

GISELE DE FREITAS LOPES

**APLICAÇÃO DO MODELO AUTOREGRESSIVO NÃO LINEAR COM ENTRADAS
EXÓGENAS PARA PREVISÃO DO NÍVEL DO RIO NO AMAZONAS**

MANAUS – AM
2022

GISELE DE FREITAS LOPES

**APLICAÇÃO DO MODELO AUTOREGRESSIVO NÃO LINEAR COM ENTRADAS
EXÓGENAS PARA PREVISÃO DO NÍVEL DO RIO NO AMAZONAS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental - PPG.EGPSA, do Instituto de Tecnologia e Educação Galileo da Amazônia- ITEGAM, como parte dos requisitos necessários à obtenção do título de Mestre.

Orientador: Dr. Manoel Henrique Reis Nascimento

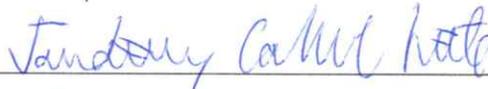
**MANAUS – AM
2022**

GISELE DE FREITAS LOPES

**APLICAÇÃO DO MODELO AUTOREGRESSIVO NÃO LINEAR COM
ENTRADAS EXÓGENAS PARA PREVISÃO DO NÍVEL DO RIO NO
AMAZONAS**

Esta dissertação foi julgada e aprovada para a obtenção do título de Mestre do Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental do Instituto de Tecnologia e Educação Galileo da Amazônia – ITEGAM.

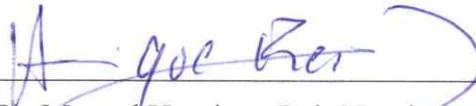
Manaus-AM, 05 de julho de 2022.



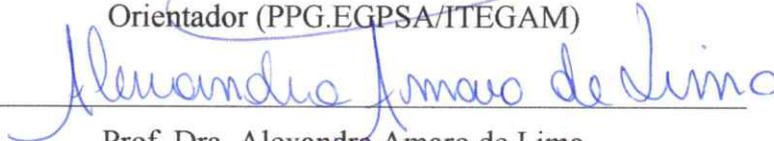
Prof. Dr. Jandecy Cabral Leite

Coordenador do PPG.EGPSA - ITEGAM

BANCA EXAMINADORA



Prof. Dr. Manoel Henrique Reis Nascimento
Orientador (PPG.EGPSA/ITEGAM)



Prof. Dra. Alexandra Amaro de Lima
Examinador Interno (PPG.EGPSA/ITEGAM)



Prof. Dra. Nadime Mustafa Moraes
Examinador Externo (UEA)

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Biblioteca do ITEGAM

Lopes, Gisele de Freitas, 2022 - APLICAÇÃO DO MODELO AUTOREGRESSIVO NÃO LINEAR COM ENTRADAS EXÓGENAS PARA PREVISÃO DO NÍVEL DO RIO NO AMAZONAS / Lopes Gisele de Freitas - 2022. 69 f., il: Colorido

Orientador: Dr. Manoel Henrique Reis Nascimento

Dissertação: Instituto de Tecnologia e Educação Galileo da Amazônia, Programa de Pós Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (PPG-EGPSA), Manaus - AM, 2022.

1. Previsão 2. Nível do Rio 3. NARX 4. Inteligência Artificial.

CDD - 1003.ed.2022.20

AGRADECIMENTOS

Agradeço à Deus por tudo e por conceder-me o fascínio pelo conhecimento e propiciar-me disciplina e força para continuar estudando, mesmo com as dificuldades.

Aos meus pais Mirenalda de Freitas Lopes e Elson Marcos Lopes por terem instruindo-me no caminho do conhecimento do qual não me desviei.

À minha irmã Gabriele de Freitas Lopes por estar sempre presente na minha vida.

Agradeço à minha filha Camila Lopes de Alencar e meu marido David Barbosa de Alencar, pela compreensão que têm pela minha dedicação e pelo tempo que dividi entre eles e os estudos.

Agradeço ao Ricardo Silva Parente no apoio computacional em diversos títulos.

Agradeço aos familiares, parentes, colegas e amigos que esperam por minhas vitórias, e aos colegas de aula que sempre me ajudaram.

Agradeço ao meu Orientador, Professor Dr. Manoel Henrique Reis Nascimento pela paciência, confiança, pelo apoio nos momentos que quis me desviar, mas suas orientações me trouxeram sempre para o caminho correto.

Agradeço ao Dr. Jandecy Cabral Leite, por dedicar sua vida ao ITEGAM e por proporcionar oportunidade de mudança de vida a muitos e ter me dado apoio constante nesta jornada.

Aos meus amigos de turma do curso de Mestrado do ITEGAM, João, Marcelo, Simone e Darlene que fizeram parte da caminhada, também aos colegas e amigos conquistados neste curso.

Agradeço aos professores do programa de pós-graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental, e todos os outros que me guiaram por esse novo caminho.

Agradeço aos meus amigos e colegas da Clínica Veterinária Minas Pet pela paciente e troca de turnos para que eu poder conquistar o sonho do mestrado.

Epígrafe

“Educação é uma descoberta progressiva de nossa própria ignorância.”

(Voltaire)

Dedicatória

À Deus pela sabedoria e perseverança, aos meus pais Mirenalda e Elson, e Gabriele (irmã), à família Camila (filha amada) e David (marido querido).

LOPES, Gisele de Freitas. Aplicação do modelo Autoregressivo não linear com entradas exógenas para previsão do nível do rio no Amazonas. 2022. 69 Folhas. Dissertação do programa de pós-graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (EGPSA), Instituto de Tecnologia e Educação Galileo da Amazônia (ITEGAM), Manaus, 2022.

RESUMO

A variação do nível dos rios é um problema constante, a previsão da variação do nível dos rios, trazem uma possibilidade de planejamento em todas as áreas de atuação, que proporciona para uma redução no impacto causado pelas enchentes e vazantes. O presente trabalho se justifica por três linhas básicas que envolvem a problemática do tema, que são o uso da Inteligência Artificial, o problema das enchentes na Amazônia e a questão da tecnologia a favor da tomada de decisão. Os impactos ambientais causados por fatores econômicos e sociais são problemas retratados em cenários como enchentes e vazantes de rios, trazendo à tona situações como aumento de doenças, redução da produção agrícola em locais que dependem de controle geológico preciso, além do aumento em processos erosivos. em locais de risco. Assim, a utilização da IA para prever o nível do rio, que conseqüentemente pode minimizar os problemas decorrentes de enchentes que causam impacto ambiental, é altamente possível, pois quando se sabe antecipadamente que um evento está próximo de acontecer, as decisões podem ser tomadas que os impactos sejam menores. Este trabalho modela e aplica o NARX para prever o nível do rio na Amazônia com variáveis de fácil acesso e implementação através do software MATLAB, a fim de contribuir com um modelo de previsão capaz de prever uma possível enchente a partir do nível do rio. Para aplicação da metodologia utilizou-se a base de dados as variáveis de entrada do Instituto Nacional de Meteorologia, e variável de saída do site do Porto de Manaus, estação do Rio Negro do porto de Manaus, 31/01/2020 a 30/06/2021. O desempenho dos modelos foi comparado com 5, 10, 15, 20 e 25 passos para frente, considerando meses como horizonte de previsão. O modelo NARX obteve melhor resposta nas previsões dentre as quais destacou-se o horizonte de 15 passos.

PALAVRAS CHAVE: Previsão; Nível do Rio; NARX, Inteligência Artificial.

LOPES, Gisele de Freitas. Application of the non-linear autoregressive model with exogenous inputs to forecast river level in the Amazon. 2022. 69 Sheets. Dissertation of the postgraduate program in Engineering, Process, Systems and Environmental Management (EGPSA), Galileo Institute of Technology and Education of the Amazon (ITEGAM), Manaus, 2022.

ABSTRACT

River level variation is a constant problem, the prediction of river level variation brings a possibility of planning in all areas of action, which provides for a reduction in the impact caused by floods and ebbs. The present work is justified by three basic lines that involve the problem of the theme, which are the use of Artificial Intelligence, the problem of floods in the Amazon and the issue of technology in favor of decision making. The environmental impacts caused by economic and social factors are problems portrayed in scenarios such as floods and ebbs of rivers, bringing up situations such as an increase in diseases, reduction of agricultural production in places that depend on precise geological control, in addition to the increase in erosive processes in risky locations. Thus, the use of AI to predict the river level, which consequently can minimize the problems arising from floods that cause environmental impact, is highly possible, because when it is known in advance that an event is about to happen, decisions can be made that impacts are smaller. This work models and applies NARX to predict the river level in the Amazon with variables that are easy to access and implement through the MATLAB software, in order to contribute with a forecast model capable of predicting a possible flood from the river level. For the application of the methodology, the input variables of the National Institute of Meteorology were used, and the output variable of the Port of Manaus website, Rio Negro station of the port of Manaus, 01/31/2020 to 06/30 /2021. The performance of the models was compared with 5, 10, 15, 20 and 25 steps forward, considering months as the forecast horizon. The NARX model obtained a better response in the predictions, among which the 15-step horizon stood out.

KEYWORDS: Forecast; River Level; NARX, Artificial Intelligence.

LISTA DE FIGURAS

Figura 2.1 - Extensão da Bacia Hidrográfica do Rio Amazonas.....	21
Figura 2.2 - Cotograma do Rio Negro em Manaus.	25
Figura 2.3 - Máximas e mínimas no período de 1903 a 2019.	25
Figura 2.4 - Comparativo entre o neurônio biológico e Artificial.....	28
Figura 2.5 - Arquitetura de uma RNA MLP.....	29
Figura 2.6 - Arquitetura de uma RNA NARX.	31
Figura 3.1 - Etapas da pesquisa.	34
Figura 3.2 - Arquitetura NARX.....	36
Figura 3.3 - Etapas para simulação e comparação de resultados.	37
Figura 4.1 - Fluxograma do algoritmo.	42
Figura 4.2 - Esquema de teste para camadas.	43
Figura 4.3 - Gráfico da função Linear para o teste de Camadas.	43
Figura 4.4 - Gráfico da função Sigmoide para o teste de Camadas.	44
Figura 4.5 - Gráfico da função Tangente Hiperbólica para o teste de Camadas.....	44
Figura 4.6 - Esquema de teste para neurônios.	46
Figura 4.7 - Gráfico de regressão da rede neural melhor cenário para 5 passos à frente... 46	46
Figura 4.8 - Gráfico de previsão com 5 passos à frente.	46
Figura 4.9 - Gráfico de regressão da rede neural melhor cenário para 10 passos à frente. 46	46
Figura 4.10 - Gráfico de previsão com 10 passos à frente.	46
Figura 4.11 - Gráfico de regressão da rede neural melhor cenário para 15 passos à frente.46	46
Figura 4.12 - Gráfico de previsão com 15 passos à frente.	46
Figura 4.13 - Gráfico de regressão da rede neural melhor cenário para 20 passos à frente.46	46
Figura 4.14 - Gráfico de previsão com 20 passos à frente.	46
Figura 4.15 - Gráfico de regressão da rede neural melhor cenário para 25 passos à frente.46	46
Figura 4.16 - Gráfico de previsão com 25 passos à frente.	46
Figura 4.17 - Comparação de performance entre os cenários.	46

LISTA DE TABELAS

Tabela 2.1 - Comparação de cotas máximas.	22
Tabela 2.2 - Comparação de cotas mínimas.	24
Tabela 2.3 - Trabalhos que utilizaram RNA para previsão do nível do rio.	27
Tabela 2.4 - Funções de ativação usada no treinamento das redes neurais artificiais.	31
Tabela 4.1 - Amostra de dados.	41
Tabela 4.2 - Resultados da simulação de performance.	45
Tabela 4.3 - Resultados da simulação de neurônios.	46
Tabela 4.4 - Configurações para previsão com 5 passos à frente.	46
Tabela 4.5 - Resultados de previsão com 5 passos à frente.	46
Tabela 4.6 - Configurações para previsão com 10 passos à frente.	46
Tabela 4.7 - Resultados de previsão com 10 passos à frente.	46
Tabela 4.8 - Configurações para previsão com 15 passos à frente.	46
Tabela 4.9 - Resultados de previsão com 15 passos à frente.	46
Tabela 4.10 - Configurações para previsão com 20 passos à frente.	46
Tabela 4.11 - Resultados de previsão com 20 passos à frente.	46
Tabela 4.12 - Configurações para previsão com 25 passos à frente.	46
Tabela 4.13 - Resultados de previsão com 25 passos à frente.	46

LISTA DE QUADROS

Quadro 3.1 - Variáveis significativas para o modelo.	32
Quadro 3.2 -Recursos computacionais da máquina simuladora.	33
Quadro 3.3 - Algoritmos de treinamento.	33
Quadro 3.4 - Terminologia entre um modelo RNA e ESTATÍSTICO.	37

LISTA DE SIGLAS E ABREVIATURAS

ANA	<i>Agência Nacional de Águas</i>
AR	Auto Regressivo
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARMA	Auto Regressive Moving Average
FDM	Filtro de Diferenças Móveis
FMME	Filtro de Média Móvel Exponencial
FMMG	Filtro de Média Móvel Gama
GPU	<i>Graphic Processing Units</i>
IA	Inteligência Artificial
INMET	Instituto Nacional de Meteorologia
LM	<i>Levenberg-Marquardt</i>
LSTM	<i>Long Short-Term Memory</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MLP	<i>Multi-Layer Perceptron</i>
MSE	<i>Mean Square Error</i>
NARX	<i>Nonlinear AutoRegressive Exogenous</i>
NRMSE	<i>Normalized Root Mean Square Error</i>
RAM	<i>Random Access Memory</i>
RMSE	<i>Root Mean Squared Error</i>
RNA	Redes Neurais Artificiais
SARIMA	<i>Seasonal AutoRegressive Integrated Moving Average</i>
SGB	Serviço Geológico do Brasil
SINGREH	Sistema Estadual de Gerenciamento dos Recursos Hídricos

SUMÁRIO

CAPÍTULO 1	16
1 INTRODUÇÃO	16
1.1 PROBLEMÁTICA E JUSTIFICATIVA.....	17
1.2 OBJETIVOS	18
1.2.1 Geral	18
1.2.2 Específicos	18
1.3 ESCOPO DO TRABALHO	19
CAPÍTULO 2	20
2 REVISÃO DA LITERATURA	20
2.1 RECURSOS HÍDRICOS DO AMAZONAS	20
2.2 PANORAMA DA CHEIA E VAZANTE DO RIO AMAZONAS.....	22
2.3 MÉTODOS E MODELOS PARA PREDIÇÃO DE SÉRIES TEMPORAIS	26
2.3.1 Modelos Estatísticos	26
2.3.2 Modelos de Previsão do Nível do Rio	26
2.4 MODELO RNA.....	27
CAPÍTULO 3	32
3 MATERIAIS E MÉTODOS	32
3.1 MATERIAIS	32
3.1.1 Variáveis Significativas para o Modelo de Previsão	32
3.1.2 Ambiente de Desenvolvimento	32
3.1.3 Recursos da Máquina de Teste	32
3.1.4 Algoritmos de Treinamento.....	33
3.1.5 Funções de Ativação.....	33
3.2 MÉTODOS.....	34
3.2.1 Levantamento de Dados Relativos à Nível do Rio.....	34

3.2.2	Mapeamento de Variáveis Significativas para um Modelo de Previsão	34
3.2.3	Seleção de Métodos Computacionais para o Modelo de Previsão	35
3.2.4	Definição e Implementação da Arquitetura NARX	35
3.2.5	Simulação e Comparação dos Resultados com o Algoritmo Vencedor	37
CAPÍTULO 4		41
4	RESULTADOS E DISCUSSÕES.....	41
4.1	BASE DE DADOS	41
4.2	DEFINIÇÃO DO ALGORITMO	42
4.2.1	Testes de Performance do Algoritmo	43
4.3	PREVISÃO DO NIVEL DO RIO	47
4.3.1	Previsão com 5 passos à frente	47
4.3.2	Previsão com 10 passos à frente	50
4.3.3	Previsão com 15 passos à frente	53
4.3.4	Previsão com 20 passos à frente	56
4.3.5	Previsão com 25 passos à frente	59
4.3.6	Comparativo de performance entre os cenários analisados	62
CAPÍTULO 5		65
5	CONCLUSÃO.....	65
5.1	SUGESTÕES PARA TRABALHOS FUTUROS.....	65

CAPÍTULO 1

1 INTRODUÇÃO

No decorrer dos anos ocorreram algumas enchentes no Brasil, que poderiam ser evitadas caso fossem previstas, devido ao fato de existirem alguns desastres naturais causados por inundações e enchentes, há uma variedade de métodos para previsão de cheias de nível de rio que podem ajudar a sociedade, principalmente os ribeirinhos. Para a prevenção de cheias de forma estocástica é necessária uma grande quantidade de amostras de dados, para que a acuracidade da previsão seja alta e assim possa ser efetiva (FAVA, 2015).

No Norte há uma grande quantidade chuvas fortes e estes eventos propiciam inundações e possivelmente prejuízos econômicos e sociais, como por exemplo perdas de materiais e indivíduos, proliferação de doenças e pessoas sem moradia (SILVA, 2006).

Os estados da região norte do Brasil por suas características de relevo, tem uma influência direta pela cheia e vazante dos rios em todo seu contexto, a previsão dessa variação do regime dos rios é crucial para tomadas de decisão tanto nas áreas ribeirinhas quanto nas áreas rurais.

Entre os modelos de previsão existentes se destacam os estocásticos que necessitam de dados de preferência em tempo real para efetuar a previsão com mais probabilidade de acerto, entre esses modelos se encontra modelos com utilizam de técnicas de Inteligência Artificial e que são utilizados por serem mais fáceis de se implementar e terem uma acuracidade satisfatória, isto unido a alertas de inundações tem o potencial de evitar catástrofes (FAVA, 2015).

Uma das grandes problemáticas de prever inundações com grande volume de variáveis é a integração de diversas fontes distintas, no qual estes dados precisam ser tratados e uniformizados, para que haja um padrão, fazendo com que a previsão seja efetuada com um grau de assertividade próximo dos 100%. Os modelos estocásticos que fazem uso de Redes Neurais Artificiais a vantagem de não haver a necessidade de obter conhecimento explícito da bacia hidrográfica, já que as RNAs se saem bem neste cenário devido a forma de aprendizado dos neurônios que a forma (MARACAJÁ, 2005; GORODETSKAYA, DA FONSECA e DE MELO RIBEIRO, 2017).

Este trabalho modela e aplica o NARX para previsão do nível do rio no Amazonas com variáveis de fácil acesso e implementação através do software *Matlab*, com o intuito de

contribuir com um modelo de previsão capaz de prever uma possível inundação a partir do nível do rio.

1.1 PROBLEMÁTICA E JUSTIFICATIVA

O presente trabalho se justifica por três linhas bases que envolve a problemática do tema, sendo elas a utilização de Inteligência Artificial (IA); A problemática das enchentes no Amazonas e a questão da tecnologia em prol de ajudar na tomada de decisão. Os impactos ambientais ocasionados por fatores econômicos e sociais são problemas que retratam cenários como cheia e vazante do rio, trazendo à tona situações como aumento de doenças, redução da produção agrícola em localidades que dependem de um controle geológico apurado, além do aumento de processos erosivos em localidades de risco.

Em virtude disso, novos métodos ou ferramentas que permitam um gerenciamento hábil de informações para determinar ações e estratégias mediante cenários de alta periculosidade se tornam necessárias. No Estado do Amazonas as cidades localizadas nas margens dos rios convivem com a realidade da subida e descida do rio, em muitos casos chega a inundar municípios impactando diretamente em ações públicas. Para se obter previsões de boa qualidade, é necessário prever ou mapear corretamente o comportamento de um sistema natural complexo, utilizando-se de informações completas e com correlação entre outras variáveis meteorológicas e hidrológicas, então se torna importante o uso de métodos computacionais por meio de algoritmos para realizar tarefas exaustivas e melhorar o desempenho de um modelo em função da resposta esperada. Tendo em vista que a tecnologia vem crescendo de forma acelerada nos últimos anos, o conceito de IA vem sendo aplicado em diversos problemas do cotidiano e de diversas formas, ajudando assim na resolução de diversos problemas do mundo real ou na minimização dos mesmos.

Desta forma, a IA é uma tecnologia que é bastante útil para os seres humanos, podendo resolver/minimizar problemas graves da população em geral, um dos problemas que aflige as pessoas, principalmente na região Amazonas, é a questão das enchentes que ocorre com uma certa frequência, em meio a esta problemática a utilização de técnicas de IA para prever o nível do rio e conseqüentemente possíveis enchentes, para que assim possa-se ter melhores tomadas de decisões em relação a enchentes eminentes, já que a IA é de uma complexidade mediana para ser implementada devido aos algoritmos serem públicos e de fácil acesso.

Assim a utilização de IA para previsão do nível do rio que conseqüentemente pode minimizar problemáticas advindas de enchentes que causam um impacto ambiental é altamente possível, já que quando se sabe antecipadamente que uma enchente está perto de acontecer, podem ser tomadas decisões para que os impactos de uma enchente sejam menores. A previsão da variação do regime dos rios é um fator fundamental para planejamento estratégico e ações.

Outro fator importante a se destacar é a rapidez com que a previsão pode ser realizada por uma IA tendo o resultado em poucos minutos ou até mesmo em segundos, tal processo fica ainda mais confiável quando se tem uma série histórica com dados de vários anos atrás, pois com esses dados é possível a IA verificar padrões sazonais durante certos períodos de tempo e realizar a previsão com base no passado. Como os dados de enchentes e nível do rio são coletados a todo momento em diversos bancos de dados é interessante ter um modelo que utilize variáveis fáceis de se conseguir, como é o caso da proposta desta dissertação.

1.2 OBJETIVOS

1.2.1 Geral

Implementar um modelo AutoRegressivo não Linear com Entradas Exógenas para previsão do nível do rio em função dos cenários de impactos ambientais causados por enchentes ou vazantes no estado do Amazonas.

1.2.2 Específicos

- Identificar as variáveis significativas de entrada com correlação com a variável de saída para previsão do nível do rio;
- Atinar as configurações (número de camadas, algoritmo de treinamento, funções de ativação, número de neurônios) ideais para aplicação no modelo de previsão;
- Simular previsões com as configurações ideais do modelo para verificar a acuracidade do mesmo;
- Comparar os resultados obtidos através do NARX a fim de verificar a performance de previsão com um outro algoritmo de previsão de séries temporais.

1.3 ESCOPO DO TRABALHO

- **Capítulo 1:** Neste capítulo foi mostrado uma introdução do tema contendo alguns elementos importantes, como a justificativa da pesquisa, problemática das enchentes no Amazonas e objetivos, tanto geral quanto específicos;
- **Capítulo 2:** Neste capítulo é apresentado uma revisão bibliográfica acerca dos temas que fundamentam a temática proposta nesta dissertação, sendo eles: Recursos Hídricos do Amazonas, Panorama da cheia e vazante do rio Amazonas, os Impactos na cheia e vazantes do rio, Métodos e modelos para predição de Séries Temporais, Séries Temporais, Modelos de Box-Jenkins, Modelo RNA e Modelo NARX, de tal forma que facilite o entendimento das abordagens para o leitor;
- **Capítulo 3:** Capítulo ao qual se encontra os materiais e métodos utilizados na pesquisa e desenvolvimento deste trabalho, como: Software para aplicação do algoritmo de previsão; Processo de escolha das variáveis utilizadas no modelo; Fluxograma de etapas do desenvolvimento do trabalho; Detalhes sobre a base de dados utilizada para a previsão; Configurações utilizadas no modelo NARX e configurações da máquina utilizada para testes.
- **Capítulo 4:** Neste capítulo é apresentado os resultados acerca da pesquisa, alcançando os objetivos específicos como: identificação das variáveis significativas que são consideradas na base de dados, definição e escolha dos algoritmos de treinamento que serão testados e fundamentação teórica e prática do modelo de previsão, neste caso NARX.
- **Capítulo 5:** Capítulo que apresenta a conclusão apresentando um cenário geral do que foi realizado nas aplicações desta dissertação.

CAPÍTULO 2

2 REVISÃO DA LITERATURA

Esta seção apresenta os principais tópicos relativos ao tema desta dissertação, enfatizando um embasamento teórico e científico acerca dos procedimentos metodológicos para aquisição dos resultados.

Este capítulo fundamenta temas em função dos Recursos Hídricos do Amazonas, Características relativas à cheia, vazante e impactos do Rio Amazonas e Modelos de predição considerando técnicas e métodos estatísticos/computacionais, considerando a modelagem de Séries Temporais.

2.1 RECURSOS HÍDRICOS DO AMAZONAS

Pode-se entender como “Recurso Hídrico” toda e qualquer água superficial e subterrânea disponível para uso, por sua vez, empregada em um determinado uso ou atividade (DE AMORIM, 2021).

Este recurso dá vida a diversas fontes de tecnologias e bens-econômicos, em virtude disso a Agência Nacional de Águas (ANA) foi criada com o objetivo de gerenciar esses recursos hídricos e regular o acesso à água, de tal forma a permitir um uso sustentável desses recursos em prol da atual e futura geração.

Contudo, a Lei nº 3.167, de 28 de agosto de 2007 reformula as normas disciplinadoras da Política Estadual de Recursos Hídricos e do Sistema Estadual de Gerenciamento dos Recursos Hídricos (SINGREH), o Art. 1º regulamenta alguns princípios na qual esta lei se baseia:

- I – A água é um bem de domínio público;
- II – A água é um recurso natural limitado, dotado de valor econômico;
- III – Em situações de escassez, o uso prioritário dos recursos hídricos é o consumo humano e a dessedentação de animais;
- IV – A gestão dos recursos hídricos deve sempre proporcionar o uso múltiplo das águas;

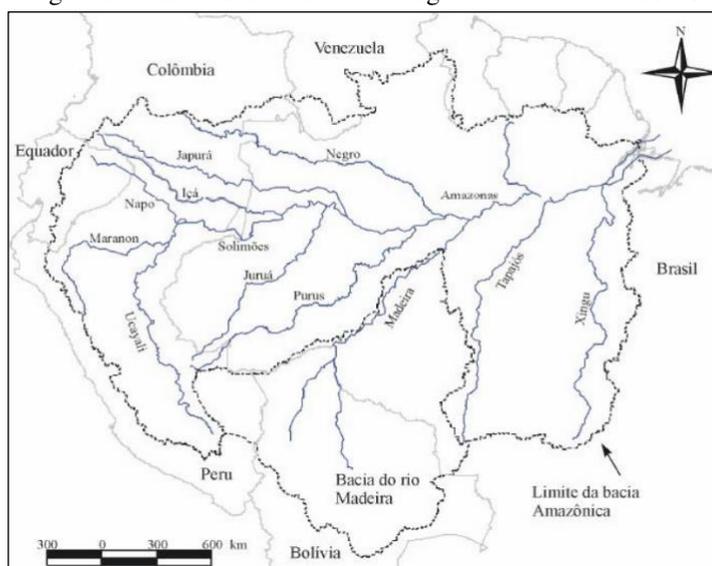
V – A bacia hidrográfica é a unidade territorial de planejamento para implementação da Política Estadual de Recursos Hídricos e atuação do Sistema Estadual de Gerenciamento de Recursos Hídricos;

VI – A gestão dos recursos hídricos deve ser descentralizada e contar com a participação do Poder Público, dos usuários e da sociedade civil.

O inciso I, explicita a disponibilidade desses recursos como bem público, o inciso II deixa claro a transformação desse recurso em bem-econômico, por isso, o seu valor se torna maior e proporcional a sua quantidade, ou seja, é limitado, o inciso III chama a atenção de situações em que há escassez de água, sendo prioritário o uso destes recursos para o consumo humano ou animal, os incisos IV, V e VI contextualizam a gestão desses recursos por meio de políticas estaduais e define a participação do poder público para assegurar essa gestão.

Em 1997, os recursos hídricos brasileiros passaram a ser regulado pela Lei Federal nº 9.433/97, essa lei representa um marco fundamental no processo de mudança do ambiente institucional regulador dos recursos hídricos no Brasil ao instituir a política nacional de recursos hídricos e criou o sistema nacional de gerenciamento de recursos hídricos (SNGRH) (SILVA, MIRANDA e SANTANA, 2016).

Figura 2.1 - Extensão da Bacia Hidrográfica do Rio Amazonas.



Fonte: Silva *et. al.*, (2013).

Na Amazônia, a rede fluvial de transporte é um dos meios mais utilizados em função da dimensão e proporção de recursos hídricos encontrados na bacia amazônica, localizada no Brasil e em mais sete países da América do Sul, sendo eles: Bolívia, Colômbia, Guiana, Guiana Francesa, Peru, Suriname e Venezuela (NATTRODT e DIAS, 2021), usufrui de

aproximadamente 7 milhões de quilômetros quadrados de extensão, sendo 4 milhões em território brasileiro, além de 23 mil quilômetros de rios navegáveis, constituindo rios como: Negro, Solimões, Branco, Juruá, Xingu, Japurá e outros. A Figura 2.1 ilustra a dimensão da Bacia Hidrográfica do Rio Amazonas.

2.2 PANORAMA DA CHEIA E VAZANTE DO RIO AMAZONAS

O rio Amazonas está localizado na maior bacia hidrográfica do Planeta, nascendo na Cordilheira dos Andes percorrendo uma distância de 6.577 km até chegar na sua foz no Oceano Atlântico, tendo nesse percurso a contribuição de mais de mil afluentes tanto na margem esquerda quanto da direita (ALBUQUERQUE, 2018).

Em 2021, os rios amazônicos apresentaram cotas entre as máximas diárias desde o início do ano e a partir do mês de abril, inundação severa ao longo da bacia, acompanhando o prognóstico do Serviço Geológico do Brasil (SGB-CPRM). O pico da cheia na bacia do rio Amazonas é normalmente observado entre os meses de junho e julho (CPRM, 2021).

O que determina a magnitude dessas cheias é a chuva que ocorre em todas as bacias que drenam para essa região, como a bacia do Negro, do Solimões e todos os seus afluentes (Purus, Juruá, Japurá, Jutai e etc.), incluindo suas áreas externas ao Brasil, na Colômbia, Peru e Equador. A Bacia Hidrográfica do Amazonas é a maior bacia hidrográfica do mundo (ALVES, 2021; CPRM, 2021).

A Tabela 2.1 apresenta um comparativo de valores das cotas máximas observadas ao longo dos anos, os dados são disponibilizados por boletins do CPRM, são relacionados os dados das estações monitoradas em função do ano de 2021 e outras observações.

A Coluna Evento máximo indica a data, a cota e a relação da cota atual observada naquele ano e registrada como máxima, a segunda coluna informa os dados daquele ano registrado como máxima para comparar com os dados da terceira coluna do ano de 2021, é possível identificar a similaridade entre os valores.

Tabela 2.1 - Comparação de cotas máximas.

Estações	Evento máximo			Comparação mesmo período do ano de máxima			Informação mais recente	
	Data da Máxima	Cota máxima	Relação cota atual	Data	Cota período	Relação cota atual	Data	Cota atual
Barcelos (Negro)	13/06/76	1032	-62	27/05/76	970	0	27/05/21	970
Beruri (Purus)	24/06/15	2236	-78	26/05/15	2200	-42	26/05/21	2158

Estações	Evento máximo			Comparação mesmo período do ano de máxima			Informação mais recente	
	Data da Máxima	Cota máxima	Relação cota atual	Data	Cota período	Relação cota atual	Data	Cota atual
Boa Vista (Branco)	08/06/11	1028	-383	28/05/11	804	-159	28/05/21	645
Caracará (Branco)	09/06/11	1114	-329	28/05/11	910	-125	28/05/21	785
Careiro (P. Careiro)	30/05/12	1743	-1	28/05/12	1741	1	28/05/21	1742
Fonte Boa (Solimões)	06/06/15	2282	-64	21/05/15	2250	-32	21/05/21	2218
Humaitá (Madeira)	11/04/14	2563	-737	28/05/14	2307	-481	28/05/21	1826
Itacoatiara (Amazonas)	19/06/09	1604	-84	28/05/09	1591	-71	28/05/21	1520
Itapeuá (Solimões)	24/06/15	1801	-70	28/05/15	1763	-32	28/05/21	1731
Manacapuru (Solimões)	25/06/15	2078	-4	28/05/15	2040	34	28/05/21	2074
Manaus (Negro)	29/05/12	2997	-2	28/05/12	2996	-1	28/05/21	2995
Parintins (Amazonas)	31/05/09	936	9	27/05/09	930	15	27/05/21	945
Rio Branco (Acre)	05/03/15	1834	-1502	27/05/15	815	-483	27/05/21	332
S. G. C. (Negro)	20/07/02	1217	26	28/05/02	1111	132	28/05/21	1243
Tabatinga (Solimões)	28/05/99	1382	-166	28/05/99	1382	-166	28/05/21	1216
S.I.N.								
Tapuruquara (Negro)	02/06/76	890	-74	27/05/76	864	-48	27/05/21	816

Fonte: (ALVES, 2021; CPRM, 2021).

A Tabela 2.2 apresenta um comparativo de valores das cotas mínimas observadas ao longo dos anos, os dados são disponibilizados por boletins do CPRM, são relacionados os dados das estações monitoradas em função do ano de 2021 e outras observações.

A Coluna Evento mínimo indica a data, a relação da cota atual observada naquele ano e registrada como mínima, a segunda coluna informa os dados daquele ano registrado como mínima para comparar com os dados da terceira coluna do ano de 2021, é possível identificar os valores registrados no ano de 2021 são superiores em relação às outras observações de anos anteriores.

Tabela 2.2 - Comparação de cotas mínimas.

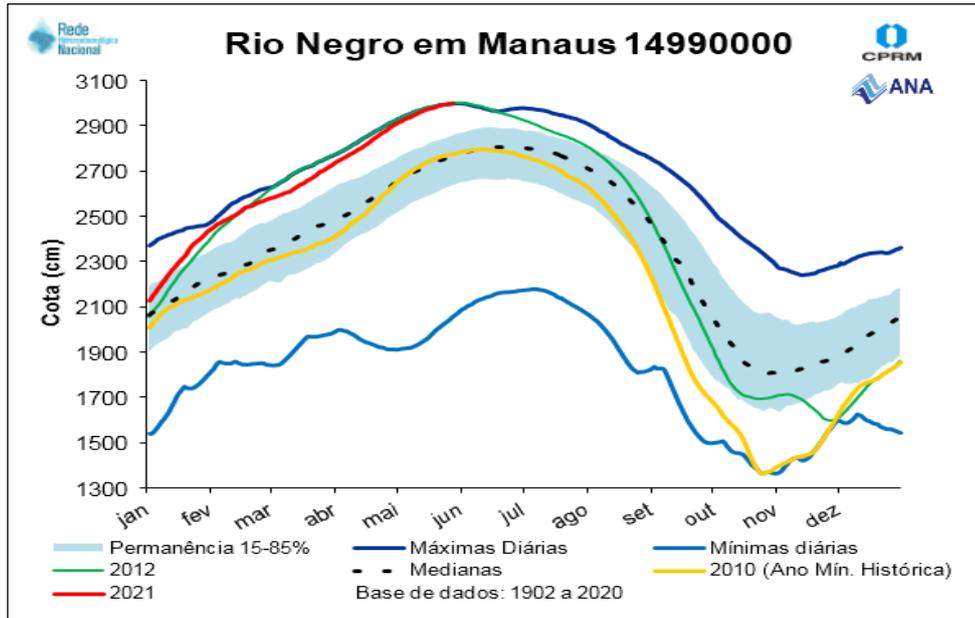
Estações	Evento mínimo			Comparação mesmo período do ano de mínima			Informação mais recente	
	Data da Mínima	Cota mínima	Relação cota atual	Data	Cota período	Relação cota atual	Data	Cota atual
Barcelos (Negro)	18/03/80	58	912	27/05/80	636	334	27/05/21	970
Beruri (Purus)	25/10/10	518	1640	26/05/10	1920	238	26/05/21	2158
Boa Vista (Branco)	14/02/16	-57	702	28/05/16	150	495	28/05/21	645
Caracaraí (Branco)	24/03/98	-10	795	28/05/98	601	184	28/05/21	785
Careiro (P. Careiro)	25/10/10	125	1617	28/05/10	1551	191	28/05/21	1742
Fonte Boa (Solimões)	17/10/10	802	1416	21/05/10	2038	180	21/05/21	2218
Humaitá (Madeira)	01/10/69	833	993	28/05/69	1559	267	28/05/21	1826
Itacoatiara (Amazonas)	24/10/10	91	1429	28/05/10	1339	181	28/05/21	1520
Itapeuá (Solimões)	20/10/10	131	1600	28/05/10	1534	197	28/05/21	1731
Manacapuru (Solimões)	26/10/10	392	1682	28/05/10	1832	242	28/05/21	2074
Manaus (Negro)	24/10/10	1363	1632	28/05/10	2776	219	28/05/21	2995
Parintins (Amazonas)	24/10/10	-186	1131	27/05/10	799	146	27/05/21	945
Rio Branco (Acre)	17/09/16	130	202	27/05/16	321	11	27/05/21	332
S. G. C. (Negro)	07/02/92	330	913	28/05/92	907	336	28/05/21	1243
Tabatinga (Solimões)	11/10/10	-86	1302	28/05/10	1074	142	28/05/21	1216
S.I.N. Tapuruquara (Negro)	13/03/80	28	788	27/05/80	688	128	27/05/21	816

Fonte: (ALVES, 2021; CPRM, 2021).

O Gráfico da Figura 2.2 apresenta dados de Cotagrama para a estação de Manaus (Rio Negro) do ano de 2021, nele é possível identificar as máximas diárias registradas, mínimas diárias registradas, o registro observado mínimo da série histórica de 2010, a mediana e a série de permanência de 2021 a 2021, as curvas envoltórias representadas pela faixa azul

caracterizam os dados entre 15 e 85% de permanência para os dados diários de cotas (CPRM, 2021).

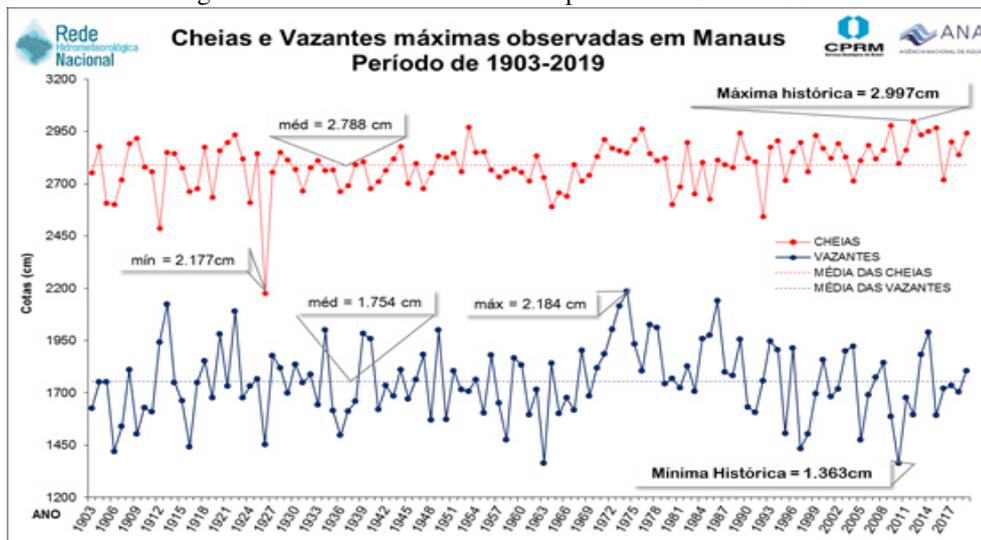
Figura 2.2 - Cotagrama do Rio Negro em Manaus.



Fonte: (ALVES, 2021; CPRM, 2021).

Segundo Alves (2021) as curvas de faixa azul apresentadas na Figura 2.2 expressam valores a serem analisados com atenção, ou seja, para os valores acima da faixa, representa um processo de cheia expressiva e nos valores abaixo um processo de vazante acentuado.

Figura 2.3 - Máximas e mínimas no período de 1903 a 2019.



Fonte: (ALVES, 2021; CPRM, 2021).

A Figura 2.3 ilustra um comparativo de máximas e mínimas históricas registradas em Manaus capital do estado do Amazonas, em função de um período de 1903 a 2019.

É possível identificar que a máxima histórica de 2,997cm é alcançada no ano de 2012 conforme apresentado na Figura 2, isso expressa o aumento expressivo do nível do rio em decorrência de eventos externos que influenciam diretamente na mudança de comportamento hidrológica. A cada ano as influências climáticas globais atingem e agravam a situação de vida dos moradores das margens dos rios e para agravar mais a situação das mudanças climáticas dentro da Amazônia têm a presença do desmatamento.

2.3 MÉTODOS E MODELOS PARA PREDIÇÃO DE SÉRIES TEMPORAIS

Na literatura encontra-se alguns modelos para a previsão de séries temporais entre eles podem ser citados os seguintes modelos: ARIMA, SARIMA, RNA e NARX.

Sendo o ARIMA utilizado para previsões de curto prazo, no qual os comportamentos dos dados não são sazonais, já o SARIMA é utilizado para séries que possuem sazonalidade. As RNAs e o modelo NARX podem ser usados para os dois tipos de séries temporais (BLÁZQUEZ-GARCÍA et al., 2020; WANG et al., 2015).

2.3.1 Modelos Estatísticos

Os modelos estatísticos são simples de implementar e possui uma característica de terem um bom desempenho quando a previsão é de curto prazo, estes modelos utilizam um histórico de dados para ter como base e prever passos adiante (CHANG et al., 2014).

Os modelos estatísticos utilizam usualmente métodos de séries temporais como: Auto Regressive - AR, Auto Regressive Moving Average – ARMA, Auto Regressive Integrated Moving Average – ARIMA e Seasonal Auto Regressive Integrated Moving Average (SARIMA) (ALENCAR et al., 2018).

Os modelos estatísticos também abordam métodos computacionais como: RNA, NARX e Neuro-Fuzzy (BARBOSA DE ALENCAR et al., 2017).

2.3.2 Modelos de Previsão do Nível do Rio

Dentre os modelos utilizados para a previsão de nível do rio, tem-se os seguintes: RNA, Modelos Hidrológicos como Filtro de Diferenças Móveis (FDM), Filtro de Média Móvel Exponencial (FMME) e Filtro de Média Móvel Gama (FMMG).

As RNAs são comumente utilizadas para previsão de séries temporais, porém para a previsão de níveis de rios e enchentes há uma gama muito limitada, tendo em vista isto, o estudo realizado por (ALBERTON et al., 2021) utilizou RNA do tipo LSTM (Long Short-Term Memory) e MLP (Multi-Layer Perceptron) para a previsão do rio Itajaí-Açu em Blumenau.

Na Tabela 2.3 pode-se observar alguns trabalhos que utilizaram RNA para prever o nível do rio.

Tabela 2.3 - Trabalhos que utilizaram RNA para previsão do nível do rio.

Autor	Título	Técnica/Método	Descrição
(ALBERTON et al., 2021)	Aplicação de redes neurais artificiais para previsão de enchentes no rio Itajaí-Açu em Blumenau, SC, Brasil	RNA do tipo LSTM e MLP	O estudo faz um comparativo entre uma RNA do tipo LSTM e MLP e propõe a utilização de RNA do tipo LSTM para previsão de nível do rio e enchentes.
(CRISTALDO et al., 2020)	Redes Neurais Artificiais aplicadas à previsão de enchentes para região do pantanal no Mato Grosso do Sul	RNA do tipo MLP	A presente pesquisa utilizou a técnica RNA para prever inundações no rio Aquidauana.
(ARAÚJO et al., 2020)	Previsão Sazonal de Vazões para a Bacia do Orós (Ceará, Brasil) Utilizando Redes Neurais e a Técnica De Reamostragem dos K-vizinhos	RNA e Reamostragem dos K-vizinhos	O artigo compara duas técnicas (RNA e Reamostragem dos K-vizinhos), aplicados na barragem do Orós, que está localizada na Bacia do Alto Jaguaribe, onde a técnica de RNA teve melhores resultados.
(FINCK, 2020)	Previsão em tempo atual de níveis fluviais com Redes Neurais Artificiais: Aplicação à bacia do rio Taquari-Antas/RS	Modelos hidrológicos com RNA	Neste estudo foi feito um método híbrido combinando um modelo hidrológico (FMMG) com RNA para previsão de enchentes na bacia de Taquari-Antas.

2.4 MODELO RNA

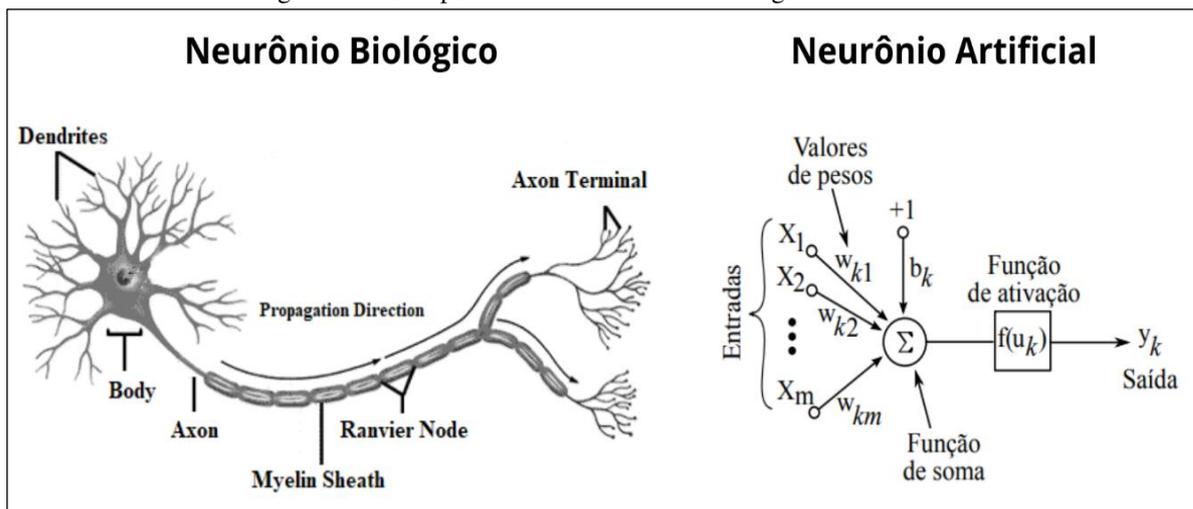
As RNAs foram constituídas inicialmente em 1943 por Mcculloch e Pitts, no qual esta técnica de IA foi baseada no funcionamento dos neurônios humanos, imitando assim a capacidade de aprendizagem que o cérebro tem de aprender, tendo como ponto de partida um

histórico de dados que simula a experiência humana ao longo do tempo e com isso pode determinar uma previsão (MCCULLOCH e PITTS, 1943).

Conforme Haykin (2008), a rede neural é como um processador com inúmeras unidades de processamento atuando ao mesmo tempo, que possui a capacidade de guardar dados e mostrar o conhecimento adquirido através do processamento dos dados.

A representação do neurônio humano e o da Rede Neural Artificial (RNA) pode ser exemplificado pela Figura 2.4.

Figura 2.4 - Comparativo entre o neurônio biológico e Artificial.



Fonte: Adaptado de CERRI (2020) e PARENTE (2021).

O neurônio artificial imita o comportamento dos neurônios biológicos de forma a aprender conforme o treinamento baseado em um histórico de dados, sendo que o modelo de uma rede neural é constituído por entradas que podem assumir qualquer valor positivo indicando a quantidade de variáveis a serem utilizadas no modelo. Os modelos de RNAs possuem três camadas, sendo divididos em camada de entrada, camada oculta e camada de saída (SILVA et. al., 2020; DE MENDONÇA et. al., 2021).

Camada de Entrada: Na camada de entrada estão as variáveis de entrada, que são utilizadas para alcançar o objetivo final, seja ele de prever uma variável x ou y . Sendo que as variáveis de entrada devem ter uma correlação com a variável de saída, quanto maior é a correlação entre as variáveis, melhor será o resultado final, vale ressaltar que a previsão vai perdendo confiabilidade na medida de passos previstos a frente, exemplo: Prever dados de um dia a frente é mais fácil do que prever de 365 dias a frente.

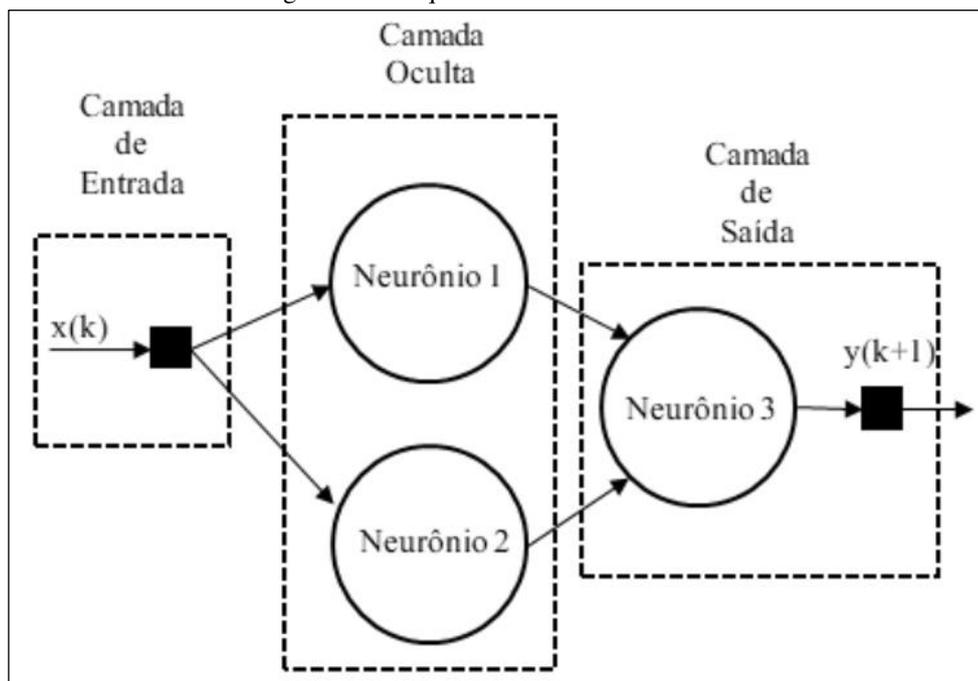
Camada Oculta: A camada oculta contém os neurônios que são responsáveis por fazer a aproximação dos valores mais adequados para se alcançar o resultado final pretendido, tais

valores de aproximação são conhecidos como pesos. A camada oculta pode ser composta por várias subcamadas e com n neurônios em cada uma delas.

Camada de Saída: A camada de saída é o resultado final do processamento feito pela Rede Neural que pode conter uma ou mais variáveis dependentes como resultado.

Na Figura 2.5 é apresentado a arquitetura de uma RNA multicamada, também conhecida como MLP.

Figura 2.5 - Arquitetura de uma RNA MLP.



Fonte: DE MENDONÇA *et al.*, (2021).

O processo de construção de uma RNA possui alguns parâmetros, entre eles, há a definição da quantidade de camadas ocultas, a quantidade de neurônios em cada camada, a definição das variáveis a serem utilizadas no problema a que se quer resolver, definir o algoritmo de treinamento da Rede Neural, encontrar a melhor função de transferência e utilizar parâmetros para medir a performance da RNA. Sendo estes elementos os principais para o desenvolvimento de uma RNA.

Definição das variáveis: O primeiro processo é definir as variáveis de entrada, sendo que estas devem ter uma correlação com a variável de saída que é o resultado a ser encontrado. Para uma boa definição de variável é necessário que haja a mesma quantidade de registros entre ambas as variáveis de entrada.

Quantidade de camadas ocultas: A quantidade de camadas ocultas geralmente é definida por testes de tentativa e erro para se chegar à quantidade que melhor se adequa a

problemática em estudo. Poucas camadas ocultas podem prejudicar o desempenho da RNA, muitas camadas ocultas também acontece o mesmo, logo é necessário testar várias camadas para se verificar com quantas camadas o problema estudado tem uma melhor performance.

Quantidade de neurônios: Com os neurônios a premissa é a mesma da quantidade de camadas ocultas, deve ser testado para se encontrar a melhor quantidade, pretendendo assim alcançar a melhor performance possível da RNA.

Algoritmo de treinamento: O algoritmo de treinamento tem a finalidade de fazer com que a RNA aprenda com os dados históricos, cada algoritmo tem suas particularidades, alguns são melhores para a previsão de dados sazonais, outros lineares, já outros para identificação de padrões, logo é interessante que no processo de escolha do algoritmo de treinamento seja testado alguns algoritmos para identificar qual o melhor para o problema em estudo. Existem alguns algoritmos de treinamento, entre os mais conhecidos podem ser elencados 12 algoritmos, sendo eles:

- *Levenberg-Marquardt,*
- *Bayesian Regularization,*
- *Broyden–Fletcher–Goldfarb–Shanno Quasi-Newton,*
- *Resilient Backpropagation,*
- *Scaled Conjugate Gradient,*
- *Conjugate Gradient with Powell/Beale Restarts,*
- *Fletcher-Powell Conjugate Gradient,*
- *Polak-Ribière Conjugate Gradient,*
- *One Step Secant,*
- *Variable Learning Rate Gradient Descent,*
- *Gradient Descent with Momentum;*
- *Gradient Descent.*

Função de transferência: A função de transferência está presente tanto nas camadas ocultas quanto na camada de saída, existem algumas funções de transferência que podem ser encontradas na Tabela 2.4.

Tabela 2.4 - Funções de ativação usada no treinamento das redes neurais artificiais.

Função	Equação	Descrição	Intervalo
Identidade	α	Com essa função, o nível de ativação é transmitido diretamente como a saída dos neurônios.	$(-\infty, +\infty)$
Logística	$\frac{1}{1 + e^{-\alpha}}$	Essa é uma curva em forma de S (sigmoide).	$(0, 1)$
Tangente hiperbólica	$\frac{e^{\alpha} - e^{-\alpha}}{e^{\alpha} + e^{-\alpha}}$	É uma função simétrica em forma de S (sigmoide).	$(-1, +1)$
Exponencial	$e^{-\alpha}$	Função exponencial negativa.	$(0, +\infty)$

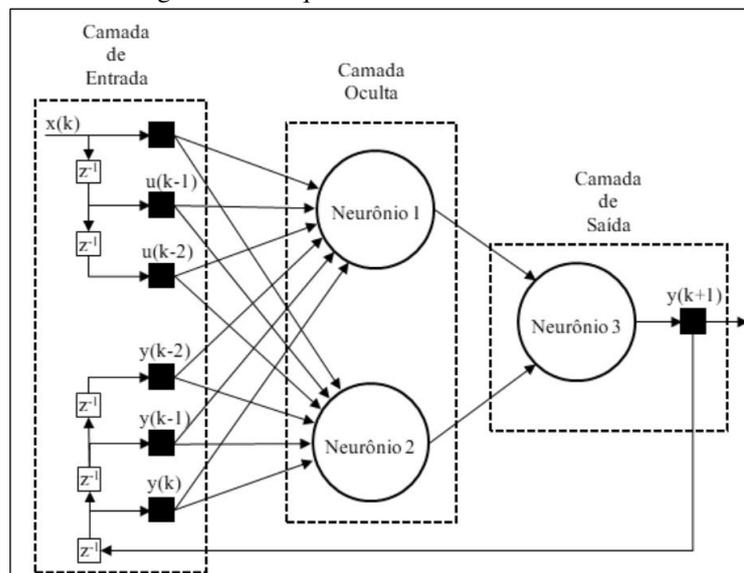
Fonte: REIS *et al.*, (2018).

Parâmetros de performance: Existem alguns parâmetros de performance que podem ser utilizados para avaliar o desempenho de uma RNA, sendo os mais utilizados o MSE, RMSE, Regressão e MAPE.

Há algumas variantes de RNA, entre elas o NARX que é a técnica selecionada para a realização deste estudo. Este modelo é muito utilizado para previsão de séries temporais (MATKOVSKYY e BOURAOU, 2019; WUNSCH, LIESCH e BRODA, 2018).

Na Figura 2.6 mostra o funcionamento da Rede Neural NARX, no qual a mesma possui camada de entrada, camada oculta e camada de saída, a principal diferença de uma Rede Neural Artificial e o NARX é que o modelo NARX possui retroalimentação, sendo indicada para previsão de séries temporais, principalmente se houver sazonalidade nos dados de entrada e no alvo.

Figura 2.6 - Arquitetura de uma RNA NARX.



Fonte: DE MENDONÇA *et al.*, (2021).

CAPÍTULO 3

3 MATERIAIS E MÉTODOS

Neste capítulo são apresentados os materiais que foram utilizados para a realização da pesquisa considerando a contextualização do que se pretende alcançar para resolver a problemática, e os métodos para se chegar no objetivo geral que é aplicar o modelo Auto Regressivo não Linear com Entradas Exógenas para previsão do nível do rio em função dos cenários de impactos ambientais causados por enchentes ou vazantes no estado do Amazonas.

3.1 MATERIAIS

3.1.1 Variáveis Significativas para o Modelo de Previsão

As variáveis utilizadas para o modelo de previsão são apresentadas no Quadro 3.1.

Quadro 3.1 - Variáveis significativas para o modelo.

Variável	Tipo
Chuva	Entrada
Temperatura do Rio	Entrada
Umidade Relativa do Ar	Entrada
Nível do Rio	Saída

3.1.2 Ambiente de Desenvolvimento

Para a implementação do modelo de previsão foi utilizado o software *MatLab* 2016a usufruindo de alguns recursos como geração de gráficos, criação de funções, implementação de modelos matemáticos e recursos de linguagem de programação para aplicação dos procedimentos do algoritmo e modelos de RNA.

3.1.3 Recursos da Máquina de Teste

As configurações da máquina utilizada para as simulações foram importantes, principalmente na relação de uso dos recursos computacionais como: Paralelismo e Processamento de dados com alocação de memória em Unidades de Processamento Gráfica (Graphic Processing Units - GPU). O Quadro 3.2 apresenta as configurações da máquina utilizada.

Quadro 3.2 -Recursos computacionais da máquina simuladora.

Recurso	Valor
Memória RAM	6GB
Processador	I5 terceira geração
Clock de processamento	2.90 GHz
Memória Cache L3	6MB
Tecnologia de armazenamento	HD
Memória Secundária	500GB

3.1.4 Algoritmos de Treinamento

Os algoritmos de treinamento para o modelo NARX foram de suma importância para encontrar o melhor estado de convergência com base na quantidade de neurônios, camadas, funções de ativação e erros como o MSE, RMSE, NRMSE e MAPE. O Quadro 3.3 apresenta os algoritmos que serão utilizados, caracterizando os seus métodos de convergência.

Quadro 3.3 - Algoritmos de treinamento.

Algoritmo	Método
<i>Levenberg-Marquardt</i>	Otimização
<i>Bayesian Regularization</i>	Otimização
<i>Broyden–Fletcher–Goldfarb–Shanno Quasi-Newton</i>	Iterativo
<i>Resilient Backpropagation</i>	Heurístico
<i>Scaled Conjugate Gradient</i>	Iterativo
<i>Conjugate Gradient with Powell/Beale Restarts</i>	Iterativo
<i>Fletcher-Powell Conjugate Gradient</i>	Quase-Newton
<i>Polak-Ribière Conjugate Gradient</i>	Otimização
<i>One Step Secant</i>	Newton
<i>Variable Learning Rate Gradient Descent</i>	Numérico
<i>Gradient Descent with Momentum</i>	Iterativo
<i>Gradient Descent</i>	Iterativo

3.1.5 Funções de Ativação

As funções de transferência são de suma importância para avaliar e reduzir a explosão do gradiente nas camadas de transferência entre os neurônios, no qual o controle de iteração, menor erro e melhor modelo são critérios de parada do algoritmo utilizado. As funções utilizadas são apresentadas a seguir:

- ·Linear;
- ·Sigmoides;
- ·Tangente hiperbólica

3.2 MÉTODOS

A pesquisa é caracterizada pela investigação de métodos computacionais que evidenciem eficiência no processamento de dados e eficácia na simulação dos resultados, para aplicar os conceitos relativos à previsão do nível do rio em função dos cenários de impactos ambientais causados por enchentes ou vazantes, por meio de base de dados referentes ao nível do rio no estado do Amazonas, foi realizado uma análise acerca do conteúdo, por fim algumas etapas foram consideradas para consolidar a pesquisa, sendo elas ilustradas pela Figura 3.1.

Figura 3.1 - Etapas da pesquisa.



3.2.1 Levantamento de Dados Relativos à Nível do Rio

O levantamento dos dados deve ser feito em *databases* meteorológicas, ou sites específicos que evidenciam a coleta de dados de forma cronológica, de tal forma que seja possível utilizar esse histórico registrado.

O mapeamento da variável de entrada deverá ser feito por meio do Instituto Nacional de Meteorologia consultando a base de dados, a variável de saída deve ser adquirida através do site do Porto de Manaus.

3.2.2 Mapeamento de Variáveis Significativas para um Modelo de Previsão

As variáveis que descrevem com aptidão o comportamento do nível do rio são de características meteorológicas, estas que, em virtude do clima tendem a serem relativas, por conta disso, o fato de chover ou não influencia na enchente ou vazante do rio também.

A chuva por sua vez, é formada por gotículas de água de uma dimensão maior que as do chuvisco, em muitos casos maior que 0,5mm de diâmetro, o máximo de intensidade de precipitação resulta normalmente da formação de gotas relativamente grandes em nuvens cumuliformes. O chuvisco provém de nuvens estratiformes, cuja espessura não excede algumas centenas de metros e influencia diretamente no comportamento de uma enchente ou vazante do rio.

A temperatura do rio é uma medida realizada por termômetros, contudo, é por meio desta variável que é possível caracterizar o fluxo de animais e vida (peixes, algas e outros organismos), estes que definem a qualidade de vida da localidade em função da escassez ou abundância de alimentos, além de proferir informações para avaliar a saúde em relação destes animais pela qualidade da água.

A Umidade relativa do ar, esta é uma variável que incide com o fenômeno da precipitação, de fato a água, em razão de seu calor específico, tende a conservar por mais tempo as temperaturas, fazendo com que haja uma menor variação delas, ou seja, a amplitude térmica (diferença entre a maior e a menor temperatura) é menor quanto maior for a umidade do ar, ou seja, A umidade do ar ou atmosférica é a quantidade de água existente no ar na forma de vapor.

Nível do rio, variável de saída que permite definir o quão perigoso será o período de enchente ou vazante mediante as variantes acima citado, em virtude desse comportamento os impactos ambientais são levados em consideração, por isso, é de suma importância a utilização de modelos de previsão ou meteorológicos para necessidades como esta.

3.2.3 Seleção de Métodos Computacionais para o Modelo de Previsão

Nesta etapa é definido os métodos computacionais que deverão ser utilizados para o processo de aprendizado do NARX, neste caso, especificamente por se tratar de séries temporais com sazonalidade, e variáveis estocásticas relativas à nível de rio, se faz necessário o uso do modelo com entradas exógenas auto-regressiva.

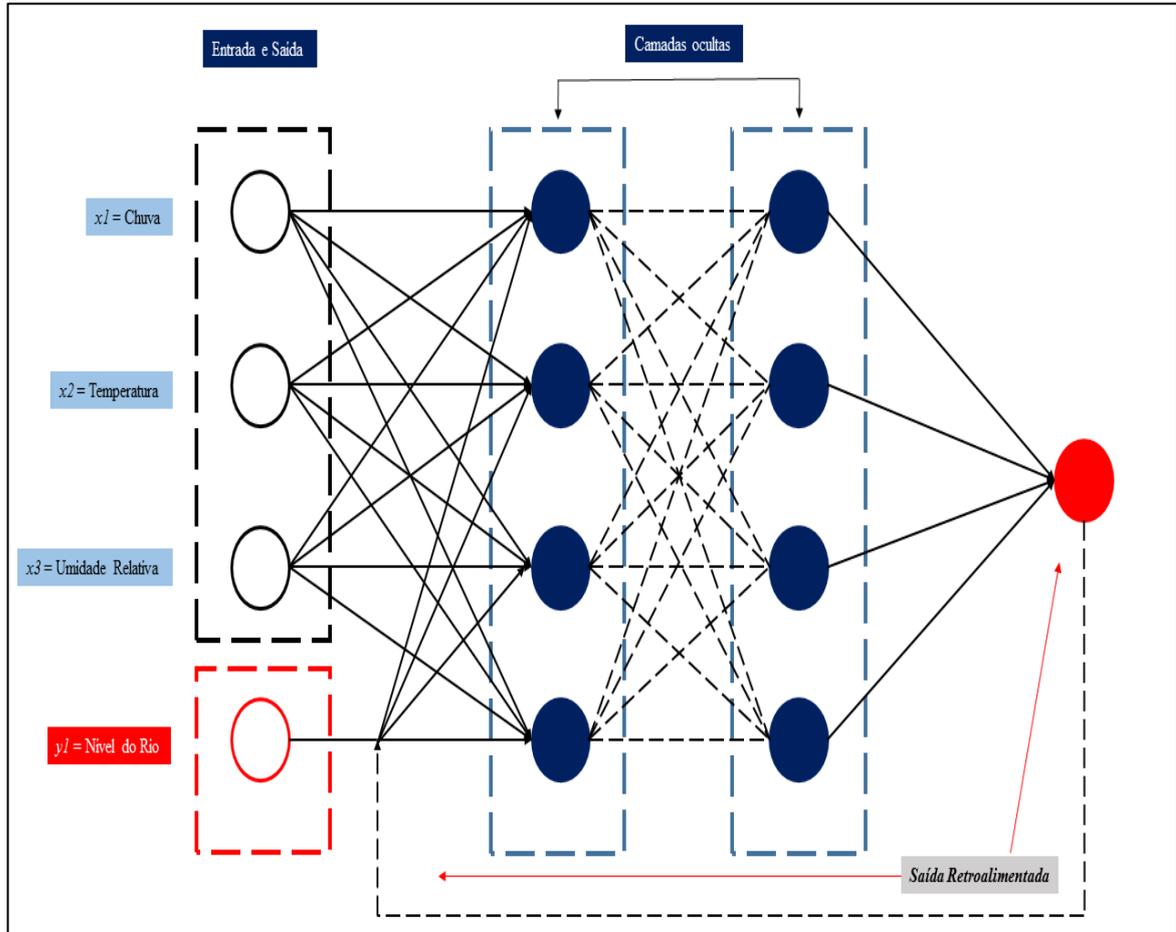
Os algoritmos utilizados para testes da viabilidade de uso do NARX foram: Otimização, Heurístico, Iterativo, Quase-Newton, Newton e Numérico, esses métodos são de suma importância por realizarem procedimentos matemáticos, estocásticos e buscas iterativas para encontrar soluções locais e próximas da global, almejando fatores de minimização ou maximização no que diz respeito performance de algoritmo em um conjunto de dados.

3.2.4 Definição e Implementação da Arquitetura NARX

Conforme mostrado na Figura 3.2, a arquitetura NARX é composta por 3 variáveis de entrada, sendo elas: Chuva, Temperatura e Umidade Relativa, além disso, 1 variável de saída que é o nível do rio. O conceito de retroalimentação, ou Rede Neural Recorrente é pelo fato de a arquitetura prover de mecanismos para chamar de forma recursiva uma função ou repassar o

parâmetro estimado para um novo ciclo de treinamento sem perder a informação a priori de ajuste.

Figura 3.2 - Arquitetura NARX.



Um modelo regressivo, corresponde à arquitetura NARX, por meio de modelos de espaço de estados a função de transição fica responsável por mapear o estado atual e a entrada atual do sistema dinâmico, de tal forma a devolver isso sem perda de informação, caracterizando uma transição de estado (MUÑOZ CHÁVEZ, 2020), ela pode ser representada pela Eq. (3.1) e (3.2).

$$x(n + 1) = Ax(n) + Bu(n) \quad (3.1)$$

$$y(n_0) = Cx(n) \quad (3.2)$$

Dessa forma, um modelo regressivo como o NARX possui as suas terminologias similares a um modelo estatístico, de tal forma que o modelo computacional alcança um grau de precisão esperado e estimado, graças aos modelos matemáticos implementados que dão

suporte e consistência na aproximação de funções ao utilizar um algoritmo de treinamento. O Quadro 3.4 apresenta uma comparação das terminologias de um modelo regressivo NARX e um modelo estatístico.

Quadro 3.4 - Terminologia entre um modelo RNA e ESTATÍSTICO.

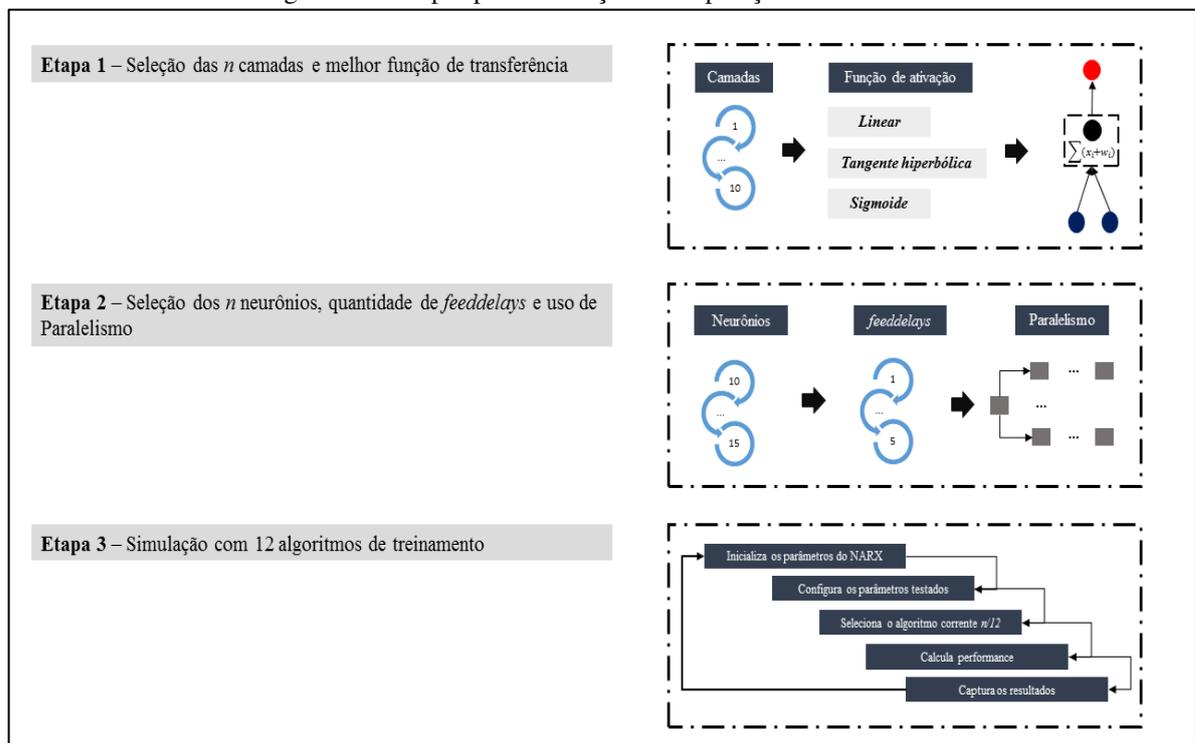
REDE NEURAL	ESTATÍSTICA
Entradas	Variáveis Exógenas
Saídas	Variáveis Endógenas
Pesos	Parâmetros
Conjunto de treinamento	Amostra
Retropropagação	Aproximação estocástica
Treinamento	Estimação

Fonte: (VILELA e MATEUS, 2016).

3.2.5 Simulação e Comparação dos Resultados com o Algoritmo Vencedor

Conforme mostrado na Figura 3.3, para a execução dos procedimentos de simulação e comparação dos resultados com o algoritmo vencedor, serão necessárias 3 etapas, sendo elas: Seleção das n camadas e melhor função de transferência; Seleção dos n neurônios, quantidade de feeddelays e uso de Paralelismo; por fim, Simulação com 12 algoritmos de treinamento.

Figura 3.3 - Etapas para simulação e comparação de resultados.



A primeira etapa, consiste em realizar procedimentos de verificação e testes para encontrar a quantidade de camadas ideal e melhor função de transferência, tendo como base um intervalo de simulações de 1 a 10, onde são utilizadas as funções de transferência Linear, Tangente Hiperbólica e Sigmoide.

Com isso, espera-se obter resultados satisfatórios em função de uma quantidade de 30 Redes Neurais treinadas e aptas a realizarem previsões, dessa forma o algoritmo desenvolvido deve analisar e apontar qual a melhor arquitetura de RNA a ser utilizada na próxima etapa.

A segunda etapa consiste em selecionar uma quantidade x de neurônios, uma quantidade y de *feeddelays* e o uso de paralelismo ou não. Em virtude da demanda em função do tempo e custo computacional, se faz necessário usufruir dos processadores auxiliares da máquina de teste caracterizando a computação paralela.

Dessa forma, espera-se encontrar a quantidade satisfatória em um intervalo de 10 a 15 neurônios, uma quantidade satisfatória de *feeddelays* variando de 1 a 5 e a definição do custo computacional para uso da computação paralela.

Por fim, a terceira etapa consiste em de fato treinar a melhor arquitetura de RNA utilizando um método de análise estatística ao apurar 12 algoritmos de treinamento, de tal forma que, seja possível a melhor RNA com o algoritmo otimizado em função das características de quantidade de camadas, neurônios, funções de ativação e uso de paralelismo.

O algoritmo terá como principal fluxo de trabalho, 5 etapas que conduzem à geração de resultados, ou seja, gráficos, tabelas e indicadores de performance em função do treinamento e das simulações.

Passo 1 – Inicializa os parâmetros do NARX;

Passo 2 – Configura os parâmetros testados;

Passo 3 – Seleciona o algoritmo corrente n de 12;

Passo 4 – Calcula e analisa a performance de treinamento;

Passo 5 – Captura os resultados.

Para analisar estatisticamente a performance de treinamento da RNA em função de suas características, neste caso, modelo calculado e modelo aproximado, se dá por meio de quatro modelos matemáticos para medir erros por meio da vazão de resíduos e taxa de dispersão, denominados:

- Regressão;
- Erro Quadrático Médio ou *Mean Square Error* (MSE);
- Raíz do Erro Quadrático Médio ou *Root Mean Square Error* (RMSE);
- Erro Percentual Absoluto Médio ou *Mean Absolute Percentage Error* (MAPE).

Expressas respectivamente pelas Eq. (3.3), (3.4) e (3.5).

$$MSE = \frac{\sum_{i=1}^n (ra_i - rs_i)^2}{n} \quad (3.3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (ra_i - rs_i)^2}{n}} \quad (3.4)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{ra_i - rs_i}{ra_i} \right| \quad (3.5)$$

Onde:

MSE = Erro Médio Quadrático;

$RMSE$ = Raiz do erro Médio Quadrático;

$MAPE$ = Erro Percentual Absoluto Médio;

n = número de elementos do vetor de saída;

ra = resultado alvo;

rs = resultado simulado;

Y = é a variável dependente e \hat{Y}_t é o valor predito de Y dado um X_i ;

X = é a variável independente;

α = é o valor previsto de Y quando $X = 0$ (o intercepto);

β = é o quanto Y muda, em média, por unidade de mudança em X (a inclinação).

Em virtude do uso de modelos estatísticos para analisar as taxas de erros, foi elaborado um modelo matemático expresso pela Eq. (3.6), a fim de facilitar o processo de seleção da melhor arquitetura de RNA com base nesses indicadores, de tal forma que, quanto menor o valor adquirido por este indicador melhor será a performance.

$$Performance = (1 - Regressão) + MSE + RMSE + MAPE \quad (3.6)$$

No final o algoritmo deve gerar resultados de análise com indicadores de desempenho da performance de simulação e dos cenários projetados para o problema de previsão do nível do rio.

CAPÍTULO 4

4 RESULTADOS E DISCUSSÕES

Os resultados obtidos estão de acordo com as etapas planejadas para pesquisa, onde o mesmo foi realizado com o intuito de validar a proposta e a hipótese de solução no trabalho. Entre as etapas de desenvolvimento da pesquisa se destaca as seguintes:

- A base de dados contendo os registros meteorológicos necessários para aquisição do modelo de previsão;
- As variáveis significativas utilizadas como histórico de entrada do modelo NARX para a previsão do nível do rio;
- A definição do algoritmo responsável pela previsão do nível do rio, computacionalmente caracterizado como modelo de previsão.
- Previsão do nível do rio por meio do NARX modelado.

4.1 BASE DE DADOS

A base de dados é composta por 5 variáveis, sendo: Data, Chuva, Temperatura, Umidade e Nível do Rio, a Tabela 4.1 apresenta uma amostra dessa base de dados. É válido ressaltar que esta tabela apresenta dados de 31/01/2020 a 30/06/2021 coletados das bases do Porto de Manaus e do INMET.

Tabela 4.1 - Amostra de dados.

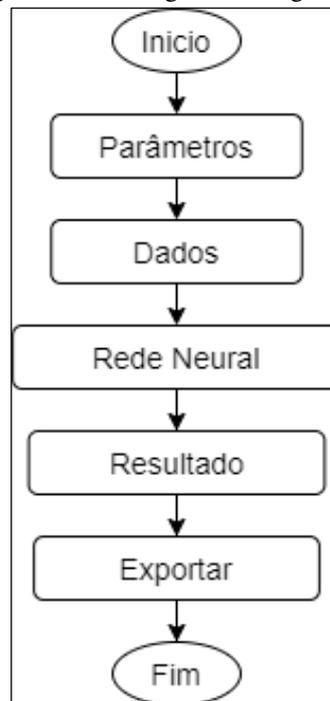
Data	Chuva	Temperatura	Umidade	Nível do Rio
31/01/2000	350,2	25,87	83,93	21,22
29/02/2000	344,4	25,69	84,58	22,46
31/03/2000	340,7	25,70	86,14	24,4
30/04/2000	535,4	25,51	86,97	26,56
31/05/2000	172,6	26,33	85,31	28,05
31/10/2020	285,8	33,4	83,6	17,16
30/11/2020	197,8	33,9	86,2	16,9
31/12/2020	260,6	33,1	89,7	19,3
31/01/2021	432,6	26,3	89,3	22,98
28/02/2021	583,2	26,6	83,6	25,19
31/03/2021	588,9	27	84,6	26,45
30/04/2021	426,8	26,4	88,2	28,15
31/05/2021	488,8	26,5	87,8	29,63
30/06/2021	89,1	27,2	79,2	30,02

Fonte Adaptado de (PORTO DE MANAUS, 2021; INMET, 2021).

4.2 DEFINIÇÃO DO ALGORITMO

A Figura 4.1 mostra o fluxograma de etapas do algoritmo principal, sendo 5 passos para aquisição dos resultados finais.

Figura 4.1 - Fluxograma do algoritmo.



Passo 1 - Definição de parâmetros em função das características do modelo NARX;

Passo 2 – Leitura da base de dados e seleção das variáveis significativas para o modelo de previsão, para treinamento e simulação;

Passo 3 – Treinamento da Rede Neural Recorrente, utilizando o modelo NARX, definições das configurações dos algoritmos de treinamento, divisão de dados e análise de performance;

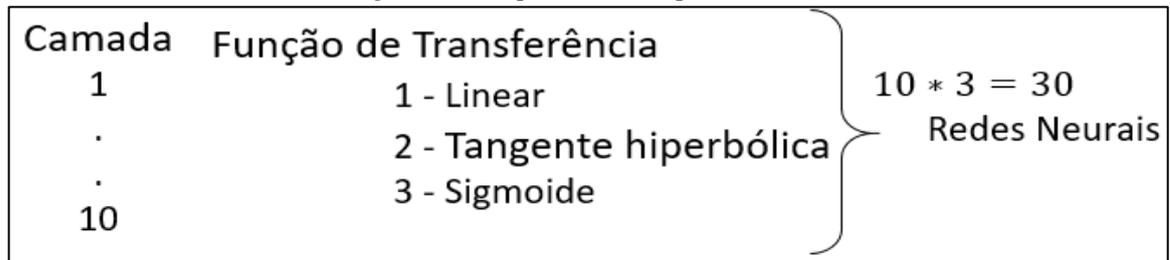
Passo 4 - Execução das simulações em função da melhor arquitetura de Rede Neural e geração dos resultados;

Passo 5 - Exportação de gráficos, tabelas e indicadores de resultados da simulação e da performance do modelo de previsão.

4.2.1 Testes de Performance do Algoritmo

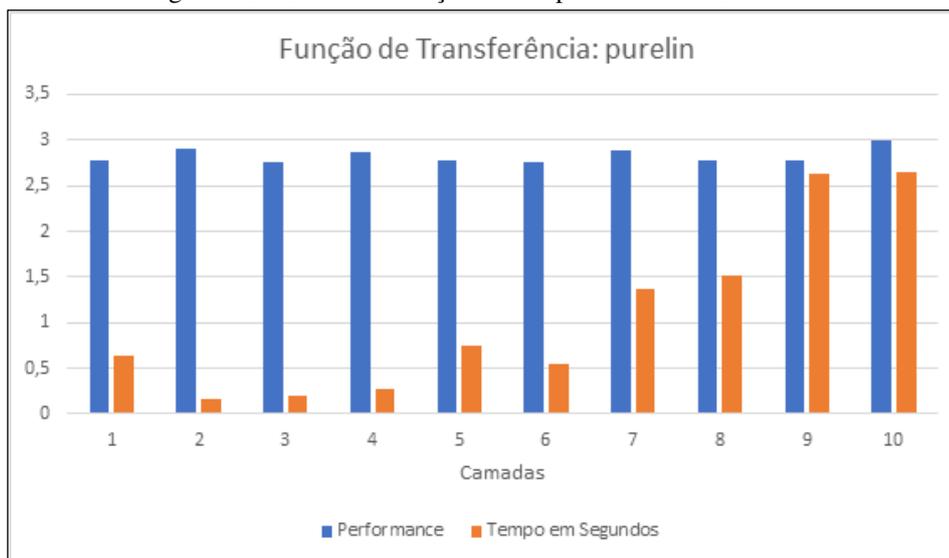
O primeiro teste teve como objetivo encontrar a quantidade de camadas ideal para o modelo computacional e a função de transferência com a melhor taxa de performance. Dessa forma, foi utilizado o algoritmo de treinamento Levenberg-Marquardt, onde é testado um intervalo de camadas entre 1 a 10, alternando entre as 3 funções de transferência: Linear, Tangente Hiperbólica e Sigmoide, a Figura 4.2 mostra o esquema do teste.

Figura 4.2 - Esquema de teste para camadas.



Mediante o esquema, os resultados encontrados são mostrados pelas Figuras 4.3, 4.4 e 4.5, respectivamente com as funções: Linear, Sigmoide e Tangente Hiperbólica. O gráfico da Figura 4.3 apresenta valores expressivos ao aumentar a quantidade de camadas, em virtude disso, a taxa de performance segue um padrão variante entre 2 e 3, contudo, o tempo em segundos também é maior à medida que a quantidade de camadas é aumentada.

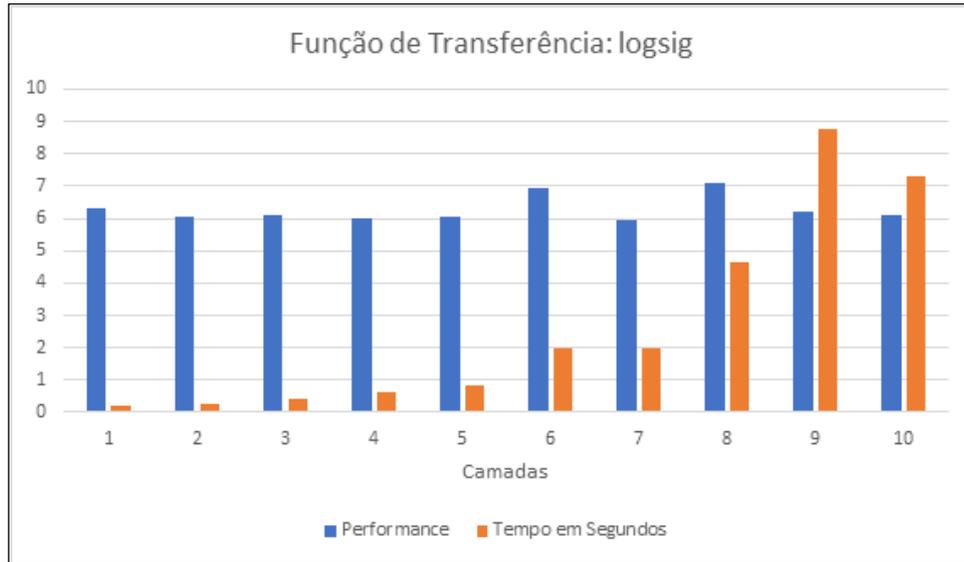
Figura 4.3 - Gráfico da função Linear para o teste de Camadas.



A Figura 4.4 mostra o gráfico da função Sigmoide, este apresenta um comportamento diferente em relação a Figura 4.3, onde o tempo em segundos aumenta em função da quantidade de camadas, contudo, a taxa de performance se mantém variável em um intervalo de 6 a 7, nele

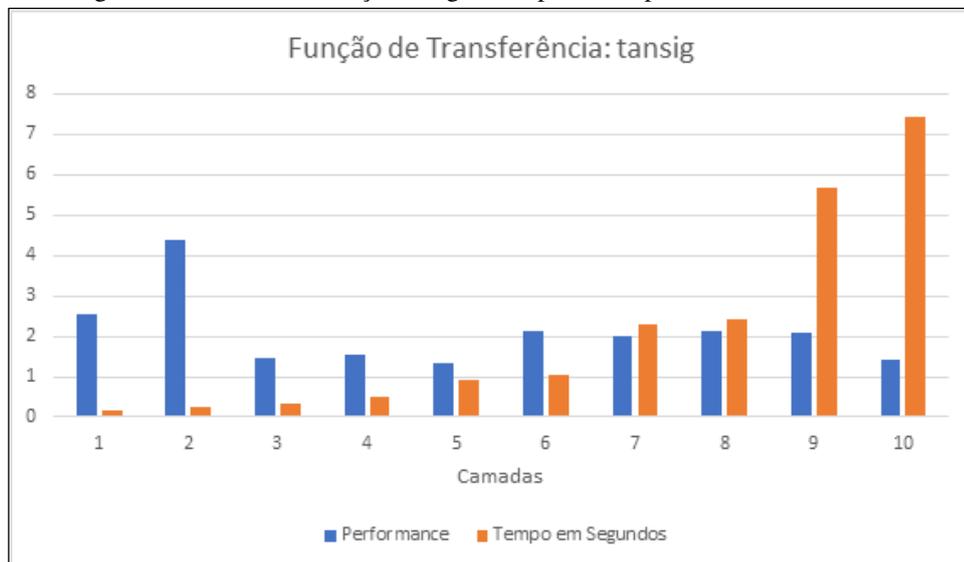
é possível identificar que a quantidade de camadas 7 apresenta os menores resultados caracterizando a melhor em relação ao intervalo de 1 a 10.

Figura 4.4 - Gráfico da função Sigmoide para o teste de Camadas.



A Figura 4.5 mostra o gráfico da função Tangente Hiperbólica, este também apresenta um comportamento diferente em relação ao anterior e ao primeiro, onde o tempo em segundos aumenta em função da quantidade de camadas, contudo, a taxa de performance é mais variável em relação as outras figuras, onde a variância se dá em um intervalo de 1,5 a 4,3, nele é possível identificar que a quantidade de camadas 5 apresenta os melhores resultados para performance e tempo em segundos.

Figura 4.5 - Gráfico da função Tangente Hiperbólica para o teste de Camadas.



A Tabela 4.2 apresenta os valores dos resultados da simulação de performance realizadas para as 3 funções de transferência utilizando o algoritmo de aprendizado Levenberg-Marquardt, onde é possível identificar que o melhor (vencedor) é a Tangente Hiperbólica Camada 5, com tempo de 0,90328, 17 épocas e uma taxa de 1,33307 para performance.

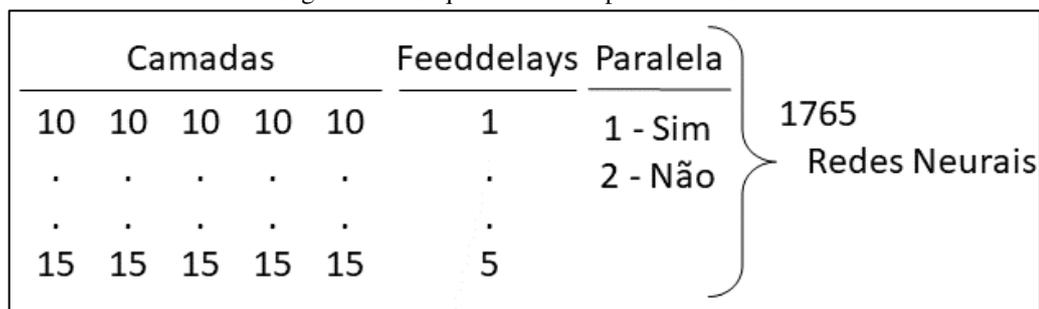
Tabela 4.2 - Resultados da simulação de performance.

Nº	Camada	Fun. Trans.	Tempo	Epochs	Fun. Perfor.	Reg.	MSE	RMSE	MAPE
1	5	tansig	0,90328	17	1,33307	0,98243	0,55023	0,74177	0,02349
2	10	tansig	7,42808	21	1,42664	0,98051	0,60514	0,77791	0,02411
3	3	tansig	0,33391	13	1,46888	0,98027	0,62997	0,79371	0,02546
4	4	tansig	0,48584	13	1,53483	0,97797	0,66811	0,81738	0,02731
5	7	tansig	2,29151	22	1,98561	0,96884	0,94815	0,97373	0,03257
6	9	tansig	5,69893	20	2,09710	0,96612	1,01989	1,00990	0,03344
7	6	tansig	1,04133	14	2,12178	0,96825	1,03828	1,01896	0,03279
8	8	tansig	2,41018	12	2,12236	0,96721	1,03639	1,01803	0,03516
9	1	tansig	0,18137	10	2,55429	0,95865	1,32437	1,15081	0,03776
10	3	purelin	0,20784	6	2,76524	0,95096	1,46417	1,21003	0,04201
11	6	purelin	0,54351	7	2,76749	0,95087	1,46574	1,21068	0,04194
12	1	purelin	0,64246	4	2,77486	0,95064	1,47049	1,21264	0,04238
13	8	purelin	1,52261	8	2,77574	0,95077	1,47146	1,21304	0,04201
14	5	purelin	0,74540	7	2,77664	0,95060	1,47166	1,21312	0,04246
15	9	purelin	2,62612	8	2,78606	0,95037	1,47808	1,21576	0,04259
16	4	purelin	0,26876	6	2,86262	0,94883	1,53079	1,23725	0,04340
17	7	purelin	1,37595	9	2,88739	0,94869	1,54808	1,24422	0,04377
18	2	purelin	0,16561	5	2,91416	0,94756	1,56674	1,25170	0,04328
19	10	purelin	2,64981	7	3,00366	0,94990	1,63296	1,27787	0,04273
20	2	tansig	0,25638	14	4,40466	0,91059	2,63619	1,62364	0,05543
21	7	logsig	2,00663	21	5,97679	0,92599	3,87302	1,96800	0,06175
22	4	logsig	0,62740	15	6,02570	0,92252	3,90788	1,97683	0,06350
23	2	logsig	0,27596	18	6,03971	0,91791	3,91513	1,97867	0,06381
24	5	logsig	0,83410	15	6,06787	0,92981	3,94744	1,98682	0,06343
25	10	logsig	7,32013	21	6,08225	0,92445	3,95336	1,98831	0,06503
26	3	logsig	0,41808	18	6,09129	0,92677	3,96319	1,99078	0,06409
27	9	logsig	8,76476	31	6,19657	0,91750	4,03795	2,00947	0,06665
28	1	logsig	0,20905	22	6,30102	0,90964	4,11653	2,02892	0,06521
29	6	logsig	1,97092	31	6,93067	0,90085	4,60907	2,14687	0,07558
30	8	logsig	4,64133	26	7,10004	0,88582	4,73304	2,17556	0,07726

O segundo teste teve como objetivo identificar a quantidade de neurônios ideal para as camadas, neste caso 5, haja visto o resultado do primeiro teste, além disso, é verificado a utilização de computação paralela e a quantidade de *feeddelays*, em virtude disso, foram

totalizadas 1765 modelos de redes neurais como teste para esta etapa, conforme mostrado na Figura 4.6.

Figura 4.6 - Esquema de teste para neurônios.



A Tabela 4.3 apresenta os resultados do teste para encontrar os parâmetros vencedores para a melhor quantidade de neurônios que será utilizada com 5 camadas no modelo computacional, nele é possível identificar que o modelo com 2 *feeddelays*, 15 neurônios na primeira camada, 10 na segunda, 15 na terceira, 10 na quarta e 10 na quinta, a taxa de performance em 0,9181 e um tempo de 1,6712 segundos, foi o vencedor.

Tabela 4.3 – Resultados da simulação de neurônios.

Nº	Feedba ck Delays	Layer 1	Layer 2	Layer 3	Layer 4	Layer 5	Epochs	Paralle l	Fun. Perf.	Tempo (s)
1	2	15	10	15	10	10	27	F	0,9181	1,6712
2	3	12	12	13	13	13	23	F	0,9724	1,7684
3	5	15	15	15	10	15	20	F	1,0565	4,0492
4	2	13	12	13	13	12	25	V	1,0690	6,6479
5	3	11	11	14	14	11	25	F	1,0887	1,9040
6	4	11	11	11	11	11	20	F	1,0945	1,0694
7	2	10	10	10	15	10	20	F	1,1112	1,2730
8	5	13	12	12	12	12	19	F	1,1120	4,7888
9	5	14	11	14	14	11	23	V	1,1121	9,9276
10	3	11	11	11	11	11	15	V	1,1180	3,2575
11	3	11	11	14	14	11	23	V	1,1183	6,4094
12	4	13	12	13	13	12	21	V	1,1214	6,4551
13	4	14	14	11	14	14	32	F	1,1242	4,4289
14	2	10	10	15	10	10	23	V	1,1264	4,0581
15	4	11	11	11	14	11	16	V	1,1347	3,7402
16	3	15	15	15	10	15	15	V	1,1378	7,2542
17	4	14	14	11	14	14	21	V	1,1572	8,9857
18	3	15	10	10	10	10	13	F	1,1687	0,6917
19	3	10	10	15	10	15	17	F	1,1701	1,0269
20	5	13	13	13	13	12	15	V	1,1716	5,9952
21	4	13	12	13	13	12	15	V	1,1722	5,0177
22	5	14	11	14	11	11	17	F	1,1724	4,3523

Nº	Feedback Delays	Layer 1	Layer 2	Layer 3	Layer 4	Layer 5	Epochs	Parallel	Fun. Perf.	Tempo (s)
23	4	13	12	12	13	12	17	F	1,1762	1,5014
24	4	13	13	13	12	12	16	F	1,1824	1,5505
25	2	10	10	10	10	10	40	F	1,1988	1,3906
26	2	15	15	10	15	15	16	F	1,1998	2,4350
27	4	12	12	12	12	13	23	F	1,2015	1,6098
28	2	15	15	15	15	10	20	F	1,2025	4,4360
29	5	11	14	11	11	11	17	V	1,2043	4,5117
30	3	11	14	14	14	14	16	V	1,2052	6,2770

4.3 PREVISÃO DO NÍVEL DO RIO

Nesta seção são apresentados os resultados obtidos através da simulação feita pelo software MATLAB, os resultados foram divididos em 5 etapas, sendo elas representadas pelas previsões do nível do rio, em horizontes de previsão, os quais são: previsão com horizonte de 5 passos à frente representa uma previsão de 5 meses; horizonte de previsão com 10 passos à frente representa uma previsão para 10 meses à frente; horizonte de previsão com 15 passos à frente representa uma previsão para 15 meses ; horizonte de previsão com 20 passos à frente representa uma previsão de 20 meses, e horizonte de previsão com 25 passos à frente representa 25 meses à frente

É possível classificar os horizontes de 5 passos e 10 passos como curto prazo, 15 passos e 20 passos como médio prazo e de 25 passos como longo prazo. Esta classificação é subjetiva, pois vai depender exclusivamente da tratativa dos. Para as previsões foram utilizados 12 algoritmos de treinamento, sendo que o melhor foi o escolhido para representar a previsão do cenário (passos à frente).

4.3.1 Previsão com 5 passos à frente

No cenário de 5 passos à frente que representa um horizonte de curto prazo para 5 meses de previsão, foram utilizadas as configurações definidas através do melhor resultado obtido nas etapas anteriores, no qual é mostrado a quantidade de camadas ocultas utilizadas na rede neural e a quantidade de neurônios em cada camada oculta, sendo que foram utilizadas a seguinte sequência 15-10-15-10-10. Para cada rede neural foi utilizada a mesma quantidade de camadas ocultas e número de neurônios, diferenciando apenas o algoritmo de treinamento, a primeira

coluna representa o identificador de cada rede neural testada, como pode ser observado na Tabela 4.4 de configurações para previsão com 5 passos à frente.

Tabela 4.4 – Tabela de configurações para previsão com 5 passos à frente.

Nº	Camadas Ocultas	Algoritmo de treinamento
1	15 10 15 10 10	Levenberg-Marquardt
6	15 10 15 10 10	Conjugate Gradient with Powell/Beale Restarts
8	15 10 15 10 10	Polak-Ribière Conjugate Gradient
5	15 10 15 10 10	Scaled Conjugate Gradient
4	15 10 15 10 10	Resilient Backpropagation
7	15 10 15 10 10	Fletcher-Powell Conjugate Gradient
9	15 10 15 10 10	One Step Secant
2	15 10 15 10 10	Regularização Bayesiana
3	15 10 15 10 10	BFGS Quasi-Newton
12	15 10 15 10 10	Gradient Descent
10	15 10 15 10 10	Variable Learning Rate Gradient Descent
11	15 10 15 10 10	Gradient Descent with Momentum

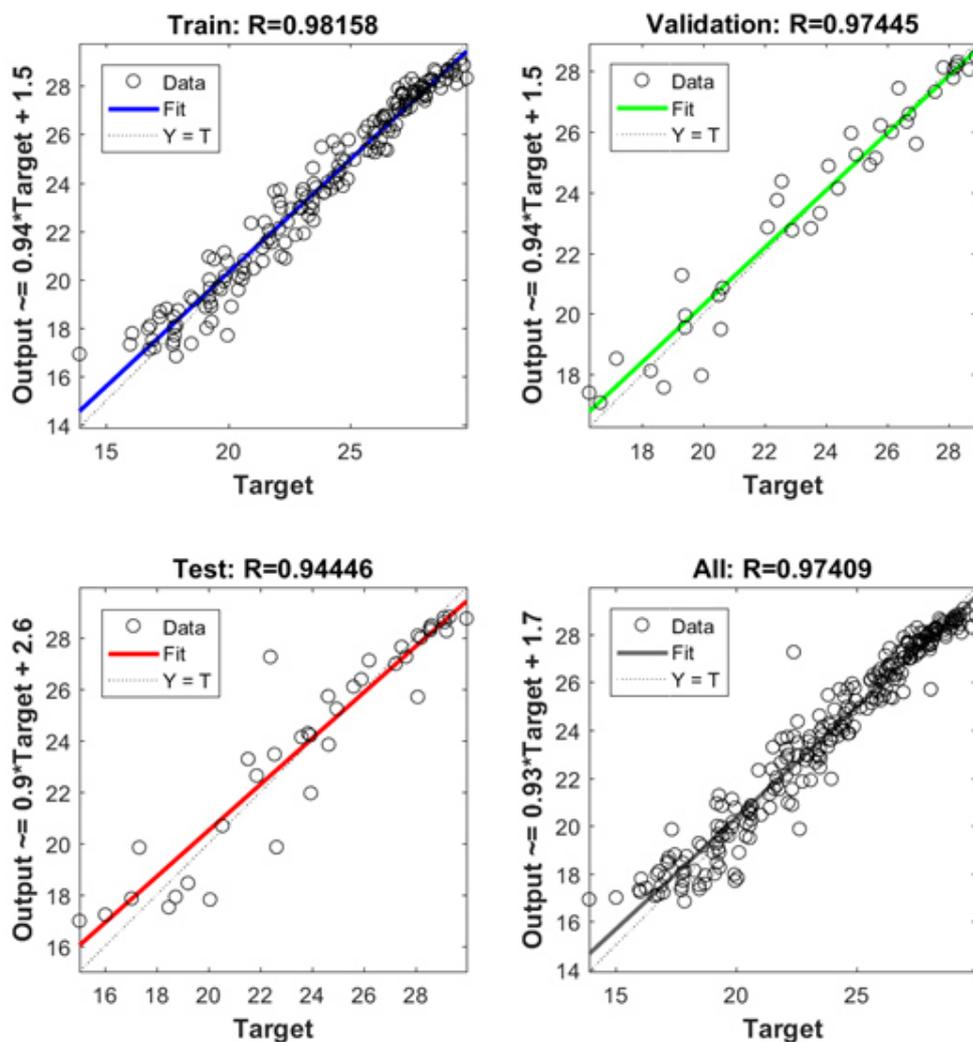
Na Tabela 4.5 de resultados são apresentados alguns dados que mostram que a rede neural (1) utilizando o algoritmo de treinamento Levenberg-Marquardt foi a que obteve o melhor resultado, sua função de performance atingiu o menor valor se comparado aos outros algoritmos utilizados na previsão, também atingiu o menor valor na quantidade de épocas para alcançar o objetivo. Apesar de ter alcançado o objetivo com menor número de épocas que os algoritmos concorrentes, não teve o menor tempo de processamento, levando quase 1 segundo (0,913 segundos).

Tabela 4.5 – Tabela de resultados de previsão com 5 passos à frente.

Nº	Tempo (Segundos)	Épocas	Função Performance (Taxa de Erro)
1	0,9131903	13	1,716627239
6	0,4389108	38	2,404921207
8	0,3929498	30	2,670749212
5	0,2807198	36	2,840748783
4	0,2173837	26	3,050722317
7	0,2962302	17	4,175391223
9	0,2928473	16	4,709934281
2	1,5798318	15	20,12071707
3	0,9820447	45	28,97535587
12	2,5716301	1000	66,61319945
10	2,6423644	1000	77,93778836
11	2,3398849	1000	106,1292538

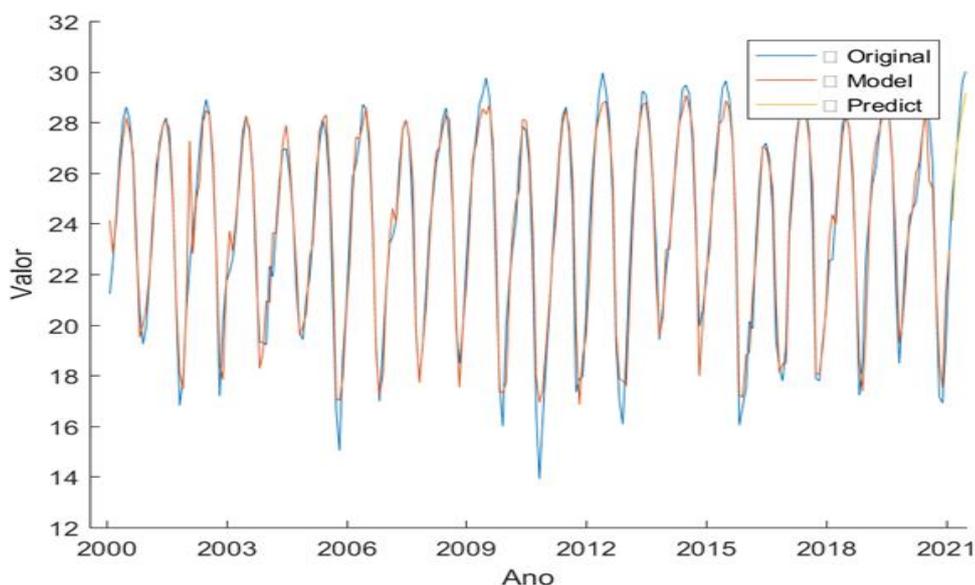
Na Figura 4.7 são apresentados os gráficos de regressão da rede neural vencedora, a que obteve o melhor resultado do primeiro cenário analisado, os resultados apresentados são os índices de assertividade do modelo nas etapas de treinamento com uma resposta de 0,98158 de assertividade, o resultado do teste do modelo com resposta de 0,944 de índice de assertividade, a validação do modelo obteve uma resposta com 0,974 índice de assertividade. Ainda pode-se observar que a rede neural teve um bom comportamento devido a sua confiabilidade ficar acima de 97,4%.

Figura 4.7 – Gráfico de regressão da rede neural melhor cenário para 5 passos à frente.



Na Figura 4.8 é mostrado a previsão de 5 passos à frente que equivale a 5 meses, já que os dados coletados foram de mês a mês. Pode-se observar que o modelo de predição obtém uma ótima previsibilidade, alcançando confiabilidade em cerca de 97% de assertividade.

Figura 4.8 – Gráfico de previsão com 5 passos à frente.



Para a previsão de 5 passos à frente obteve-se resultados muito bom e com uma alta taxa de confiabilidade, sendo possível afirmar que o modelo teve um desempenho satisfatório.

4.3.2 Previsão com 10 passos à frente

No cenário de 10 passos à frente, foram utilizadas as configurações, como pode ser observado na Tabela 4.6 de configurações, no qual é mostrado a quantidade de camadas ocultas utilizadas na rede neural e a quantidade de neurônios em cada camada oculta, sendo que foram utilizadas a seguinte sequência 15-10-15-10-10. Para cada rede neural foi utilizada a mesma quantidade de camadas ocultas e número de neurônios, diferenciando apenas o algoritmo de treinamento, a primeira coluna representa o identificador de cada rede neural testada.

Tabela 4.6 – Tabela de configurações para previsão com 10 passos à frente.

Nº	Camadas Ocultas	Algoritmo de treinamento
6	15 10 15 10 10	Conjugate Gradient with Powell/Beale Restarts
9	15 10 15 10 10	One Step Secant
1	15 10 15 10 10	Levenberg-Marquardt

4	15	10	15	10	10	Resilient Backpropagation
8	15	10	15	10	10	Polak-Ribière Conjugate Gradient
7	15	10	15	10	10	Fletcher-Powell Conjugate Gradient
5	15	10	15	10	10	Scaled Conjugate Gradient
2	15	10	15	10	10	Regularização Bayesiana
11	15	10	15	10	10	Gradient Descent with Momentum
10	15	10	15	10	10	Variable Learning Rate Gradient Descent
3	15	10	15	10	10	BFGS Quasi-Newton
12	15	10	15	10	10	Gradient Descent

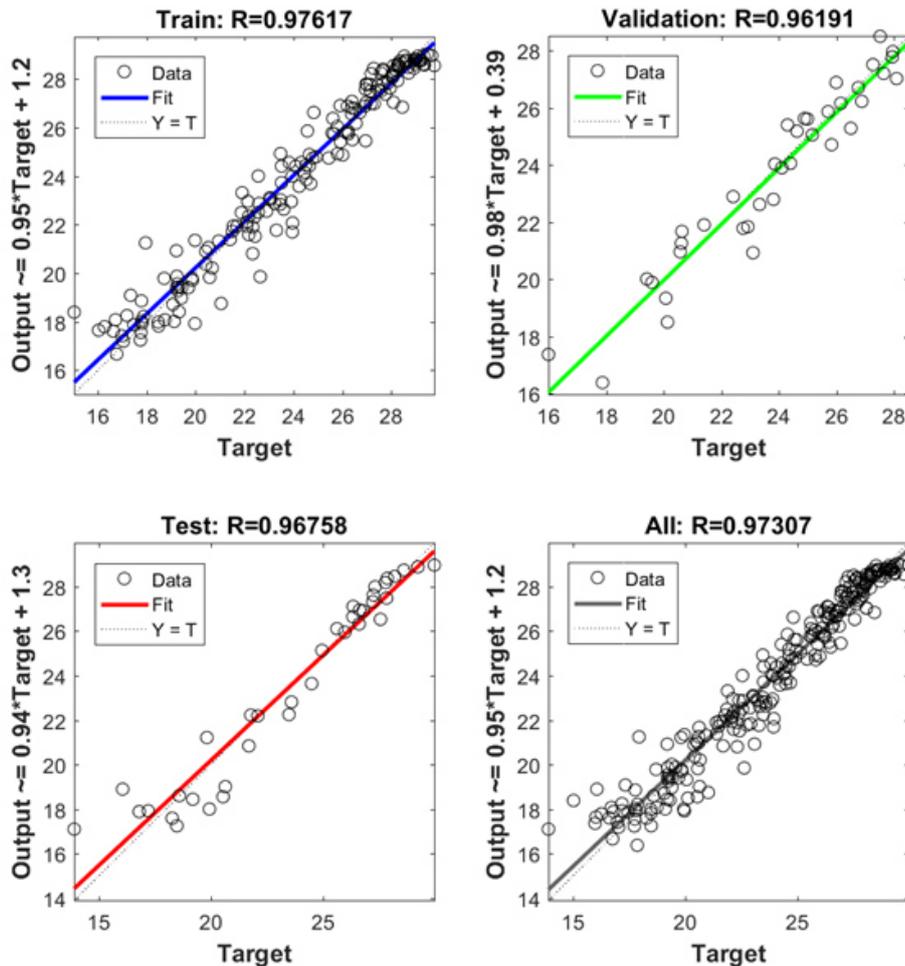
Na Tabela 4.7 de resultados são apresentados alguns dados que mostram que a rede neural (1) utilizando o algoritmo de treinamento Conjugate Gradient with Powell/Beale Restarts foi a que obteve o melhor resultado, já que sua função de performance atingiu o menor valor se comparado aos outros algoritmos utilizados na previsão, além de atingir o menor valor na função de performance 1,738, também atingiu o menor valor na quantidade de épocas para alcançar o objetivo. Apesar de ter alcançado o objetivo com menor número de épocas que os algoritmos concorrentes, não teve o menor tempo de processamento, mas levou menos que meio segundo (0,451 segundos).

Tabela 4.7 – Tabela de Resultados de previsão com 10 passos à frente.

Nº	Tempo	Épocas	Função Performance
6	0,4511623	39	1,738074246
9	0,5321934	48	1,862248117
1	1,0125881	14	2,123409004
4	0,2282654	31	2,205791144
8	0,5453814	45	2,472873158
7	0,3567277	24	2,890686782
5	0,2744911	27	4,446078071
2	1,4498385	13	19,0625173
11	2,3742464	1000	19,50623196
10	2,49041	1000	28,69096001
3	0,2613613	1	59,35745853
12	2,3792872	1000	71,96839829

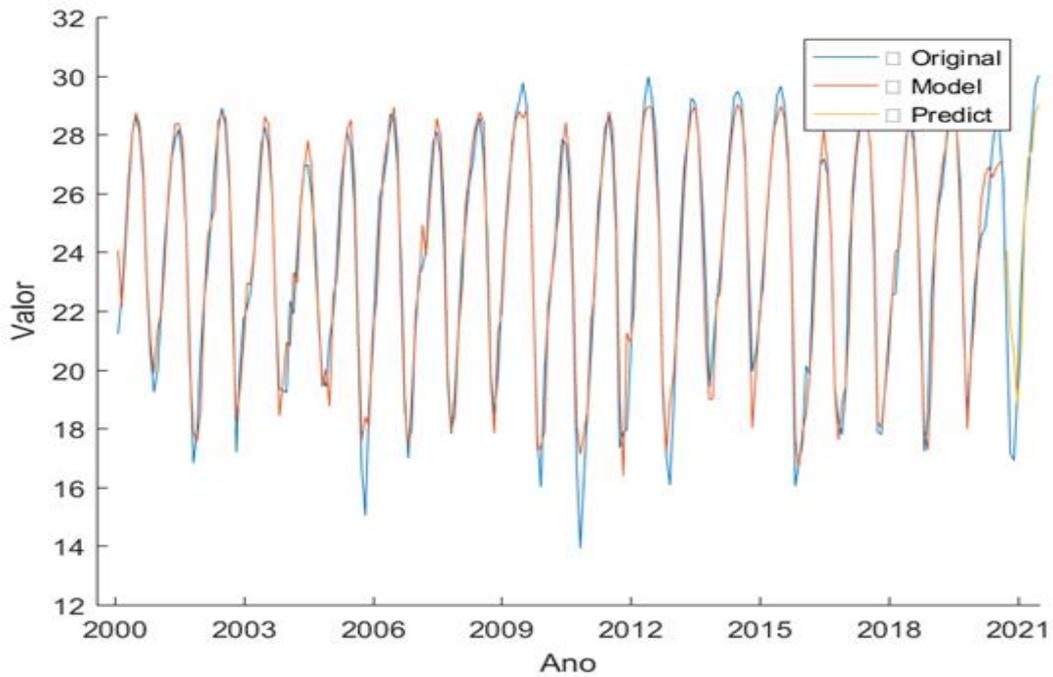
Na Figura 4.9 é apresentado o gráfico de regressão da rede neural vencedora do primeiro cenário analisado, com 0,961 de taxa de assertividade. Nele pode-se observar que a rede neural teve um bom comportamento devido a sua confiabilidade ficar acima de 96%.

Figura 4.9 – Gráfico de regressão da rede neural melhor cenário para 10 passos à frente.



Na Figura 4.10 é mostrado a previsão de 10 passos à frente que equivale a 10 meses, já que os dados coletados foram de mês a mês. Pode-se observar que o modelo de previsão obtém uma ótima previsibilidade, alcançando cerca de 96,1% de assertividade.

Figura 4.10 – Gráfico de previsão com 10 passos à frente.



Para a previsão de 10 passos à frente obteve-se resultados bons e com uma alta taxa de assertividade, porém com um desempenho neste quesito inferior ao de 5 passos.

4.3.3 Previsão com 15 passos à frente

No cenário de 15 passos à frente, foram utilizadas algumas configurações, como pode ser observado na Tabela 4.8 de configurações, no qual é mostrado a quantidade de camadas ocultas utilizadas na rede neural e a quantidade de neurônios em cada camada oculta, sendo que foram utilizadas a seguinte sequência 15-10-15-10-10. Para cada rede neural foi utilizada a mesma quantidade de camadas ocultas e número de neurônios, diferenciando apenas o algoritmo de treinamento, a primeira coluna representa o identificador de cada rede neural testada.

Tabela 4.8 - Tabela de configurações para previsão com 15 passos à frente.

Nº	Camadas Ocultas	Algoritmo de treinamento
4	15 10 15 10 10	Resilient Backpropagation
1	15 10 15 10 10	Levenberg-Marquardt
3	15 10 15 10 10	BFGS Quasi-Newton

7	15	10	15	10	10	Fletcher-Powell Conjugate Gradient
6	15	10	15	10	10	Conjugate Gradient with Powell/Beale Restarts
8	15	10	15	10	10	Polak-Ribière Conjugate Gradient
9	15	10	15	10	10	One Step Secant
5	15	10	15	10	10	Scaled Conjugate Gradient
2	15	10	15	10	10	Regularização Bayesiana
10	15	10	15	10	10	Variable Learning Rate Gradient Descent
12	15	10	15	10	10	Gradient Descent
11	15	10	15	10	10	Gradient Descent with Momentum

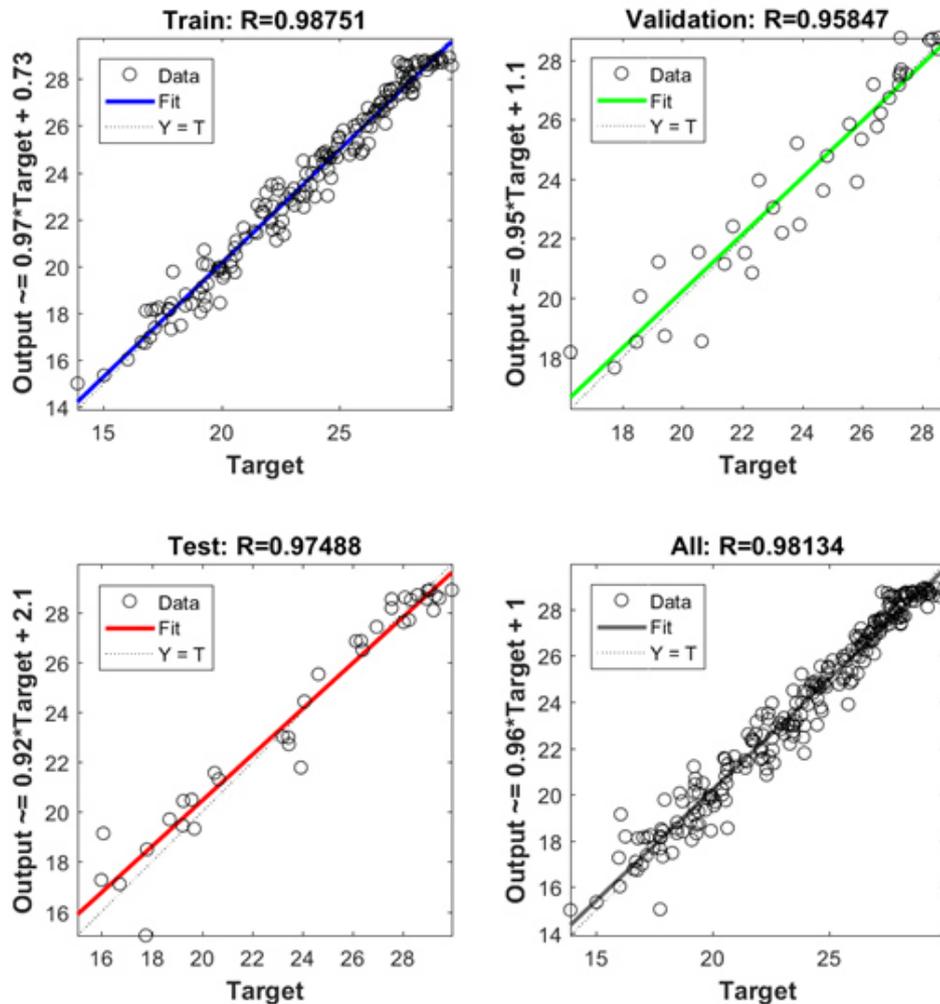
Na Tabela 4.9 de resultados são apresentados alguns dados que mostram que a rede neural (1) utilizando o algoritmo de treinamento Resilient Backpropagation foi a que obteve o melhor resultado, já que sua função de performance atingiu o menor valor se comparado aos outros algoritmos utilizados na previsão, além de atingir o menor valor na função de performance 1,341, também atingiu o menor valor na quantidade de épocas para alcançar o objetivo. Apesar de ter alcançado o objetivo com menor número de épocas que os algoritmos concorrentes, teve o segundo melhor tempo de processamento, levando menos de um terço de segundo (0,327 segundos).

Tabela 4.9 – Tabela de Resultados de previsão com 15 passos à frente.

Nº	Tempo	Épocas	Função Performance
4	0,3270754	72	1,341922244
1	0,9580315	14	1,498988578
3	2,2605226	29	1,632032957
7	0,6339389	67	1,824570428
6	0,4160583	35	1,86650175
8	0,4220003	33	2,277672383
9	0,3855767	25	3,058905608
5	0,2326076	19	4,350325085
2	1,7924435	16	19,96468293
10	2,5520363	1000	28,38989947
12	2,6031889	1000	33,68250117
11	2,4943088	1000	77,36456837

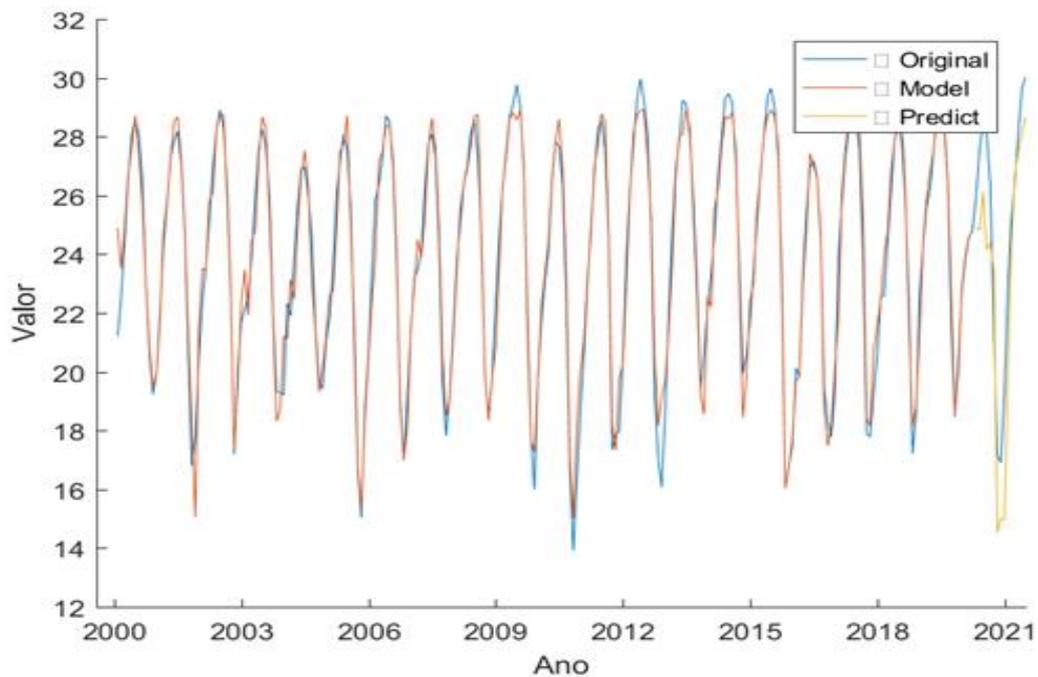
Na Figura 4.11 é apresentado o gráfico de regressão da rede neural vencedora do primeiro cenário analisado, com 0,958 de taxa de assertividade. Nele pode-se observar que a rede neural teve um bom comportamento devido a sua confiabilidade ficar acima de 9,85%.

Figura 4.11 – Gráfico de regressão da rede neural melhor cenário para 15 passos à frente.



Na Figura 4.12 é mostrado a previsão de 15 passos à frente que equivale a 15 meses, já que os dados coletados foram de mês a mês. Pode-se observar que o modelo de previsão obtém uma ótima previsibilidade, alcançando cerca de 95,8% de assertividade.

Figura 4.12 – Gráfico de previsão para 15 passos à frente.



Para a previsão de 15 passos à frente obteve-se resultados excelente e com uma alta taxa de assertividade, sendo possível afirmar que o modelo teve um desempenho muito satisfatório.

4.3.4 Previsão com 20 passos à frente

No cenário de 20 passos à frente, foram utilizadas algumas configurações, como pode ser observado na Tabela 4.10 de configurações, no qual é mostrado a quantidade de camadas ocultas utilizadas na rede neural e a quantidade de neurônios em cada camada oculta, sendo que foram utilizadas a seguinte sequencia 15-10-15-10-10. Para cada rede neural foi utilizada a mesma quantidade de camadas ocultas e número de neurônios, diferenciando apenas o algoritmo de treinamento, a primeira coluna representa o identificador de cada rede neural testada.

Tabela 4.10 – Tabela de configurações para previsão com 20 passos à frente.

Nº	Camadas Ocultas	Algoritmo de treinamento
4	15 10 15 10 10	Resilient Backpropagation
7	15 10 15 10 10	Fletcher-Powell Conjugate Gradient
9	15 10 15 10 10	One Step Secant
3	15 10 15 10 10	BFGS Quasi-Newton

1	15	10	15	10	10	Levenberg-Marquardt
8	15	10	15	10	10	Polak-Ribière Conjugate Gradient
5	15	10	15	10	10	Scaled Conjugate Gradient
6	15	10	15	10	10	Conjugate Gradient with Powell/Beale Restarts
2	15	10	15	10	10	Regularização Bayesiana
10	15	10	15	10	10	Variable Learning Rate Gradient Descent
12	15	10	15	10	10	Gradient Descent
11	15	10	15	10	10	Gradient Descent with Momentum

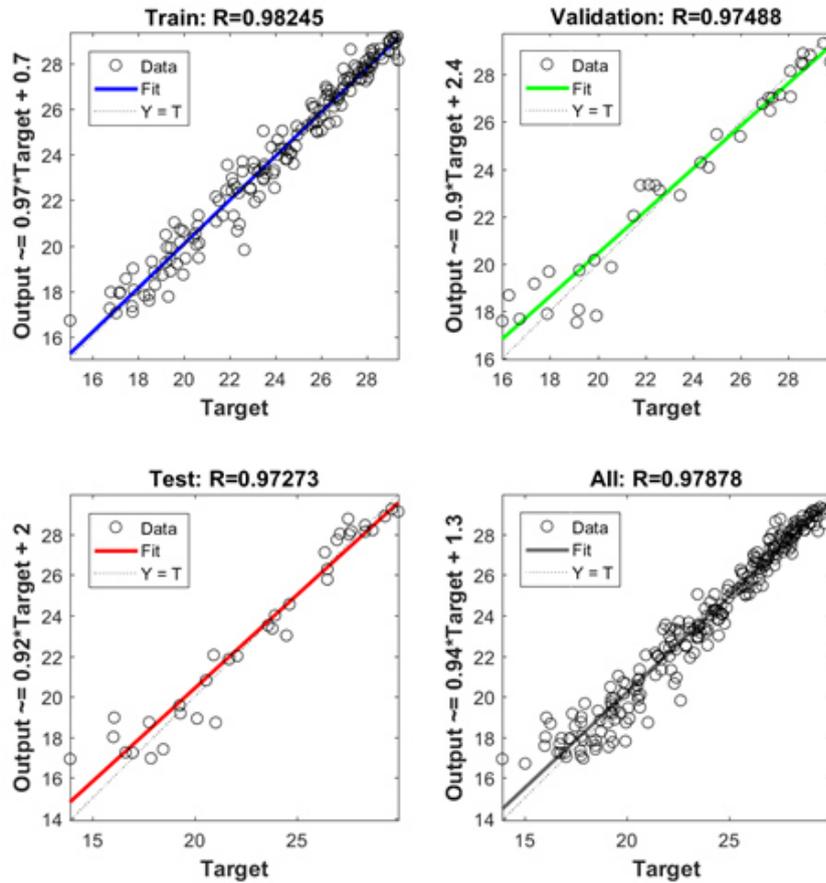
Na Tabela 4.11 de resultados são apresentados alguns dados que mostram que a rede neural (1) utilizando o algoritmo de treinamento Resilient Backpropagation foi a que obteve o melhor resultado, já que sua função de performance atingiu o menor valor se comparado aos outros algoritmos utilizados na previsão, além de atingir o menor valor na função de performance 1,491 e, também atingiu o menor valor na quantidade de épocas para alcançar o objetivo. Mesmo tendo alcançado o objetivo com menor número de épocas que os algoritmos concorrentes, obteve o segundo menor tempo de processamento, levando somente (0,273 segundos).

Tabela 4.11 – Tabela de resultados de previsão com 20 passos à frente.

Nº	Tempo	Épocas	Função Performance
4	0,2733084	52	1,491386234
7	0,5339969	48	2,083066261
9	0,5238745	50	2,126569889
3	1,1872574	14	2,200483581
1	0,6980682	9	2,271728589
8	0,3469194	27	2,373109131
5	0,240693	24	2,873169268
6	0,3278522	21	3,204382552
2	1,622443	16	20,26038318
10	2,4507954	1000	34,95513635
12	2,3776566	1000	38,87462345
11	2,4549428	1000	50,57796485

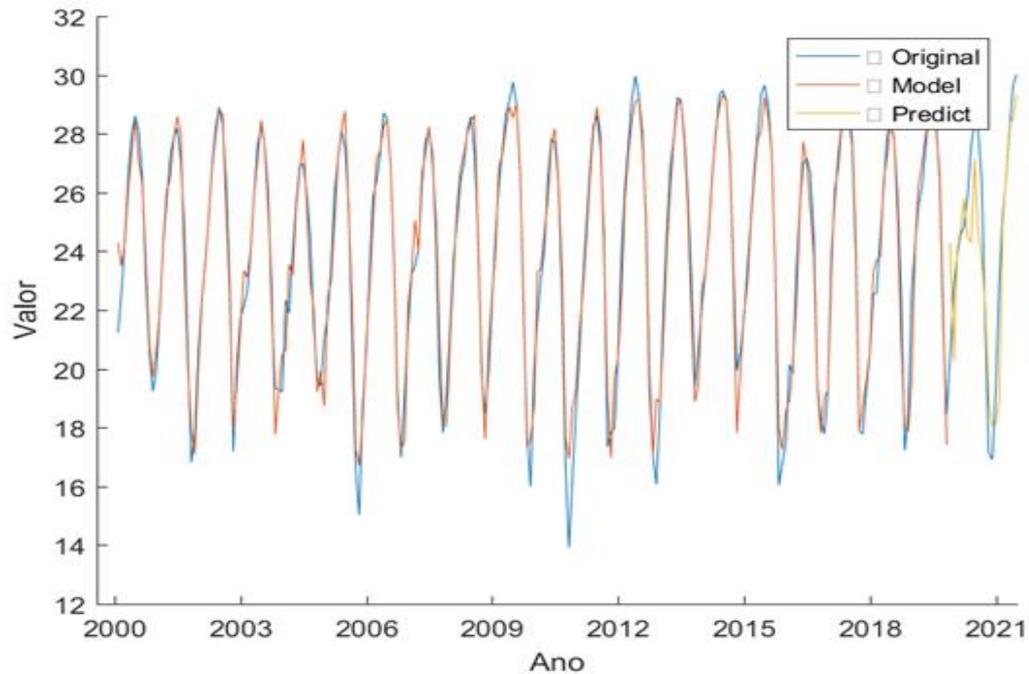
Na Figura 4.13 é apresentado o gráfico de regressão da rede neural vencedora do primeiro cenário analisado, com 0,974 de taxa de assertividade. Nele pode-se observar que a rede neural teve um bom comportamento devido a sua confiabilidade ficar acima de 97,4%.

Figura 4.13 – Gráfico de regressão da rede neural melhor cenário para 20 passos à frente.



Na Figura 4.14 é mostrado a previsão de 20 passos à frente que equivale a 20 meses, já que os dados coletados foram de mês a mês. Pode-se observar que o modelo de previsão obtém uma ótima previsibilidade, alcançando cerca de 97,4% de assertividade.

Figura 4.14 – Gráfico de previsão para 20 passos à frente.



Para a previsão de 20 passos à frente obteve-se resultados excelentes e com uma alta taxa de acerto, mesmo sendo inferior ao de 15 passos, ainda é possível afirmar que o modelo teve um desempenho satisfatório.

4.3.5 Previsão com 25 passos à frente

No cenário de 25 passos à frente, foram utilizadas algumas configurações, como pode ser observado na Tabela 4.12 de configurações, no qual é mostrado a quantidade de camadas ocultas utilizadas na rede neural e a quantidade de neurônios em cada camada oculta, sendo que foram utilizadas a seguinte sequência 15-10-15-10-10. Para cada rede neural foi utilizada a mesma quantidade de camadas ocultas e número de neurônios, diferenciando apenas o algoritmo de treinamento, a primeira coluna representa o identificador de cada rede neural testada.

Tabela 4.12 – Tabela de configurações para previsão com 25 passos à frente.

Nº	Camadas Ocultas	Algoritmo de treinamento
6	15 10 15 10 10	Conjugate Gradient with Powell/Beale Restarts
9	15 10 15 10 10	One Step Secant
4	15 10 15 10 10	Resilient Backpropagation
1	15 10 15 10 10	Levenberg-Marquardt

3	15	10	15	10	10	BFGS Quasi-Newton
8	15	10	15	10	10	Polak-Ribière Conjugate Gradient
5	15	10	15	10	10	Scaled Conjugate Gradient
2	15	10	15	10	10	Regularização Bayesiana
7	15	10	15	10	10	Fletcher-Powell Conjugate Gradient
11	15	10	15	10	10	Gradient Descent with Momentum
10	15	10	15	10	10	Variable Learning Rate Gradient Descent
12	15	10	15	10	10	Gradient Descent

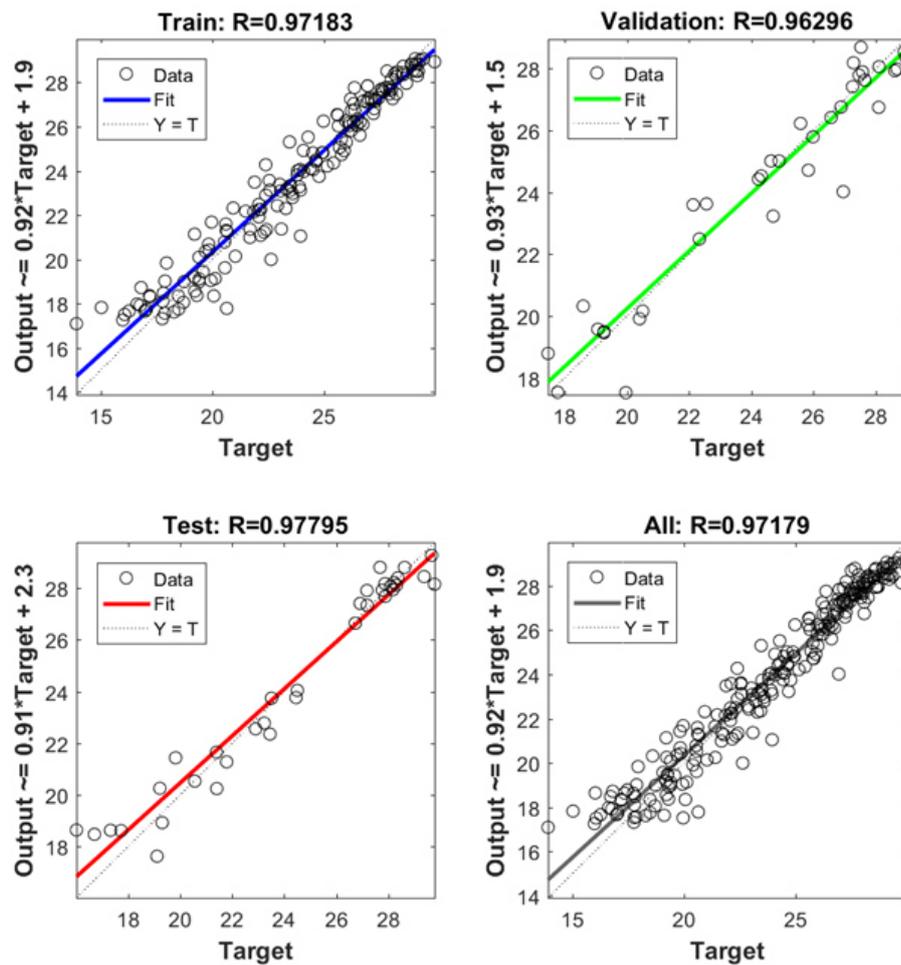
Na Tabela 4.13 de resultados são apresentados alguns dados que mostram que a rede neural (1) utilizando o algoritmo de treinamento Conjugate Gradient with Powell/Beale Restarts foi a que obteve o melhor resultado, já que sua função de performance atingiu o menor valor se comparado aos outros algoritmos utilizados na previsão, além de atingir o menor valor na função de performance 1,835, também atingiu o menor valor na quantidade de épocas para alcançar o objetivo. Apesar de ter alcançado o objetivo com menor número de épocas que os algoritmos concorrentes, não teve o menor tempo de processamento, levando quase 1/3 de segundo (0,366 segundos).

Tabela 4.13 – Tabela de resultados de previsão com 25 passos à frente:

Nº	Tempo	Épocas	Função Performance
6	0,366851	27	1,835478714
9	0,575877	53	1,873002701
4	0,2682861	45	1,98578335
1	0,8618136	13	2,360166224
3	1,2451781	15	2,674064463
8	0,3057758	20	3,779698025
5	0,2778389	35	3,94422335
2	76,5906161	1000	4,035000756
7	0,2305787	9	6,082090164
11	2,3794663	1000	14,15131767
10	2,4501014	1000	52,7877864
12	2,2858247	1000	88,39336145

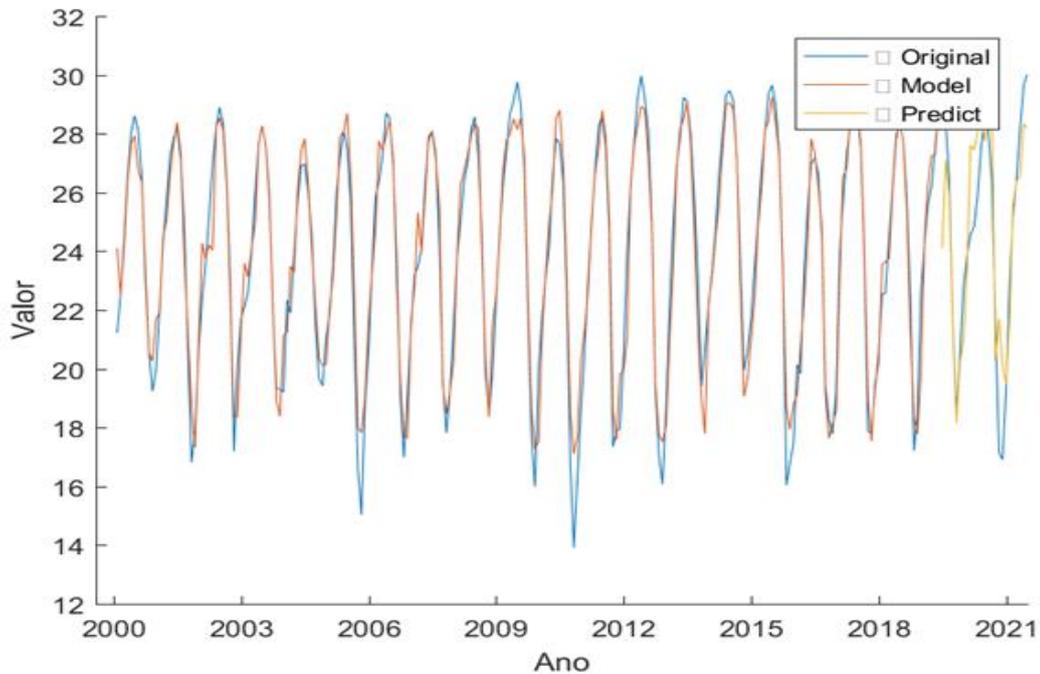
Na Figura 4.15 é apresentado o gráfico de regressão da rede neural vencedora do primeiro cenário analisado, com 0,962 de taxa de assertividade. Nele pode-se observar que a rede neural teve um bom comportamento devido a confiabilidade ficar acima de 96,2% de taxa de assertividade.

Figura 4.15 – Gráfico de regressão da rede neural melhor cenário para 25 passos à frente.



Na Figura 4.16 é mostrado a previsão de 25 passos à frente que equivale a 25 meses, já que os dados coletados foram de mês a mês. Pode-se observar que o modelo de previsão obtém uma ótima previsibilidade, alcançando cerca de 96,2% de acerto.

Figura 4.16 – Gráfico de previsão para 25 passos à frente.



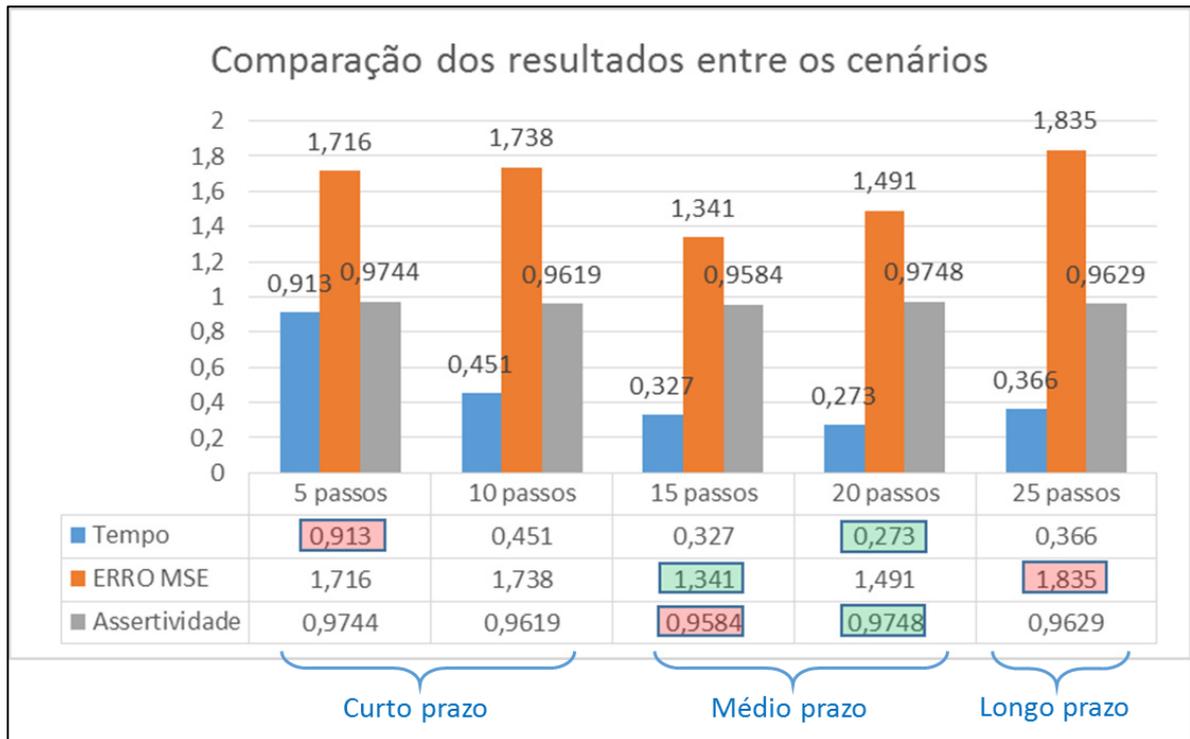
Para a previsão de 25 passos à frente obteve-se resultados aceitável e com uma alta taxa de assertividade, porém foi o pior cenário obtido para todas a previsões neste quesito.

4.3.6 Comparativo de performance entre os cenários analisados

A comparação dos resultados de horizontes de previsão obtidos no modelo NARX neste trabalho, demonstra o comportamento dos elementos tempo de geração, taxa de erro quadrático médio – MSE, e a performance que representa a confiabilidade do modelo.

Comparando as performances dos cenários analisados, pode-se observar que na Figura 4.17 o cenário que obteve o melhor resultado da função de performance totalizando uma menor taxa de erro de 1,341 e, foi o cenário 3 (15 passos à frente) que totaliza 1 ano e 3 meses (15 meses). Isso pode ser justificado pela sazonalidade do nível do rio que tem suas baixas e cheias em períodos específicos, meio do ano e fim de ano, fazendo com que a previsibilidade tenha uma taxa de acerto maior se for nesses períodos.

Figura 4.17 – Comparação de performance entre os cenários.



O horizonte classificado de curto prazo com 5 passos de previsão, obteve no tempo de processamento a pior classificação de todos os horizontes com 0,913 segundos, o erro quadrático médio MSE foi o mediano sendo o terceiro melhor erro obtido 1,716 e , na assertividade do modelo ou confiabilidade ficou em segundo lugar com uma resposta de 0,9744.

O horizonte de curto prazo com 10 passos de previsão, obteve no tempo de processamento a segunda pior classificação de todos os horizontes com 0,451 segundos, o erro quadrático médio MSE foi o quarto pior erro obtido 1,738 e, na assertividade do modelo ou confiabilidade ficou em quarto lugar com uma resposta de 0,9619.

A análise do horizonte de médio prazo com 15 passos de previsão, obteve no tempo de processamento a segunda melhor classificação de todos os horizontes com 0,327 segundos, o erro quadrático médio MSE obteve o melhor resultado 1,341 e, porém obteve na assertividade do modelo ou confiabilidade o pior resultado, com uma resposta de 0,9584.

A análise do horizonte de médio prazo com 20 passos de previsão, obteve no tempo de processamento a melhor classificação de todos os horizontes com 0,273 segundos, o erro quadrático médio MSE obteve o melhor resultado 1,491 e, obteve na assertividade do modelo ou confiabilidade o melhor resultado, com uma resposta de 0,9748.

No último horizonte de longo prazo com 25 passos de previsão, obteve no tempo de processamento a terceira melhor classificação de todos os horizontes com 0,273 segundos, o erro quadrático médio MSE obteve o pior resultado 1,835 e, obteve na assertividade do modelo ou confiabilidade o terceiro melhor resultado, com uma resposta de 0,9629.

Com os cenários testados, observou-se que o melhor resultado de previsão do nível do rio com o algoritmo NARX foi obtido para o horizonte de médio prazo, mesmo que a assertividade para o horizonte de 15 passos tenha obtido o pior resultado, ainda está acima de 95% o que retorna um excelente resultado.

CAPÍTULO 5

5 CONCLUSÃO

A previsão da velocidade do rio no Amazonas foi realizada conforme proposto, para isso foi utilizada o NARX, foi realizada as previsões de 5, 10, 15, 20 e 25 passos a frente, cada passo representou um horizonte de um mês para cada passo, um total de 60 combinações de análises de previsões.

A identificação das variáveis significativas de entrada, que tem correlação com a variável de saída para previsão do nível do rio, são apresentadas no capítulo 3 deste trabalho, as quais são variáveis de entrada a chuva, temperatura do rio, umidade relativa do ar, e a variável de saída é o nível do rio.

A dedução das configurações (número de camadas, algoritmo de treinamento, funções de ativação, número de neurônios) ideais para aplicação no modelo de previsão, são apresentadas no capítulo 3. Os resultados encontrados com as simulações computacionais para encontrar a quantidade de camadas e a quantidade de neurônios ideal, é possível afirmar que as simulações foram de suma importância para averiguar os indicadores de performance e qualidade do modelo computacional em função do algoritmo de treinamento escolhido (Levenberg-Marquardt).

Foram realizadas as simular previsões com as configurações ideais do modelo para verificar a acuracidade do mesmo e apresentados no capítulo 4 deste trabalho, e foram encontrados resultados satisfatórios com os melhores resultados para o horizonte de médio prazo, sendo o resultado que melhor satisfez as previsões de horizonte de 15 passos, demonstrando que a previsão de médio prazo tem maior confiabilidade para esse modelo.

5.1 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestão para trabalhos futuros tem-se a aplicação do modelo SARIMA para previsão do nível do rio;

Aplicação de um modelo híbrido NARX e SARIMA para previsão do nível do rio;

REFERÊNCIAS

- ALBERTON, Gabriel Barreto et al. Aplicação de redes neurais artificiais para previsão de enchentes no rio Itajaí-Açu em Blumenau, SC, Brasil. *Revista Ibero-Americana de Ciências Ambientais*, v. 12, n. 4, 2021.
- ALBUQUERQUE, Francisco Roberto. Os problemas causados pela cheia do rio Amazonas na área do bairro da Francesa na cidade de Parintins no ano de 2015. 2018.
- ALENCAR, David B. et al. Hybrid approach combining SARIMA and neural networks for multi-step ahead wind speed forecasting in Brazil. *IEEE Access*, v. 6, p. 55986-55994, 2018.
- ALVES, Luna Gripp Simões. Relatório para estabelecimento de cotas de referência para alerta hidrológico em Municípios da Amazônia Ocidental. 2021.
- ARAÚJO, Carla Beatriz Costa de et al. Previsão Sazonal de Vazões para a Bacia do Orós (Ceará, Brasil) Utilizando Redes Neurais e a Técnica De Reamostragem dos K-vizinhos. *Revista Brasileira de Meteorologia*, v. 35, p. 197-207, 2020.
- BARBOSA DE ALENCAR, David et al. Different models for forecasting wind power generation: Case study. *Energies*, v. 10, n. 12, p. 1976, 2017.
- BLÁZQUEZ-GARCÍA, Ane *et al.* Short-term office building elevator energy consumption forecast using SARIMA. *Journal of Building Performance Simulation*, v. 13, n. 1, p. 69-78, 2020.
- CERRI, Ricardo. Introdução às Redes Neurais Artificiais com Implementações em R. In: *Anais da I Escola Regional de Aprendizado de Máquina e Inteligência Artificial de São Paulo*. SBC, 2020. p. 47-50.
- CHANG, Wen-Yeau et al. A literature review of wind forecasting methods. *Journal of Power and Energy Engineering*, v. 2, n. 04, p. 161, 2014.
- CRISTALDO, Marcia Ferreira et al. [artigo retratado] redes neurais artificiais aplicadas à previsão de enchentes para região do pantanal no mato grosso do sul. *Geosciences= Geociências*, v. 39, n. 1, p. 191-201, 2020.

DE AMORIM, Renata Ferreira. A gestão dos recursos hídricos através da tríade soberania, sustentabilidade e desenvolvimento sustentável–recorte na Região Hidrográfica Amazônica. Anais dos Seminários de Iniciação Científica, n. 23, 2021.

DE MENDONÇA, Leonardo Melo et al. Modelagem chuva-vazão via redes neurais artificiais para simulação de vazões de uma bacia hidrográfica da Amazônia. Revista de Gestão de Água da América Latina, v. 18, n. 2021, 2021.

FAVA, Maria Clara. Modelo de alerta hidrológico com base participativa usando sistema de informações voluntárias para previsão de enchentes. 2015. Tese de Doutorado. Universidade de São Paulo.

FINCK, Juliano Santos. Previsão em tempo atual de níveis fluviais com redes neurais artificiais: aplicação à bacia do Rio Taquari-Antas/RS. 2020.

GORODETSKAYA, Yulia; DA FONSECA, Leonardo Goliatt; DE MELO RIBEIRO, Celso Bandeira. Previsão de vazão de curto prazo utilizando redes neurais artificiais. Estudo de caso: Rio Paraíba do Sul, 2017.

HAYKIN, S. O. Neural Networks and Learning Machines. 3 Prentice Hall. New York, 2008.

INMET. 2021. Acessado em: 18/08/2021. Disponível em: <https://bdmep.inmet.gov.br/>

MARACAJÁ, José Rosenilton de Araújo et al. Previsão regionalizada de vazão sazonal utilizando redes neurais artificiais. 2005.

MATKOVSKYY, romano; BOURAOUI, Taoufik. Aplicação de redes neurais a índices compostos de séries temporais curtas: Evidência do modelo não linear autoregressivo com entradas exógenas (narx). Journal of Quantitative Economics, v. 17, n. 2, pág. 433-446, 2019.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, v. 5, n. 4, p. 115-133, 1943.

MUÑOZ CHÁVEZ, Jairo José. Modelagem em espaço de estados e predição da geometria do cordão de solda no processo GMAW usando redes SVM, neurodifusa e recorrentes de alta ordem. 2020.

NATTRODT, Thaísy Nitis Mota; DIAS, Maria Das Graças Santos. As relações entre os recursos hídricos, a energia e a sustentabilidade na Amazônia. *Brazilian Journal of Development*, v. 7, n. 4, p. 38319-38339, 2021.

PARENTE, Ricardo Silva et al. Application of the narx model for forecasting wind speed for wind energy generation”. *International Journal of Development Research*, v. 11, n. 04, p. 46461-46466, 2021.

Porto de Manaus, o coração do Amazonas. 2021. Acessado em: 18/08/2021. Disponível em: <https://www.portodemanaus.com.br/?pagina=nivel-do-rio-negro-hoje>

REIS, Leonardo Pequeno et al. Prognose da distribuição diamétrica na Amazônia utilizando redes neurais artificiais e autômatos celulares. *Floresta*, v. 48, n. 1, p. 93-102, 2018.

Serviço Geológico do Brasil (CPRM). Boletim de Monitoramento Hidrometeorológico da Amazônia Ocidental. 2021.

SILVA, João Batista Lopes da. Modelos de previsão de enchentes em tempo real para o município de Nova Era MG. 2006.

SILVA, Marcos Cardoso et al. Aplicação de redes neurais artificiais na cultura do mogno (*Khaya spp.* e *Swietenia spp.*). *Journal of Biotechnology and Biodiversity*, v. 8, n. 1, p. 017-023, 2020.

SILVA, Maria do Socorro Rocha da et al. Bacia hidrográfica do Rio Amazonas: contribuição para o enquadramento e preservação. 2013.

SILVA, Maria do Socorro Rocha da; MIRANDA, Sebastião Átila Fonseca; SANTANA, Genilson Pereira. Bacia Hidrográfica do Rio Amazonas: Condições de suas águas versus Resolução nº 357/CONAMA/2005. Volume 6, Pags. 83-90, 2016.

VILELA, Leticia Biagi; MATEUS, Tiago Henrique de Abreu. APLICAÇÃO DE REDE NEURAL NARX PARA A PREVISÃO DO PREÇO DA SOJA. XXXVI Encontro nacional de engenharia de produção. 2016.

WANG, Wen-chuan *et al.* Improving forecasting accuracy of annual runoff time series using ARIMA based on EEMD decomposition. *Water Resources Management*, v. 29, n. 8, p. 2655-2675, 2015.

WUNSCH, Andreas; LIESCH, Tanja; BRODA, Stefan. Previsão dos níveis de água subterrânea usando redes autorregressivas não lineares com entrada exógena (NARX). *Journal of hydrology*, v. 567, p. 743-758, 2018.