ter áreas alagadas que impactam a vida das populações e os ecossistemas.

Esta pesquisa se insere neste contexto de busca e avaliação de métodos de modelagem de vazão afluente para o melhor gerenciamento e a utilização correta dos recursos hídricos nos processos de hidrelétricas (TUCCI *et al.*, 2002).

## 1.2 Objetivos

### 1.2.1 Objetivo Geral

Ajustar um modelo de previsão de vazão afluente diária, por meio do método Redes Neurais Recorrentes *Long Short-Term Memory* (LSTM) para a Usina Hidrelétrica de Tucuruí.

### 1.2.2 Objetivos Específicos

- Levantar a série histórica das vazões afluentes diárias dos reservatórios presentes na BTA;
- Realizar a aplicação do método RNA do tipo LSTM na previsão de vazão afluente para cenários distintos;
- Avaliar o desempenho dos modelos produzidos comparando os resultados computacionais obtidos, com a porção dos dados originais separados para a validação do modelo.

## 1.3 Metodologia

O desenvolvimento deste trabalho partiu do estudo do problema de previsão de vazões afluentes em reservatórios, com foco na UHE-Tucuruí da BTA. Verificou-se que entre os temas atuais de pesquisa na área destacam-se as técnicas baseadas em redes neurais recorrentes tipo LSTM.

Neste caso fez-se uso do estudo teórico e computacional da implementação, treinamento e validação destas redes. A abordagem de aprendizagem de máquina faz uso intensivo de dados para treinamento de seus modelos. Assim, investigou-se repositórios de bancos de dados nacionais das vazões das UHEs brasileiras. Dados obtidos da plataforma do ONS mostraram-se em quantidade e qualidade adequados para os propósitos deste trabalho.

Seguiu-se então com a obtenção e o pré-processamento dos dados coletados, que envolveu a normalização por reescalonamento dos dados, sendo esta tarefa conduzida na biblioteca *Pandas* da linguagem *Python*. Foram coletados dados de vazões diárias de 7 usinas da BTA em uma faixa de tempo de aproximadamente 22 anos.

Buscou-se então implementar o modelo LSTM no ambiente *Colab*<sup>1</sup> utilizando a biblioteca *Keras*, um pacote de métodos de AM em linguagem *Python*.

Na estratégia de formulação do modelo foram concebidos 3 cenários distintos para a estrutura das redes LSTM:

- Cenário 1: Onde a rede LSTM foi treinada recebendo como entrada apenas dados atrasados da vazão na UHE Tucuruí buscando prever a amostra de um passo a frente;

<sup>1</sup> <<https://colab.research.google.com/>>

- Cenário 2: Onde a rede LSTM recebe também os dados da Usina de Estreito como uma entrada adicional, buscando prever a amostra de um passo a frente em Tucuruí;
- Cenário 3: Em que se replicam as entradas do cenário 2 mas buscando prever a amostras com 7 passos a frente da vazão em Tucuruí;

Seguindo os métodos convencionais de aprendizagem de máquinas, os modelos dos diferentes cenários foram treinados e validados a partir de uma separação apropriada do conjunto de dados entre treinamento e validação. Em todos os cenários também foram tentadas diferentes estruturas para as redes pela variação de seus hiperparâmetros como o número de camadas, o número de neurônios por camada e a função de ativação. Buscou-se variar também o atraso e o número de variáveis de entrada em cada modelo, além das variações dos elementos de treinamento como os algoritmos de otimização e o número de épocas.

Com os modelos treinados buscou-se validá-los sob duas perspectivas: (i) Predição, onde o modelo era sempre alimentado com os dados originais continham a memória do conjunto (ii) Simulação, onde foi elaborada sequências de amostras simuladas de saída, no qual o modelo não estava utilizando apenas os dados originais oferecido, mas também os dados previstos de acordo com suas interações, ou seja, os próprios dados de saída previstos pelo modelo alimentaram sua entrada, até completar o período de interação.

Em seguida, com os dados já estruturados foi utilizado a rede neural LSTM, para o treinamento dos modelos apresentados, produzindo dados preditos e simulados, em que cada cenário realizou a etapa de validação do modelo, comparado os valores oferecidos pelo modelo, com os dados originais separados para validar a eficiência do projeto.

Por meio da análise dos resultados, também pretende-se validar qual é o melhor modelo que descreve o comportamento desse sistema não-linear por meio do seu desempenho ao serem apresentadas propostas de situações distintas para sua finalidade. Sendo elas, a sua utilização para a previsão, e para simulação dos dados originais, observando os retornos obtidos e a sua eficiência. A validação do modelo foi conduzida por métrica de ajustes baseadas em erro médio quadrático.

O principal foco dessa pesquisa está relacionado ao cenário 3 com a predição de uma sequência de amostras 7 passos a frente da vazão afluente da UHE Tucuruí, uma vez que este é o cenário mais realista para aplicações reais deste tipo de modelo, onde os gestores dos reservatórios precisam ter conhecimento de um cenários de múltiplos passos a frente das vazões para a devida tomada de decisão.

Em suma, espera-se que pelo menos um dos modelos apresentados seja capaz de ter um comportamento coerente com os dados originais apresentados e que consiga realizar uma sequencias de dados simulados de vazão afluente da UHE Tucuruí de acordo com a realidade apresentada.

## 1.4 Estrutura do Trabalho

O Capítulo 2 apresenta uma visão geral dos conceitos teóricos com relação a Bacia Tocantins Araguaia, como também a dinâmica de uma bacia hidrográfica. E, algumas especificações da UHE de Tucuruí, e de demais reservatórios que estão localizados a sua montante.

No Capítulo 3 detalha a metodologia de Aprendizagem de Máquina que esse trabalho se baseia, apresentado os conceitos sobre as Redes Neurais Artificiais Recorrentes, e a estrutura do algoritmo *Long Short-Term Memory*.

Já o Capítulo 4 apresenta e discute a implementação e treinamento dos algoritmos, sistematiza e discute os resultados alcançados.

O trabalho se encerra com um capítulo de conclusão onde são apresentadas as considerações finais e sugestões de avanços e trabalhos futuros.

## 2 A hidrologia da Bacia Araguaia Tocantins

Neste capítulo serão explanados conceitos gerais de uma Bacia Hidrográfica, em especial as características da Bacia Hidrográfica Tocantins Araguaia, tendo como foco apresentar as Usina Hidrelétricas (UHE) que estão presentes no Rio Tocantins.

E, apresentar uma análise por meio dos dados históricos da vazão afluente diária de cada uma dessas UHE's, quais reservatórios mais teriam relevância neste trabalho.

### 2.1 Bacia Tocantins Araguaia

A Bacia Tocantins Araguaia é considerada a maior bacia hidrográfica exclusivamente brasileira. Ela leva o nome de seus dois rios principais: O Rio Tocantins e o Rio Araguaia. Ambos nascem na região Centro-Oeste do Brasil, e escoam do centro do continente rumo à Região Norte. O Tocantins tem sua nascente localizada na Serra Dourada, entre os municípios de Ouro Verde e Petrolina, no estado de Goiás. O Araguaia nasce na região do Parque Nacional das Emas no município de Mineiro, estado de Goiás. Trata-se de uma área com aproximadamente 920 mil Km<sup>2</sup>, equivalente a 10,8% do território nacional, que engloba partes dos estados de Tocantins, Pará, Maranhão, Goiás, Mato Grosso e Distrito Federal. A Figura 1 apresenta um mapa da região com destaque para a rica hidrografia que é drenada pelos dois rios (MMA, 2006).

O clima predominante da BTA é tropical, tornando-se mais úmido e quente conforme vai se aproximando da foz, localizada na Ilha do Marajó, Estado do Pará. A Bacia apresenta duas caracterizações climáticas bem distintas ao longo do ano: um período marcadamente seco de estiagem, tipicamente entre os meses de setembro e outubro, e um outro mais úmido que vai de fevereiro a abril, onde ocorre uma concentração maior de chuvas (BARRAGENS, 2000).

Com relação à vegetação, o Cerrado é o bioma dominante, dado que que grande parte BTA situa-se na Região Centro-Oeste brasileira. Nas regiões mais ao Norte, a Bacia é marcada pela presença da floresta Amazônica. Toda esta região tem sido alvo nas últimas décadas de forte desmatamento, dada a intensa presença da agropecuária, da mineração e da exploração madeireira, o que se reflete em impactos negativos no solo e rios (MMA, 2006). A Tabela 1 apresenta o percentual das áreas dos estados que correspondem a BTA.

A hidrografia da região também é marcada ou utilizada em importantes atividades de natureza socioeconômicas, com destaque para: Pesca, irrigação, navegação e, destacadamente, a geração de

Estado	Porcentagem da BTA
Pará	30%
Tocantins	30%
Goiás	21%
Mato Grosso	15%
Maranhão	4%
Distrito Federal	0,1%

Tabela 1 – Percentual de abrangência da área da BTA nos estados.

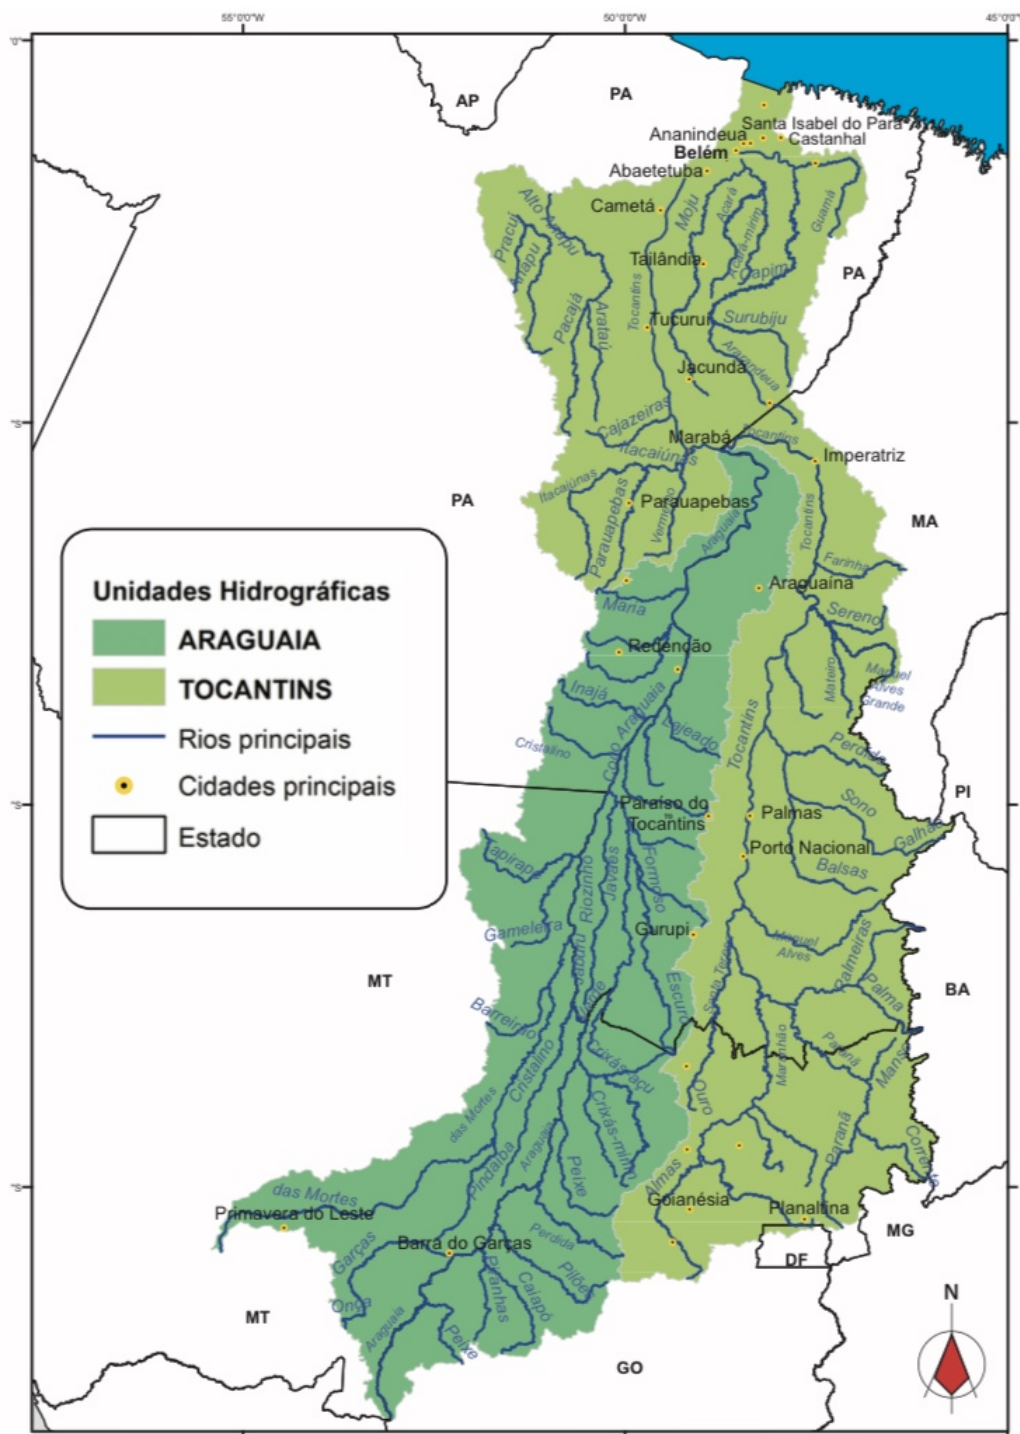


Figura 1 – Mapa da localização geográfica da BTA, de (ANA, 2020)

energia elétrica, tendo estas atividades um papel muito relevante na dinâmica econômica do país (MMA, 2006).

Os dois grandes rios da BTA se encontram na região denominada Bico do Papagaio. As suas drenagens conjuntas conferem à BTA uma vazão média de  $13.799 \text{ m}^3/\text{s}$ , o que correspondente a 8% do total nacional (RIBEIRO, 2018). A geologia da região ajuda a compreender esta dinâmica hidrográfica, uma vez que a BAT está situada entre regiões do planalto central brasileiro e o vale amazônico.

A abundância de água, associado a esta geologia particular, despertou interesse do Estado Brasileiro em aproveitar a hidrografia da região para a geração hidrelétrica de energia, o que tem sido

fortemente explorado ao longo do tempo.

### 2.1.1 Usinas Hidrelétricas na BTA

Por volta de 1974, a Eletronorte/Eletronorte iniciou o estudo do aproveitamento energético que se poderia alcançar na região. No Rio Tocantins, mais precisamente na cidade de Tucuruí, onde constatou-se que seria um investimento viável e promissor, e por volta dos anos 1975, já iniciou a questão de mobilização da população que vivia nos entornos da área do projeto, e as primeiras obras de desvio do rio (JURÍDICO, 2020).

Já em 1977 iniciou as obras oficiais do projeto da UHE de Tucuruí, sendo dividido em duas etapas, e inaugurada em 22 de novembro de 1984 pelo presidente João Figueiredo. A 1ª etapa aconteceu no final de 1977 durando até 1992, onde foi realizada uma grande parte da estrutura da barragem e a montagem de 12 turbinas, tendo capacidade de geração de 4000 MW, e sendo ampliada na 2ª etapa em 1998, realizando um acréscimo de 11 turbinas e contemplando assim sua capacidade energética para 8370 MW, a vazão média nesse reservatório é em torno de 11000 m<sup>3</sup>/s (ELETRICIDADE, 2015). Na Figura 2 é mostrada uma fotografia da Usina Hidrelétrica de Tucuruí, tirada no ano de 2019.

Bem certo de que esse projeto trouxe diversos impactos para região, sejam eles: ambientais, econômicos e sociais. Com relação aos impactos ambientais, as espécies de fauna, flora e aquáticas foram afetadas negativamente, nas etapas de alagamento e construção que estavam presentes no escopo do projeto do reservatório; já os impactos econômicos tantos positivos com negativos, positivos pela fato de ter gerados novos empregos, mas negativos, já que as atividades econômicas das pessoas que moravam na região, foram diminuídas ou até menos finalizadas; e por último, mas não menos importantes, os impactos sociais, alagamentos de cidades, e até hoje ainda ocorre essa questão em período de cheia, as cidades que foram afetadas diretamente são Tucuruí, Breu Branco, Novo Repartimento, Goianésia, Ipixuna e Itupiranga por contando da construção do lago artificial. Fazendo assim, com que muitas famílias fiquem sem moradia e sem recursos necessários para viver dignamente, e juntamente com isso, veio também impactos na saúde, nessa região aconteceu um surto de malária, praga de mosquitos e alimentos infectados com mercúrio, e outras doenças por conta dos processos implantação do projeto (FEARNSIDE, 1999).

A energia produzida pela UHE é considerada uma das maiores usinas do mundo, e a segunda maior exclusivamente brasileira. A BTA, não contém apenas esse reservatório de geração, mas também outros, que estão à jusante dele, sendo eles Serra da Mesa (MA), Cana Brava (GO), São Salvador (GO/TO), Peixe Angical (TO), Lajeado (TO/MA) e Estreito (TO/MA). Todos os reservatórios citados anteriormente, estão presentes no Rio Tocantins, mas à estudos que buscam compreender a viabilidade de implementação de usinas hidrelétricas no Rio Araguaia (ARAÚJO, 2003). Na Tabela 2, estão presentes alguns dados gerais sobre essas usinas hidrelétricas e de Tucuruí.

Sendo que a primeira usina a entrar em operação no Rio Tocantins foi a UHE de Tucuruí, em 1984. Já em 1998, a UHE Serra da Mesa foi inaugurada. Logo depois, entraram em operação Lajeado (2001), Cana Brava (2002), Peixe Angical (2006), São Salvador (2009) e, por último, Estreito (2011) (ARAÚJO, 2003). Essas usinas estão posicionadas em forma de uma cascata no Tocantins, como mostra a Figura 3 na forma geográfica, e a Figura 4 na forma de um diagrama.

Das usinas hidrelétricas da cascata do rio Tocantins, apenas as UHE's Serra da Mesa, Peixe Angical e Tucuruí possuem reservatórios com capacidade de regularização de vazões, segundo (ANA, 2020)



Figura 2 – Usina Hidrelétrica de Tucuruí, de (SOUSA, 2019).

Código ANA	Usina	Estado	Potência (MW)
20920080	Serra da Mesa	GO	1.275
21050080	Cana Brava	GO	465
21360000	São Salvador	GO	243
22041080	Peixe Angical	TO	452
23700080	Lajeado	TO/MA	902
23700080	Estreito	TO/MA	1.087
29680080	Tucuruí	PA	8.365

Tabela 2 – Dados das usinas em operação da BTA no Rio Tocantins.

Usina	Cota mínima(m)	Cota máxima(m)	Volume mínimo( $hm^3$ )	Volume máximo( $hm^3$ )	Volume útil( $hm^3$ )
Serra da Mesa	417,30	460,0	11.150,00	54.400,00	43.250,00
Cana Brava	330,00	333,0	1.906,13	2.300,00	393,87
São Salvador	286,50	287,0	892,88	892,88	59,13
Peixe Angical	261	263,0	2223,73	2.755,55	526,82
Lajeado	211,50	212,3	4.711,11	5.193,48	482,37
Estreito	151	156,0	2907,66	5.298,54	2.390,88
Tucuruí	51,6	74	11.292,78	50.272,18	38.982,40

Tabela 3 – Dados das usinas em operação da BTA no Rio Tocantins.

“[...]com destaque para Serra da Mesa, maior reservatório do Brasil em termos de volume de água, com 54,4 bilhões de  $m^3$ , e Tucuruí com a segunda maior capacidade instalada totalmente nacional  $(8.365MW)^2$ .” A Tabela 3 apresenta características dos reservatórios do Rio Tocantins.

Sendo que, a cota mínima operacional faz referência entre a diferença do volume útil como o volume morto do reservatório, a cota máxima está presente entre o volume espera e o volume útil. Assim como, o volume útil pode ser calculado através da diferença de altura entre a cota máxima e mínima, ou da diferença do volume máximo e mínimo operacional. Na Figura 5, é possível visualizar o comportamento de cada característica (LOPES; SANTOS, 2002).

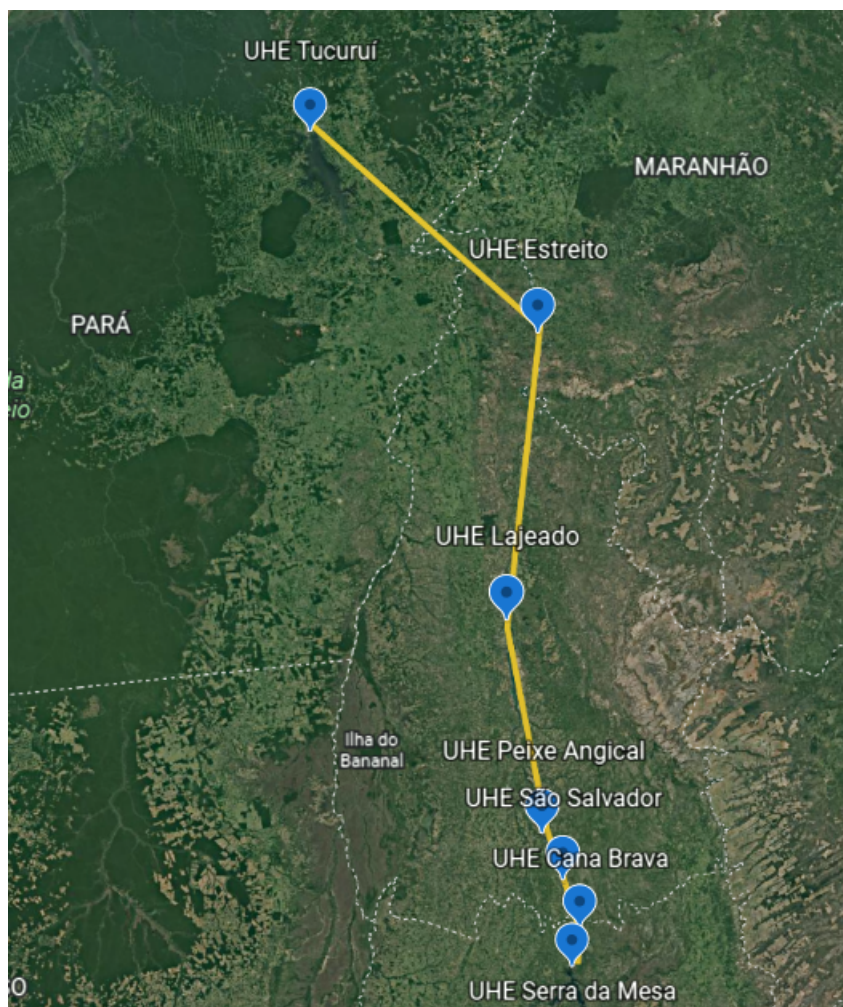


Figura 3 – Mapa da localização das usinas hidrelétricas na BTA, de (EARTH, 2020)

Diagrama esquemático de hidrelétricas da bacia hidrográfica do rio Tocantins



Figura 4 – Diagrama com usinas hidrelétricas na BTA, de (ANA, 2021) .

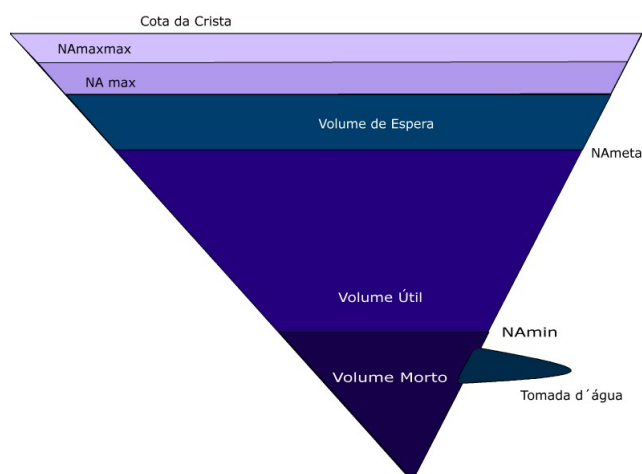


Figura 5 – Característica de um reservatório típico, de (GUILHERME, 2020) .

## 2.2 A dinâmica de uma bacia hidrográfica

Segundo (TUCCI *et al.*, 2004) a “hidrologia é a ciência que trata da água na Terra, sua ocorrência, circulação e distribuição, suas propriedades físicas e químicas e sua reação com o meio ambiente, incluindo sua relação com as formas vivas”.

Essa ciência busca estudar e apresentar a melhores formas de se utilizar a água, tendo como um dos principais focos a observação do processo do ciclo hidrológico de acordo com a região estudada, tendo em vista que, uma região que contenham uma maior densidade de corpos arbóreos tem uma maior precipitação local através do processo de evapotranspiração do ciclo hidrológico, do que em regiões onde essa densidade de arvores é menor (BALBINOT *et al.*, 2008).

Como já citado, o ciclo hidrológico contém os seguintes processos: evaporação, condensação, precipitação, infiltração e transpiração (BALBINOT *et al.*, 2008; DINIZ, 2018).

Sendo que: na evaporação ocorre a transformação do estado líquido da água para gasoso conforme a temperatura irradiada pelo sol; na condensação o vapor da água ao ser resfriado, se acumula e é condensado em forma de gotículas na nuvens ou nevoeiros, após isso; quando um porção considerável de água é condensada, ocorre a etapa de precipitação quando as gotículas suspensas no ar se tornam pesadas e caem no solo na forma de chuva, ecoando para rios, mares, e oceanos; na infiltração a água alimenta os lençóis subterrâneos; e por último, na transpiração acontece a devolução de uma porção da água absorvida pelas plantas e solo para a atmosfera (BALBINOT *et al.*, 2008; DINIZ, 2018; SPERLING, 1996).

Além disso, por conta da grande importância da BH para a sobrevivência dos seres vivos, meio ambiente, e economia global, é necessário ter diversos cuidados e ações que venham monitorar a quantidade de área e vazão afluente disponível para sua utilização conforme os seus períodos de águas altas e estiagem. Sem que, para ser avaliada a eficiência da sua utilização, antes de tudo é necessário conhecer as características hidrológicas presentes nesse ecossistema, e as ações antrópicas que influenciaram no seu comportamento (BALBINOT *et al.*, 2008).

Uma BH, como mostrado na Figura 6 , pode ser dividida em curso alto, médio e baixo, essa relação se refere a divisão do percurso de um rio da nascente até a foz. A fase curso alto, está presente na nascente de um rio, e é determinada para regiões de altitudes superiores a 600 metros, já na fase do médio é determinada para regiões de altitudes entre 600 metros à 300 metros, e na do baixo é

determinada para regiões de altitudes inferiores a 300 metros, é nela que está presente a foz de um rio (MMA, 2006).




Figura 6 – Característica de uma bacia hidrográfica, de (CONCEIÇÃO, 2014)

Na BTA em seu curso alto, estão presentes as nascentes do Rio Tocantins e Araguaia localizadas na Região do Planalto Central Brasileiro, marcado predominantemente por regiões de Planaltos Sedimentares. Dominada pela Agricultura Mecanizada, nos estados de Goiás, Tocantins e Mato Grosso, especialmente com o cultivo de grãos (soja, milho, trigo etc.), e largamente ocupada pela pecuária, sobretudo a pecuária de corte (produção de proteína animal). Essas atividades, são consideradas responsáveis por grande parte do desmatamento em larga escala do Cerrado nacional, influenciando por sua vez, na aceleração do processo de erosão do solo, nessa região (MMA, 2006).

Já no seu curso médio, está localizada a Hidrovia Tocantins Araguaia, sendo uma das hidrovias mais importantes do Brasil, tendo papel fundamental no escoamento de alguns dos produtos produzidos e desenvolvidos na região Brasil Central, transportando principalmente grãos, fertilizantes e proteína animal (MMA, 2006).

E, no curso baixo encontra-se a Usina Hidrelétrica de Tucuruí (UHT), ela é uma central hidroelétrica localizada no Rio Tocantins, no município de Tucuruí, no estado do Pará, com uma capacidade geradora instalada de 8.370 MW. Ela foi construída em meados da década de 70, com o propósito de abastecer o Projeto Novo Carajás, sendo o mesmo, um projeto de mineração. Esse projeto está conectado à bacia hidrográfica, tanto pela utilização da geração de energia, quanto pelo escoamento do minério, que principalmente é realizado pela ferrovia que cruza com a BTA, chamada de Estrada de Ferro Carajás. Além da Usina Hidrelétrica de Tucuruí na BTA, existem outras UHE's que estão presentes nesta BH, que contribuem para o aproveitamento hidrelétrico da região (MMA, 2006).

No trabalho em questão, estão sendo referenciadas a UHE Estreito, Lajeado, Peixe Angical, São Salvador, Cana Brava e Serra da Mesa, onde estão presentes no estado do Pará, Maranhão e Tocantins.

Existem duas funções muito importantes relacionadas com os reservatórios, uma delas é a de atender as demandas para a sociedade, seja com relação as atividades de irrigação, geração de energia e demais, e a outra de prevenir inundações as cidades que ficam alocadas a jusante desses reservatórios. Para ser possível realizar a primeira função, os reservatórios devem-se manter em níveis altos de reserva de água para garantir essa demanda em períodos de seca, e a segunda função, os reservatórios devem-se manter água em níveis mínimos, com o objetivo de ter espaço para abrigar água nos períodos de cheias. Um fato importante, é que quando um reservatório atua com essas funções podem surgir conflitos em

seu controle, e por meio disso surge a necessidade que conter um cenário futuro previsto de alguns dias para uma melhora administração em suas operações, por meio da previsão de vazão afluente, tendo uso dessas informações para mitigar, medir, e produzir ações que contornem esses possíveis impactos para população (KERSTNER; MOURA; MARTINS, ). Na Figura 5 é possível visualizar a divisão dos níveis de um reservatório, e na Tabela 3 estão presentes as demissões de cada nível dos reservatórios estudados nesse trabalho.

Algo importante que deve ser apresentado é o significado dos termos jusante e montante, no qual são bastante utilizados nesse trabalho. E, as diferentes vazões presentes em reservatório. No decorrer do texto, essas características serão evidenciadas.

O termo jusante e montante são muito utilizados como pontos de referências, sendo jusante o lugar que está abaixo do ponto considerado, e montante o lugar que está acima do ponto considerado, como por exemplo em uma BH a sua nascente pode ser considerado uma localização a montante, e a foz a jusante.

Agora já redirecionando para características dos reservatórios, existem algumas vazões que influenciam no seu comportamento, sendo elas: vazão natural, afluente, turbinada, defluente e vertida. A vazão natural, como já mencionado, é considerado o fluxo de um rio que percorre a BH sem a interferência de ações antrópicas; vazão afluente, a vazão que chega a um aproveitamento hidrelétrico; vazão turbinada é a que passa através das turbinas da UHE; vazão defluente é considerada a vazão que sai da UHE, sendo a mesma, a soma da vazão turbinada com a vertida; e vazão vertida é a vazão liberada através do vertedouro de um reservatório hidrelétrico (CARVALHO; LIMA, ; MORI, 2016).

## 2.3 Vazão Afluente em Usinas na BTA

As usinas instaladas ao longo do Rio Tocantins realizam uma constante medição da vazão afluente, estabelecendo pontos de coleta de dados. O acesso a estes dados tem sido facilitado dada a disponibilidade do acesso ao repositório do ONS.

Como mostrado nas Figuras 3-4, existem 7 UHE's conectadas em cascata, sendo 6 localizadas a montante de Tucuruí, onde dessas UHE's apenas a de Estreito foi considerada para contribuir com os seus dados para o treinamento dos modelos, juntamente com os de Tucuruí. Nas imagens 7-8-9-10-11-15-13, será apresentado o comportamento das vazões afluentes diárias de cada um desses reservatórios durante o mesmo período selecionado para o treinamento dos modelos presentes neste trabalho, e a justificar o motivo não terem sido utilizados todos os reservatórios.

Neste trabalho, o interesse principal é nos dados de vazão afluente diárias. As Figuras 12-13 apresentam séries temporais dos dados das UHE Tucuruí e Estreito no período de estudo de interesse do trabalho. Tendo como série histórica, dados referentes ao período de 1999 a 2021.

Todos esses dados, foram carregados da plataforma do OSN (Operador Nacional do Sistema Elétrico), para a extensão Colab (Google Colaboratory), uma plataforma do Google que permite a escrita e execução de códigos em Python através do navegador, especialmente utilizado para a realização de aprendizagem de máquina, e análise de dados, por esse motivo foi utilizado esse programa para a execução dos dados nos diferentes cenários que serão apresentados.

Para selecionar as UHE's que poderiam ter uma maior relevância para esse trabalho, foi analisado cada reservatório tendo como parâmetros de avaliação, a dimensão da sua vazão, a questão de ruídos, e se em todo o período determinado para treinamento as suas amostras estavam presentes.




Figura 7 – Vazão afluente na UHE de Serra da Mesa, Autoria própria.




Figura 8 – Vazão afluente na UHE Cana Brava, Autoria própria.




Figura 9 – Vazão afluente na UHE São Salvador, Autoria própria.

O critério da dimensão de vazão afluente tem como referência a Tabela 4 na qual apresenta a vazão média calculada através dos dados do conjunto de cada reservatório obtidos pela a plataforma do OSN durante o período de interesse desta pesquisa. Em que pelo menos 10% dessa vazão deve ser de relevância para o trabalho. As UHE's que não atenderam a esse critério foram Serra da Mesa tendo uma vazão media de  $55,06 \text{ m}^3/\text{s}$ , Cana Brava com  $653,37 \text{ m}^3/\text{s}$ , São Salvador com  $496,08 \text{ m}^3/\text{s}$ , Peixe Angical com  $1177,6 \text{ m}^3/\text{s}$ , e Lajeado com  $1739,91 \text{ m}^3/\text{s}$ , todas essas vazões médias foram calculadas de acordo com as amostras presentes no intervalo determinado para este trabalho, mesmo a UHE Lajeado tendo uma porcentagem de 9,9% de relevância, a mesma não foi utilizada. E as que tiveram




Figura 10 – Vazão afluente na UHE Peixe Angical, Autoria própria.




Figura 11 – Vazão afluente na UHE Lajeado, Autoria própria.




Figura 12 – Vazão afluente na UHE Estreito, Autoria própria.

relevância foram Estreito com  $3251.50 \text{ m}^3/\text{s}$  e Tucuruí com  $9753.71 \text{ m}^3/\text{s}$ . Na Figura 15, é possível visualizar por meio do gráfico a porcentagem de contribuição de cada UHE de acordo com suas vazões medias calculadas. O comportamento de cada uma desses reservatórios, está apresentados nas Figuras 7-8-9-10-11-15-13, respectivamente, onde na Figura 14, estão presentes todos esses comportamentos.

Outro critério também utilizado, foi a questão de ruídos que em sua maioria acontece por meio da manipulação da vazão desses reservatórios para o controle de sua operação. Por meio das Figuras 8-9 é bem nítido a visualização destes ruídos.

Além disso, em algumas UHE's não estavam presentes todas as amostras que poderiam contribuir




Figura 13 – Vazão afluyente na UHE Tucuruí, Autoria própria.

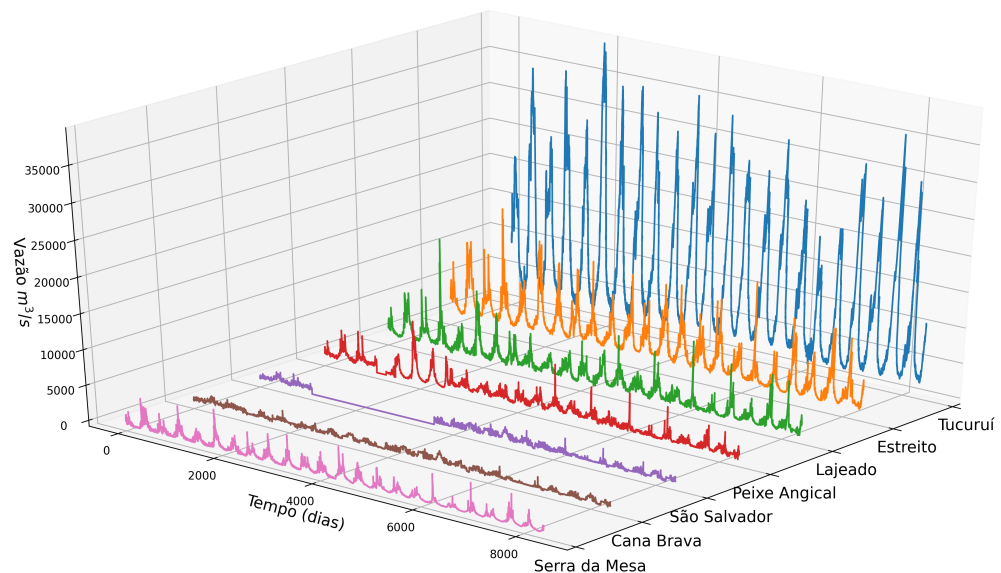


Figura 14 – Vazão afluyente das UHE's, Autoria própria.

para esse trabalho, sendo elas UHE São Salvador e Peixe Angical, apresentadas nas Figuras 9-10.

A UHE de Estreito atende a todos esses requisitos determinados, na qual também o seu comportamento é similar ao da UHE de Tucuruí. Cerca de 18,4% de relevância para esse trabalho, como pode ser visto na Figura 15, através da sua vazão afluyente média calculada de  $3251.50 \text{ m}^3/\text{s}$ . Outro fato importante é que em toda sua série histórica está presente todas as amostras.

Como pode ser notado na Figura 13, em que está presente o comportamento do reservatório de Tucuruí. O ganho de sua vazão afluyente com relação a de Estreito aproximadamente duplicou, tendo como vazão média calculada  $9753.71 \text{ m}^3/\text{s}$ , isso se deve ao fato da contribuição do Rio Araguaia ao desaguar no Rio Tocantins na região do Bico de Papagaio localizado a jusante de Estreito e a montante de Tucuruí, como pode ser visto na Figura 1.

Os dados de Rio Araguaia são de grande ajuda para o treinamento dos modelos apresentados nesse




Figura 15 – Vazão afluyente média das UHE's, Autoria própria.

Usina	Vazão Média( $m^3/s$ )	Porcentagem
Serra da Mesa	553,06	3,1%
Cana Brava	653,37	3,7%
São Salvador	496,08	2,8%
Peixe Angical	1177,6	6,7%
Lajeado	1739,91	9,9%
Estreito	3251,50	18,4%
Tucuruí	9753,71	55,3%

Tabela 4 – Dados da vazão média calculada das UHE's durante o período de relevância do trabalho.

trabalho por conta que sua vazão influencia em grande parte do comportamento da vazão da UHE Tucuruí.

## 2.4 Revisão da literatura

Segundo (GUILHON; ROCHA; MOREIRA, 2007) a vazão afluyente é considerada a vazão provida totalmente da natureza, sem conter interferência de ações humanas que alterem o seu regime. O conhecimento de cenários futuros desta variável, permite aos gestores de reservatórios de água, inferir e planejar o comportamento das outras variáveis, seja elas relacionadas com operação de reservatórios, o volume, a evaporação entre outros.

O problema da previsão de vazões tem se mostrado um desafio para a modelagem matemática. Questões como multivariabilidade, a dinâmica não-linear, a não-estacionariedade, são alguns elementos que oferecem dificuldades aos modelos convencionais (TUCCI *et al.*, 2002; GROPPPO *et al.*, 2005).

Modelos de previsão de vazão afluyente, como os estudados nesse trabalho, devem ter como ponto

inicial o estudo do comportamento e da estrutura que abrange a bacia hidrográfica e os rios que a compõem, isso pelo fato que cada bacia hidrográfica possui características específicas, de acordo com a região que está localizada a natureza dinâmica das variáveis que definam o seu comportamento podem ir mudando, como discutido em (NOVAES, 2005).

Um dos principais elementos utilizados para a análise do comportamento das bacias e para a criação dos modelos são os dados coletados em séries temporais históricas. Dada esta importância, no Brasil os dados de vazão natural são continuamente coletados pelo ONS, visando o planejamento e programação da operação do Sistema Interligado Nacional (SIN) (LEOCÁDIO; FERREIRA, 2012).

Há diversos modelos descritos na literatura para modelar a vazão afluente de um reservatório, utilizando diferentes metodologias. Como os modelos analíticos, computacionais, Inteligência Artificial, e entre outros, como apresentado em (MARACAJÁ *et al.*, 2005).

Utilizando métodos analíticos a hidrologia busca explicar conjuntos de dados de vazão por modelos lineares clássicos, baseados sobretudo nas estruturas lineares de Box-Jenkins, discutidos em detalhes em (AGUIRRE, 2007), e suas derivações como: Modelos auto-regressivos (AR), média móvel (MA), auto-regressivos com média móvel (ARMA), auto-regressivos com entrada (ARX) e auto-regressivos com média móvel e entrada (ARMAX). Embora consagradas, estas abordagens tem como principal limitação a sua estrutura linear, incapaz de modelar dados observados em fenômenos não-lineares.

O SIN utiliza alguns métodos de modelagem matemática analíticos desenvolvido pelo CEPEL, chamados de PREVIVAZ e PREVIVAZH, como já anteriormente (BRAVO *et al.*, 2008; LEOCÁDIO; FERREIRA, 2012).

Na busca de se utilizar modelos com estrutura abrangente o suficiente para incorporar informações não-lineares e a não-estacionariedade dos dados, a pesquisa atual nesta área tem se direcionado para técnicas de aprendizagem de máquina baseadas em aprendizagem profunda (BELOTTI *et al.*, 2019), mais particularmente, o uso de redes neurais artificiais recorrentes. Sendo este o escopo deste trabalho.

## 3 Redes Neurais Artificiais Recorrentes

Este capítulo apresenta o fundamento teórico do método de aprendizagem de máquina utilizado para a modelagem da vazão afluyente na BTA. As redes neurais artificiais são revistas a partir de seu paralelo com redes biológicas, a partir do que tanto o neurônio quanto redes do tipo MLP são definidas.

Apresenta-se então as motivações para a utilização de redes recorrentes na modelagem dinâmica não linear. As redes LSTM são apresentadas, discutidas e definidas, visando a sua aplicação na modelagem matemática da BTA.

### 3.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são algoritmos que emulam as estruturas básicas das redes de neurônios biológicas, buscando replicar em ambiente computacional características cognitivas verificadas entre os organismos vivos, como capacidade de aprendizagem e de reconhecimento de padrões, por exemplo (FURTADO, 2019).

Estes algoritmos surgiram na década de 40, a partir dos trabalhos do neurologista Warren McCulloch e do matemático Walter Pitts, que buscando modelar o comportamento das células nervosas, chegaram ao que é considerado o primeiro modelo de um neurônio artificial, a unidade de processamento fundamental de uma RNA, trabalho publicado pela IBM (SILVA; NETO, 2011).

Um neurônio biológico é a célula de processamento de informação nervosa. Sua estrutura é apresentada na Figura 16, onde se destacam os dendritos, ou canais de entrada da informação, o corpo celular, onde a informação é processada, e o axônio, estrutura que conduz o resultado do processamento da célula e pode ser entendido como o seu canal de saída. Do axônio derivam ramificações que estabelecem conexões sinápticas com outros neurônios, criando-se assim uma estrutura interconectada de rede (KRUG *et al.*, 2008).




Figura 16 – Estrutura genérica de um neurônio biológico, de (BOOK, 2019b)

O modelo criado pelos pesquisadores é uma idealização e simplificação do modelo biológico. A Figura 17 apresenta a estrutura do modelo do neurônio. A informação, ou sinal de entrada, é representada por um vetor  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_j]$ . Cada componente  $x_j$  é ponderada por um peso correspondente  $w_{kj}$ , uma componente do vetor de pesos  $\mathbf{w}$  do neurônio  $k$  (FURTADO, 2019).

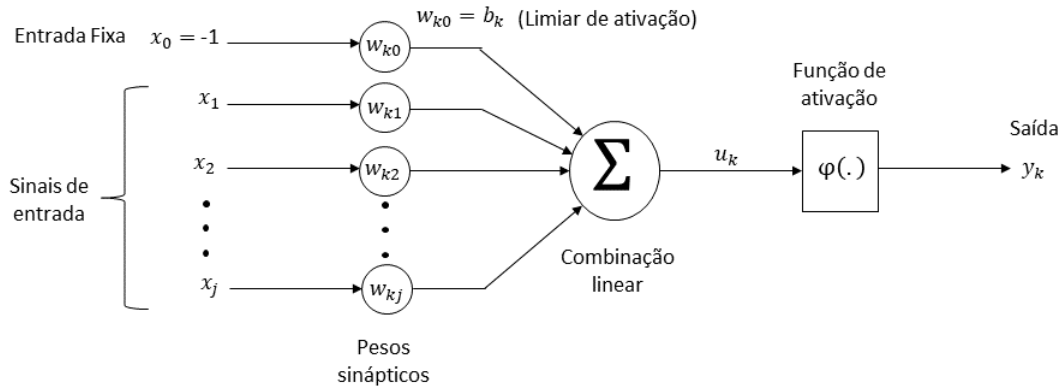


Figura 17 – Estrutura do modelo matemático de um neurônio artificial, da autora.

O potencial de ativação do neurônio é o escalar  $u_k$  dado pelo produto entre a informação de entrada e os pesos, na forma

$$u_k = \sum_{j=1}^p w_{kj} x_j. \quad (3.1)$$

Esta operação linear combina de forma ponderada a informação de entrada e repassa para a função de ativação  $\varphi(u)$ , uma operação não-linear que atua sobre o potencial de ativação do neurônio para produzir a saída

$$y_k = \varphi(u_k). \quad (3.2)$$

Um outro elemento fundamental para essa estrutura, é o chamado *bias* ou limiar de ativação, sendo representado por  $b_k$ , constitui um peso sináptico associado a uma entrada constante 1, tendo por finalidade promover ajustes com maior liberdade a informação no somatório das entradas. Neste caso (3.2) ficaria como

$$y_k = \varphi(u_k + b_k) \quad (3.3)$$

As funções de ativação têm se mostrado um hiperparâmetro importante na estrutura das redes. Inicialmente, além das funções de ativação chaveadas as pesquisas se direcionaram para funções com formato sigmoidal, como a sigmoide e a tangente hiperbólica, dada a transição suave verificada entre um estado e outro do neurônio modelado por estas funções. Contudo, uma função em particular tem se destacado, a função ReLu, pela sua simplicidade, pelo fato de sua derivada ser constante, o que tende a melhorar o desempenho dos algoritmos de otimização e principalmente pelo seu bom desempenho em embutir não linearidade na estrutura da rede, sendo essa função uma abreviação para *rectified linear unit*, ou unidade linear retificada. Todas as funções de ativação listadas anteriormente (FURTADO, 2019), estão ilustradas na Figura 18, com suas respectivas equações.

O neurônio de McCulloch e Pitts, apesar de simples, ainda é utilizado. Com o desenvolvimento dos computadores nos anos 50 surgiram vários novos pesquisadores motivados em realizar estudos, voltadas para RNAs.

A Figura 19 apresenta um diagrama contendo marcos importantes na evolução e desenvolvimento de pesquisas voltadas para RNA's. Algo que está nítido, é que até os dias de hoje muito ainda está sendo descoberto e trabalhado para a evolução desse tema, por meio de diversos trabalhos de pesquisadores e profissionais de inteligência computacional por todo mundo.




Figura 18 – Funções de ativação típicas de RNAs, Autoria própria.

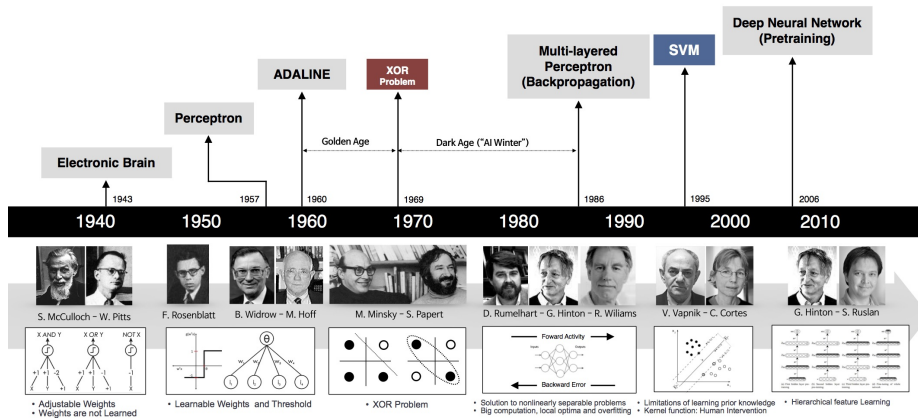


Figura 19 – Marcos históricos do desenvolvimento das Redes Neurais, de (BOOK, 2019a).

Merece destaque entre estes marcos da pesquisa o desenvolvimento do algoritmo perceptron, devido a Frank Rosenblatt, que abriu espaço para a aplicação de outras funções de ativação nos neurônios, particularmente as funções em formato sigmoidais. E ainda, o desenvolvimento do algoritmo de backpropagation, que é utilizado na etapa de aprendizagem da rede para o ajuste dos pesos sinápticos buscando minimizar alguma função custo em um processo de otimização (FURTADO, 2019).

### 3.1.1 Rede Perceptron de Múltiplas Camadas

O modelo do neurônio proposto por Roseblatt, embora fundamental, possui algumas limitações para os propósitos mais ambiciosos das RNAs, por exemplo, sua incapacidade de classificar dados não linearmente separáveis. Para contornar estas limitações estudos apontaram que a disposição de diversos neurônios em camadas sequenciais de processamento de informação conduzia a resultados mais promissores. Desta forma, surgiu o conceito de uma RNA do tipo Perceptron de Múltiplas Camadas (MLP), que é a estrutura convencional destas redes utilizada amplamente em problemas de classificação e regressão.

De acordo com (FLECK *et al.*, 2016) em uma MLP, os neurônios estão dispostos em várias camadas, que podem ser classificadas em camadas de entrada, camadas intermediárias (escondidas, ocultas), e camada de saída. Nas camadas de entrada ocorre a apresentação dos dados de entrada e padrões à rede; nas camadas intermediárias é onde ocorre grande parte do processamento, e na camada de saída, o resultado do processamento é apresentado.

A Figura 20 ilustra uma rede MLP composta por 2 camadas ocultas que recebe o sinal  $x$  em

uma camada de entrada. A rede é estruturada para que a saída desta camada alimente uma próxima camada, sequencialmente, o que corresponde a uma camada oculta. A rede pode possuir várias camadas ocultas que processam informações sequenciais. Por fim, a camada de saída processa e agrega as informações para gerar o sinal de saída da rede. A rede aparece assim como um grafo orientado adiante, onde os nós correspondem aos neurônios e os ramos que interligam os nós correspondem aos pesos sinápticos (OLIVEIRA; HERNANDEZ; GUALBERTO, 2003).

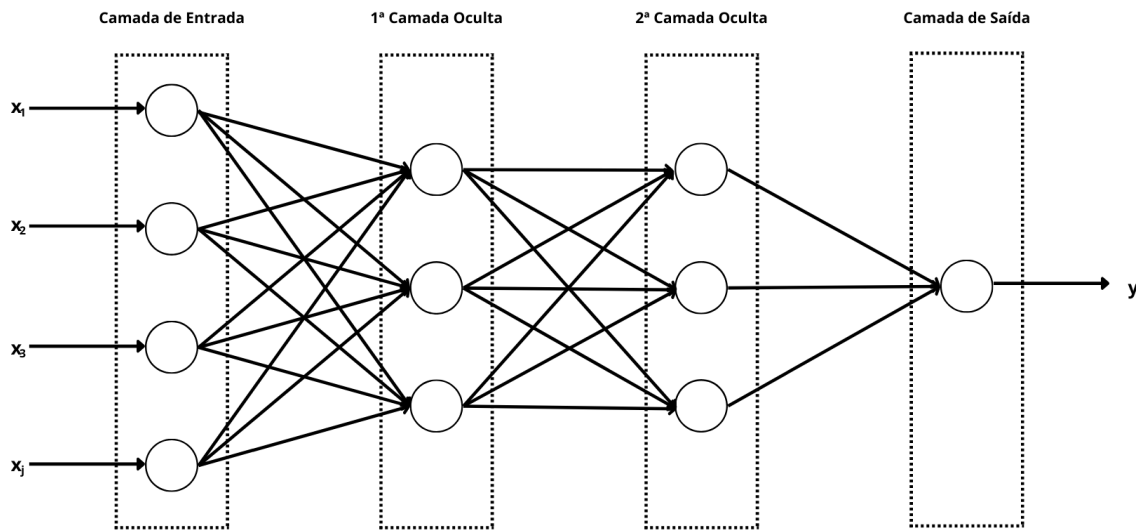


Figura 20 – Arquitetura MLP com Duas Camadas Ocultas, da autora.

A capacidade de se estruturar modelos tipo MLP com maior número de camadas, necessárias para modelar conjunto de dados mais numerosos e abstratos, levou ao surgimento das técnicas de aprendizagem profunda que tem revolucionado muitas áreas do conhecimento em anos recentes.

As redes MLP podem ser consideradas aproximadores universais de funções, de forma que são amplamente utilizadas em problemas de classificação e regressão. Contudo, em problemas onde informações dinâmicas são requeridas, como é o caso da modelagem da vazão estudada neste trabalho, redes MLP estáticas não preveem em sua estrutura elementos de memória, que deem ao modelo capacidade de representar o processamento sequencial de informação. Neste caso, um grupo diferente de redes neurais tem sido estudado ao longo do tempo, as chamadas redes recorrentes (OLIVEIRA; HERNANDEZ; GUALBERTO, 2003).

## 3.2 Redes neurais Recorrentes

A estrutura de uma Rede Neural Recorrente (RNN) tem como característica realizar conexões com realimentação. Neste caso, a rede pode preservar informações do instante passado  $t - 1$  que irão afetar sua saída no instante  $t$ , de maneira que ela passa a incluir memória no processamento da informação, comportamento portanto associado a de um sistema dinâmico de natureza não linear.

Pelo fato de a RNN possuir memória, essa estrutura tem a capacidade de aprender relações dinâmicas envolvidas nos dados ao longo do tempo, se comparado com demais estruturas que não contêm essa realimentação. Esse é o fato mais relevante desta estrutura, que tem sido aplicada a problemas de processamento de voz, de imagem, e em muitos contextos em que a informação a ser modelada sequencialmente, como em um texto escrito, por exemplo.




Figura 21 – Estrutura de uma RNA recorrente genérica, expressando os laços de realimentação e os operadores de atraso  $z^{-1}$ . Adaptado de (HAYKIN, 2001).

Essa habilidade de RNN é muito útil para sistemas dinâmicos, isto por que, sendo a rede uma estrutura de aproximação de funções ou relações não lineares, quando dotada de memória pode-se obter modelos complexos que estabelecem relações não triviais entre os dados em diferentes instantes de tempo, de forma que treinar uma RNA recorrente torna-se equivalente a identificar o modelo não-linear de um sistema (LJUNG *et al.*, 2020).

A Figura 21 apresenta um exemplo de uma RNA recorrente dita convencional (HAYKIN, 2001), onde as saídas são realimentadas em entradas via operadores de atraso, responsáveis por embutir memória a estrutura da rede. Modelos como este são bastante básicos e limitados considerando a perspectiva atual das redes recorrentes, principalmente pelo fato de que a memória é inserida na rede com elementos fora dos neurônios.

As redes neurais recorrentes apresentam-se como um modelo promissor para o problema da modelagem de vazão afluyente pela sua capacidade estrutural de estabelecer relações não-lineares entre os dados, além da presença de elementos de memória, além da capacidade de memorizar padrões expressos na natureza sazonal dos dados de vazão. Um avanço notável nas redes recorrentes aparece quando a própria unidade de processamento de informação, o neurônio, passa a incluir o elemento de memória, deixando este de ser executado por unidades de atrasos em laços de realimentação. A motivação para a implementação desta arquitetura nasceu da verificação de que as redes recorrentes convencionais, como as da Figura 21 serem incapazes de preservar na memória informações de longo prazo expressa nos dados (MURPHY, 2022).

A Figura 22 apresenta a estrutura de uma rede recorrente onde a memória é uma propriedade intrínseca dos neurônios e de suas relações, onde amostras da entrada  $x_t$  em diferentes instantes de tempo são processadas por neurônios que além destas entradas recebem também informações preservadas em uma estrutura de memória das saídas  $h_t$  das células adjacentes. A função de ativação, neste caso, é uma tangente hiperbólica. A estrutura mostra-se bastante simples, podendo ser modelado por:

$$h(t) = \tanh(h_{t-1}, x_t), \quad (3.4)$$




Figura 22 – Estrutura de processamento e célula de uma RNA recorrente convencional, adaptado de (BRUNTON; NOACK; KOUMOUTSAKOS, 2019).

que faz lembrar uma equação de estados onde o estado da célula é a própria saída. Sendo que na equação (3.4) está presente uma função de ativação que contém em sua estrutura a relação da concatenação entre a entrada  $x_t$  e a saída do neurônio anterior  $h_{t-1}$  com os seus respectivos pesos.

Esta estrutura apresenta dificuldades de convergência do modelo durante o processo de treinamento (MURPHY, 2022). Uma crítica comum é a sua simplicidade estrutural que associa o estado e a saída do neurônio em uma única variável. Isto implica em uma capacidade bastante precária em preservar informações de longo prazo. Um problema verificado é a própria instabilidade dos pesos durante o treinamento, o que limita a sua aplicação.

### 3.2.1 Redes Recorrentes LSTM

Neste trabalho será explorado um tipo particular de redes neurais recorrentes, as chamadas redes de memória longa de curto prazo (Long Short-Term Memory - LSTM), que têm sido aplicadas a uma ampla gama de problemas de modelagem de sequência em dados. Estas redes têm como principal característica a capacidade de aprender relações de dependência de longo prazo entre os dados.

Isto é atingido com uma maior complexidade estrutural da sua célula de treinamento, que passa a incluir os chamados gates, funções de ativação que têm a função específica de atenuar, esquecer, ou reforçar o estado da célula. Conforme o padrão expresso de forma temporal nos dados.

A Figura 23 apresenta a célula (ou neurônio) de uma LSTM. Uma célula LSTM se assemelha a um modelo por espaço de estados. Ela recebe o estado  $c_{t-1}$  e a saída  $h_{t-1}$ , da célula anterior, juntamente com uma entrada  $x_t$  para produzir um novo estado  $c_t$  e uma nova saída  $h_t$  que será repassado para a célula seguinte. Um conjunto de funções de ativação  $\sigma()$  (gate) permite modular de maneira não-linear o fluxo de informação, reforçando ou atenuando o estado de cada célula, ponderando a forma como informações de entrada passam a compor o estado e gerando a informação de saída a partir do estado.

A ideia central da célula é, além de gerar a saída  $h$  a partir da entrada  $x$ , como em uma célula convencional, preservar informações associada à sequência temporal, o que é feito pelo estado  $C$ . A Figura 23 apresenta as diferentes partes de processamento de informação de uma célula LSTM, onde na Figura 24a é apresentado a geração do estado  $C_t$  a partir do estado anterior  $C_{t-1}$ , da saída da célula anterior  $h_{t-1}$  e da entrada no instante  $t$ ,  $x_t$ . A relação entre estas grandezas é modelada pela




Figura 23 – Sequência de processamento de informação em uma camada LSTM, com destaque para a estrutura da célula e seus múltiplos canais fluxo de informação, de (BRUNTON; NOACK; KOUMOUTSAKOS, 2019).




Figura 24 – Atualização do Estado das células LSTM, de (JUNIOR, 2022).

equação de estado da LSTM, dada por:

$$C_t = f_t C_{t-1} + i_t \sigma_c(W_c x_t + U_c h_{t-1} + b_c). \quad (3.5)$$

A implementação gráfica desta relação é apresentada na Figura 24. Neste caso os termos  $W_c$  e  $U_c$  são pesos sinápticos da equação de estado e  $b_c$  a bias. Verifica-se ainda a presença do fator de esquecimento  $f_t$ , que pondera quanto do estado anterior será esquecido (ou preservado) em  $C_t$  e ainda, do termo  $i_t$  associado a quanto das entradas será agregado ao novo estado. Esta agregação é dada por uma relação não-linear modelada pela função de ativação  $\sigma_c()$ .

A Figura 25a apresenta o canal de entrada na geração do fator de esquecimento  $f_t$ . Este termo é gerado pela seguinte equação:

$$f_t = \sigma_f(W_f x_t + U_f h_{t-1} + b_f), \quad (3.6)$$

onde  $W_f$ ,  $U_f$  e  $b_f$  são respectivamente os pesos sinápticos da entrada, da saída anterior e a bias, que definem o potencial de ativação da função  $\sigma_g()$ .

O canal de entrada visando agregar a nova informação ao estado  $C_t$  é apresentado na Figura 25b, o qual é modelado por:

$$i_t = \sigma_i(W_i x_t + U_i h_{t-1} + b_i) \quad (3.7)$$




Figura 25 – Processamento não-linear pelas funções de ativação  $\sigma()$  na estrutura da LSTM. De (JUNIOR, 2022).

Novamente,  $W_i$ ,  $U_i$  e  $b_i$  são os pesos que geram o potencial a ser processado pela função de ativação.

A nova saída, a ser propagada para a próxima célula, é apresentada graficamente na Figura 25c, relação que é modelada por:

$$h_t = o_t \sigma_h(C_t), \tag{3.8}$$

onde  $\sigma_h$  é a função de ativação, modelada por  $\tanh()$  na célula, que recebe o novo estado  $C_t$  e gera a saída  $h_t$ , esta relação é ainda parametrizada pelo fator de saída  $o_t$  o qual é dado por:

$$o_t = \sigma_o(W_o x_t + U_o h_{t-1} + b_o), \tag{3.9}$$

com os pesos,  $W_o$ ,  $U_o$  e  $b_o$ .

Este modelo pode ser considerado o modelo padrão da célula LSTM. Muitas alterações nesta estrutura têm sido testadas no ambiente de grande interesse por estas redes.

Redes LSTM exibem uma grande versatilidade tanto no formato dos dados que podem receber quanto daqueles que podem gerar. Como a sua proposta é processar sequências de dados, a rede pode tanto receber sequências para gerar a próxima amostra quanto receber sequências para gerar novas sequências, sendo ambas as abordagens de interesse deste trabalho. Estas topologias são estabelecidas tanto pela estrutura da camada de entrada e de saída quanto pelos padrões de dados a serem apresentados na rede no seu treinamento, validação e teste.

Como visto, o modelo de uma única célula possui uma certa complexidade para a compreensão, que deve ocorrer também na implementação computacional. Este trabalho se vale dos excelentes pacotes computacionais que possuem implementados métodos para a estruturação, compilação, treinamento e teste destas redes. O pacote Keras, escrito em linguagem Python, será adotado na implementação computacional da metodologia proposta.

## 4 Previsão de vazão na BTA por LSTM

Neste capítulo é apresentada a estruturação da metodologia em forma de codificação computacional em linguagem Python, na qual após a coleta dos dados, ocorre o pré-processamento do conjunto, o treinamento e validação das redes LSTM, além da sistematização e análise dos resultados dos modelos, estas etapas estão ilustradas na Figura 26. Como o pré-processamento dos dados é etapa comum aos cenários de modelagem proposto sua abordagem vai se dar em separado.



Figura 26 – Esquema Geral do Método de Pesquisa, da autora.

Os cenários de modelagem e avaliação considerados incluem três casos:

- Modelo LSTM-1: Onde a rede LSTM busca modelar a vazão a partir unicamente dos dados de Tucuruí, sendo considerada assim uma abordagem não-linear, auto-regressiva de previsão com um passo a frente.
- Modelo LSTM-2: Onde a rede LSTM busca modelar a vazão de Tucuruí utilizando como entrada as vazões da Usina de Estreito, a primeira Usina a montante no Rio Tocantins. Esta abordagem se assemelha a de um modelo não linear, auto-regressivo, com entrada, buscando a previsão um passo a frente.
- Modelo LSTM-3: Onde se busca repetir o caso do modelo 2, mas treinando a LSTM para se prever múltiplos passos (dias) a frente, sendo esta a tentativa mais ambiciosa e a que possui maior apelo efetivo a utilização do modelo em cenários reais de operação do reservatório.

### 4.1 Pré-processamento dos dados

Em se tratando de um modelo baseado em dados, seguindo uma estratégia de identificação de sistemas baseada em aprendizagem de máquina, os modelos das redes LSTM fazem uso intensivo dos dados de vazão buscando aprender os padrões expressos nas séries históricas.

Os dados brutos coletados do ONS apresentaram uma boa organização e qualidade numérica, uma vez que vem dispostos em forma de tabela sem se verificar, na janela de tempo considerada, falta de informação ou mesmo inconsistências, como por exemplo, valores negativos ou mesmo não-numéricos para a vazão. Desta forma, a etapa de pré-processamento incluiu basicamente a normalização dos dados e a sua separação entre identificação e validação.

Para treinamento e validação das redes LSTM, foram utilizados dados diários de vazões afluentes das UHE's de Tucuruí e Estreito, que serão rotulados respectivamente por  $y(t)$  e  $x(t)$ , uma vez que na

Dados	Amostras	Percentual
Identificação	6700	80%
Validação	1674	20%
Originais	8375	100%

Tabela 5 – Divisão dos dados de identificação e validação.

perspectiva do modelo concebido, Estreito aparece como variável de entrada e Tucuruí como a variável alvo, de saída, nos cenários que se busca modelar. A janela de dados foi considerada no intervalo de tempo entre 01/01/1999 à 05/12/2021, totalizando assim o conjunto de dados com 8374 amostras.

Os dados originais foram adicionados a um *DataFrame* da biblioteca Python *Pandas*. Seguindo as boas práticas de pré-processamento, estes dados foram inicialmente normalizados, visando evitar que a rede e principalmente o algoritmo de otimização por gradiente descendente incorram em erros numéricos comuns em cenários onde valores de grande magnitude são utilizados.

A normalização adotada consistiu basicamente em reescalonar os dados de vazão entre 0 e 1. Para tanto, mostrou-se suficiente dividir os valores das vazões de Tucuruí e Estreito por  $y_{max}$ , a máxima vazão de Tucuruí em toda a janela de tempo considerada, de modo que:

$$y(t) \leftarrow y(t)/y_{max} \quad \text{Dados de Tucuruí.} \quad (4.1)$$

$$x(t) \leftarrow x(t)/y_{max} \quad \text{Dados de Estreito.} \quad (4.2)$$

Uma outra manipulação de pré-processamento necessária é a divisão do conjunto em dados de treinamento e dados de validação, onde foi utilizada a relação 80/20, sendo que 80% dos dados normalizados foram separados para identificação, e 20% para validação. Na qual esta divisão dos dados foi utilizada para ambos os 3 cenários analisados. As Figuras 27-28 apresentam, respectivamente os dados de Estreito e Tucuruí normalizados e com a divisão treinamento/validação utilizada. Dessa forma, os dados ficaram divididos quantitativamente conforme a Tabela 5.




Figura 27 – Dados de Estreito normalizados e separados entre treinamento e validação.

Nestas condições os dados estão prontos para serem utilizados nas etapas de treinamento e validação da rede LSTM. Esta validação incluirá 2 cenários, um chamado de predição e outro de simulação, que serão assim compreendidos:




Figura 28 – Dados de Tucuruí normalizados e separados entre treinamento e validação.

- A **predição** consiste em apresentar aos modelos valores de entrada oriundos dos dados medidos de validação buscando prever a próxima amostra do modelo, no caso a amostra de um passo a frente (OSA - *one step ahead*).
- A **simulação** consiste em estabelecer uma condição inicial para a primeira iteração do modelo e a partir de então realimentar a variável simulada, no caso  $y(t)$  reiteradamente, buscando confrontar o resultado do modelo com o dos dados de identificação.

A perspectiva da simulação é bem mais ambiciosa que a da predição, uma vez que ela busca criar um modelo efetivo do sistema, algo desafiados considerando a natureza da bacia hidrográfica e o uso de dados reais para a identificação do modelo.

No que segue, será apresentada a estruturação da metodologia em ambiente computacional para cada um dos casos abordados.

## 4.2 Modelo LSTM-1

Partindo então para o treinamento das redes LSTM, o primeiro cenário buscará treinar um modelo para a previsão da vazão afluyente em Tucuruí, usando unicamente os dados históricos de Tucuruí, ou seja, trata-se de uma abordagem auto-regressiva (AR) não linear. Nesse caso, o modelo receberá um vetor de amostras passadas da vazão, buscando fazer a predição da amostra um passo a frente (OSA) da vazão afluyente diária do reservatório.

Nestas condições propostas deve-se observar que o conjunto de dados de treinamento e de validação devem ser trabalhados para a geração dos padrões entrada-saída a serem processados pela LSTM. A rede recebe como entrada em cada instante  $t$  uma matriz  $\mathbf{X}_t$ , de dimensões  $n_i \times n_f$ , associada a um dados de saída  $y(t)$ . No cenário proposto  $\mathbf{X}_t$  terá uma única coluna ( $n_f = 1$ ), correspondente a uma única *feature*, uma vez que receberá apenas dados atrasados de Tucuruí, que é dada por:

$$\mathbf{X}_t = \begin{bmatrix} y(t-1) \\ y(t-2) \\ \vdots \\ y(t-n_i) \end{bmatrix}, \quad (4.3)$$

Sendo  $n_i$  o máximo atraso considerado para a variável de entrada e passa a ser um hiperparâmetro importante do modelo. A Figura 29 apresenta um bloco de entrada e saída expressando esta ideia.




Figura 29 – Bloco entrada-saída da LSTM-1

A partir do conjunto de dados procedeu-se então com a geração dos padrões de pares entrada  $\times$  saída para treinamento e validação. Para tanto, fez-se uso de uma função chamada *GeraSequencias()*<sup>1</sup>, cujo código Python é apresentado abaixo. A função recebe como parâmetros de entrada a série temporal e  $n_i$ , devolvendo os padrões entrada-saída a serem utilizados na LSTM.

```

1 def GeraSequencias(sequencias, ni):
2     X, y = list(), list()
3     for i in range(len(sequencias)):
4         Ie = i + ns
5         if Ie > len(sequencias):
6             break
7         # Reunir partes da entrada e saída do padrao:
8         seq_x, seq_y = sequencias[i:Ie, :-1], sequencias[Ie-1, -1]
9         X.append(seq_x)
10        y.append(seq_y)
11    return np.array(X), np.array(y)

```

Abaixo é apresentada, a título de exemplo, uma sequência de 4 padrões entrada-saída na forma  $X_t \rightarrow y(t)$ , geradas para  $n_i = 5$ .

```

1 [ y(t-5), y(t-4), y(t-3), y(t-2), y(t-1) ] -> y(t)
2 [ 0.229, 0.214, 0.248, 0.215, 0.226 ] -> 0.253
3 [ 0.214, 0.248, 0.215, 0.226, 0.253 ] -> 0.254
4 [ 0.248, 0.215, 0.226, 0.253, 0.254 ] -> 0.237
5 [ 0.215, 0.226, 0.253, 0.254, 0.237 ] -> 0.236

```

A ideia expressa no algoritmo de aprendizagem da LSTM é que a rede aprenda a gerar  $y(t)$  a partir da generalização da relação expressa nos pares de padrões destas sequências.

## 4.2.1 Estrutura do modelo LSTM-1

Com os dados pré-formatados, buscou-se então formular a estrutura modelo da LSTM a ser testado neste cenário 1. Dada a grande quantidade de hiperparâmetros a serem ajustados, alguns foram escolhidos preliminarmente diante de alguns testes do algoritmo, e mantidos constantes nas tentativas que foram se mostrando mais vantajosas. Este é o caso, por exemplo, do otimizador, cujo algoritmo ADAM foi selecionado por ter desempenho de tempo e convergência superior a outros como o SGD e sua variante AdaGrad. A LSTM utilizada foi do tipo mais fundamental, conhecida na comunidade de aprendizagem de máquinas por *vanilla*, que recebe uma sequência e busca prever o próximo valor.

<sup>1</sup> Proposta em <<https://bityli.com/KbOqbF>>, de onde foi adaptada.

Este modelo pode ser implementado a partir da biblioteca *Keras* de Python utilizando seu método de construção de modelo sequencial, conforme apresentado no código a seguir.

```
1 # Carrega metodos de Keras:
2 from keras.models import Sequential
3 from keras.layers import LSTM
4 from keras.layers import Dense
5
6 # Cria modelo LSTM-1:
7 model = Sequential()
8 model.add(LSTM(50, activation='relu', input_shape=(ni, nf)))
9 model.add(Dense(1))
10 model.compile(optimizer='adam', loss='mse')
```

A rede assim criada expressa uma LSTM com duas camadas, uma com 50 neurônios com função de ativação ReLu e outra densa, com apenas um neurônio. A camada de entrada recebe dados no formato  $n_i \times n_f$ . A camada densa agrega a saída de todos os neurônios da primeira camada, na geração da saída da rede.

O código apresenta ainda o otimizador *Adam* da família de algoritmos de otimização por gradiente descendente, e a função custo medido pelo erro médio quadrático *MSE*.

Para a realização do treinamento do modelo, definiram-se então os seus hiperparâmetros, que foram em parte concebidos a partir de uma estratégia de tentativa e erro na busca de um modelo com desempenho satisfatório. Os valores utilizados no modelo LSTM-1 podem ser então assim sumarizados:

- Dados de treinamento: 6700 amostras (dias);
- Dados de validação: 1674 amostras (dias);
- Número de camadas: 2;
- Função de ativação: ReLU;
- Otimizador: Adam;
- Padrões entrada-saída de treinamento: 6681;
- Épocas de treinamento: 100;
- Atrasos na entrada:  $n_i = 20$ ;

A rede LSTM foi então treinada utilizando o método *fit* de Keras, a Figura 30 apresenta a convergência do custo medido pelo MSE para os dados de treinamento e validação, ambos expressos em escala logarítmica. O modelo parece convergir para um valor aproximadamente constante de erro, o qual não apresenta melhorias com o aumento do número de épocas de treinamento. Este comportamento ocorre tanto para os dados de treinamento quanto para os de validação, sugerindo que o treinamento ocorreu sem anomalias, como o super-ajuste, por exemplo.

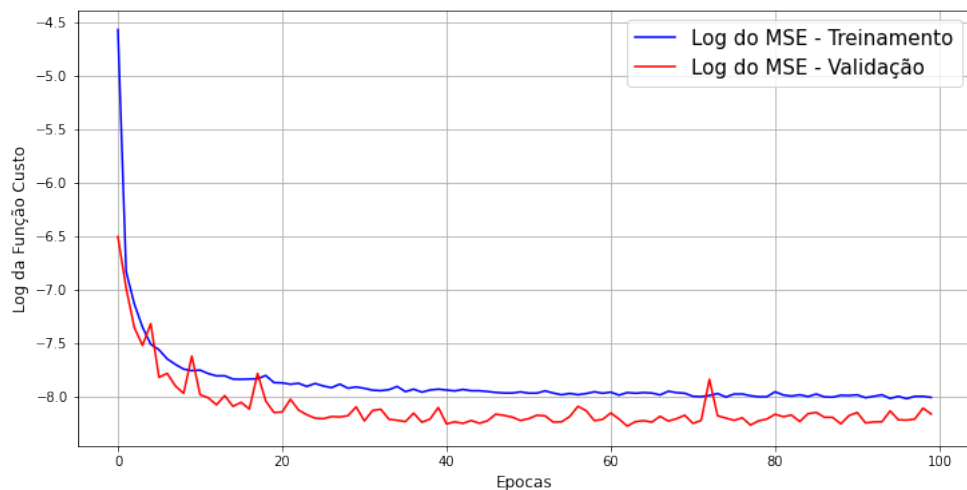


Figura 30 – Curva do custo de treinamento para o modelo LSTM-1.

#### 4.2.2 Validação do modelo LSTM-1

A partir desse treinamento, é possível analisar por meio dos dados de validação quão eficiente é o modelo do Cenário 1. Sendo que os dados de validação também precisaram ser tratados pela função de geração de sequências para que os padrões apresentados a LSTM estejam no formato adequado. O mesmo procedimento de produzir sequências de entrada - saída é realizado para os dados de validação, produzindo 1674 amostras de validação.

Procedeu-se então com a predição do modelo, que utilizava a sequência dos dados gerada para a produção de uma amostra na saída. Desta forma o modelo está sendo sempre alimentado com os dados originais buscando a predição de uma amostra de saída, correspondente a vazão do dia seguinte. Uma simulação preditiva tipo OSA, cuja sequência de dados produzida é plotada na Figura 31.




Figura 31 – Predição OSA para o modelo LSTM-1, confrontados com os dados de validação para a vazão afluyente em Tucuruí

O resultado sugere uma boa capacidade do modelo em prever a próxima amostra da sequência, dada a correspondência visual da dinâmica dos dados. Isto deve contudo ser visto com cautela, tendo em conta que a única amostra gerada na saída deve possuir necessariamente uma correlação forte com os dados reais utilizados na simulação, gerando portanto uma expectativa de resultado satisfatório mesmo com estruturas auto-regressivas mais simples, não podendo, portanto, ser tomado como um resultado surpreendente.

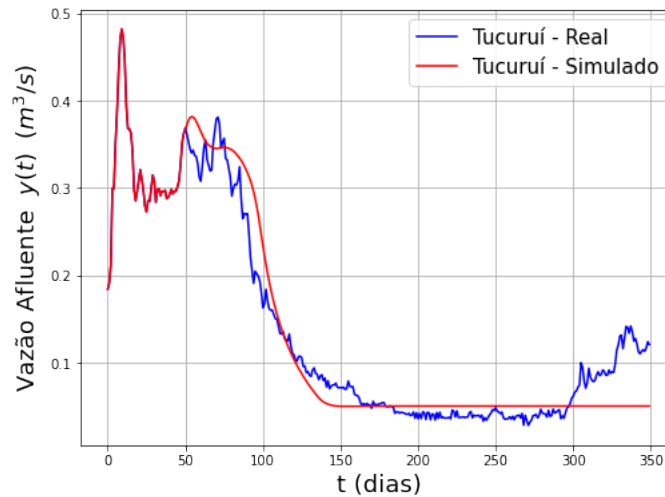


Figura 32 – Simulação do Modelo 1, partindo de uma condição inicial na tentativa de reproduzir a série temporal.

Uma maneira de medir este desempenho do modelo é a partir da aplicação de uma métrica de erro. Como a função custo utilizada foi o MSE, optou-se por utilizar como métrica de medida de desempenho o complemento do erro médio quadrático normalizado (NRMSE), definido por:

$$J = \left( 1 - \frac{\sqrt{\sum(y - y_p)}}{\sqrt{\sum(y - \mu_y)}} \right) 100\%, \quad (4.4)$$

está métrica normaliza e determina o complemento do raiz do MSE, de forma que devolva  $J = 100\%$  para modelos com ajuste perfeito e  $J \rightarrow 0$ , ou mesmo valores negativos, quando o sinal previsto pelo modelo não possui boa correlação com os dados de validação.

O ajuste medido dos dados de validação aos do modelo medido pela métrica acima foram de 91,083%, ressaltando a correspondência já visualizada nos gráficos.

Agora, a outra etapa da validação corresponde à *simulação*, onde a partir unicamente das condições iniciais é criada a sequência de amostras simuladas de saída, que são realimentados para a criação dos novos padrões de entrada do modelo. Um típico cenário de simulação auto-regressiva, onde os próprios dados de saída previstos pelo modelo irão realimentar a entrada na próxima interação de previsão da saída. Na Figura 32 é possível visualizar o comportamento do modelo 1 para simulações.

O modelo demonstrou ser incapaz de reproduzir, ou mesmo de sustentar, qualquer informação na saída nestas circunstâncias. Isso pode ser entendido pelo fato de que a cada amostra nova simulada um erro é produzido, com a realimentação deste erro na entrada o modelo não sustenta a informação de saída no longo prazo. Além disso, a variável de saída converge para um valor constante, que pode estar associado a algum ponto de equilíbrio do modelo.

### 4.3 Modelo LSTM-2

Buscando promover melhorias no comportamento do modelo optou-se por incluir o que será tomado como uma variável de entrada da dinâmica da vazão afluente em Tucuruí. Trata-se da medição da vazão afluente na usina de Estreito, a primeira usina a montante de Tucuruí. O contexto proposto

possui como limitação a ausência de uma segunda variável de entrada importante, que corresponde a vazão do Rio Araguaia, que ficará de fora pela falta de dados.

O modelo LSTM proposto neste cenário 2, passa a contar então com duas sequências de entrada: (i) a vazão em Estreito e (ii) a vazão em Tucuruí. Esta estrutura se assemelha a de um modelo não-linear auto-regressivo com entrada (NARX) (AGUIRRE, 2007). A saída continua sendo a vazão predita em Tucuruí.

Entre as topologias investigadas para o modelo verificou-se que os melhores desempenhos são atingidos com duas camadas de células LSTM.

```

1 model = Sequential()
2 model.add(LSTM(50, activation='relu', return_sequences=True, input_shape=(Nsi, nf
   )))
3 model.add(LSTM(50, activation='relu', input_shape=(Nsi, nf)))
4 model.add(Dense(1))
5 model.compile(optimizer='adam', loss = 'mse')
6
7 # Treina modelo:
8 model.fit(X_treino, y_treino, epochs = 100, verbose=1,
   validation_data=(X_teste, y_teste))

```

O espaço de hiperparâmetros mostrou-se grande, sendo necessário especificar número de neurônios em cada camada, função de ativação, atrasos da entrada, dentro muitos outros. No entanto verificou-se nos treinamentos que pouca ou nenhuma vantagem era alcançada buscando promover grandes buscas em cada um destes parâmetros. Além disso, o tempo de treinamento de cada modelo mostrou-se demasiadamente grande para que uma busca mais detalhada e sistemática fosse possível. Uma terceira questão é que, mesmo para modelos com estruturas idênticas, diferentes episódios de treinamento conduziram a diferentes resultados, o que se deve a natureza estocástica do algoritmo de otimização.

Uma dificuldade enfrentada no treinamento é o tempo médio por época. Mesmo utilizando o sistema Colab, que prevê a utilização das CPUs dedicadas do google, o tempo médio por época foi de aproximadamente 4 segundos. Este tempo, aparentemente pequeno, oferece dificuldades para uma repetição exaustiva de cenários com variações grandes de hiperparâmetros.

A Figura 33 apresenta o logaritmo da função custo para os dados de treinamento e validação em função das épocas. O custo também parece convergir com um número relativamente pequeno de épocas, em torno de 30, valor a partir do qual o treinamento mostra-se desnecessário.

A avaliação do modelo prossegue então com a simulação de um passo a frente do modelo treinado, onde foram apresentadas sequências de dados de entrada de Tucuruí e Estreito, visando produzir a próxima amostra em Tucuruí.

Na Figura 34 está presente o resultado predito do modelo um passo a frente, onde se verifica uma boa correspondência entre as duas curvas. A medida da métrica de erro NRMSE resultou em um ajuste de 91,88% para este modelo, verifica-se que ambas as curvas convergem para valores aproximadamente iguais, sem que ocorra divergência. E, a Figura 35 apresenta o comportamento do modelo de simulações, onde nesse caso foi utilizada a mesma metodologia do cenário 1, porém tem a diferença a adição dos dados de Estreito em sua entrada. Para essa aplicação, o modelo demonstrou ser falho já que a cada ciclo entende-se que há uma taxa de erro, mesmo assim ele conseguiu obter comportamentos similares aos dados originais de Tucuruí, diferentemente do cenário 1, isso se deve ao fato de existir uma variável externa, sendo ela a vazão da UHE Estreito, que contém em seus dados memória

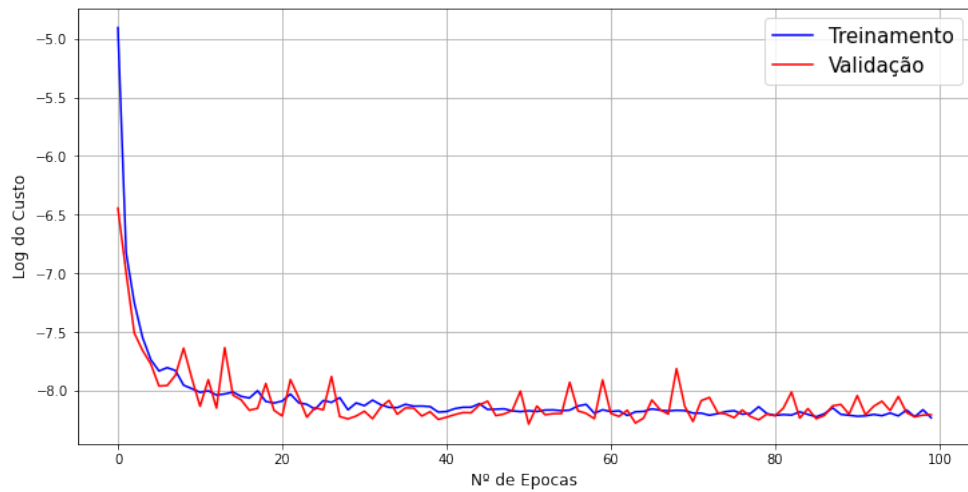


Figura 33 – Curva do custo de treinamento para o modelo LSTM-2.




Figura 34 – Predição de um passo a frente do modelo LSTM-2.




Figura 35 – Simulação do modelo LSTM-2.

do comportamento do sistema, fazendo assim com que a mesma seja um suporte e um direcionamento para a simulação de tais dados.

## 4.4 Modelo LSTM-3

O modelo proposto a seguir constitui o principal foco deste trabalho. A ideia é utilizar a rede LSTM e sua capacidade de processar sequências para prever novas sequências, e não apenas uma única amostra

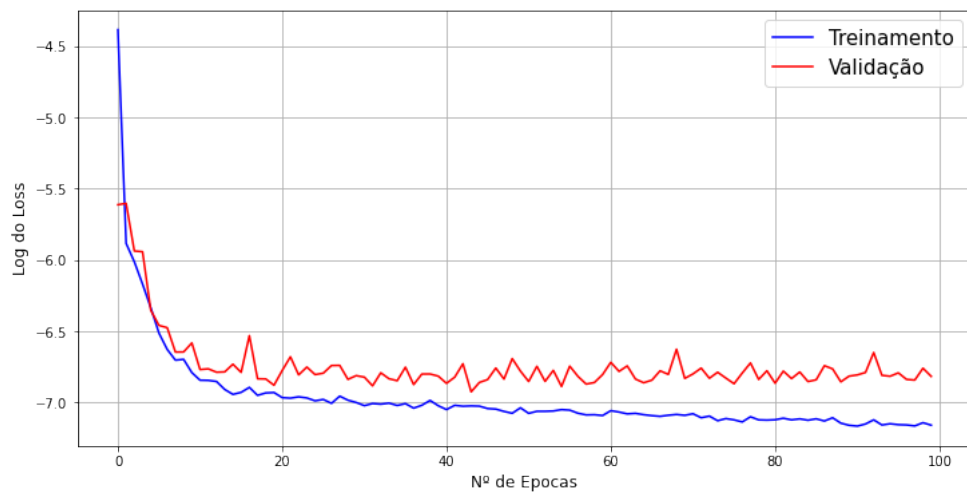


Figura 36 – Curva do custo de treinamento para o modelo LSTM-3.

de saída. Com isso busca-se produzir um modelo com alguma perspectiva de aplicabilidade real, isso considerando que os agentes que utilizam a modelagem para a predição de vazões afluentes necessitam da previsão de um cenário de alguns passos a frente para a tomada de decisão.

A ideia é então a de replicar a estrutura do modelo LSTM-2, com a diferença de que na saída serão tomados uma sequência de amostras. Serão tentados modelos buscando prever a vazão afluente em Tucuruí 7 amostras (dias) a frente, o que pode ser considerado uma janela relevante para o planejamento da operação hidráulica diária.

O modelo tomará uma sequência de amostras atrasadas de Tucuruí, o que corresponde a informação auto-regressiva, além da sequência de amostras da usina de Estreito, a entrada, para se gerar a informação de saída.

Definidas estas ideias, a estrutura do modelo foi alterada em relação à LSTM-2 apenas na camada de saída, que passou a contar com 7 neurônios, ao invés de 1, cada um dos quais correspondendo a uma das amostras que se busca prever, conforme apresentado no código abaixo.

```

1 # Cria modelo:
2 model = Sequential()
3 model.add(LSTM(50, activation='relu', return_sequences=True, input_shape=(Nsi, nf
   )))
4 model.add(LSTM(50, activation='relu'))
5 model.add(Dense(7))
6 model.compile(optimizer='adam', loss='mse')

```

Na Figura 36, apresenta-se o custo de treinamento e validação do modelo neste cenário. Nota-se que embora aparentemente exista uma pequena melhoria no desempenho do modelo quanto aos dados de treinamento, esta não é observada para os dados de validação, quando se aumenta o número de épocas.

Com o modelo treinado procedeu-se então com a validação unicamente para o cenário de predição (OSA). As Figuras 37 e 38 apresentam, respectivamente, a confrontação dos dados reais com os dados preditos pelo modelo para cada 1 dos 7 dias a frente.

Nota-se novamente uma boa correspondência entre estes dados em cada cenário, a mudança as vezes se mostra quase imperceptível aos olhos de um dia para o outro. Contudo se se observar a curva gerada para o dia  $y(t + 1)$  é possível verificar que seu desempenho é bem superior ao da curva

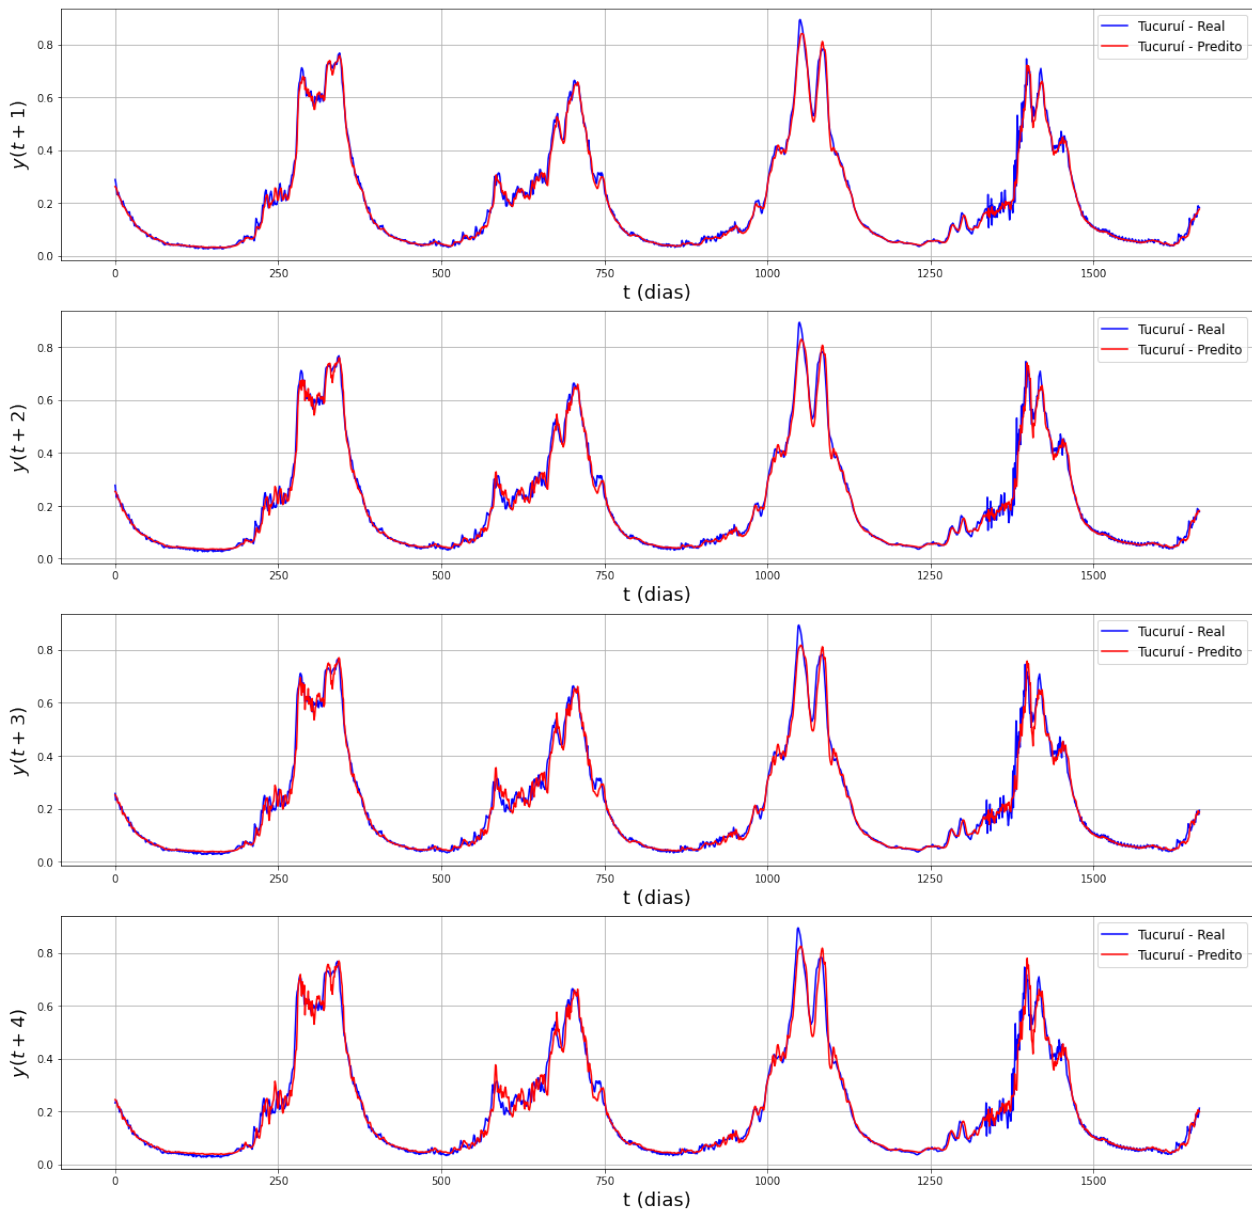


Figura 37 – Curvas de resposta do modelo para  $y(t + 1)$ ,  $y(t + 2)$ ,  $y(t + 3)$  e  $y(t + 4)$  com o modelo LSTM-3.

$y(t + 7)$ , onde a precisão já parece bastante degradada. De fato, existe uma piora ou degradação do desempenho da rede na previsão da sequência para dados mais distantes da amostra dos dados de entrada.

Este fato pode ser medido a partir da métrica NRMSE. A Figura 39 apresenta o ajuste para cada amostra com  $n$  passos a frente. Nota-se que a precisão decai à medida que a amostra fica mais distante e este decaimento é persistente e aproximadamente linear. No caso, a previsão para 1 dia a frente foi de 90,875%, enquanto para 7 dias a frente a precisão cai para 76,3%.

O resultado pode ser interessante e até mesmo coerente quando se toma em perspectiva o problema real de previsão da vazão afluente. Isto por que o modelo LSTM-3 identificado permitiu criar um cenário de 7 dias a frente a partir do último dado medido de Tucuruí e Estreito. O decaimento na precisão pode ser compreendido como o erro propagado entre os estados dos neurônios de saída da rede LSTM, e estão de acordo com a perspectiva de que, para um problema de previsão o aumento do tempo implicaria na maior imprecisão na resposta.




Figura 38 – Curvas de resposta do modelo para  $y(t + 5)$ ,  $y(t + 6)$  e  $y(t + 7)$  com o modelo LSTM-3.

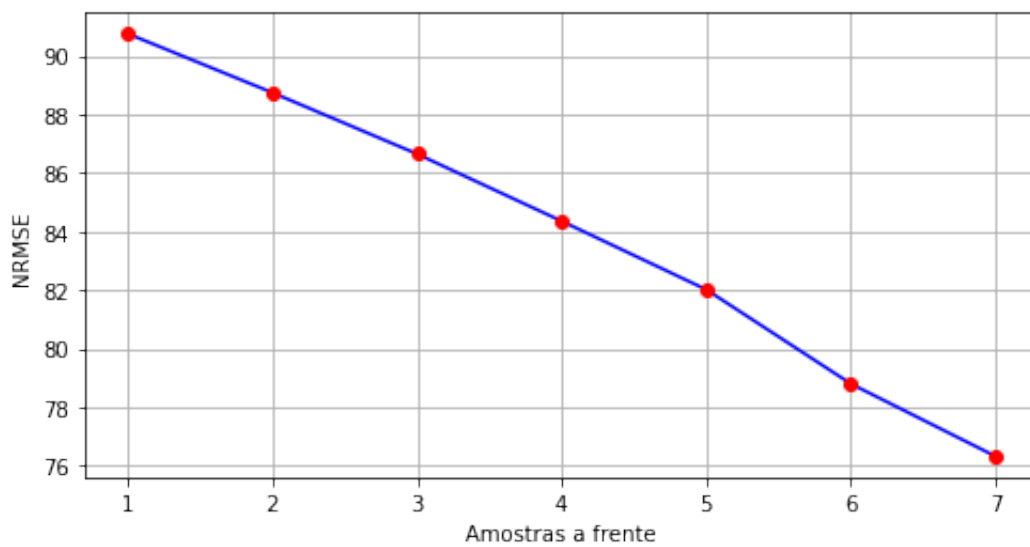


Figura 39 – Medida por NRMSE do ajuste para as curvas dos 7 dias a frente gerados pelo modelo confrontados com os dados reais.

## 5 Conclusão

Nos últimos anos, vem sendo estudados métodos mais eficientes para a previsão de vazão afluentes no SIN, tendo em vista que a previsão antecipada desta variável é muito importante para a economia brasileira e para uma melhor utilização do recurso hídrico. Este trabalho abordou o problema da previsão de vazão afluente sob a perspectiva de modelos baseados em aprendizagem de máquina. Tendo a função de obter previsões de vazões afluentes das possíveis condições operacionais futuras para tomada de decisões das usinas hidrelétricas, aumentando assim a confiabilidade e sendo uma das possíveis soluções para mitigar eventos, como alagamentos, má distribuição do rio, e baixa produtividade, por exemplo.

Para isso, esse projeto teve como objetivo principal produzir um modelo de previsão de vazão afluente diária com horizonte de sete dias à frente referente a UHE Tucuruí, tendo como técnica computacional a utilização de Redes Recorrentes LSTM para o treinamento do modelo através dos dados de vazão afluente diária da UHE Tucuruí e Estreito fornecidos pela ONS. Foram apresentados 3 cenários de modelagem, para visualizar o comportamento do sistema e da LSTM conforme a sua estrutura mudava, no qual seus desempenhos foram medidos a partir da aplicação de uma métrica de erro, chamada função custo MSE. Sendo validados confrontando a série temporal dos seus dados gerados com as medições reais de vazões do ONS.

O cenário 1, através dos testes realizados mostrou que suas previsões com horizonte de 1 passo à frente utilizando apenas os dados da UHE Tucuruí, sendo considerado uma estrutura auto-regressiva (NAR), teve um desempenho muito bom no treinamento de predição, tendo entorno de 91,083% em seu desempenho, porém ao ser realizada a de simulação, no qual o modelo utiliza seus dados de entrada preditos em cada interação, o mesmo não conseguiu evoluir o seu treinamento por conta da produção de erros a cada ciclo realizado.

Já o cenário 2, por meio da sua estrutura denominada auto-regressiva com entrada (NARX), com horizonte de 1 passo à frente, teve um desempenho de 91,88% na validação dos dados preditos, e no simulado teve um grande melhora comprado com o primeiro caso, onde o modelo simulado conseguiu apresentar um comportamento similar aos do dados originais, isso pelo fato de está utilizando os dados das UHE's Tucuruí e Estreito.

E o cenário 3, também utilizou a estrutura NARX, porém tendo como horizonte 7 passos a frente, esse modelo desempenhou também um bom resultado em ambos os treinamentos, tendo como desempenho no dia 1 de 90,875% e no dia 7 de 77%. E da mesma forma que o cenário 2, em seu modelo de simulação, os resultados adquiridos foram similares ao comportamentos do sistema original.

Os resultados mostraram que o cenário mais assertivo com relação aos apresentados nesse trabalho, contém a estrutura NARX, na qual nela está presente os dados históricos da UHE Tucuruí e Estreito, onde Estreito é um elemento muito importante para a sustentação do treinamento dos modelos. O cenário 3, pode ser de mais interesse para o departamento de operação e controle de um reservatório, pelo fato de apresentar não apenas um dia futuro, mas sim uma serie histórica futura das possíveis previsões de vazões afluentes, isso para uma maior visibilidade dos comportamentos do rio analisado.

Como sugestão de trabalhos futuros para melhorar a performance da previsão afluente diária da UHE Tucuruí, recomenda-se (i) a investigação e exploração de novas variáveis que influenciam na

vazão afluyente da BTA que venham contribuir para aumento de novos padrões, desenvolvendo assim, modelos mais robustos e, (ii) considerar novas arquiteturas de Redes Neurais Recorrentes que venham aperfeiçoar o desempenho dos resultados.

# Referências

- AGUIRRE, L. A. *Enciclopédia de automática (vol. 3): controle e automação*. [S.l.]: Editora Blucher, 2007. v. 3.
- ANA, A. N. d. e. S. B. *RELATÓRIO DE ANÁLISE DE IMPACTO REGULATÓRIO N 1/2020/CORSH/SOE Documento n 02500.054561/2020-75*. 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: 10/03/2022.
- \_\_\_\_\_. *Saiba mais (Tocantins)*. 2021. <<https://www.gov.br/ana/pt-br/sala-de-situacao/tocantins/saiba-mais-tocantins>>. Acessado em: 10/06/2022.
- ARAÚJO, R. M. Uma retrospectiva da expansão do sistema elétrico na bacia do rio tocantins, com estudo de caso na região de lajeado–palmas–porto nacional,(to), 1996-2003. *Campinas: Curso de Pós-Graduação da Faculdade de Engenharia Mecânica (Mestrado em Planejamento de Sistema Energético), Universidade de Campinas SP*, 2003.
- BALBINOT, R.; OLIVEIRA, N. K. de; VANZETTO, S. C.; PEDROSO, K.; VALÉRIO, Á. F. O papel da floresta no ciclo hidrológico em bacias hidrográficas the forest role in the hydrological cycle at hydrological basins. *Ambiência*, v. 4, n. 1, p. 131–149, 2008.
- BARRAGENS, C. M. D. Estudos de caso da comissão mundial de barragens: Usina hidrelétrica de tucuruí (brasil). *RELATÓRIO FINAL. CAPE TOWN*, 2000.
- BELOTTI, J. T. *et al. Previsão de vazões afluentes utilizando redes neurais artificiais e ensembles*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2019.
- BOOK, D. L. *Capítulo 2—Uma Breve História das Redes Neurais Artificiais*. 2019.
- \_\_\_\_\_. *Capítulo 4 – O Neurônio, Biológico e Matemático*. 2019.
- BRANDÃO, J. L. B. *Modelo para operação de sistemas de reservatórios com usos múltiplos*. 50 p. Tese (Doutorado) — Universidade de Sao Paulo, 2004.
- BRAVO, J. M.; COLLISCHONN, W.; TUCCI, C. E. M.; PILAR, J. V.; SILVA, B. C. d. Avaliação dos benefícios de previsões de vazão na operação de reservatórios. *Rbrh: revista brasileira de recursos hídricos. Porto Alegre, RS. Vol. 13, n. 1 (jan./mar. 2008), p. 197-213*, 2008.
- BRITO, B. O. d. *et al. Modelagem inteligente para previsão de séries de vazões afluentes*. Universidade Federal de Alfenas, 2016.
- BROWNLEE, J. *Long short-term memory networks with python: develop sequence prediction models with deep learning*. [S.l.]: Machine Learning Mastery, 2017.
- BRUNTON, S. L.; NOACK, B. R.; KOUMOUTSAKOS, P. Machine learning for fluid mechanics. *Annual Review of Fluid Mechanics*, 2019.
- CARVALHO, É. de O.; LIMA, W. da S. Modelo de decisão de defluência neural e de inferência nebulosa aplicada ao planejamento da operação de sistemas hidrotérmicos. *CEP*, v. 74, p. 220.
- COLONESE, J. P. *Diagnóstico de Erros do Modelo Hidrológico Estocástico PREVIVAZ para Previsão de Vazões Semanais no Planejamento da Operação do Sistema Elétrico Brasileiro*. 17 p. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2014.
- CONCEIÇÃO, g. *Parte de uma rio*. 2014. <<http://geoconceicao.blogspot.com/2014/05/partes-de-um-rio.html>>. Acessado em: 12/06/2022.

- DEUS, F. L. D. de. *Geração de Cenários de Energia Natural Afluente Através da Adoção da Metodologia do Hiper cubo Latino*. 26–27 p. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2010.
- DINIZ, T. F. *Aprimoramento de modelo chuva-vazão para aplicação em regiões semiáridas*. Dissertação (B.S. thesis), 2018.
- EARTH, G. *UHEs presentes no rio tocantins*. 2020. <<https://earth.google.com/web/@-8.90525607,-47.87818391,481.1262763a,1822082.74287879d,35y,8.78725064h,0t,0r>>. Acessado em: 12/06/2022.
- ELETRICIDADE, M. D. Memória da eletricidade. *Disponível em: http://www.memoriadaeletricidade.com.br/Default.asp*, 2015.
- FEARNSIDE, P. M. Social impacts of brazil's tucuruí dam. *Environmental Management*, Washington eDC DC, v. 24, n. 4, p. 483–495, 1999.
- FERREIRA, C. d. C. *et al.* Previsão de vazões naturais diárias afluentes ao reservatório da uhe tucuruí utilizando a técnica de redes neurais artificiais. Universidade Federal de Goiás, p. 3, 2012.
- FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. d. M. Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, v. 1, n. 13, p. 47–57, 2016.
- FURTADO, M. I. V. Redes neurais artificiais: uma abordagem para sala de aula. *Ponta Grossa, PR. Atena Editora*, 2019.
- GORODESTSKAYA, Y.; TAVARES, G. G.; FONSECA-LEONARDO, L. G. da; RIBEIRO-CELSO, C. B. de M. Comparac ao de metodos de aprendizado de maquina para a previs ao de curto prazo de vaz ao do baixo curso do rio paraíba do sul. 2018.
- GROPPO, J.; MORAES, J. de; BEDUSCHI, C.; MARTINELLI, L. Analysis of time series of flow and precipitation in some basins of the são paulo state with different degrees of human impact. *Geociencias*, v. 24, p. 181–192, 01 2005.
- GUILHERME, a. *Projetos Hidrelétricos*. 2020. <[https://www.antonioguilherme.web.br.com/Arquivos/proj\\_hidro.php](https://www.antonioguilherme.web.br.com/Arquivos/proj_hidro.php)>. Acessado em: 11/06/2022.
- GUILHON, L. G. F.; ROCHA, V. F.; MOREIRA, J. C. Comparação de métodos de previsão de vazões naturais afluentes a aproveitamentos hidroelétricos. *Revista Brasileira de Recursos Hídricos*, v. 12, n. 3, p. 13–20, 2007.
- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2001.
- JUNIOR, J. R. *Redes Neurais Recorrentes — LSTM*. 2022. <<https://medium.com/@web2ajax/redes-neurais-recorrentes-lstm-b90b720dc3f6>>. Acessado em: 15/06/2022.
- JURÍDICO, Â. Disponível em:< <https://ambitojuridico.com.br/cadernos/direito-ambiental/a-usina-hidreletrica-de-tucuru-i-para-e-os-instrumentos-juridicos-de-gestao-de-riscos-e-danos-ambientais>>. *Acesso em*, v. 22, n. 07, 2020.
- KERSTNER, L.; MOURA, M. M. D.; MARTINS, M. Rede de monitoramento como ferramenta didática no ensino de hidrologia-estudo de caso: Bacia hidrográfica do arroio cadeia.
- KRUG, Á. B.; PARRAGA, A.; LORENZI, F.; NICOLAO, M.; MORALES, A. S. Análise e reconhecimento de padrões usando processamento de imagens e inteligência artificial. *Revista de Iniciação Científica da ULBRA*, v. 7, n. 7, 2008.
- LEOCÁDIO, C. M.; FERREIRA, V. H. Inferência bayesiana no desenvolvimento de previsores neurais de vazão diária utilizando informações de precipitação. *Journal of the Brazilian Neural Network Society*, v. 10, n. 3, p. 157–165, 2012.

- LJUNG, L.; ANDERSSON, C.; TIELS, K.; SCHÖN, T. B. Deep learning and system identification. *IFAC-PapersOnLine*, Elsevier, v. 53, n. 2, p. 1175–1181, 2020.
- LOPES, E. R. d. N.; SOUZA, J. C. d.; FILHO, J. L. A.; LOURENÇO, R. W. Gestão de bacias hidrográficas na perspectiva espacial e socioambiental. *Economía, sociedad y territorio*, El Colegio Mexiquense AC, v. 20, n. 62, p. 631–653, 2020.
- LOPES, J. E. G.; SANTOS, R. C. P. Capacidade de reservatórios. *São Paulo: Escola Politécnica da Universidade de São Paulo*, 2002.
- MACHADO, A. L. S.; PACHECO, J. B. Serviços ecossistêmicos e o ciclo hidrológico da bacia hidrográfica amazônica-the biotic pump. *Revista Geonorte*, v. 1, n. 1, p. 71–89, 2010.
- MARACAJÁ, J. R. d. A. *et al.* Previsão regionalizada de vazão sazonal utilizando redes neurais artificiais. Universidade Federal de Campina Grande, 2005.
- MMA. Caderno setorial de recursos hídricos. Ministério do Meio Ambiente, 2006.
- MONREAL, D. A. C.; ZANZINI, J. C.; LINO, J. D. S.; SILVA, T. L. D. Estudo sobre a eficiência energética de fontes renováveis no brasil: Avaliação da utilização da biomassa da cana-de-açúcar na cogeração de energia elétrica no setor sucroenergético.
- MORI, C. R. R. Rebaixamento dinâmico em reservatórios de usinas hidrelétricas: estudo de caso aplicado à bacia do rio iguaçu. 2016.
- MURPHY, K. *Probabilistic Machine Learning*. [S.l.]: MIT Press., 2022.
- NOVAES, L. F. d. Modelo para a quantificação da disponibilidade hídrica na bacia do paracatu. Universidade Federal de Viçosa, 2005.
- OLIVEIRA, C.; HERNANDEZ, E. D. M.; GUALBERTO, C. U.-A. P. L. As redes neurais de hopfield e multi-layer perceptrons formando uma arquitetura neural híbrida (mlp+ h) com características próprias. In: *6th Brazilian Conference on Neural Networks*. [S.l.: s.n.], 2003. p. 13–18.
- OLIVEIRA, V. G. d. Atualização das previsões de curto prazo de aflúências ao sistema hidroelétrico brasileiro a partir da técnica de ponderação bayesiana e de previsões mensais de aflúência com uso de informação climática. p. 2–3, 2015.
- PEREIRA, M. d. M. *et al.* Aprendizado profundo: redes lstm. Universidade Federal da Grande Dourados, 2017.
- REIS, G. B. Análise do regime hidrológico em bacia hidrográfica do sudeste brasileiro e predição de séries temporais de vazões diárias utilizando aprendizado de máquina. Universidade Federal de Viçosa, p. 12–13, 2020.
- RIBEIRO, M.; BORTOLIN, T. A.; MENDES, L. A.; RITA, L. S. Análise de séries hidrológicas na bacia hidrográfica afluente à usina hidrelétrica castro alves, rs. *Revista Brasileira de Geografia Física [online]*, v. 14, p. 1–2, 2021.
- RIBEIRO, M. d. F. Caracterização morfométrica das bacias hidrográficas da apa lago de palmas, município de porto nacional-to. 2018.
- SILVA, F. D. C. S.; NETO, M. R. Redes neurais artificiais e as células da glia: Novas pesquisas na área da neurociência. 2011.
- SOUSA, d. f. *Tucuruí a Primeira grande Usina Hidrelétrica da Amazônia*. 2019. <<https://ferdinandodesousa.com/2019/10/25/tucuru-i-a-primeira-grande-usina-hidreletrica-da-amazonia/>>. Acessado em: 12/06/2022.

- SOUSA, W. d. S. *et al.* Rede neural artificial aplicada à previsão de vazões médias mensais da bacia hidrográfica do rio piacó. Universidade Federal de Campina Grande, 2008.
- SPERLING, M. V. *Introdução à qualidade das águas e ao tratamento de esgotos*. [S.l.]: Editora UFMG, 1996. v. 1.
- TOSCANO, W.; CABRAL, E. L. L. Contextualização de redes neurais recorrentes. *Exacta*, v. 4, n. esp, p. 65–66, 2006.
- TUCCI, C.; CLARKE, R.; DIAS, P. S.; COLLISCHONN, W. Previsão de médio prazo da afluência de reservatórios com base na previsão climática. *Brasília: MCT*, 01 2002.
- TUCCI, C. E. *et al.* Hidrologia: Ciência e aplicação, 3ª edição. *Porto Alegre, Editora da UFRGS/ABRH*, 2004.