

GUSTAVO GALDINO RODRIGUES BERNHARD

MODELO DE PREVISÃO DE CHUVA USANDO REDES NEURAS ARTIFICIAIS

MANAUS – AM
2022

GUSTAVO GALDINO RODRIGUES BERNHARD

MODELO DE PREVISÃO DE CHUVA USANDO REDES NEURAIAS ARTIFICIAIS

Dissertação para obtenção do título 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.

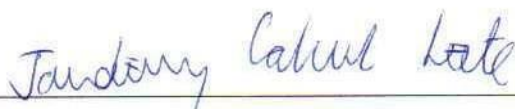
Orientadora: Dra. Alexandra Amaro de Lima

GUSTAVO GALDINO RODRIGUES BERNHARD

**MODELO DE PREVISÃO DE CHUVA USANDO REDES NEURAIAS
ARTIFICIAIS.**

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.

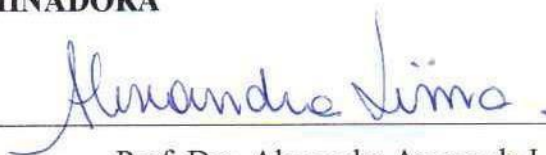
Manaus-AM, 20 de setembro de 2022.



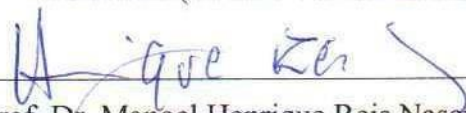
Prof. Dr. Jandecy Cabral Leite

Coordenador do PPG.EGPSA - ITEGAM

BANCA EXAMINADORA



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



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



Prof. Dra. Rosa Maria Nascimento dos Santos
Examinador Externo (UEA)

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

Bernhard, Gustavo Galdino Rodrigues, 2022 - MODELO DE PREVISÃO DE CHUVA USANDO REDES NEURAIAS ARTIFICIAIS / Gustavo Galdino Rodrigues Bernhard - 2022. 64 f., il: Colorido

Orientador: Dr(a). Alexandra Amaro de Lima

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. Rede Neural 2. Precipitação Pluvial 3. Dados Meteorológicos Superficiais

CDD - 1003.ed.2022.33

AGRADECIMENTOS

Gostaria de iniciar os agradecimentos a minha família, pois é a base de minha sabedoria e proporcionou as condições necessária para que eu chegasse até este dia com a certeza de ter desenvolvido um bom trabalho a minha família meus sinceros agradecimentos.

Aos meus amigos que de forma direta ou indireta colaboram com os processos de nossa caminhada. Nesta jornada, VIDA.

Inicialmente agradecer meu professor Dr. **Manoel Henrique Reis do Nascimento**, que ministrou a primeira disciplina, incentivando a buscar novas ferramentas tecnológicas para desenvolvimento das pesquisas, muito obrigado, o senhor foi fundamental para a conquista.

Agradecer imensamente a minha orientadora professora Doutora **Alexandra Amaro Lima**, pelos ensinamentos, incansáveis momentos de orientação, por sua dedicação e amor ao ensinar, sem sua presteza e compreensão, este trabalho não aconteceria, pois soube de forma precisa conduzir todo o processo como um excepcional zelo. MUITÍSSIMO Obrigado!

Durante o processo nos deparamos com amigos que nos inspiram e incentivam, e por este motivo agradeço em especial ao meu sogro e amigo, **Carlos Marques**, que com sua sabedoria, nunca mediou palavras para me incentivar.

In memoriam agradeço um grande mentor, professor e Mestre **Antônio Venâncio Castelo Branco**, a quem me inspiro diariamente como servidor público honrado e perseverante, um apaixonado pela educação técnica, pública e de qualidade, está em que me dedico como docente diuturnamente a seguir seus ensinamentos ele dizia: *“fazer educação de qualidade é difícil no Amazonas é ainda mais difícil e no interior do Amazonas é um desafio”*.

In memoriam a minha mãe, **Ledy Rodrigues Bernhard**, que por vontade de deus não está conosco para viver está conquistada.

Agradecer aos meus filhos **Mateus Bernhard** e **Artur Bernhard**, minha fonte diária de inspiração, ter vocês neste momento e um grande orgulho e poder dar como incentivo a vocês a certeza de que a educação não possui limites, nem momento, basta termos vontade e perseverança pois somente ela nos transforma.

Agradecer a minha esposa **Carla Bernhard**, minha esposa, minha vida, meu eterno amor, agradecer pela paciência, pelos cuidados, pelos momentos de incentivo, pelas cobranças, pela parceria e ajuda. Sem você nada disso seria possível, ter você comigo e a única inspiração que preciso para dar os voos mais altos. Seu amor me aquece e assim supero qualquer dificuldade e problema, tornando minha vida um lugar iluminado. Te Amo!!!

Epígrafe

“As pessoas não constroem conhecimento; elas, na verdade, reconstroem a partir do que já existe e já se sabe. O que o aprender significa? Não é só reconstruir conhecimento, é também forjar o sujeito capaz de ser o dono do seu conhecimento, ser autônomo em seu conhecimento”. (Pedro Demo,2000)

Dedicatória

Dedico este trabalho ao amor da minha vida, minha esposa Carla Condé Marque e Oliveira Bernhard, confidente e companheira de todas as horas e dificuldades, não deixando em momento algum de motivar-me, mesmo em momentos de perdas importantes em anos tão difíceis. A sua contribuição acadêmica, com ideias relevantes e inspirações, nortearam meus caminhos nos momentos mais difíceis da pesquisa. Sem sua luz não seria possível atravessar este caminho, obrigado por estar sempre ao meu lado.

Dedico também aos meus filhos Mateus Bernhard e Artur Bernhard, que me inspiram e tranquilizam os momentos mais difíceis.

RESUMO

BERNHARD, Gustavo Galdino Rodrigues. **MODELO DE PREVISÃO DE CHUVA USANDO REDES NEURAIAS ARTIFICIAIS**. 2022. 64f. 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.

A precipitação é importante na manutenção do meio ambiente e vida dos seres vivos. Por meio de seus estudos e previsões cada vez mais precisas a fim de diminuir os impactos relacionados à enchentes desastres ambientais, prejuízos nos setores agrícolas e turismo. Contudo, as mudanças climáticas vêm dificultando as análises desta variável. Apresentaremos um modelo de previsão de chuva hora a hora utilizando Redes Neurais Artificiais, utilizando informações de temperatura instantânea, máxima e mínima, umidade relativa, vento e precipitação através das estações meteorológicas automáticas do Instituto Nacional de Meteorologia (INMET), como metodologia apresentaremos em três etapas, denominadas de montagem, pois nela é definido o tipo de rede, arquitetura (camadas e neurônios ocultos), funções de ativação, tipo de propagação, algoritmo de aprendizado, e outros parâmetros. Treinamento, onde a RNA captura todas as características relevantes do conjunto de dados selecionados sendo divididos, de forma que 70% das informações disponibilizadas para que o modelo realize o aprendizado da rede, e 15% são resguardados para realizar a validação e entre 15% no teste da rede e a terceira etapa ocorre os testes da RNA, onde está é para executar as previsões da precipitação e as correções dos valores encontrados pela rede. As previsões realizadas com o modelo mostraram resultados satisfatórios, mostrando que o modelo conseguiu reproduzir o mesmo comportamento da precipitação observada para o dia previsto, apresentando praticamente os mesmos totais milímetros (mm), principalmente nos dias mais chuvosos. Por outro lado, nos casos em que o observado mostrava uma característica de precipitação convectiva o modelo não conseguiu capturar a intensidade, o que mostra que esse deve ser testado com outras variáveis atmosféricas.

Palavras-chave: Rede Neural; Precipitação Pluvial; Dados Meteorológicos Superficiais.

ABSTRACT

BERNHARD, Gustavo Galdino Rodrigues. **RAINFORE PREDICTION MODEL USING ARTIFICIAL NEURAL NETWORKS**. 2022. 64f. Dissertation of the graduate program in Engineering, Process, Systems and Environmental Management (EGPSA), Galileo da Amazônia Institute of Technology and Education (ITEGAM), Manaus, 2022.

Precipitation is important in maintaining the environment and life of living beings. Through their studies and increasingly accurate forecasts, we can reduce the impacts related to floods, environmental disasters, and losses in the agricultural and tourism sectors. However, climate change has made the analysis of this variable difficult. In this article, we will present an hourly rain forecast model using Artificial Neural Networks, using the information on instantaneous, maximum and minimum temperature, relative humidity, wind, and precipitation through the automatic weather stations of the Instituto Nacional de Meteorologia (INMET). As a methodology, we will present it in three steps, called assembly, because it defines the type of network, architecture (layers and hidden commands), activation functions, type of control, learning algorithm and other parameters. Training, where the ANN captures all the relevant characteristics of the selected data set being divided, so that 70% of the information made available for the model to carry out the network learning, and 15% are saved to carry out the validation and between 15% not network test and a third stage takes place the RNA tests, where it is to perform the precipitation forecast and corrections of the values found by the network. The forecasts made with the model had strong results, showing that the model was able to reproduce the same behavior as the observed observation for the predicted day, presenting practically the same total millimeters (mm), mainly on the rainiest days. On the other hand, in cases where the observed showed a characteristic of convective precipitation, the model failed to capture the intensity, which shows that this should be tested with other astrological variables.

Keywords: Neural Network; Ranfail; meteorological surface data.

LISTA DE FIGURAS

Figura 2.1 - Estrutura vertical da atmosfera terrestre até 110 km de altura.....	25
Figura 2.2 - Precipitação frontal.....	28
Figura 2.3 - Precipitação orográfica.....	29
Figura 2.4 - Precipitação convectiva.....	29
Figura 2.5 - Anomalia de precipitação total	30
Figura 2.6 - Ciclo Hidrológico.....	31
Figura 2.7 - Efeitos da Ilha de calor.....	34
Figura 2.8 - As mudanças climáticas e as interações com o ser humano.....	37
Figura 2.9 - Esquema gráfico de um neurônio artificial.....	40
Figura 10 - Outro exemplo de esquema gráfico de um neurônio artificial.....	41
Figura 3.11 - Fluxograma de Resumo dos Procedimento Metodológicos.....	46
Figura 4.12 - Fluxograma de Resumo dos Procedimento Metodológicos.....	48
Figura 4.13 – Análise do MSE para a escolha da melhor função de Transferência.....	50
Figura 4.14 – Análise do ERRORMSE para a escolha da melhor função de Transferência..	51
Figura 4.15 - Melhor Valor de Validação da Performance.....	52
Figura 4.16 - a) Teste de regressão entre os resultados obtidos versus esperados da RNA: a) treinamento; b) validação; c) teste da melhor rede; d) Aspectos em conjunto da rede.....	53
Figura 4.17 - Previsão de precipitação prevista por meio da Rede Neural em comparação aprecipitação observada em mm/hora referente ao dia 01/01/2022.....	54
Figura 4.18 - Previsão de precipitação prevista por meio da Rede Neural em comparação a precipitação observada em mm/hora referente ao dia 08/02/2022.....	54
Figura 4.19 - Previsão de precipitação prevista por meio da Rede Neural em comparação aprecipitação observada em mm/hora referente ao dia 07/03/2022.....	55
Figura 4.20 - Previsão de precipitação prevista por meio da Rede Neural em comparação aprecipitação observada em mm/hora referente ao dia 02/04/2022.....	56
Figura 21 - Previsão de precipitação prevista por meio da Rede Neural em comparação aprecipitação observada em mm/hora referente ao dia 07/05/2022.....	56

LISTA DE QUADROS

Quadro 2.1 Escala de Beaufort.....	32
---	----

LISTA DE TABELAS

- Tabela 4.8** - Melhor resultado de combinações entre as funções de treinamento e transferência.....47
- Tabela 4.9** - Valores calculados do MSE de cada combinação das funções de Treinamento (FTrain) com as funções de Transferência (FTrans) após as simulações.....48
- Tabela 4.10** - Valores calculados do ERRORMSE de cada combinação das funções de Treinamento (FTrain) com as funções de Transferência (Ftrans) após as simulações.....49

LISTA DE SIGLAS

°C - Graus Celsius

GPM - Global Precipitation Measurement

IMERG - Integrated Multisatellite Retrievals

COSMO-CLM - Consortium for Small-scale Modeling

CPTEC - Centro de Previsão de Tempo e Clima

HDD - Hard Disk Drive

INMET - Instituto Nacional de Meteorologia

INPE - instituto nacional de Pesquisa Espacial

IPPC - Intergovernmental Panel on Climate Change

KM - Quilômetros

MAE - Erro Médio Absoluto - MAE Mean Absolute Error

MAPE - Erro Percentual Médio Absoluto

MAPE - Mean Absolute Percentage Error

MATLABR2016a® - Matrix Laboratory

Mb - Unidade milibar

MM - milímetros

MSE - erro médio quadrático

MSE - Mean Square Error

NNTOOL - Neural Network Toolbox

NRMSE - Raiz Quadrada do Erro Quadrático Médio Normalizado

NRMSE – Normalized Root Mean Square Error

OMS - Organização mundial da saúde

ONU - Organização Nações Unidas

PPM - Parte por milhão

RMSE - Raiz Quadrada do Erro Quadrático Médio

RMSE - Root Mean Square Error

RNAs - Redes Neurais Artificiais

TRAINBFG - BFGS Quasi-Newton

TRAINBR - Regularização Bayesiana

TRAINCGB - Gradiente conjugado com reinicialização de Powell /Beale

TRAINCGF - Fletcher-Powell Conjugado Gradiente

TRAINCGP - Polak-Ribire

TRAINLM - Levenberg-Marquardt

TRAINOSS - Secante de Um Passo Conjugado Gradiente),

TRAINRP - Retropropagação resiliente

TRAINSCG - Gradiente de Conjugado Escalado

TRMM - Tropical Rainfall. Measuring Mission

UV - Ultra violeta

WMO - World Meteorological Organization

ZCIT - Zona de convergência intertropical

SUMÁRIO

CAPÍTULO 1.....	18
1. INTRODUÇÃO.....	18
1.1 JUSTIFICATIVA DA DISSERTAÇÃO.....	20
1.2 OBJETIVOS	21
1.2.1 Objetivo Geral.....	21
1.2.2 Objetivos Específicos	21
1.3 ESCOPO DO TRABALHO	21
CAPÍTULO 2.....	23
2. REVISÃO DE LITERATURA	23
2.1 ESTRUTURA DA ATMOSFERA	23
2.2 TROPOSFERA	23
2.3 ESTRATOSFERA	24
2.4 MESOSFERA	24
2.5 TERMOSFERA	24
2.6 CLIMA: CONCEITOS	25
2.7 ELEMENTOS CLIMÁTICOS.....	26
2.8 PRESSÃO ATMOSFÉRICA.....	26
2.9 TEMPERATURA	27
2.10 PRECIPITAÇÃO	27
2.10.1 Precipitação frontal.....	28
2.10.2 Precipitação orográfica.....	28
2.10.3 Precipitação convectiva	29
2.10.4 Chuvas leves.....	30
2.11 UMIDADE RELATIVA.....	30
2.12 VENTO	31
2.13 A IMPORTÂNCIA DOS ELEMENTOS CLIMÁTICOS PARA O MEIO	

AMBIENTE URBANO E NATURAL	31
2.13.1 Ilha de calor	32
2.14 INUNDAÇÕES URBANAS	33
2.15 ALTERAÇÕES CLIMÁTICAS E AS DOENÇAS	34
2.16 NATURAL	36
2.16.1 Previsão climática	36
2.17 INTELIGENCIA ARTIFICIAL	36
2.18 REDES NEURAIS ARTIFICIAIS	37
2.18.1 Redes neurais artificiais (RNAs)	37
2.18.2 Neurônio artificial	38
2.18.3 Modelagem com redes neurais artificiais	39
CAPÍTULO 3	41
3. MATERIAL E MÉTODOS	41
3.1 MATERIAIS	41
3.2 ANÁLISE DESCRITIVA DAS VARIÁVEIS NUMÉRICAS DA RNA	41
3.3 METODOLOGIA APLICADA COM RNA	42
3.3.1 AVALIAÇÃO DAS ESTIMATIVAS GERADAS PELA RNA'S	43
CAPÍTULO 4	46
4. RESULTADOS E DISCUSSÕES	46
4.1 TREINAMENTO DA REDE	46
CAPÍTULO 5	57
5. CONCLUSÃO	57
5.1 CONSIDERAÇÕES FINAIS	57
REFERENCIAS	58

CAPÍTULO 1

1. INTRODUÇÃO

A precipitação é uma das variáveis meteorológicas que possui um importante papel na conservação do meio ambiente natural, manutenção do ciclo hidrológico e dos mananciais de abastecimento de água nas áreas urbanas (SCHMIDT & MATTOS, 2013; SILVA et al., 2021; NETO et al., 2022; MAUD 2022). Contudo, o regime da precipitação tem sido modificado por diversos fatores, mas principalmente pelas mudanças climáticas (HUANG et al., 2021; GEORGESCU et al., 2021; BACK et al., 2022).

Os estudos sobre aquecimento global e mudanças do estado do clima mundial apontam que a precipitação é a variável mais significativa no processo, contudo conhecer o comportamento da precipitação em uma determinada região e sua variação ao longo do período, pode ser uma ferramenta útil para os gestores públicos para ações durante períodos de eventos extremos, além das ações necessárias para possíveis soluções de mudanças climáticas (CHOWDHUR et al., 2016; GOLDBERG et al., 2020; GOMES et al., 2021). Contudo, a variabilidade climática é a principal justificativa para continuarmos os esforços de uma previsão climática mais precisa, pois os setores de saúde, produção de energias, agricultura (HELLDÉN, et al., 2021; EBI et al., 2022; KUGO et al., 2022).

O Brasil é um país com dimensões continentais e por seu grande espaço territorial, apresenta uma grande variação dos elementos climáticos e conseqüentemente, das previsões climáticas que historicamente utilizam-se dos modelos das alterações químico-físico-químicas da atmosfera para suas previsões.

Segundo Marengo e Nobre (2001), a capital, Manaus, local deste estudo, está em uma Zona de convergência intertropical, apresentando uma região com dois períodos sazonais distintos, trazendo um período seco e um chuvoso.

Importante ressaltar as frequentes ocorrências de cheias e inundações que a cidade vem sofrendo ao longo dos anos, onde a última no ano de 2021. (WMO, 2021)

A cada ano, as cheias e as Vazantes alteram o cotidiano e a vida dos ribeirinhos, que precisam viver um recomeço frequente, com as relações de impacto direto com as inundações e com a seca dos rios. (ALENCAR, 2005).

Com as mudanças climáticas em processo acelerado, a Amazônia viveu tranquilidade aparente até a seca do rio Manaquiri em 1999, alterando o leito do rio que possuía cerca de 2 km de largura para pouco menos de dois metros com uma seca avassaladora e sem

precedentes na região. No ano de 2005, o leito dos rios chegou a uma profundidade ínfima de 30 centímetros, provocando uma mortandade de peixes e destruindo as produções agrícolas e sem possibilidade de navegação, as cidades ficaram sem abastecimento. Problemas que se arrastou até 2007, pois iniciou-se um processo de assoreamento dos rios e com isso, bancos enormes de areia dificultavam a navegação, onde a via hídrica de transporte é fundamental para a vida das cidades e comunidades, culminando na grande cheia de 2009, que destruiu comunidades e produções inteiras. (SOUZA e ALMEIDA, 2010)

Por essas razões, nas últimas décadas, esforços têm sido realizados para criação de modelos e ferramentas que possam estimar e prever a precipitação em áreas oceânicas e continentais (LIU et al., 2017; SUN et al., 2018). Em Soko et al., (2021), é realizada uma revisão sobre a importância dos radares meteorológicos. Os autores apontam os radares com uma ferramenta eficaz de estimativa e previsão da precipitação, devido a sua resolução temporal e espacial, e sua capacidade de fornecer dados praticamente em tempo real da chuva, sendo capaz de auxiliar nas aplicações hidrológicas e meteorológicas (ZANG et al., 2018). Modelos de estimativa de precipitação por satélite são ferramentas poderosas. A missão TRMM (*Tropical Rainfall Measuring Mission*) (KUMMEROW et al., 1998; KUMMEROW et al., 2000; KIDD et al., 2017) forneceu produtos de precipitação durante muitos anos com alta resolução temporal e espacial, sendo substituída pelos produtos de precipitação GPM (*Global Precipitation Measurement*) KIRSCHBAUM et al., 2017; HUFFMAN et al., 2019).

Além dos modelos matemáticos de previsão, COSMO-CLM (*Consortium for Small-scale Modeling*) (ROCKEL et al., 2008; MUGUME et al., 2018; PAUL & SURAHAMANYAM, 2021; BAUR et al., 2022), WRF (POLITI et al., 2021; ZHU, et al., 2021; PIERSANTE, et al., 2021; DEVI et al., 2021), e de estimativa de precipitação, alguns modelos computacionais como os de Redes Neurais Artificiais (RNAs) conseguem reproduzir as variáveis meteorológicas (BENALI et al., 2019; CARVALHO & DELGADO, 2022) e hidrológicas (OYEBODE & STRECHT, 2019; ALTHOFF et al., 2021; KARUNANAYAKE et al., 2021; LOPES et al., 2022). Por ser um modelo auto adaptativo, as RNAs, ao contrário dos modelos tradicionais, por meio dos exemplos e das relações funcionais entre os dados, são possível que as redes se aprimorem, sendo adequadas para problemas que possuem dados substanciais, mesmo que as soluções sejam de grande complexidade como as previsões. (ZHANG et al., 1998).

Em Sonderby et al., (2021) os autores criaram um modelo baseado em RNA denominado de MetNet, que previa a precipitação para 8 horas e resolução temporal de 1 km², produzindo mapas probabilísticos da variável através de imagens de satélite e radar. Chen et

al., (2019) desenvolve dois modelos de RNA, onde a primeira treina a rede com os pontuais de precipitação, refletividade de radar em superfície, enquanto o segundo modelo acrescenta a precipitação do satélite TRMM, mostrando ao modelo híbrido de RNA, uma proposta promissora para prever a precipitação. Contudo, em Li *et al.*, (2021) os autores usaram cinco anos de dados para treinar uma RNA autor regressivo não linear, com a finalidade de prever a precipitação para 48 horas, mostrando que o modelo é eficaz para prever a variável em áreas urbanas. Enquanto, em Pan et al., (2021) usou-se as RNs como uma alternativa aos modelos *downscaling*.

O uso de diferentes técnicas de estimativa de precipitação, como regressão linear múltipla, RNA e interpolação Spline e dados de satélite (GPM-IMERG), além da identificação da nuvem e de sua morfologia, mostrando que os modelos híbridos possibilitam uma maior cobertura geográfica (SHARIFH et al., 2019). Inspirado nas famílias *of deep learning models for binary segmentation*, U-Net (RONNEBERGER et al., 2015) e SegNet (BADRINARAYANAN, et al., 2017; SHI et al., 2017), Ayzel et al., (2020) apresentou o modelo de RNA colovional para estimar a precipitação a cada 60 min, usando dados de radar, denominando de *RainNet v. 1.0*, apesar da limitação para precipitação intensa, o modelo mostrou bastante promissor nos estudos de modelos híbridos de RNA.

Ainda, Misra et al., (2018) usa um modelo de *downscaling* estatístico baseado em uma RNA recorrente com memória longa e curta para capturar as dependências espaço-temporais na precipitação local, os resultados mostraram que a RNA recorrente de memória de longo prazo acoplado ao *autoencoder*, tem o melhor desempenho em comparação com outros métodos existentes, além de capturar os extremos de precipitação (MANDAL, SRIVASTAV AND SIMONOVIC, 2016; KLINSDONK, et al., 2022).

Assim, este artigo mostrará o desenvolvimento de um modelo de RNA utilizando variáveis meteorológicas coletadas através de estações de superfície automáticas para prever a precipitação pontualmente em uma região.

1.1 JUSTIFICATIVA DA DISSERTAÇÃO

Dois motivos suscitaram a elaboração do presente estudo. O primeiro deles é de natureza teórica e visa refletirmos o quanto a evolução do homem moderno interfere nos elementos climáticos e conseqüentemente estas variações irão alterar a vida humana. O desenvolvimento desordenado, interfere diretamente nos elementos climáticos e conseqüentemente, na temperatura e umidade do ar, condições dos ventos, alteração do conforto térmico, determinando a nossa qualidade de vida.

A alteração dos elementos climáticos, quer sejam por meio das modificações das características naturais ou devido ao processo de Urbanização, promovem subprodutos para a vida humana. (MONTEIRO, 1976).

Busca-se com isso, não apenas efetuar revisão de literatura sobre os assuntos aqui tratados, mas também encorajar a realização de outros estudos, como objetivo de propor soluções para outros municípios e comunidades amazônicas. Esta é uma abordagem necessária, posto que a região amazônica é uma zona geográfica estratégica para o meio ambiente global, (PINHEIRO; ROCHA; SANTOS, 2016).

Conforme apresentado nos estudos (WMO, 2021) e (ALENCAR, 2005), as cheias e as secas assolam os ribeirinhos e alteram a vida deles de forma permanente.

O outro fator que motivou a realização do estudo é de cunho prático e visa propor uma solução capaz de auxiliar na previsão das precipitações através da utilização de redes neurais artificiais. É um trabalho que possui grande impacto social, posto que ao prever situações extremas e com antecedência, podemos mitigar os prejuízos e diminuir os impactos a sociedade. Com isso, espera-se que a partir deste estudo, outras soluções tecnológicas devidamente embasadas sejam cientificamente criadas e disponibilizadas para a sociedade.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Desenvolver um modelo de Rede Neural Artificial (RNA) para previsão da precipitação em tempo quase real, usados dados de estações meteorológicas automáticas Manaus/AM.

1.2.2 Objetivos Específicos

- Definir as especificações do modelo de RNA para a previsão da precipitação;
- Avaliar o desempenho do modelo construído para os dados ambientais;
- Gerar a previsão da precipitação em tempo real;
- Validar as informações geradas pelo modelo.

1.3 ESCOPO DO TRABALHO

Este estudo será estruturado em cinco capítulos. O Capítulo I aborda o problema de pesquisa, sua fundamentação, formulação do problema, objetivos e justificativa. No Capítulo II será apresentado Referencial Teórico relacionado ao histórico da Educação no Brasil; Definições de Meio Ambiente; Educação Ambiental; O Capítulo III abordará os materiais e o

método usado na pesquisa, além do tipo e nível de investigação, desenhos de investigação; população e amostra, fontes, técnicas e instrumentos de investigação e análise e interpretação dos resultados

No Capítulo IV serão apresentados os principais resultados e discussões elaboradas na pesquisa. Este capítulo apresenta os resultados através de tabelas estatísticas com análise e interpretação percentual através de estatística descritiva. Finalmente, o Capítulo V as conclusões e recomendações.

CAPÍTULO 2

2. REVISÃO DE LITERATURA

2.1 ESTRUTURA DA ATMOSFERA

O que chamamos de atmosfera terrestre é a composição de gases, material particulado e radiação que envolve a crosta terrestre e que se estende por milhões de quilômetros, tendo como limites inferiores à superfície da crosta terrestre e os oceanos e os seus limites superiores, não estão bem definidos e se confundem com o meio interplanetário (DIAS e MILITAO, 2007).

Em sua composição química, verifica-se que em maior parte se apresentam os gases, tais como: 78,10% é de gás nitrogênio, 20,94% de oxigênio, 0,93% de argônio, 0,03% de dióxido de carbono e em menores quantidades e concentrações podemos citar os gases: hélio, neon, metano, hidrogênio, xenônio, ozônio e outros que representam uma parcela de 0,003% (30 ppm) da composição geral da atmosfera (ALMEIDA, 1999). Além dos gases citados, a atmosfera apresenta outras substâncias artificiais e naturais, na sua composição tais como: clorofluorcarbonos, que em forte concentração, pode afetar sua composição básica; partículas sólidas e líquidas em suspensão; substâncias químicas e concentrações variáveis, como pólen e microrganismos. (ALMEIDA, 1999)

Todavia, em Raven *et. al*, 1995 os autores mostram que a camada atmosférica e principalmente continuidade de oxigênio e nitrogênio, composta por cinco camadas concêntricas, tais como: troposfera, estratosfera, mesosfera, termosfera e exosfera.

Ao longo dos anos, alguns mostravam a atmosfera como uma sucessão de camadas homogêneas, a qual se referia as propriedades físicas. Contudo, atualmente o mais aceitável está fundamentado na relação da variação da temperatura com a altitude. Seguindo esta lógica de pensamento, divide-se a atmosfera em quatro camadas aproximadamente homogênea, tais como troposfera, estratosfera, mesosfera e termosfera, separadas por zonas de transição conhecidas como tropopausa, estratopausa, mesopausa. (VAREJAO-SILVA 2005).

2.2 TROPOSFERA

Denomina-se troposfera, a camada inferior e mais próxima da superfície terrestre, camada esta que abriga em torno 99% de todo o vapor d'água, além dos demais elementos químicos e material particulado. É na troposfera onde acontecem todos os fenômenos

atmosféricos mais importantes como, precipitação, ventos, ciclones dentre outros. A temperatura ao longo da troposfera diminui em uma taxa média de $6,5\text{ }^{\circ}\text{C}/\text{km}$ a cada quilômetro. A troposfera se apresenta como a camada mais instável da atmosfera, isto se dá em virtude do intenso movimento das massas de ar em virtude das alterações temperatura. A troposfera é limitada pela tropopausa, que tem como característica própria e seu subsistema, possuindo uma zona de inversão de temperatura, ou seja, uma zona isotérmica em que a temperatura é constante independente da altitude. (SEINFELD; PANDIS, 1998; VAREJÃO-SILVA, 2005).

2.3 ESTRATOSFERA

Esta camada tem seu início na tropopausa e segue até a altitude de 50 km. Ainda que esta camada possua a maior parte do ozônio da atmosfera, o valor mais elevado de temperatura que pode ser maior que $0\text{ }^{\circ}\text{C}$ acontece na estratopausa. A partir da altitude de 20 km, as temperaturas começam a aumentar com a altitude, aumento da temperatura se dá em virtude da absorção da radiação ultravioleta solar pelo ozônio. (SEINFELD; PANDIS, 1998; VAREJÃO-SILVA, 2005).


2.4 MESOSFERA

A camada da atmosfera conhecida pela baixa pressão do ar que alcança valores em torno de 1mb (unidade milibar), a 50 km, até valores de baixa pressão equivalentes a 0,1 mb a 90 km. A sua delimitação não é universalmente aceita, onde pode variar do início da estratopausa a 20 km a 80 km, neste último, as temperaturas podem alcançar valores em torno de $-90\text{ }^{\circ}\text{C}$. Em simultâneo, acima de 80 km ocorre a camada de inversão de temperatura conhecida por mesopausa. (SEINFELD; PANDIS, 1998; VAREJÃO-SILVA, 2005).

2.5 TERMOSFERA

Região imediatamente acima da mesosfera, não possui limite máximo bem definido, contudo compreende o espaço entre 80 km, até a faixa de 500m a 1,00 km. A temperatura começa a subir desde a mesopausa e atinge o valor superior a $1500\text{ }^{\circ}\text{C}$, este aumento se dá em virtude do aumento da temperatura média do ar em relação a da altitude e a absorção da radiação, que é afetada pelos raios-X e UV (ultravioleta) provocando a ionização ou carregamento elétrico. Possui condições físicas completamente diferentes das regiões citadas acima. (SEINFELD e PANDIS, 1998; VAREJÃO-SILVA, 2005).

Figura 2.1: Estrutura vertical da atmosfera terrestre até 110 km de altura.



Fonte ADAPTADO DE AHRENS, C.D.: METEOROLOGY TODAY 9TH EDITION

2.6 CLIMA: CONCEITOS

Segundo Julius Hann (1983) descreve que o clima é um conjunto de efeitos meteorológicos que caracteriza a condição média da atmosfera sobre determinado lugar, conceito este ainda do século XIX. Na atualidade, a definição mais aceita foi escrita em (2006) por Max Sorre, definindo o clima como uma série de estados atmosféricos sobre determinado lugar em sua sucessão habitual.

Como uma referência para melhor entendimento dos conceitos de clima, citaremos a *World Meteorological Organization* (WMO, 2009), onde definiam que o clima reflete as condições atmosféricas caracterizadas pela sequência usual de estados representados por elementos meteorológicos (temperatura do ar, vento, pressão atmosférica, umidade relativa, precipitação, etc.) em locais específicos da superfície da Terra, e essas condições precisam ser consideradas e que deve ocorrer em um contínuo manifestado, e mantido as características, por pelo menos 30 anos.

De acordo com Giovani (1976), o clima será determinado pela apresentação dos padrões das variações de todos os elementos e suas combinações. O citado autor ainda descreve

os principais elementos, tais como: umidade, vento, precipitação, temperatura do ar, radiação solar e comprimento da onda de radiação.

Com objetivo de melhor entendermos as formas de estudo, é importante entendermos a diferença entre tempo e clima. O tempo está relacionado às observações das condições atmosféricas em um determinado instante, ou seja, uma experiência momentânea e o clima é um conjunto complexo de elementos com dados de registros meteorológicos coletados a longo de muitos anos de modo a serem estudados.

Da mesma forma, Santos (2002) acredita que o papel do clima é ser um fornecedor de energia, ou seja, responsável por fornecer energia ao sistema. O clima é considerado constituído por variáveis dependentes ou abrangentes que o homem pode intervir com o auxílio da tecnologia; e independente, sobre o qual o homem não tem controle. O mesmo autor destaca a importância do clima como principal regulador da vida econômica da sociedade. A partir do estudo, pode-se concluir que a visão dinâmica do clima permite a visualização de fenômenos temporais mais limitados, como a identificação do ritmo climático expresso pelo regime chuvoso em períodos de alta estiagem, ou por mudanças nos valores de pressão do ar ao longo da penetração de frentes frias, juntamente com mudanças na velocidade e direção do vento.

Os elementos climáticos são definidos pelas propriedades físicas que representam uma propriedade da atmosfera geográfica de um determinado local. A temperatura, a umidade e a pressão afetam como a precipitação elementar se comporta, vento, nublado, onda de calor e frio, etc. variação espacial e a temporalidade se deve ao desempenho correspondente aos fatores climáticos. Diversas características geográficas da paisagem, como latitude, elevação, terreno, vegetação, continentalidade, área marítima e atividades Humanas (VIANELLO et al., 1991; MENDONÇA, DANNI-OLIVEIRA, 2007).

2.7 ELEMENTOS CLIMÁTICOS

Os principais Elementos Climáticos segundo Vianello et al., (1991), são: pressão atmosférica, temperatura, radiação solar, vento, precipitação e umidade. Estes elementos são ações meteorológicas que comunicam ao meio atmosférico suas propriedades e características.

2.8 PRESSÃO ATMOSFÉRICA

Peso aplicado pela atmosfera por unidade de área. Sabendo que o ar é um fluido, ele tende a se mover para áreas de menor pressão. Portanto, o movimento da atmosfera está relacionado com a distribuição da pressão atmosférica. (Varejão-Silva, 2006)

2.9 TEMPERATURA

De acordo com Varejão-Silva, (2006) a temperatura é a forma de medir o calor sensível armazenado no ar, que pode ser feito em (três) escala: graus *Celsius*, *Kelvin* ou *Fahrenheit*, por meio de termômetros. A temperatura do ar pode ser regulada por inúmeros fatores, que determinamos como controladores de temperatura, que são facilmente variáveis ao tempo e no espaço.

Controladores de Temperaturas:

- Radiação;
- Advecção de massas de ar;
- Aquecimento diferencial da superfície terrestre e da água;
- Correntes oceânicas;
- Altitude;
- Posição geográfica.

De outra forma, podemos definir que a temperatura é a medida de movimento das moléculas, pois com o movimento das moléculas de forma rápida e acelerada teremos um corpo mais quente. Dentre os fatores e condições externa para a saúde dos seres vivos, destacamos a temperatura, pois esta é extremamente importante, pois ela determina as condições ambientais ideais, bem como estabelece o grau de conforto térmico. (GRIMM, 1999).

2.10 PRECIPITAÇÃO

É a grande responsável pelo abastecimento dos recursos hídricos e consequentemente, pela alimentação das populações, tecnicamente definida por elemento climatológico. (VIANELO et al., 1991; TUBELIS, 1984; VAREJÃO-SILVA, 2005).

Em linhas gerais, precipitação, comumente chamada de chuva, momento em que a água condensada na atmosfera retorna, de forma natural e atinge o solo. Tecnicamente, a precipitação é o retorno para o solo da água que estava na fase líquida para gasosa, processo conhecido como evaporação, completando o ciclo da água. Este fenômeno tem variabilidade espacial e temporal e tem enorme importância na manutenção do clima. (GRIMM, 1999)

Para entendermos a precipitação e consequentemente as chuvas, precisamos compreender e perceber o principal ator neste processo, a coalescência. Momento onde as minúsculas gotículas de água são transportadas pelo vento dentro de uma nuvem em um processo de colisão e coalescendo. Neste momento, a sua capacidade de sustentação é maior que a força da gravidade. A diferença entre o processo de nuvem e elementos de precipitação

está no diâmetro da gotícula que no primeiro estará em (100 micras) e no segundo em (2mm) (GRIMM, 1999; VAREJÃO-SILVA, 2005).

Segundo Varejão-Silva (2006), o processo chamado Coalescência explica o crescimento da gotícula de água condensada até o tamanho necessário e suficiente para cair em uma fase gravitacional, vencendo a resistência e as correntes de ar ascendentes. Explicaremos abaixo as diferentes formações e concorrências de precipitação:

2.10.1 Precipitação frontal :

Como o próprio nome sugere, esta ocorre quando duas massas de ar opostas se encontram. Quando o deslocamento de uma massa quente avança sobre uma fria, teremos como resultado uma frente quente em desenvolvimento, em caso oposto, a massa fria for a que esteja em avanço, o resultado será uma frente fria. (Figura 02) (VAREJÃO-SILVA, 2005).

Figura 2.2: Precipitação frontal.




Fonte: MAY & PRADO (2004)

2.10.2 Precipitação orográfica:

Está ocorre quando o ar quente e úmido em deslocamento em um terreno é forçado a ascender, por encontrar uma resistência geográfica como uma colina. (TUBELIS, 1984).

Figura 2.3 : Precipitação orográfica.




Fonte: MAY & PRADO (2004)

2.10.3 Precipitação convectiva:

Está é formada quando temos ar quente em ascensão com grande carga de vapor d'água. Durante o processo, o ar é resfriado condensando o vapor de água transformando em precipitação. (May & Prado, 2004)

Figura 2.4 - Precipitação convectiva

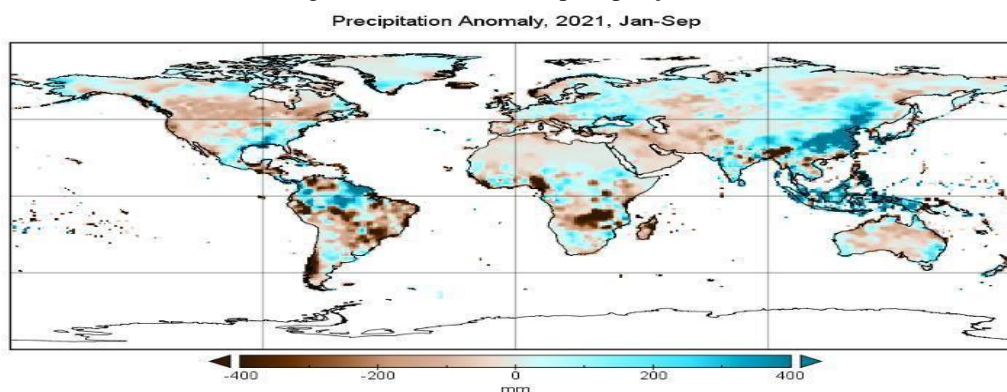


Fonte: MAY & PRADO (2004)

Segundo Santos (2005), existem variações nas formas de precipitações, onde estas podem ser sazonais ou ocorrerem do ponto de vista geográfico, contudo, o mais importante é conhecer e estudar as variações de cada região para entendermos os períodos de chuvas, chuvas intensas, períodos de seca, controle do solo, erosões, inundações etc.

Na primeira metade do ano de 2021, chuvas intensas estiveram acima da média em todo o norte da América do Sul, em especial no norte da bacia amazônica, provocando inúmeras inundações. Especificamente em Manaus, o rio Negro teve seu nível mais alto já registrado, igualmente atingiram regiões da África Oriental, com maior dano ao Sudão do Sul. (WMO, 2021)

Figura 2.5 - Anomalia de precipitação total.



(Fonte: CENTRO MUNDIAL DE CLIMATOLOGÍA DE LAS PRECIPITACIONES, DEUTSCHER WETTERDIENST, ALEMANIA) ”

Anomalia de precipitação total no período de janeiro a setembro de 2021 em relação ao período de referência de 1951 a 2000. A cor azul indica precipitação acima da média de longo prazo, e a cor marrom indica totais de precipitação abaixo do normal. As partes mais escuras das cores representam a magnitude do desvio.

A região de Manaus, local do nosso estudo, é conhecida por possuir um período seco e um período chuvoso, conforme já explicados, pois possuímos dois períodos sazonais distintos quanto ao regime pluviométrico, fato este que altera o movimento anual da (ZCIT), zona de convergência intertropical, trazendo um período seco e um chuvoso (MARENGO; NOBRE, 2001).

2.10.4 Chuvas leves :

Segundo Ometto (1981), ocorrem durante o processo de injeção de vapor em superfície úmida com maior energia, que possua acima uma camada de ar com menos energia, com um potencial resfriamento secundário dessa massa de ar e as Chuvas intensas, que são provocadas por movimentos térmicos convectivos.

2.11 UMIDADE RELATIVA

A umidade relativa do ar, possui uma relação direta com as variações de temperatura e pressão do vapor de água. Este elemento climático é de suma importância para a saúde humana e para a agricultura, pois inúmeras doenças respiratórias estão diretamente relacionadas a umidade do ar. (Vianello *et al.* 1981).

Conforme podemos observar na (figura 06) todos os processos dos elementos climáticos, a umidade relativa é o maior responsável, pelo ciclo hidrológico, e a fonte das precipitações, e o elemento controlador da evaporação da água em solo e dos reservatórios e da transpiração dos vegetais. (Tucci, 2001)

Figura 2.6- Ciclo Hidrológico



Fonte: USGS (UNITED STATES GEOLOGICAL SURVEY)

2.12 VENTO

Evento que promove o deslocamento horizontal do ar em direção a superfície terrestre, em grande maioria resultante da diferença de pressão entre dois pontos. A causa mais provável para este acontecimento é o resfriamento e/ou aquecimento da atmosfera. O que define o vento é sua direção e sua velocidade. (Shahidian S, Guimarães R, Rodrigues C., 2012)

QUADRO 2.1 Escala de Beaufort.

Nº de Beaufort	Descrição	Velocidade (m s ⁻¹)	Observações
0	calmo	<0,4	O fumo sobe na vertical
1	aragem	0,5-1,5	O fumo é lentamente empurrado
2	fraco	1,6-3,3	As folhas sussuram
3	bonançoso	3,4-5,4	As folhas e os raminhos movem-se
4	moderado	5,5-7,9	Os ramos pequenos movem-se
5	fresco	8,0-10,7	As pequenas árvores oscilam
6	muito fresco	10,8-13,8	Os ramos grandes oscilam
7	forte	13,9-17,1	Todas as árvores se movem
8	muito forte	17,2-20,7	Os raminhos partem-se
9	tempestuoso	20,8-24,4	Os ramos partem-se
10	temporal	24,5-28,4	As árvores quebram-se e caem
11	temp. desfeito	28,5-33,5	Os danos são extensos
12	furacão	>33,5	Os danos são extremos

Fonte: SHAHIDIAN S, GUIMARÃES R, RODRIGUES C. (2012)

2.13 A IMPORTÂNCIA DOS ELEMENTOS CLIMÁTICOS PARA O MEIO AMBIENTE URBANO E NATURAL

Iniciaremos com um pensamento de Correa, 1996, em que a firma que o crescimento e desenvolvimento de um povo pode ser evidenciado pelas condições apresentadas por meio do principal elemento do meio natural, o clima.

A industrialização acelerada após a 2.ª Revolução Industrial, traz a urbanização pós-guerra e a grande expansão territorial, acelerou a necessidade e importância de estudos acerca do clima urbano. Estas alterações no balanço energético do ambiente climático desencadeiam uma série de alterações nos elementos climáticos. (AMORIM, 2000; MENDONÇA, 2004b).

Com objetivo de entender o clima urbano, Monteiro (1993) descreve a percepção científica do que é o clima urbano, “é o produto da alteração da vegetação natural por um ambiente construído”.

Este pensamento reflete o quanto a evolução industrial interfere nos elementos climáticos e conseqüentemente, estas variações irão alterar a vida humana. O desenvolvimento não planejado da área urbana, interfere nos elementos como a temperatura e umidade do ar, condições dos ventos, alteração do conforto térmico, determinam e alteram nossa qualidade

devida.

A alteração dos elementos climáticos, quer sejam por meio das modificações das características naturais ou devido o processo de Urbanização, promove subprodutos para a vida humana tais como: (MONTEIRO, 1976).

- 1- Ilhas de calor e ilhas secas;
- 2- Desconforto térmico e inversões térmicas;
- 3- Inundações e alagamentos;
- 4- Chuvas acidas e poluição do ar.

Segundo Mascaró (1991), a temperatura, Movimento do Ar, a radiação e a Umidade, definidos pelo autor como elementos dinâmicos do clima, em conjunto, afetam a perda de calor no organismo humano, pois os elementos atuam conjuntamente e se denomina pressão térmica.

2.13.1 Ilha de calor


O aumento da temperatura nas áreas urbanas, mais conhecidas como ilhas de calor, se dá em função do aumento da impermeabilidade do solo, pelo aumento da pavimentação das ruas e dos locais construídos, alterando o clima, por meio da alteração da superfície, da vegetação, prejudicando a drenagem, e infiltração da água no solo, alterando os níveis de umidade, degradando a vegetação e alterando o movimento dos ventos.

As alterações das superfícies ambientais naturais em decorrência da evolução urbana alteram as características térmicas, as taxas de evaporação e movimento do vento com novos padrões de circulação dos ventos, criando conseqüentemente as ilhas de calor, decorrente o aumento da temperatura de uma determinada área quando correlacionada a outras próximas. (LABAKI & SANTOS, 1996)

Amorim (2017) define as ilhas de calor, como grandes bolsas de ar quente encontrado nos centros urbanos, em decorrência da alteração antrópica da superfície do solo modificando sua condição natural de refletir e armazenar a energia solar, gerando calor.

Conforme podemos observar na (figura 07) as ilhas de calor podem ser consideradas como anomalias térmicas e calculadas em comparação simultânea com a diferença da temperatura em locais construídos e não construídos. (OKE, 1982)

Figura 2.7- Efeitos da Ilha de calor



Fonte: WORLD METEREOLOGICAL ORGANIZATION (WMO) Y URBAN LAND INSTITUTE

Segundo os estudos de Oke, as ilhas de calor urbana, pode ser classificada com referência à sua localização e podem ser apresentadas através de três tipos:

- **Superficial:** encontrada com sensoriamento remoto, com o cálculo de temperatura dos alvos (OKE et al., 2017);
- **Atmosférica inferior:** Segundo Oke (1978), *urban canopy layer*, nesta tipologia a análise do calor é feita na distância que compreende o limite médio dos telhados e o solo;
- **Atmosférica superior:** escrita como *urban boundary layer* por Oke (1978), a análise de calor será imediatamente a partir do limite máximo da *urban canopy layer*, até a atmosfera livre.

2.14 INUNDAÇÕES URBANAS

Com o crescimento e concentração da população e pequenos espaços, percebemos uma enorme procura por recursos naturais em potencial, água e solo, acarretando desequilíbrio e deteriorando a biodiversidades. Este novo meio que se desenvolve de forma dinâmica e descontrolada, tem por um lado o ambiente natural e o antrópico, que em pouco tempo pode colapsar. (TUCCI, 2008)

Segundo a ONU, (2014) o Brasil já se tornou um, país, urbano, pois sua

população encontra-se com mais de 85,7% nesta região, restando 14,93% para regiões rurais. Segundo o mesmo estudo, isto está relacionado ao grande crescimento das regiões metropolitanas e pode chegar a 91% em 2050.

Este aumento tem inúmeros prejuízos, quando percebemos nas alterações realizadas no solo com o processo de urbanização. Pois, corroborando com o estudo acima e a alta taxa de crescimento das zonas urbanas no Brasil, nos deparamos com enormes espaços urbanos, quando acometidos pelas precipitações, se apresentam impermeáveis em decorrência da pavimentação, com grande aumento no deslocamento e vazão das águas diminuindo em consequência o ritmo de infiltração e evapotranspiração, em contrário em uma zona rural, as precipitações infiltram no solo com bastante facilidade, são absorvidos pelas plantas e vegetais presentes e pelo maior tempo de deslocamento meio as depressões e vegetações rasteiras evaporam com maior facilidade. (MENEZES, 2012)

Tucci 2016, apresenta outros fatores negativos a urbanização descontrolada e os riscos das inundações definidos pelo autor como **EFEITOS DA URBANIZAÇÃO**:

- 1- Erosão – provocada pela velocidade do deslocamento da água em escoamento superficial;
- 2- Potabilidade e qualidade dos corpos d'água – O deslocamento da água superficial, promove um escoamento dos resíduos sólidos, industriais, residências e a lavagem das vias urbanas contaminada pelo transporte urbano.

Como consequência destes efeitos da urbanização o autor destaca uma grande degradação do meio ambiente citando:

- 1- Inundações;
- 2- Baixa qualidade da água;
- 3- Erosão com áreas degradadas; 4- Deposição de resíduos;
- 5- Assoreamento dos corpos d'água;
- 6- Proliferação de doenças.

2.15 ALTERAÇÕES CLIMÁTICAS E AS DOENÇAS

As alterações climáticas ao longo dos anos, traz inúmeras discussões sobre os efeitos destas mudanças em relação a saúde humana. (BRASIL, 2008).

É fato, que tais alterações no clima impactam de forma direta à saúde humana, estando relacionada ao comportamento biológico, eventos climáticos e/ou meteorológicos extremos: furacões, inundações dentre outros, contudo, falaremos dos indiretos, estes quando alteram o ambiente em que o indivíduo se encontra: ecossistemas, doenças infecciosas, doenças

não transmissíveis, desnutrição e doenças mentais. (CONFALONIERI, 2003)

Segundo Confalonieri (2008), independentemente dos níveis e escalas das mudanças climáticas, tais alterações causam morbimortalidade, por meio da proliferação de vetores e agente infecciosos, onde podemos citar: malária, dengue, cólera, leishmaniose, leptospirose, hepatite A, gastroenterite virótica, diarreias dentre outras, acometendo em grande parte as comunidades com maior vulnerabilidade socioambiental.

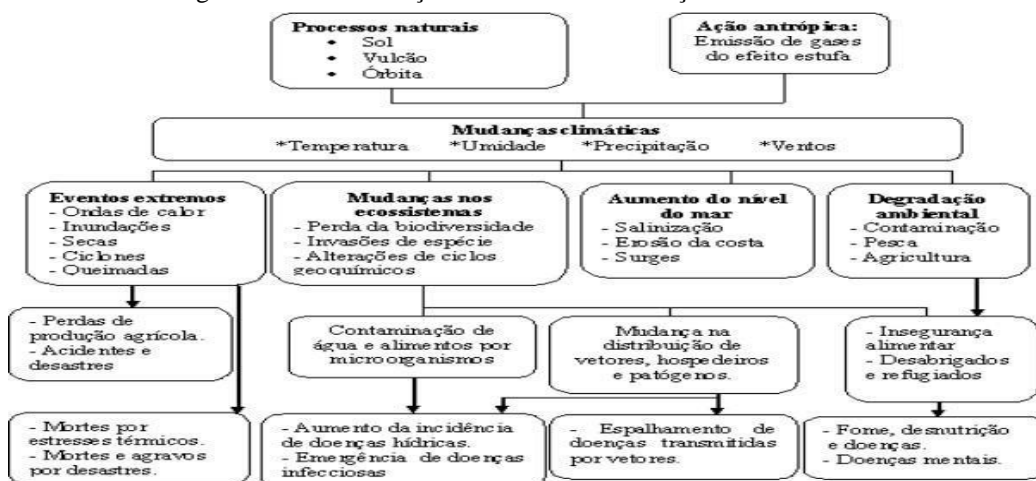
A alteração de temperatura, um dos principais elementos climáticos já citados, somado as alterações de umidade do ar interfere diretamente nos processos biológicos, proliferando pragas, insetos e vetores. Temperaturas acima de 29 °C são potencialmente favoráveis ao aumento na capacidade e proliferação do mosquito-da-dengue, segundo a Organização mundial da saúde (OMS), neste mesmo raciocínio segundo WHO (2014), o protozoário transmissor da malária não resiste a temperaturas mais baixas que 16 °C.

Os agentes indiretos que podem impactar a saúde humana, conforme já citado, podem ser provenientes de migrações, em virtude de enchentes e outras catástrofes, que obrigam populações a migrarem e trazem com elas, doenças para populações ainda não infectadas. (IDMC3, 2015)

Com base nas afirmações dos autores acima, podemos afirmar que uma alteração climática ou meteorológica extrema também trará alterações biológicas, pois a primeira interfere diretamente no desequilíbrio biológico e do meio ambiente trazendo doenças das mais diversas.

Os eventos climáticos extremos têm uma problemática maior, pois são de difícil detecção, tornando uma previsão ineficiente. O esquema da (figura 2.8) busca exemplificar como as mudanças climáticas interferem na população. (McMICHAEL et al., 2006).

Figura 2.8 - As mudanças climáticas e as interações com o ser humano



Fonte: ADAPTADO DE MCMICHAEL ET AL. (2006)

2.16 NATURAL

2.16.1 Previsão climática

Segundo Sousa e Sousa (2010), a previsão climática é um conjunto de elementos naturais e condições específicas daquela região, alteradas constantemente pelo comportamento atmosférico, tais como (precipitação, temperatura, vento, etc.) apresentados em um espaço de tempo com objetivos de obtermos a características da região.

A variabilidade climática e a principal justificativa para continuarmos os esforços de uma previsão climática mais precisa, pois os setores de saúde, produção de energias, agricultura e infraestruturas urbanas são diretamente afetados com as previsões imprecisas. Quando falamos de um país continental como o Brasil, possuindo inúmeras alterações climáticas e variáveis dos elementos climáticos, corrobora a importância dos estudos relacionados ao tema acerca de implementações de modelos para o monitoramento do clima.

O centro de previsão de Tempo e Clima do Instituto nacional de Pesquisas espaciais (CPTEC/INPE) dentre outros centros, utilizam para as suas previsões, modelos que visam descrever o comportamento das condições físico-química da atmosfera, em específico, o CPTEC/INPE utiliza um sistema de grandes computadores conhecido atualmente como Tupã.

O Tupã hoje instalado e operado no prédio CPTEC/INPE, possui 14 gabinetes com 31.296 processadores, sendo capaz de processar 258 Teraflop/s (trilhões de cálculos por segundo), estando entre os supercomputadores mais eficientes para previsão de tempo do mundo. (CPTEC, 2015)

Como podemos perceber, a previsão climática hoje ocorre com modelos globais de circulação dos parâmetros atmosféricos, que podem ser apreciados no site o IPCC (*Intergovernmental Panel on Climate Change*). Contudo, as redes neurais já provaram ser capazes de realizar previsões climáticas sendo um importante alternativa, como podemos corroborar no estudo de TANGANG et al. (1998), quando por meio da modelagem climática com uso de RNA previram o fenômeno *El Nino*.

2.17 INTELIGENCIA ARTIFICIAL

Inteligência Artificial (IA), desenvolvida para reproduzir a natureza humana. Talvez este seja um conceito filosófico acerca da IA, buscamos entender como funciona, pois, sua definição ainda não é muito coesa entre os pesquisadores. Segundo Michaelis (2018) a IA deve ser compreendida como uma condição das máquinas de aprender e resolver soluções.

A partir desta ideia inicial definimos que IA e a produção de super máquinas capas

de aprender, por meio de algoritmos eficientes complexos com propósito de proporcionar a ela tomada de decisões com base nas informações prestadas previamente.

A inteligência Artificial pode ser subdividida conforme segue:

1. Machine Learning
2. Deep Learning.

O primeiro se trata do poder da máquina em promover a si mesmo um contínuo aprendizado com base nas informações iniciais e as interações e o segundo é o processo de aprimorar seu conhecimento, agora de forma mais intensa e profunda e proporcionando a máquina realizar tarefas mais complexas, como por exemplo previsões a partir de treinamento o computador passa a aprender sozinho, ficando muito próximo do aprendizado humano.

Aplicação da Inteligência artificial está mais inerente em nosso cotidiano que talvez não percebemos, pois, desde as automações de indústrias aumentando os processos de produção, ou simplesmente facilitando nosso cotidiano e proporcionando vantagens inovadoras e com soluções eficazes de problemas simples e/ou complexos otimizando nosso tempo. (COELHO, 2019)

Na atualidade podemos citar alguns produtos disponíveis nos aplicativos de smartphones, tais como o reconhecimento de voz, além de redes sociais que se apropriam de suas visualizações para indicar post futuros considerando seus históricos de visualizações e um IA bem conhecida e utilizada oferecida pela Google é o sistema de tradução.

Podemos apresentar as redes neurais artificiais como um método Deep Learning, pois disponibiliza RNA com objetivo de aprender dentro da mesma rede conforme os neurônios humanos, reproduzindo o que aprendeu e desenvolvendo novos sistemas que continuam a aprender enquanto treinam apresentando cada vez mais soluções.

2.18 REDES NEURAIS ARTIFICIAIS

2.18.1 Redes neurais artificiais (RNAs)

Segundo Aleksander e Morton (1990), as Redes Neurais Artificiais ou (RNA) são capazes de apreender por meio das informações disponibilizadas, por meio da armazenagem do conhecimento experimental, tornando as informações recebidas em aprendizado para previsões futuras. Sendo possível que as RNAs aprendam por meio dos processos de exemplo e por meio dos dados já disponibilizados, evoluindo seu aprendizado.

Este método estatístico segundo HAYKIN (1999), é capaz de produzir excelentes resultados, pois seu formato matemático, propicia reduzir os problemas com alto grau de não

linearidade e por ser frequentemente utilizado em problemas, que envolvem as ciências atmosféricas.

Figura 2.9 - tipos de Redes Neurais artificiais

Tipo de neurônio	Principais Características	Desvantagens	Vantagens
Perceptron	Usa variáveis binárias de entrada	Não possui camada oculta	Sistema de base para demais tipos de neurônios
	Introduz pesos nas variáveis de entrada		
	Produz uma única saída binária	Aprendizado de recursos pouco complexos	Utilização para dados separados linearmente
Perceptron Multicamadas	Possui camadas ocultas empilhadas	Grande consumo de memória para aprendizado	Camadas ocultas com pesos distintos permite o aprendizado de recursos mais complexos
		Função de ativação Step (linear e não suave)	
Sigmóide	Utiliza backpropagation	Redes de neurônios mais complexos	Ajuste repetidos dos pesos minimiza a diferença entre a saída real e a saída desejada
	Função de ativação Sigmóide		Função de ativação estável e suave Permite classificação de limites ou padrões de decisões não lineares

Fonte: ADAPTADO ABU-MOSTAFA (2012)

2.18.2 Neurônio artificial

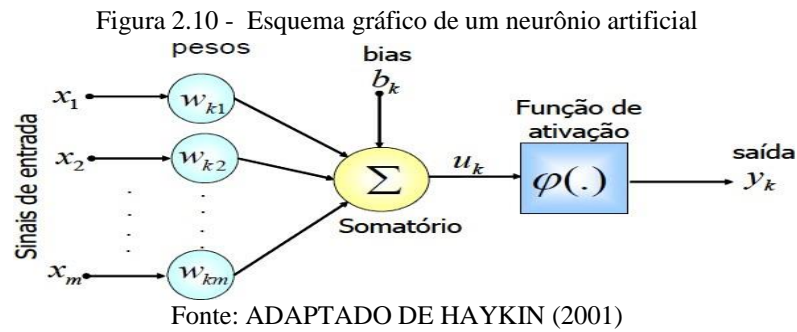
As RNAs são técnicas computacionais que apresentam um modelo matemático que utiliza na estrutura neural de organismos inteligentes. Esses organismos inteligentes são treinados com o objetivo de adquirirem conhecimento. E esse conhecimento é essencial na determinação do raciocínio e na estruturação da (RNA). No contexto computacional, o neurônio é uma componente que calcula a soma ponderada de vários *inputs*, aplica uma função e passa o resultado adiante.

Para que possamos compreender o funcionamento dos neurônios na (RNA), imaginemos que temos “*n*” sinais de entrada X_1, X_2, \dots, X_n e estes possuem seus respectivos pesos w_1, w_2, \dots, w_n e limitador t ; com sinais assumindo valores booleanos (0 ou 1) e pesos com valores reais, e modelo, o nível de atividade (a) é dado por:

$$a = w_1X_1 + w_2X_2 + \dots + w_pX_p$$

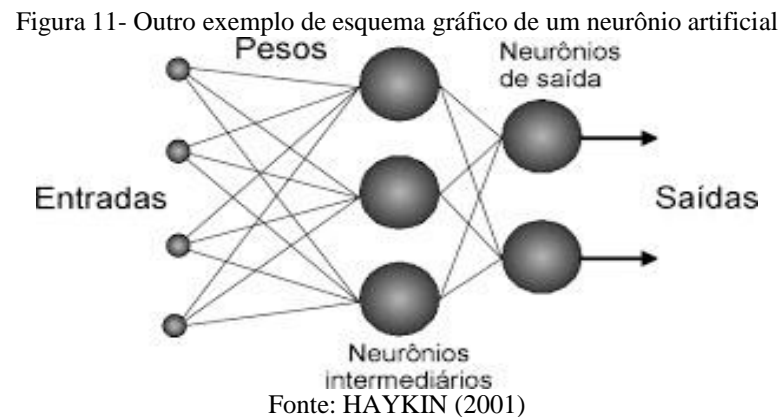
(Eq. 2.1)

Onde a saída y é dada : $y = 1$, se $a \geq t$ ou $y = 0$, se $a < t$. Segundo Haykin (2001) A arquitetura de uma rede neural determina o tipo de problema e a sua utilização eu começa a ser definida a partir do número de camadas que pode ser: única ou múltiplas camadas, além de variáveis como tipo de conexão entre os nós (feedforward ou feedback), o número de nós em cada camada, e ou, sua topologia. A (figura 2.9) demostramos um neurônio artificial do denominado de perceptron.



As redes neurais possuem regras específicas para o treinamento dos neurônios, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados durante o treinamento, mostrando assim que cada RA aprende com os exemplos pré-determinados. Uma outra característica importante é a arquitetura da RA, organizada em camadas, as quais estão conectadas às unidades da camada posterior, como mostra a Figura 7.

Os grupos e/ou camadas são classificadas em camada de entrada, onde os padrões são apresentados à rede; camada intermediárias ou escondidas, são aquelas em que é feita a maior parte do processamento, onde este processamento é realizado através das conexões ponderadas, podendo ser consideradas como extratoras de características; camada de saída, onde o resultado final é concluído e apresentado. A RA é especificada por sua topologia, pelas características dos nós e pelas regras de treinamento.



2.18.3 Modelagem com redes neurais artificiais

Ao longo dos estudos, percebemos que os pesquisadores vêm utilizando a RNA para uma grande variedade de estudos e mostrando-se eficiente quando se busca aproximação para padrões de reconhecimentos, agrupamento e predição. (RUMELHART; HINTON; WILLIAMS, 1986).

Por ser um modelo auto adaptativo, as RNAs ao contrário dos modelos tradicionais, por

meio dos exemplos e das relações funcionais entre os dados, são possível que as redes se aprimorem, sendo adequadas para problemas que possuem dados substanciais, mesmo que as soluções sejam de grande complexidade como as previsões. (ZHANG et al., 1998).

Como as RNAs inferem corretamente as partes ocultas de uma determinada população, mesmo quando os dados não estão claro ou exatos, isto só é possível, pois as RNA aprendem com os dados pretéritos disponíveis, se tornado assim com o exemplo do comportamento do passado possível prever o comportamento do futuro. (ZHANG et al., 1998)

Segundo Singh *et al.* (2012), a RNA se mostrou como excelente ferramenta para a previsão da qualidade do ar, durante seu estudo, Singh desenvolveu muitos modelos, dentre eles aproximação linear e não linear e redes neurais, onde dentre os resultados os modelos lineares (mínimos quadrados parciais) foi o de menor desempenho.

CAPÍTULO 3

3. MATERIAL E MÉTODOS

3.1 MATERIAIS

Para a construção do modelo de previsão de chuva a cada hora usando RNA, foi usado um conjunto de variáveis atmosféricas medidas em superfície através das estações meteorológicas automáticas do Instituto Nacional de Meteorologia (INMET), localizada na cidade de Manaus/AM.

A escolha das variáveis meteorológicas medidas em superfície usadas para compor a base de treinamento da RNA, foi devido à importância dessas variáveis no controle e monitoramento ambiental. Os dados foram coletados diretamente na plataforma *Web* do INMET, onde estes passaram por um rígido controle de qualidade das informações, sendo retirados os valores discrepantes, ausência de informações e outros. Basicamente, os dados usados para treinar a RNA foram as variáveis de Temperatura instantânea ($^{\circ}\text{C}$), Temperatura máxima ($^{\circ}\text{C}$), Temperatura mínima ($^{\circ}\text{C}$), Umidade Relativa (%), Temperatura de Ponto de Orvalho ($^{\circ}\text{C}$) e Precipitação (mm).

3.2 ANÁLISE DESCRITIVA DAS VARIÁVEIS NUMÉRICAS DA RNA

Antes de apresentar a RNA utilizada, é importante determinar os principais requisitos necessários para configuração dela, além dos ajustes necessários. Para isso, serão simulados diversos parâmetros de configuração da RNA para que ela possa desenvolver um sistema inteligente de previsão da precipitação para a hora posterior a que ela foi rodada, ou seja, a previsão proposta será executada praticamente em tempo real. O processo de definição dos parâmetros da RNA é bastante complexo pois foi inserido uma quantidade de parâmetros e variáveis que apesar de representarem processos fisicamente diferentes participam do processo. A referência para definir os parâmetros da rede foi baseada nos dados históricos de informações.

O Software definido para o desenvolvimento deste Sistema Inteligente foi o MATLABR2016a® (*Matrix Laboratory*). Através do software é possível implementar vários tipos de RNA's através da sua interface gráfica (*Toolbox*) *Neural Network Toolbox (NNTool)*. Para inicializar o *software* e compilar o modelo de RNA usou-se um *hardware* padrão, ou seja, um microcomputador portátil (*Notebook*) com processador Intel Core I5 7ª Geração, Memória Ram 8 Gigabyte DDR4, Placa de Vídeo NVIDIA GeForce 940 MX 2 Gigabyte Dedicated VRAM e 1 Terabyte de Hard Disk Drive (HDD).

3.3 METODOLOGIA APLICADA COM RNA

Nesta seção serão apresentados os procedimentos e direcionamentos aplicados na concepção da RNA, para isso, o método será apresentado em três etapas, denominadas de montagem, treinamento e previsão. A fase de montagem é a mais importante, pois nela é definido o tipo de rede, arquitetura (camadas e neurônios ocultos), funções de ativação, tipo de propagação, algoritmo de aprendizado, e outros parâmetros.

Posteriormente, inicia-se a segunda etapa fase do treinamento da rede, é nesta fase que ocorre o treinamento/aprendizado da RNA, onde ela captura todas as características relevantes do conjunto de dados selecionados, como por exemplo, os picos, aleatoriedade e sazonalidade das informações. É nesta etapa que os dados são divididos, de forma que 70% das informações disponibilizadas para que o modelo realize o aprendizado da rede, e 15% são resguardados para realizar a validação e entre 15% no teste da rede. Um procedimento igualmente importante nesta etapa é a forma como os pesos serão modificados, que é definida em função do algoritmo de treinamento específico para cada modelo de RNA. Geralmente os pesos relativos a cada neurônio são alterados de modo a tornar a rede capaz de representar a relação entre os dados de entrada e de saída. Neste processo a rede definiu um neurônio como principal, chamado de neurônio ativo, o peso deste neurônio se mantém constante e os demais que se adaptam ao mesmo. Essa fase de aprendizado deve ser a mais rígida e eficiente, pois é ela que determina o bom resultado do modelo, além de evitar erros espúrios. O conhecimento da RNA está armazenado nas “sinapses”, ou seja, nos pesos atribuídos às conexões entre os neurônios.

Por último apresenta-se a terceira etapa. Esta etapa está relacionada aos testes da RNA, onde esta é para executar as previsões da precipitação e as correções dos valores encontrados pela rede. Ainda nesta etapa são realizadas as comparações dos valores de precipitação observados e a chuva prevista através de medidas de erros calculados pela rede, geralmente se utiliza a raiz do erro médio quadrático (MSE). Caso os valores sejam insatisfatórios, o treinamento é reiniciado usando novas informações, modificando a quantidade de iterações e desta forma, a própria rede altera suas informações sinápticas, pois assim o desempenho da RNA pode ser melhorado. Vale a pena destacar que a própria RNA pode ser configurada para executar o processo automaticamente.

Todavia, a RNA usada para previsão de series temporais implica em nós de entrada conectados a uma série de valores observados no passado para assim, identificar os processos no tempo futuro. Adicionalmente, a função de ativação tem o papel de determinar a relação

entre as entradas e saídas de um nó e a rede. Ao mesmo tempo, são os nós na camada oculta que fazem com às RNAs detectem as características, captar o padrão das informações de entrada, e ainda, executar complicado mapeamento não-linear entre as entradas e saídas.

3.3.1 Avaliação das estimativas geradas pela RNA's

Uma forma de verificar a eficácia da RNA e a qualidade da informação que é gerada por ela é através de análises estatísticas. O próprio modelo na sua concepção analisa estatisticamente a variável geradas e aquelas usadas para obter a rede. Inicialmente, são analisados através do Coeficiente de Correlação de *Person* (ver Equação 1) entre o conjunto de dados de temperatura, umidade, e os demais usados com a precipitação estimada pela RNA (Eq. 1) (GALARÇA et al., 2010).

O coeficiente de correlação de Person tem por objetivo através de um único coeficiente medir o grau da relação (linear) entre duas variáveis, que admite valores que vão de -1 a 1, o 0 indica que não há associação entre as duas variáveis. Um valor maior que 0 indica uma associação positiva. Isto é, à medida que o valor de uma variável aumenta, o mesmo acontece com o valor da outra variável. Um valor menor que 0 indica uma associação negativa. Isto é, à medida que o valor de uma variável aumenta, o valor da outra diminui. E para a realização dos testes é necessário que o intervalo temporal entre as variáveis seja a mesma; possuir uma distribuição homogênea; estar associadas linearmente e não possui falha de dados ou valores atípicos.

$$CP = \frac{\sum_{i=1}^n (x_i - \bar{x}) * (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} * \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

(Eq. 3.1)

Onde: x_1, x_2, \dots, x_n são as variáveis observadas, enquanto y_1, y_2, \dots, y_n , são as variáveis geradas pela RNA, e, \bar{x} e \bar{y} são as respectivas médias aritméticas. Adicionalmente, a estimativas realizadas pela RNA passam por outros testes estatísticos como o Erro Quadrático Médio (MSE - *Mean Square Error*) e o NRMSE (PAIVA et al., 2010) (WANG et al., 2021). O MSE é usualmente usado para medir o grau de acuraria das saídas dos modelos matemáticos, estabelecendo um maior peso aos maiores erros. Cada erro é calculado individualmente e elevado ao quadrado, sendo calculada posterior a média dos erros, como mostra a Equação 2.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y})^2}$$

(Eq. 3.2)

Onde, n são o número de observações; Y_i , são as variáveis meteorológicas observadas; e \hat{Y} , a precipitação estimada pela RNA. O RMSE, é uma estimativa do desvio padrão da componente aleatória nos dados, avalia a diferença quadrática média entre os valores observados e os valores estimados. A similaridade das variáveis foi testada através do O Erro Médio Absoluto (MAE - Mean Absolute Error) é definido pela Eq. (3) (FRÍAS-PAREDES et al., 2017) (MISHRA et al., 2020).

$$MAE = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n}$$

(Eq. 3.3)

Sendo, n são o número de observações; Y_i , são as variáveis meteorológicas observadas; e Y , a precipitação estimada pela RNA. Posteriormente, a Raiz Quadrada do Erro Quadrático Médio Normalizado (NRMSE – *Normalized Root Mean Square Error*) expressa pela Eq. (4) (ISHAQUE et al., 2020 (HAGHNAZARI et al., 2020)).

$$NRMSE = \frac{RMSE}{M} \times 100$$

(Eq. 3.4)

Onde, M é a média das observações.

Além dos erros apresentados acima, foi calculado igualmente o MAPE (Erro Percentual Médio Absoluto (MAPE - *Mean Absolute Percentage Error*), ver Eq. (5) (MISHRA et al., 2020). O MAPE é uma medida para avaliar os precisão desvios da previsão efetuada pela RNA, e dada em unidades percentuais.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right|$$

(Eq. 3.5)

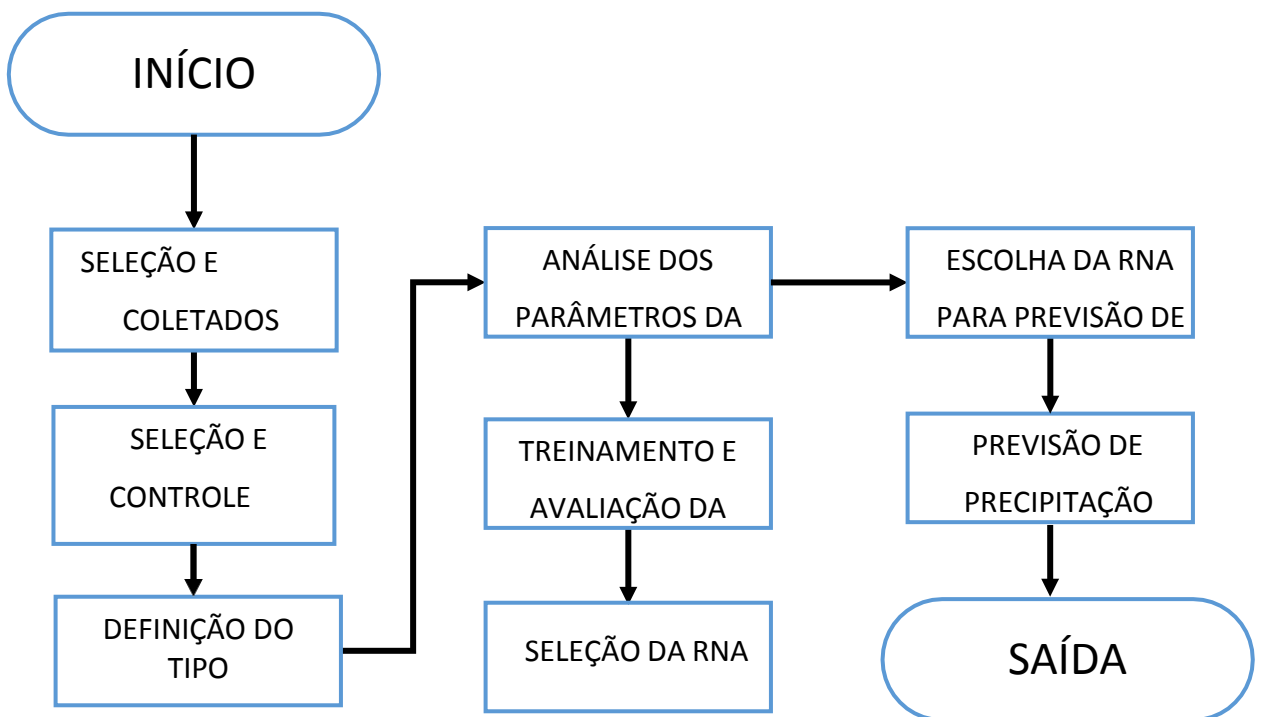
Onde: n são o número de observações; Y_i , são as variáveis meteorológicas observadas; e \hat{Y} , a precipitação estimada pela RNA. E finalmente, será realizada, para mostra graficamente a similaridade entre as variáveis. A análise de dispersão dos erros (resíduos) percentuais em relação as variáveis observadas e estimadas (Eq. 6).

$$ERRO(\%) = \frac{(Y_i - \hat{Y}_i)}{Y_i} \times 100$$

(Eq. 3.6)

Sendo as variáveis usadas na equação: n são o número de observações; Y_i , são as variáveis meteorológicas observadas; e \hat{Y} , a precipitação estimada pela RNA. A Figura 11, apresentada abaixo, mostra um resumo dos procedimentos realizados na metodologia.

FIGURA 3.12: Fluxograma de Resumo dos Procedimento Metodológicos



CAPÍTULO 4

4. RESULTADOS E DISCUSSÕES

4.1 TREINAMENTO DA REDE

Nesta seção será apresentado o processo de treinamento e escolha da rede neural para a previsão a curtíssimo prazo da precipitação. Para o treinamento foram testadas as combinações para doze tipos de redes Levenberg-Marquardt (trainlm), Regularização Bayesiana (trainbr), BFGS Quasi-Newton (trainbfg), Retropropagação resiliente (trainrp), Gradiente de Conjugado Escalado (trainscg), Gradiente conjugado com reinicialização de Powell /Beale (traincgb), Fletcher-Powell Conjugado Gradiente (traincgf), Polak-Ribire (traincgp), Secante de Um Passo Conjugado Gradiente (trainoss), Gradiente descendente de taxa de aprendizagem variável (traingdx), Gradient Descent with Momentum (traingdm), Gradiente descendente (traingd'). As redes foram combinadas com as três funções de ativação, 'purelin', 'tansig' e 'logsig', totalizando 36 combinações.


Como variáveis de entrada para o treinamento, foram usados um conjunto de dados atmosféricos convencionais, tais como: Temperatura instantânea, é a temperatura média do ar; Temperatura máxima média do ar em 1 hora; Temperatura mínima média do ar em 1 hora; Umidade relativa (%) média durante as 1 hora; a temperatura de Ponto de Orvalho média durante o período de 1 hora; e Precipitação média medida em milímetros a cada hora, medidos durante o período de 01 de maio a 31 de outubro de 2021 na estação meteorológicas automatizado Instituto Nacional de Meteorologia (INMET).

A RNA foi configurada através dos parâmetros gerais para a simulação apresentados abaixo:

- ✓ Função para da Rede do tipo feedforwardnet ([7,5]), com duas camadas ocultas a primeira com 7 neurônios e a segunda com 5 neurônios;
- ✓ net.trainParam.epochs = 1000, número máximo de evoluções;
- ✓ net.trainParam.lr = 0.001, taxa de aprendizagem;
- ✓ net.trainParam.time = inf, tempo máximo de treinamento.

Determinados os parâmetros estruturais da RNA usados durante a simulação da rede. Como rede básica optou-se pela rede do tipo *Feedforward*, como mostra a Figura (4.12), sendo esta a que demonstrou a estrutura que melhor se adequou ao conjunto de dados atmosféricos.

figura 4.13 - Fluxograma de Resumo dos Procedimento Metodológicos



A estrutura geral da rede *Feedforward* a arquitetura da rede mostra que esta será treinada a partir dos cinco valores de entrada, que foram apresentados anteriormente, duas camadas ocultas (a primeira com 7 neurônios e segunda com 5 neurônios) e finalmente uma camada de saída e uma saída com apenas um valor 1 (um) real simulado, que será a precipitação.

Um conjunto das saídas estimadas pela RNA's não serão apresentados por este documento a combinação das funções de Treinamento (FTrain) com as funções de Transferência (FTrans) após as simulações geram 36 combinações entre os parâmetros de treinamento e transferência diferentes das RNA's, mostrando uma matriz de saída (*output*) de 4302 x 36 combinações para o treinamento.

Tabela 4.8 - Melhor resultado de combinações entre as funções de treinamento e transferência

ID	Função de Treinamento	Função de Transferência	Saída da Rede (Output)									
			0,049	0,017	0,184	0,450	0,218	0,063	0,480	1,673	0,532	0,354
1	trainlm	purelin	0,049	0,017	0,184	0,450	0,218	0,063	0,480	1,673	0,532	0,354
2	trainlm	transig	-0,01	-0,006	-0,017	-0,03	-0,01	-0,02	-0,02	12,617	0,2	0,07
3	trainlm	logsig	0,009	0,015	-0,030	-0,10	-0,13	-0,12	-0,14	8,0395	-0,13	-0,296
4	trainbr	purelin	0,006	0,080	0,203	0,481	0,236	0,095	0,514	1,910	0,602	0,4020
5	trainbr	transig	0,015	0,015	0,015	0,015	0,016	0,017	0,015	7,2050	0,114	0,0776
6	trainbr	logsig	0,008	0,009	0,009	0,01	0,015	0,014	0,012	7,1603	0,167	0,118
7	trainbfg	purelin	-0,045	0,032	0,138	0,391	0,165	0,034	0,440	1,7646	0,527	0,344
8	trainbfg	transig	0,063	0,063	0,063	0,063	0,063	0,063	0,063	4,7942	0,063	0,063
9	trainbfg	logsig	0,208	0,208	0,208	0,208	0,208	0,208	0,208	0,209	0,208	0,208
10	trainrp	purelin	-0,269	0,123	0,106	0,335	0,158	0,077	0,441	2,134	0,669	0,4853
11	trainrp	transig	0,294	0,294	0,294	0,294	0,294	0,294	0,294	0,2941	0,294	0,2941
12	trainrp	logsig	0,232	0,232	0,232	0,232	0,232	0,232	0,232	0,232	0,232	0,232
13	trainscg	purelin	367,1	62,29	231,6	274,5	228,0	169,8	144,5	-249,92	6,699	0,302
14	trainscg	transig	0,204	0,204	0,204	0,204	0,204	0,204	0,204	0,204	0,204	0,204
15	trainscg	logsig	0,154	0,154	0,154	0,154	0,154	0,154	0,154	0,154	0,154	0,154
16	traincgb	purelin	-10,78	5,072	-1,016	-4,59	0,989	4,020	-1,28	6,3985	6,487	8,652
17	traincgb	transig	0,260	0,260	0,260	0,260	0,260	0,260	0,260	0,260	0,260	0,260
18	traincgb	logsig	0,114	0,114	0,114	0,114	0,114	0,114	0,114	0,114	0,114	0,114
19	trainscf	purelin	-137,5	550,8	315,8	282,4	261,7	383,1	-24,3	513,70	55,65	-27,26
20	trainscf	transig	0,198	0,198	0,198	0,198	0,198	0,198	0,198	0,198	0,198	0,198
21	trainscf	logsig	0,105	0,105	0,105	0,105	0,105	0,105	0,105	0,105	0,105	0,105
22	traincgp	purelin	166,8	339,7	353,4	379,3	456,3	471,0	396,9	591,3	560,2	568,6
23	traincgp	transig	0,240	0,240	0,240	0,240	0,240	0,240	0,240	0,240	0,240	0,240
24	traincgp	logsig	0,074	0,074	0,074	0,074	0,074	0,074	0,074	0,074	0,074	0,074
25	trainoss	purelin	0,042	-0,096	0,185	0,491	0,262	0,047	0,549	1,769	0,619	0,446

26	trainoss	transig	0.168	0.168	0.168	0.168	0.168	0.168	0.168	0.168	0.168	0.168
27	trainoss	logsig	0.154	0.154	0.154	0.154	0.154	0.154	0.154	0.154	0.154	0.154
28	traingdx	purelin	938.9	293.0	740.9	2453.6	1095.8	678.5	3072.5	9460.1	3546.0	2422.3
29	traingdx	transig	-0.688	-0.688	-0.688	-0.69	-0.69	-0.69	-0.69	-0.69	-0.69	-0.69
30	traingdx	logsig	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271
31	traingdm	purelin	75848.8	73102.3	72566.6	71749.3	71376.9	71636.9	71882.4	66166.7	69816.6	70156.6
32	traingdm	transig	-55.80	-55.80	-55.80	-55.8	-55.8	-55.8	-55.8	-55.80	-55.80	-55.80
33	traingdm	logsig	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271
34	traingd	purelin	75848.80	73102.34	72566.61	71749.3	71376.93	71636.86	71882.40	66166.67	69816.56	70156.61
35	traingd	transig	-55.80	-55.80	-55.80	-55.8	-55.8	-55.8	-55.8	-55.80	-55.80	-55.80
36	traingd	logsig	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271	0.271

A (tabela 4.8) apresenta que o melhor resultado para as combinações entre as funções de treinamento e as funções de transferência usadas foram a trainlm (Levenberg-Marquardt) e transig, respectivamente, mostrando que os valores do erro estão próximos do valor médio para o conjunto de 05 meses de observações horária. Isso mostra que a rede *Feedforward* usada para a previsão da precipitação a partir das estações meteorológicas poderão ser usadas para estimar a chuva pontualmente em uma localidade.

Apesar dos dados apresentados mostrarem saídas coerentes e com uma excelente margem de tolerância, vale a pena frisar que a tabela apresenta somente os 10 primeiros valores. Nota-se que em muitos casos a variável mostra valores bem diferentes para uma mesma simulação, o que é devido à ausência de observações em algumas horas, mas o que não desqualifica os bons resultados da RNA, o que pode ser constatado através do RMSE e MSE, apresentados nas figura 4.14 e 4.15.

Tabela 4.9 - Valores calculados do MSE de cada combinação das funções de Treinamento (FTrain) com as funções de Transferência (FTrans) após as simulações.

Função de Transferência	purelin	tansig	logsig
trainlm	2.91	0.50	0.75
trainbr	2.91	105.00	0.92
trainbfg	2.91	1.72	2.78
trainrp	2.95	12.64	3.41
trainscg	74076.92	3.41	3.41
traincgb	162.33	3.41	3.42
traincgf	539869.27	3.41	3.42
traincgp	119065.17	3.41	3.42
trainoss	2.97	3.41	3.41
traingdx	26325722.85	78.75	3.41
traingdm	5759799655.07	3170.15	3.41
traingd	5759799655.08	3170.15	3.41

Um dos objetivos do processo de treinamento supervisionado de uma RNA é ajustar os pesos e os *thresholds* dos dados atmosféricos e assim, encontrar o modelo de RNA mais e a função de transferência que mais se ajusta ao conjunto de dados usados, sendo a base para a escolha o menor valor possível para os erros (MSE). A Figura apresenta graficamente os valores de MSE, onde no eixo horizontal relacionamos o tipo de modelo e a cor azul, laranja e cinza, as equações de transferência *Purelin*, *Transing* e *Logsig*, respectivamente. Nota-se que para todas as combinações realizadas, a equação de transferência *Transing* apresenta o menor valor de MSE durante o treinamento, e ao mesmo tempo, *Transing* e a equação *tranlm* foi a melhor avaliação, em torno de 0,50. Apesar disso, outros testes deverão, ser realizados para que essa escolha possa ser oficializada.

Figura 4.14 – Análise do MSE para a escolha da melhor função de Transferência





Tabela 4.10- Valores calculados do ERRORMSE de cada combinação das funções de Treinamento (FTrain) com as funções de Transferência (Ftrans) após as simulações.

Função de Transferência	purelin	tansig	logsig
trainlm	1.71	0.71	0.87
trainbr	1.70	10.25	0.96
trainbfg	1.71	1.31	1.67
trainrp	1.72	3.56	1.85
trainscg	272.17	1.85	1.85
traingcb	12.74	1.85	1.85
traingcf	734.76	1.85	1.85
traingcp	345.06	1.88	1.85
traingdx	5130.86	8.87	1.85
traingdm	75893.34	56.30	1.85
traingd	75893.34	56.30	1.85

O Root Mean Square Error (ERRORMSE) assim como as demais análises estatísticas apresentadas, é usado igualmente para mostrar o desempenho dos tipos de RNAs testadas e as

funções de transferências disponível. A configuração da Figura 4.14 é semelhante a apresentada anteriormente (ver Figura 4.13). Nota-se que o bom desempenho e escolha dos parâmetros da RNA de previsão é igualmente obtido através dos menores valores do *Root Mean Square Error* gerado pelas combinações. Assim, verifica-se que dentre as combinações realizadas durante o processo de treinamento da RNA, a que apresentou os menores valores de erro, foi a equação Trainlm e a equação de transferência – tansig, chegando a 0,71.

Figura 4.15 – Análise do ERRORMSE para a escolha da melhor função de Transferência



Na Figura 4.14, é apresentada *Performance* da RNA, onde a curva azul mostra o ajuste do treinamento da rede, enquanto a validação é representada pela curva verde, e o teste a curva vermelha, nota-se que a melhor performance das curvas e do teste foi possível através de 26 evoluções (*Epochs*). Os *epochs* representado pela circunferência significa os critérios de parada do treinamento da RNA, momento este que são encontrados os melhores resultados (*best*).


Após a fase de treinamento a RNA está pronta para ser testada, e assim será possível avaliar a capacidade da rede de inferir uma classe coerente ao treinamento realizado. Ao mesmo tempo existe uma grande limitação nos modelos baseados no aprendizado de neurônios, que segundo Haykin (1999) os modelos possuem uma única medida de desempenho. Mas é possível medir esse desempenho através da regressão estatística.

Apesar dos excelentes resultados obtidos durante o treinamento, apresentado anteriormente, observa-se que após algumas tentativas de treinar a rede, a validação apresentou

valores acima de 1, ou seja, 1,999 um resultado esperado devido ao tamanho do conjunto de valores de entrada para o treinamento e teste da rede.

As simulações e as análises estatísticas da rede, apresentam um grau significativo de confiabilidade na especificação do modelo de Rede Neural Artificial para a previsão da precipitação a curtíssimo prazo, obsecrando-se a descida ou ajuste da curva de deslizamento, a cada época realizada percebemos que o tempo de convergência aumenta, de acordo com o gráfico o algoritmo levou 26 épocas para encontrar o melhor estado de convergência, demonstrando que este é o estado ótimo de convergência do algoritmo para atingir uma constante na reta de aprendizado. Podendo ser utilizada como uma ferramenta para o auxílio da tomada de decisão.

Figura 4.16 - Melhor Valor de Validação da Performance



Podemos observa na figura 4.12 mostra as curvas do Erro Quadrado Médio (MSE) entre o conjunto de dados de entrada e saída da rede neural. A curva em vermelho ilustra o conjunto de dados de teste, a curva em azul, os dados de treinamento e a curva em verde, o conjunto de dados de validação. A linha tracejada é o melhor valor encontrado. Os dados convergem rapidamente (em 26 épocas).

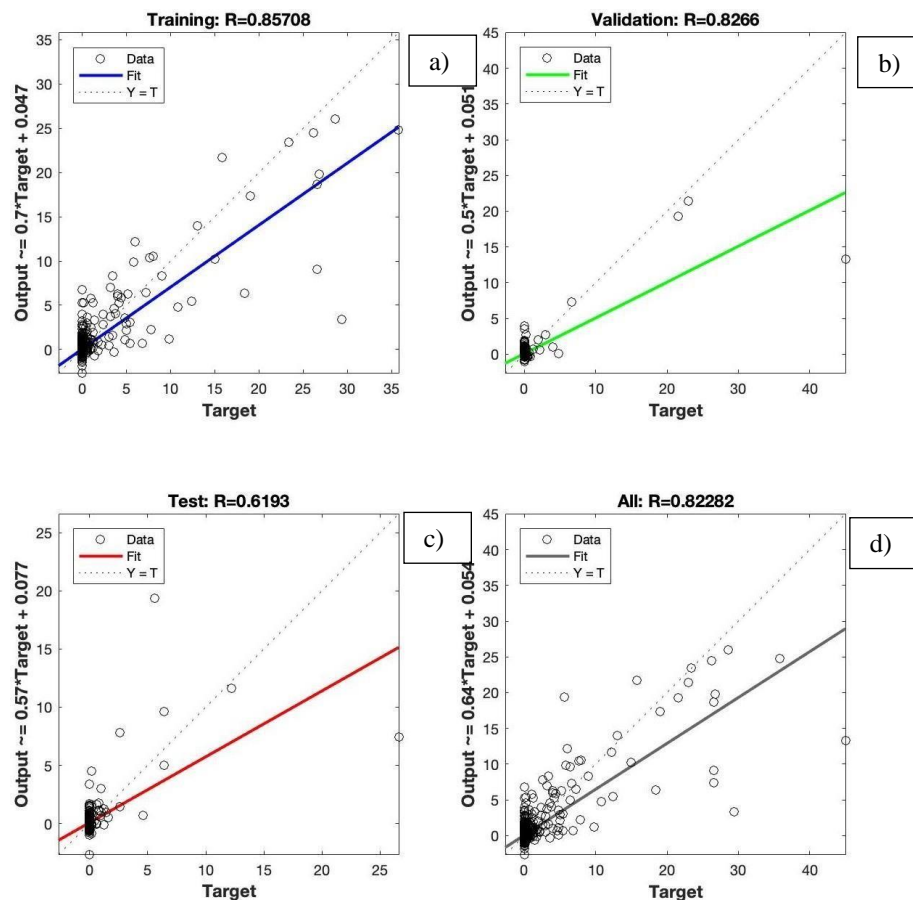
Para termo uma rede com alto desempenho, só será possível quando os dados responderem corretamente ao período de treinamento. Durante o procedimento da validação cruzada, método este utilizado para verificar se a rede foi treinada de forma adequada e que não ouve um (overtraining). Desta forma será dividido em três posições:

- Teste – Determina o desempenho final da rede;
- Treinamento - Determina a performance da rede;

- Validação – A rede é considerada treinada quando se encontra o mínimo erro de validação sem sobre-treinamento. (FRANCO; JEREZ; ALIZONDO, 2009)

Após o treinamento e escolha dos parâmetros da RNA, foram realizadas previsões e validações, mostrando assim seu desempenho para prever precipitação a partir de dados de superfície.

Figura 4.17 - a) Teste de regressão entre os resultados obtidos versus esperados da RNA: a) treinamento; b) validação; c) teste da melhor rede; d) Aspectos em conjunto da rede.

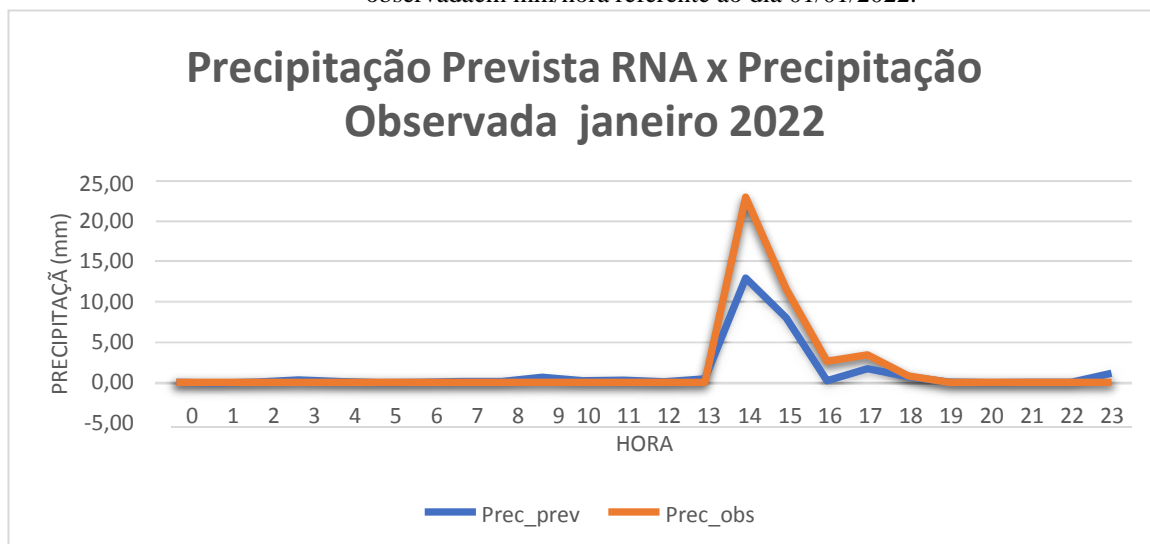


A Figura 4.16 apresenta a análise entre os resultados obtidos e os esperados durante a fase de treinamento, que apresentou cerca de 86% de acertos (Figura 16a). Através das informações inseridas na entrada da RNA, os 15% utilizados para validar a rede testada mostraram que ela apresentou um alto índice de correlação, o que mostra que dos dados previstos pela RNA, cerca de 82% são fortemente correlacionados (Figura 16b).

Para demonstrar o melhor teste de rede, (Figura 16c) observa-se com resultado mais próximo de 1 quando é considerado o melhor teste, corroborando a eficiência da rede por (Figura 16c), quando analisamos juntos todos os aspectos da rede já apresentados em (figuras 16a, 16b e 16c) com valor de correlação próximo de 1 com índice de correlação de 82,2%.


Em um segundo momento, foi testado o desempenho do modelo para prever a precipitação diária na cidade de Manaus utilizando dados em tempo real durante os meses de janeiro a maio de 2022.

Figura 4.18 - Previsão de precipitação prevista por meio da Rede Neural em comparação a precipitação observada em mm/hora referente ao dia 01/01/2022.



Na Figura 4.17 a previsão é representada pela linha azul, enquanto a linha laranja mostra a precipitação observada em uma estação meteorológica automática. Aplicando o modelo, durante o mês de janeiro verificou-se que o modelo apresentou excelente desempenho na previsão do comportamento da chuva, apesar de ter um pequeno registro no período da manhã (09:00), enquanto a chuva observada foi zero, mas por outro lado, o lado superestimou a chuva da tarde (14:00-15:00). Vale ressaltar que, embora a região amazônica seja caracterizada por alta pluviosidade, é chamada de verão amazônico.

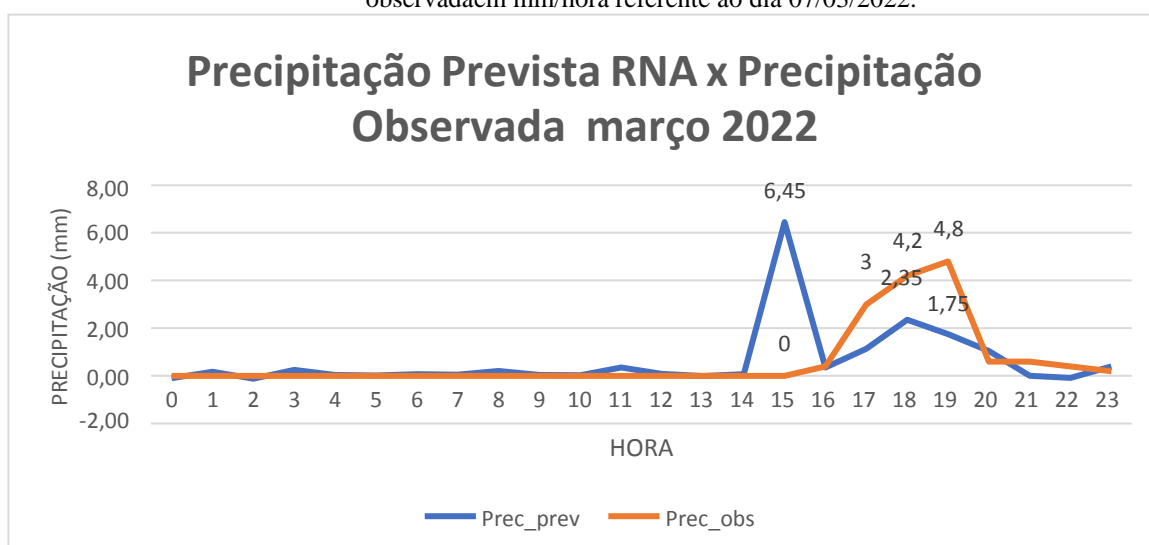
Figura 4.19 - Previsão de precipitação prevista por meio da Rede Neural em comparação a precipitação observada em mm/hora referente ao dia 08/02/2022.



A Figura 4.18 mostra que o modelo de previsão de chuva utilizando RNA foi capaz de reproduzir o comportamento da curva de precipitação observada (linha laranja) no mês de fevereiro. Nota-se que essa semelhança também ocorre com os totais de chuva a cada hora, principalmente às 20:00, quando ocorreu um pico de precipitação. Por outro lado, nota-se que nos dois meses testados o modelo apresentou um pequeno pico no final da noite, fato que não aparece nos dados observados.


Ao analisar os meses de transição do período chuvoso para o seco, o modelo superestimou em quase todos os momentos, além da curva do ciclo diurno praticamente não apresentar similaridade com a curva de observação. Figura 4.19, maior margem de erro com a previsão (PREV) x observada (OBS) onde a rede neural apresentou uma pequena instabilidade na previsão de 15:00 (UTC) com valor PREV. 6,45 mm, e era OBS. 0,0 mm de precipitação, no entanto, observamos às 18:00 (UTC) e 19:00 (UTC) que a rede se estabilizou e apresentou PREV, respectivamente. 2,35 mm e ANTERIOR. 1,75 mm e NOTA. 4,8 mm, confirmando a confiabilidade do RN.

Figura 4.20 - Previsão de precipitação prevista por meio da Rede Neural em comparação a precipitação observada em mm/hora referente ao dia 07/03/2022.




Ao observar a Figura 4.20, a rede neural pode ser vista seguindo as precipitações observadas com valores superestimados dos valores em mm. Destacaremos na Figura 09 a previsão de precipitação para as 12:00 (UTC) com os valores PREV. 9,4 mm e NOTA. 1,2 mm, bem como na previsão de precipitação para as 14:00 (UTC) com valores PREV. 8,5 mm e NOTA. 36,4 mm, no entanto, a rede foi assertiva com a previsão de precipitação, exigindo uma nova análise dos valores que podem ter passado por essa distorção, pois a previsão de precipitação envolve inúmeras variáveis.

Figura 4.21- Previsão de precipitação prevista por meio da Rede Neural em comparação a precipitação observada em mm/hora referente ao dia 02/04/2022.



Observamos na Figura 4.20, uma maior margem de erro com a previsão x observada onde a rede neural apresentou uma pequena instabilidade na previsão de 15:00 (UTC) com valor PREV. 6,45 mm, e era OBS. 0,0 mm de precipitação, porém, observamos às 18:00 e 19:00 a rede se estabilizou e teve PREV, respectivamente. 2,35 mm e NOTA. 4,2 mm - ANTERIOR. 1,75 mm e NOTA. 4,8 mm, confirmando a confiabilidade do RN.

Figura 22 - Previsão de precipitação prevista por meio da Rede Neural em comparação a precipitação observada em mm/hora referente ao dia 07/05/2022.



Ao olhar para a Figura 4.21, verifica-se que a rede neural acompanha a precipitação observada com valores superestimados dos valores em mm. Vamos destacar na Figura 4.20 a previsão de precipitação para 12:00 (UTC) com valores PREV. 9,4 mm e NOTA. 1,2 mm, bem

como na previsão de precipitação para as 14:00 (UTC) com valores PREV. 8,5 mm e NOTA. 36,4 mm, no entanto, a rede foi assertiva com a previsão de precipitação, exigindo uma nova análise dos valores que podem ter passado por essa distorção, pois a previsão de precipitação envolve inúmeras variáveis. Para a Figura 4.21, o padrão linear foi mantido e a rede mostrou-se eficiente na previsão de precipitação com horário de aumento entre 9:00 (UTC) e 10:00 (UTC) subestimando os valores, PREV. 7,5 mm e NOTA. 12,4 mm e respectivamente PREV. 4,6 mm e NOTA. 10,6 milímetros.

CAPITULO 5

5. CONCLUSÃO

5.1 CONSIDERAÇÕES FINAIS

Inicialmente buscamos determinar que a rede ideal para previsão proposta deverá utilizar as funções de treinamento e transferência, “*transing*” e “*tranlm*”, respectivamente. Posteriormente, foram realizados testes para determinar a arquitetura e o treinamento da rede, sendo definida uma rede neural com sete neurônios na primeira camada, cinco neurônios na camada oculta e um neurônio na camada de saída.

Os testes realizados com o modelo apresentado neste trabalho, durante o período de janeiro a maio de 2022, mostraram que ele pode representar o ciclo diurno de precipitação observada e foi capaz de reproduzir a precipitação total a cada hora durante os meses chuvosos (janeiro e fevereiro), mas durante a transição da estação seca para a chuvosa, o modelo superestimou.

O treinamento e validação da rede mostraram que ela apresenta uma forte correlação entre treinamento (85%) e previsão (82%).

Concluimos que este trabalho mostra a construção de um modelo de Redes Neurais Artificiais do tipo *feedforward* para prever pontualmente a precipitação horária na cidade de Manaus/AM.

Sugerimos que para estudos futuros, possa ser realizado uma comparação dos dados utilizados nesta rede com dados meteorológicos de outra localidade a fim de se perceber o seu comportamento.

REFERÊNCIAS

- INPE, Supercomputação do. Cachoeira Paulista, 2015. Disponível em:<<http://supercomputacao.inpe.br/recursos2>>. Acesso em: 01 ago. 2021.
- ABU-MOSTAFA, Yaser S., Malik Magdon-Ismail, and Hsuan-Tien Lin. *Learning from data*. Vol. 4. New York, NY, USA:: AMLBook, 2012.
- ALENCAR, E.F. 2005, Políticas públicas e (in) sustentabilidade social: o caso de comunidades da várzea do Alto Solimões, Amazonas. In: Lima, D. (org.). Diversidade socioambiental nas várzeas do rios Rios Amazonas e Solimões: perspectivas para o desenvolvimento da sustentabilidade, Ibama, Pro Várzea, Manaus. p. 59-99.
- ALTHOFF, D.; RODRIGUES, LN; BAZAME, HC Quantificação de incertezas para modelos hidrológicos baseados em redes neurais: o dropout ensemble. Pesquisa Ambiental Estocástica e Avaliação de Riscos, v. 35, p. 1051-1067, 2021.
- AMORIM, M. C. C. T.; DUBREUIL, V. Intensity of Urban Heat Islands in Tropical and Temperate Climates. *Climate.* , v.5, p.91 - 104, 2017.
- AMORIM, M.C.C.T. O clima urbano de Presidente Prudente/SP. São Paulo, 2000. 378p. Tese (Doutorado em Geografia) – Faculdade de Filosofia Letras e Ciências Humanas – USP.
- Ayoade, J.O. 2007. Introdução á Climatologia para os Trópicos. 12ª Edição. Rio De Janeiro: Bertrand Brasil
- BADRINARAYANAN, V.; KENDALL, A; CIPOLLA, R.: SegNet : A Deep convolutional Encoder-Decoder Architecture for Image Segmentation , IEEE T. Pattern Anal., 39, 2481–2495, <https://doi.org/10.1109/TPAMI.2016.2644615>, 2017 .
- BAUR, F.; KEIL, C.; BARTHLOTT, C. Efeitos combinados da umidade do solo e distúrbios microfísicos em nuvens convectivas e precipitação para um caso localmente forçado sobre a Europa Central. *Jornal trimestral da Royal Meteorological Society*, p.1-15, 2022.
- BENALI, L.; NOTTON, G.; FOUILLOY, A.; VOYANT, C.; DIZENE, R. Previsão de radiação solar usando redes neurais artificiais e métodos de floresta aleatória: Aplicação a componentes de feixe normal, difuso horizontal e global. *Energias Renováveis*, v. 132, p. 871-884, 2019.
- BRASIL. Ministério da Saúde. Mudanças climáticas e ambientais e seus efeitos na saúde: cenários e incertezas para o Brasil /BRASIL. Ministério da Saúde; Organização Pan-Americana da Saúde. – Brasília: Organização Pan-americana da Saúde, 2008.
- CARVALHO, RL DA S.; DELGADO, ARS Comparação de modelos perceptron multicamadas na estimativa da evapotranspiração de referência. *Revista Inova Ciência e Tecnologia*, v.8, p.1-7, 2022.

CENTRO DE PREVISÃO DE TEMPO E ESTUDOS CLIMÁTICOS (CPTEC). Início da estação chuvosa nas regiões SE/CO/S/NE do Brasil. Cachoeira Paulista, 2021. Disponível em: <<http://energia1.cptec.inpe.br/regiaoafetadas/pt>>. Acesso em: 01 ago. 2021.

COÊLHO, Marcus Vinicius Furtado. O uso da inteligência artificial no meio jurídico.2019.Disponível em: <<https://www.editorajc.com.br/o-uso-da-inteligencia-artificial-no-meio-juridico/>> Acesso em: 08 Out. 2021

CONFALONIERI, U. E. C. 2003. Variabilidade Climática, Vulnerabilidade Social e Saúde no Brasil. TERRA LIVRE, SÃO PAULO, V.19, N.20, JAN./JUL., P.193- 204.

CONFALONIERI, U. E. C. Mudança climática global e saúde humana no Brasil. Parcerias Estratégicas, Brasília, n.27, p. 323-349, 2008.

CORRÊA, R. L. Região e organização espacial. São Paulo: Ática, 1986.

CHEN, H.; CHANDRASEKAR, V.; TAN, H.; CIFELLI, R. Estimativa de Precipitação a partir de Ground RadaR e Radar de Precipitação TRMM usando Redes Neurais Profundas Híbridas. Cartas de Pesquisa Geofísica, v. 46, P. 10669-10678, 2019.

EBI, KL; VANOS, J.; BALDWIN, JW; BELL, J, E.; HONDULA, DM ERRET, NA; HAYES, K.; REID, CE; SAHA, S.; SPECTOR, J.; BERRY, P. Condições meteorológicas extremas e Mudanças Climáticas: Implicações do Sistema de Saúde da População . Revisão Anual de Saúde Pública, v . 1; não. 42, pág. 293-315, 2022.

FRANCO, Leonardo; JEREZ, José M.; ALIZONDO, David A.. Constructive Neural Networks. Spain: Springer, 2009. 281 p.

GEORGESCU, M.; AMPLO, AM; WANG, M.; SCOTT KRAYENHOFF, E.; MOUSTAOU, M. Resposta da precipitação às mudanças climáticas e ao desenvolvimento urbano nos Estados Unidos continentais. Cartas de Pesquisa Ambiental, vol. 16, não. 4 de 2021.

GIVONI, *Baruch. Climate and architecture.* 2° ed. Applied Science, Architectural Science Series. London: 1976 (reprinted 1981)

GRIMM, Alice Marlene. *Material básico de estudo para os alunos da Disciplina Meteorologia Básica da Universidade Federal do Paraná.* 1999. Disponível em: <http://fisica.ufpr.br/grimm/>. Acesso em 10 de dezembro de 2010.

HANN, Julius. Handbuch der Klimatologie. Meteorologische zeitschrift, Viena, 1983

HELLDEN, D.; ANDERSSON, C.; NILSSON, M.; LEBI, K.; FRIBERG, P. ALFVÉN, T. Mudanças climáticas e saúde infantil: uma revisão de escopo e uma estrutura conceitual expandida. V.5, n.3, p. e164-e175, 2021.

HUANG, H.; CUI, H.; GE, Q. Avaliação dos riscos potenciais induzidos pelo aumento da precipitação extrema sob a mudança climática, Natural Hazards, v. 108, p. 2059-2079, 2021.

HUFFMAN, EF STOCKER, DT BOLVIN, EJ NELKIN, J. Tan Chuva final GPM IMERG L3 Meia hora 0,1 grau x 0,1 grau V06 Goddard Earth Science Information and Data Services Center (GES DISC), Greenbelt, MD, 2019.

INTERNAL DISPLACEMENT MONITORING CENTRE, NORWEGIAN REFUGEE COUNCIL/IDMC. Global Estimates 2015: People displaced by Disasters p. 109,2015. Disponível: www.internaldisplacement.org/publications/2015/global-estimates-2015-people-displaced-by-disaster. Acesso em 10 de junho de 2022.

KIRSCHBAUM, DB; HUFFMAN, GJ; ADLER, RF; BRAUN, S.; GARRETT, K.; JONES, E.; Precipitação de Sensoriamento Remoto da NASA: Um Reservatório para Usuários de Aplicativos. Boletim da American Meteorological Society, v.98, n. 6, pág. 1169-1184, 2017.

KIDD, C.; BECKER, A.; HUFFMAN, G.; MULLER, C.; JOE, P.; SKOFRONICK-JACKSON, G.; KIRSCHBAUM, D. Então, quanto da superfície da Terra é coberta por pluviômetros? Boletim da American Meteorological Society , 98, 69-78, 2017.

KARUNANAYAKE, Ç.; GUNATHILAKE, NO; MARASINGHA, N.; SAMARASINGHE, JT; ISURU M. BANDARA, EU ESTOU; RATHNAYAKE, U. Inteligência Computacional Aplicada e Computação Suave, v. 121, p. 1-9, 2021.

KUGO, BK; KUMAR, L.; KOECH, R. Mudanças climáticas e variabilidade no Quênia: uma revisão dos impactos na agricultura e na segurança alimentar. Meio Ambiente, Desenvolvimento e Sustentabilidade, v. 23, p. 23-43, 2021.

KUMMEROW, Ç.; BARNES , C.; KOZU , T.; SHIUE, J.; SIMPSON , J. O pacote de sensores Tropical Rainfall Measuring Mission (TRMM) . *Journal Atmospheric Oceanic Technology* , v. 15 , pág. 809-817, 1998.

KUMMEROW, C.; SIMPSON, J.; THIELE, O.; BARNES, W.; CHANG, ATC; STOCKER, E.; ADLER, RF; HOU, A.; KAKAR, R.; WENTZ, F.; ASHCROFT, P.; KOZU, T.; HONG, Y.; OKAMOTO, K.; IGUCHI, T.; KUROIWA, H.; IM, E.; HADDAD, Z.; HUFFMAN, G.; FERRIER, B.; OLSON, WS; ZIPSER, E.; SMITH, kT . E A; WILHEIT, TT; NORTE, G.; KRISHNAMURTI, T.; NAKAMURA, K. O Status da Missão de Medição de Chuvas Tropicais (TRMM) após Dois Anos em Órbita. *Journal Applied Meteorology* , v. 39, n.12, p. 1965-1982, 2000.

LE, TT.; PHAM, BT; LY, HB.; SHIRZARDI, A.; LE, LM Desenvolvimento de Modelo de Previsão de Precipitação de 48 Horas Utilizando Rede Neural Autoregressiva Não-Linear. (eds) CIGOS 2019, Inovação para Infraestrutura Sustentável. Notas de Palestra em Engenharia Civil, vol 54. Springer, Cingapura.

LIU, X .; YANG, T .; HSU, K .; LIU, C .; SOROOSHIAN, S. Avaliando a capacidade de simulação de fluxo de produtos de precipitação diária PERSIANN-CDR em duas bacias hidrográficas no planalto tibetano . *Hidrologia e Ciências do Sistema Terrestre* , v. 21, n.1 , p.169–181 , 2017 .

MAUAD, JN Abastecimento de água no Brasil: um estudo de diretrizes e desafios e perspectivas. *Estudos em Ciências Ambientais*, v.3, n.2, p. 264-275, 2022.

Marengo J.A, Nobre, C.A. 2001. General characteristics and variability of climate in the Amazon Basin and its links to the global climate system. In: McClain ME, Victoria RL, Richey JE (eds), *The Biogeochemistry of the Amazon Basin*, pp. 17–41. Oxford University Press, Oxford.

MAY, S.; PRADO, R.T.A., *Estudo de Viabilidade de Aproveitamento de Água de Chuva para o consumo Não Potável em Edificações*. Dissertação de Mestrado do Curso de Pós Graduação em Engenharia Civil. Escola Politécnica da Universidade Federal de São Paulo. São Paulo, 2004

MCMICHAEL, A.J.; WOODRUFF, R.E.; HALES, S. Climate change and human health: present and future risks. *Lancet*, v. 367, p. 859-869, 2006.

MICHAELIS, Dicionário Brasileiro da Língua Portuguesa, Cia. Inteligência.Melhoramentos, 2018. Disponível em: <<http://michaelis.uol.com.br/moderno-portugues/busca/portugues-brasileiro/intelig%C3%A2ncia>>. Acesso em: 01 outubro. 2022.

MENDONÇA, F.A. (org). *Impactos socioambientais urbanos*. Curitiba: Editora UFPR, 2004b.

MENEZES FILHO, F. C. M. ; TUCCI, C. E. M. . Alteração na relação entre densidade habitacional x área impermeável: Porto Alegre-RS. *REGA. Revista de Gestão de Águas da América Latina* , v. 9, p. 49-55, 2012

MISRA, S.; SARKAR, S.; MITRA, P. Redução estatística de precipitação usando redes neurais recorrentes de memória de longo prazo. *Climatologia Teórica e Aplicada*, v 134, p. 1179-1196, 2018.

MUGUME, I.; BASALIRWA, D.; NSABAGWA, M.; NGAILO, TJ; REUDER, J.; ULRICH, S.; SEMUJU, S. Uma Análise Comparativa do Desempenho dos Modelos COSMO e WRF na Previsão Quantitativa de Chuvas. *Revista Internacional de Ciências **Marinhas e Ambientais***, v.12, n. 2, pág. 130-138, 2018.

NETO, JFA; MEDEIROS, IS; AGUIAR, GJA; DUARTE, AD; SILVA, GL Avaliação dos impactos das chuvas na manutenção da rede de esgotamento sanitário do Município de Caruaru, Agreste de Pernambuco. *Revista Brasileira de Gestão Ambiental e Sustentabilidade* , v. 9, no. 21, pág. 3-19, 2022.

ONU, 2014: *World Urbanization Prospects*. Organização das Nações Unidas (ONU). Disponível em: <<https://esa.un.org/unpd/wup/Publications/Files/WUP2014-Report.pdf>>. Acesso em: Out. 2016.

OKE, TR (1982) A base energética da ilha de calor urbana. *Jornal trimestral da Royal Meteorological Society* , v. 108, no. 455, pág. 1 a 24 de janeiro.

OYEBODE, O.; & STRECTH, D. Modelagem de redes neurais de sistemas hidrológicos: Uma revisão de técnicas de implementação. *Modelagem de Recursos Naturais*, vol. 323, nº. 1, pág. 1-14, 2019.

PAUL, FP & SUBRAHAMANYAM, DB Previsão de Trajetórias de Ciclones Tropicais sobre o Norte do Oceano Índico usando COSMO. *Meteorologia e Física Atmosférica*, v. 133, p. 789-802, 2021.

PAN, B. HSU, K.; KOUCHAK, AA; SOROOSHIAN, S. Melhorando a Estimativa de Precipitação Usando Rede Neural Convolutacional. *Pesquisa de Recursos Hídricos*, v.55, p. 2301-2321, 2019.

PIERSANTE, JO; SCHUMACHER, RS; RASMUSSEN, KL Comparação de vieses nas previsões do WRF para estações quentes nas Américas do Norte e do Sul. *Tempo e Previsão*, v. 36, p. 979-1001, 2021.

POLITI, N. VLACHOGIANNIS, D.; SFETSOS, A.; NASTOS, PT Redução dinâmica de alta resolução de temperatura e precipitação ERA-Interim usando o modelo WRF para a Grécia. *Climate Dynamics*, V. 57, p. 799-825, 2021.

ROCKEL, B.; WILL, A.; HENSE, A. O Modelo Climático Regional COSMO-CLM (CCLM). *meteorologia Zeitschrift*, Vol. 17, nº 4, 347-348, 2008.

RONNEBERGER, O., FISCHER, P., AND BROX, T.: U-Net: Convolutional Networks for Biomedical Image Segmentation, in: *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, editado por: Navab, N., Hornegger, J., Wells, WM, e Frangi, AF, Springer International Publishing, Cham, pp. 234-241, 2015.

SANTOS, J.W.M.C. (2002) - Clima e produtividade de soja nas terrasde cerrado do Sudeste de Mato Grosso. Tese (Doutorado). PÔs-Gradua-Á,,o em Geografia FÌsica, Universidade de S,,o Paulo (FFLCH-USP).388p

Shahidian S, Guimarães R, Rodrigues C. 2012. *Hidrologia Agrícola* (Editores). ICAAM- ECT Universidade de Évora

SCHMIDT, DM; MATTOS, A. Dinâmica das chuvas e regimes de vazão na bacia hidrográfica do Alto Piranhas-Açu/PB. *Sociedade e Território*, Natal, v. 25, n. 2, edição especial, pág. 67-77, 2013.

SHARIFI, E.; SAGHAFIAN, B.; STEINACHER, R. Downscaling Estimativas de Precipitação de Satélites com Regressão Linear Múltipla, Redes Neurais Artificiais e Técnicas de Interpolação Spline. *JGR Atmospheres*, v. 124, p. 789-805, 2019.

SHI, X.; GAO, Z. LAUSEN, L. WANG, H.; YEUNG, DY.; WONG, WK; UAU, WC. Deep Learning para Precipitação Nowcasting: Um Benchmark e um Novo Modelo. em: *Advances in Neural Information Processing Systems 30*, editado por: Guyon, I., Luxburg, UV, Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R. ., Curran Associates, Inc., Red Hook, NY, EUA, 5617-5627, 2017.

SILVA, KN da.; FERREIRA, EC. ; FERREIRA, JC.; OLIVEIRA, V.; COELHO, M. dos S. .; RODRIGUES, VB.; LOUREIRO, G. Influência da precipitação e do uso do solo nas vazões da Sub-Região Hidrográfica de Itacaiúnas (SRHI). *Pesquisa, Sociedade e Desenvolvimento*, v. 10, n. 15, pág. e56101522520, 2021.

SONDERBY, CK; SPEHOLT, L.; HEEK, J.; DEHGNI, M.; OLIVER, A.; SALIMANS, T.; AGRAWAL, S.; HICHEY, J.; KALCHBRENNER, N. MetNet: Um Modelo Neural de Tempo para Previsão de Precipitação. *Ciência da Computação*, arXiv: 2003.12140v2, p. 1-17, 2020.

SOL, Q.; MIAO, C.; DUAN, Q.; ASHOURI, H.; SOROOSHIAN, S. HSU, KL Uma Revisão de Conjuntos de Dados de Precipitação Global: Estimativa de Fontes de Dados e Intercomparações. *Comentários de Geofísica*, vol. 56, nº. 1, pág. 79-107, 2018.

SOUSA, W.; SOUSA, F. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio piacó. *Revista Brasileira de Engenharia Agrícola e Ambiental*, SciELO Brasil, v. 14, n. 2, p. 173–180, 2010.

SORRE, M. (2006). Object and method of climatology *Revista do Departamento de Geografia*, n. 18, p. 89-94

SOUZA, J.C.R E ALMEIDA R. A - VAZANTE E ENCHENTE NA AMAZÔNIA BRASILEIRA: IMPACTOS AMBIENTAIS, SOCIAIS E ECONÔMICOS - VI Seminário Latino-Americano de Geografia Física II Seminário Ibero-Americano de Geografia Física - Universidade de Coimbra, Maio de 2010.

TANGANG, F.T., B. TANG, A.H. MONAHAN, AND W.W. HSIEH, Forecasting ENSO Events: A Neural Network-Extended EOF Approach. *J Climate*, 11,29--41, 1998

TUCCI, C. Regulamentação da drenagem urbana no Brasil. *Revista de Gestão de Água da América Latina* , v. 13, p. 29-42, 2016.

TUCCI, C. E. M. . Águas urbanas. *Estudos Avançados (USP.Impresso)* , v. 22, p. 97-112, 2008.

VAREJÃO-SILVA, M. A. *Meteorologia e Climatologia*. Versão digital. Recife. PE. Brasil. 2005.

VOLTA, AJ; PETRY, HB; SONEGO, M. Análise de tendência na série histórica de chuvas no município de Saudades, Santa Catarina. *Simpósio de Fruticultura da Região Sul*, v.3 n.1.

VIANELLO, R. L. e ALVES, R. A. *Meteorologia Básica e Aplicações*. Viçosa, UFV. Impr. Univ. 1991

World Meteorological Organization - Estado del clima en 2021: los fenómenos extremos y sus principales repercusiones – 2021

WMO. WORLD METEOROLOGY ORGANIZATION. *Climate System*. Understanding Climate. Disponível em: <www.wmo.int/pages/themes/climate/understanding_climate>. Acesso em 15 dez. 2010.

WHO, 2014: Quantitative risk assessment of the effects of climate change on selected causes of death, 2030s and 2050s. World Health Organization. United Nations. Geneva, Switzerland. 2004. 128 p.

ZANG, Y.; XIE, S. KLEIN SA; MARCHAND, R.; KOLLIAS, P.; CLOTHIAUX, EE; LIN, W.; SWALES, D.; BODAS-SALCEDO, A.; TANG, S.; HAYNES, JM; COLIS, S.; JESEN, M.; BHARADWAJ, N.; HARDIN, J.; ISOM, B. O Simulador de Radar em Nuvem ARM para Modelos Climáticos Globais: Ligando dados de campo e modelos climáticos. Boletim da American Meteorological Society, v.99, n. 1, pág. 21-26, 2018.

ZHU, K.; XUE, BYM; ZHOU, B.; HU, XM. Precipitações da temporada de verão em 4 km Previsões WRF sobre o sul da China: diagnósticos das causas dos vieses. Atmosferas JGR, v. 126, no. 23, 2021.