



UNIVERSIDADE FEDERAL DE PERNAMBUCO

CENTRO DE TECNOLOGIA E CIÊNCIAS

DEPARTAMENTO DE OCEANOGRAFIA

CURSO DE GRADUAÇÃO EM OCEANOGRAFIA



BRUNO MATOS CHIQUITO

**TREINAMENTO DE UM MODELO DE “DEEP LEARNING” PARA
PREVISÃO DE CHUVAS NA CIDADE DE RECIFE - PERNAMBUCO**

RECIFE

2025

BRUNO MATOS CHIQUITO

Treinamento de um modelo de “Deep learning” para previsão de chuvas na cidade de Recife - Pernambuco

Trabalho de Conclusão de Curso apresentado ao Curso de Oceanografia da Universidade Federal de Pernambuco, Centro Acadêmico do Recife, como requisito para a obtenção do título de bacharel em Oceanografia.

Orientadora: Profa. Dra. Dóris Regina Aires Veleda.

Coorientador: Dr. Pedro Tyaquiçã da Silva Santos

RECIFE

2025

**Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE**

Chiquito, Bruno Matos.

Treinamento de um modelo de ?Deep learning? para previsão de chuvas na
cidade de Recife - Pernambuco / Bruno Matos Chiquito. - Recife, 2025.

51 : il., tab.

Orientador(a): Dóris Regina Aires Veleda

Cooorientador(a): Pedro Tyaquiçã da Silva Santos

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Tecnologia e Geociências, Oceanografia -
Bacharelado, 2025.

Inclui referências.

1. Previsão de chuvas. 2. Recife - PE. 3. Modelo de Deep Learning. 4.
Multilayer Perceptron (MLP). I. Veleda, Dóris Regina Aires. (Orientação). II.
Santos, Pedro Tyaquiçã da Silva. (Coorientação). IV. Título.

550 CDD (22.ed.)

BRUNO MATOS CHIQUITO

**TREINAMENTO DE UM MODELO DE “DEEP LEARNING” PARA PREVISÃO DE CHUVAS NA CIDADE DE
RECIFE - PERNAMBUCO**

TCC apresentado ao Curso de Oceanografia da Universidade Federal de Pernambuco, Centro Acadêmico do Recife, como requisito para a obtenção do título de bacharel em Oceanografia.

Aprovado em: 21/02/2025.

BANCA EXAMINADORA

Profa. Dra. Doris Regina Aires Veleda (Orientadora)
Universidade Federal de Pernambuco

Prof. Dr. Thiago Luiz do Vale Silva (Examinador Externo)
Agência Pernambucana de Águas e Clima (APAC)

Prof. Dr. Luis Henrique Bezerra Alves (Examinador Interno)
Universidade Federal de Pernambuco

A minha mãe, pelo amor e apoio incondicional. Aos meus amigos e professores, pela paciência, companheirismo e incentivo. E a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho.

AGRADECIMENTOS

Agradeço, com todo o meu coração, à minha mãe, Lucigleide Oliveira Matos, pelo amor incondicional, apoio incansável e por ser minha maior força nesta caminhada. Obrigado por nunca ter desistido de mim, mesmo nos momentos em que eu próprio duvidei do meu caminho. Sem sua paciência, dedicação e incentivo, esta conquista não seria possível.

Aos meus amigos Rodrigo, Nicolas e Marcela, que foram verdadeiros pilares nos momentos mais difíceis, oferecendo apoio, motivação e amizade genuína. Obrigado por cada palavra de encorajamento e por estarem sempre ao meu lado, independentemente dos desafios.

À minha família, especialmente aos meus irmãos e à minha querida avó, Hilda Matos, que tenho no coração como minha segunda mãe. Seu carinho, amor e ensinamentos foram fundamentais para que eu chegasse até aqui.

À minha professora orientadora Doris Veleda, pelo suporte, paciência e contribuições, tanto neste trabalho quanto ao longo de toda a minha graduação.

Ao meu coorientador Pedro Tyaquiçã da Silva Santos, pelas contribuições que ajudaram a moldar este trabalho.

Ao CNPq, pelo apoio financeiro através das bolsas concedidas ao longo do curso, permitindo que eu me dedicasse integralmente aos estudos e à pesquisa.

Aos colegas e amigos do departamento, que tornaram os dias mais leves, com os quais dividi conhecimento, desafios, risadas e muitas conversas, incluindo as minhas incessantes reclamações. A convivência com vocês fez toda a diferença nesta jornada.

A todos que, direta ou indiretamente, contribuíram para minha formação e para a realização deste trabalho, o meu mais sincero obrigado.

“In clouds of code, where data weaves,
A forecast forms from virtual leaves.
Machine learning, with eyes so keen,
Predicts the rain, where clouds have been.

From past patterns, it reads the sky,
Sensing when the heavens will cry.
With each drop's fall, its knowledge grows”
Grok

RESUMO

A precipitação na região costeira de Pernambuco é sensível a variabilidade climática, o que reforça a necessidade de monitoramento e melhoria das previsões, considerando o aumento da incerteza e a intensificação de eventos climáticos extremos. Neste trabalho é realizada uma análise detalhada sobre variabilidade temporal das principais variáveis atmosféricas que influenciam na precipitação em Recife. Foi desenvolvido um modelo de Deep Learning que utiliza 5 variáveis atmosféricas como entrada e realiza uma previsão de precipitação com um horizonte de sete dias à frente. O modelo foi treinado com séries temporais horárias, com um total de 3.681.720 valores, de 1941 até 2009. O período de dados de 2010 até 2023 foi utilizado para validar o modelo. A comparação entre os resultados de precipitação modelada pelo modelo de IA e a precipitação da reanálise mostraram uma correlação de Pearson de 0,6913, MAE de 79,3, MSE de 94,9, RMSE de 281,7 e R^2 de 0,48.

Palavras-chave: Previsão de chuvas; Recife - PE; Modelo de Deep Learning; Multilayer Perceptron (MLP)

ABSTRACT

Precipitation in the coastal region of Pernambuco is sensitive to climate change, which underscores the need for monitoring and improving forecasts, given the increased uncertainty and intensification of extreme weather events. This study provides a detailed analysis of the temporal variability of the main atmospheric variables influencing precipitation in Recife. A Deep Learning model was developed that uses five atmospheric variables as inputs and produces a seven-day-ahead precipitation forecast. The model was trained using hourly time series data—totaling 3,681,720 values—from 1941 to 2009. The period from 2010 to 2023 was used to validate the model. A comparison between the modeled precipitation results and reanalysis precipitation data showed a Pearson correlation of 0.6913, MAE of 79.3, MSE of 94.9, RMSE of 281.7, and R^2 of 0.48.

Keywords: Rainfall forecast; Recife - PE; Deep Learning model; Multilayer Perceptron (MLP)

LISTA DE ILUSTRAÇÕES

Figura 1.1. Desenho esquemático de uma rede neural artificial de multicamadas feedforward. Fonte: PIRES et al, 2023.	15
Figura 1.2. Desenho esquemático de uma MLP. Fonte: ALBUQUERQUE, 2024.	17
Figura 3.1. Área de Estudo. Fonte: IBGE, https://www.ibge.gov.br .	19
Figura 3.2. Modelo computacional de um neurônio.	20
Figura 3.3. Neurônios combinados formando uma rede.	21
Figura 4.1.1. Série mensal da temperatura do ar a 2 metros, de 1941 até 2023.	23
Figura 4.1.2. Climatologia mensal da temperatura do ar a 2 metros, de 1941 até 2023.	23
Figura 4.1.3. Série da média anual da temperatura do ar a 2 metros, de 1941 até 2023.	24
Figura 4.1.4. Anomalia mensal da temperatura a 2 metros, de 1941 até 2023.	24
Figura 4.1.5. Série mensal da Pressão atmosférica na superfície, de 1941 até 2023.	25
Figura 4.1.6. Climatologia mensal da Pressão atmosférica na superfície, de 1941 até 2023.	25
Figura 4.1.7. Série da média anual da Pressão atmosférica na superfície, de 1941 até 2023.	26
Figura 4.1.8. Anomalia mensal da Pressão atmosférica na superfície, de 1941 até 2023.	26
Figura 4.1.9. Série mensal da temperatura da superfície do mar, de 1941 até 2023	27
Figura 4.1.10. Climatologia mensal da temperatura da superfície do mar, de 1941 até 2023.	27
Figura 4.1.11. Série da média anual da temperatura da superfície do mar, de 1941 até 2023.	28
Figura 4.1.12. Anomalia mensal da temperatura da superfície do mar, de 1941 até 2023.	28
Figura 4.1.13. Série mensal da Pressão ao Nível Médio do Mar, de 1941 até 2023.	29
Figura 4.1.14. Climatologia mensal da Pressão ao Nível Médio do Mar, de 1941 até 2023.	29
Figura 4.1.15. Série da média anual da Pressão ao Nível Médio do Mar, de 1941 até 2023	30
Figura 4.1.16. Anomalia mensal da Pressão ao Nível Médio do Mar, de 1941 até 2023.	30
Figura 4.1.17. Série mensal da Precipitação Total, de 1941 até 2023.	31
Figura 4.1.18. Climatologia mensal da Precipitação Total, de 1941 até 2023.	31
Figura 4.1.19. Série da média anual da Precipitação Total, de 1941 até 2023.	32
Figura 4.1.20. Anomalia mensal da Precipitação Total, de 1941 até 2023.	32
Figura 4.2.1. Evolução do loss do treinamento e validação ao longo das épocas de treinamento.	36
Figura 4.2.2 Comparação entre Valores Reais e Previsões do Modelo	37

LISTA DE TABELAS

Tabela 4.1 - Valores obtidos a partir de treinamento e validação

35

LISTA DE ABREVIASÕES

ANN	<i>Artificial Neural Networks</i> (Redes Neurais Artificiais)
ATS	Atlântico Tropical Sul
DNN	<i>Deep Neural Networks</i> (Redes Neurais Profundas)
DOL	Distúrbios Ondulatórios de Leste
ECMWF	<i>European Centre for Medium-Range Weather Forecasts</i> (Centro Europeu de Previsões Meteorológicas de Médio Prazo)
ENEB	Leste do Nordeste Brasileiro
ENSO	El Niño-Oscilação Sul
ERA5	<i>ECMWF Reanalysis v5</i>
GPCP	<i>Global Precipitation Climatology Project</i>
GRU	<i>Gated Recurrent Unit</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IPCC	<i>Intergovernmental Panel on Climate Change</i>
LSTM	<i>Long Short-Term Memory</i>
MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Squared Error</i> (Erro Quadrático Médio)
MSL	<i>Mean Sea Level Pressure</i> (Pressão ao Nível Médio do Mar)
NEB	Nordeste do Brasil
PDO	<i>Pacific Decadal Oscillation</i> (Oscilação Decadal do Pacífico)
R ²	Coeficiente de Determinação
RMSE	<i>Root Mean Squared Error</i> (Raiz do Erro Quadrático Médio)
SP	<i>Surface Pressure</i> (Pressão Atmosférica na Superfície)
SST	<i>Sea Surface Temperature</i> (Temperatura da Superfície do Mar)
T2M	<i>Temperature at 2 meters</i> (Temperatura a 2 metros)
TFT	Temporal Fusion Transformer
TP	Precipitação Total
TSM	Temperatura da Superfície do Mar
ZCAS	Zona de Convergência do Atlântico Sul
ZCIT	Zona de Convergência Intertropical

	SUMÁRIO
1. INTRODUÇÃO	13
2. OBJETIVOS	18
2.1 Objetivo Geral	18
2.2 Objetivos Específicos	18
3. METODOLOGIA	18
3.1 ÁREA DE ESTUDO	18
3.2 Base de Dados	19
3.3 Modelo de aprendizado profundo	20
4. RESULTADOS	22
4.1. Análise de variabilidade temporal das variáveis assimiladas pelo modelo	22
4.2. Modelagem e validação	34
5. CONCLUSÃO	41
REFERÊNCIAS	44

1. INTRODUÇÃO

A Região Nordeste do Brasil (NEB) é caracterizada por uma alta variabilidade espacial e temporal de chuvas, determinadas por sua posição geográfica, relevo e sistemas de pressão atmosféricos, que estão entre os principais fatores climáticos que determinam a sua sazonalidade (Ferreira, 2005). Entre os fenômenos de grande escala que atuam sobre o NEB, a Zona de Convergência Intertropical (ZCIT) e o El Niño-Oscilação Sul são os mais importantes (Hastenrath e Lamb 1977; Chiang et al. 2002; Giannini et al. 2004; Da Silva, 2004; Dos Santos et al., 2023). Em escala interanual, o NEB é influenciado pela evaporação do Pacífico e Atlântico tropical, pela temperatura da superfície do mar (TSM), que ocasionam o El Niño/La Niña, o Dipolo do Atlântico e outros eventos que podem ocorrer na bacia oeste do Atlântico Tropical Sul (ATS). Estas forçantes interanuais podem amplificar os períodos de seca e chuvas intensas (Kayano; Andreoli, 2006; Rafaela; Lima, 2021; Souza et al., 2021). Dentro dessa variabilidade natural do NEB também se encontram os fatores resultantes de interação oceano-atmosfera, onde os mesmos influenciam o regime de chuvas das regiões semiáridas e litorâneas (Silva et al., 2019; Rao; Chapa; Franchito, 1999). Alguns dos sistemas meteorológicos mais relevantes para o NEB são: A ZCIT, A Zona de Convergência do Atlântico Sul, Os Vórtices Ciclônicos de Altos Níveis e Os Distúrbios Ondulatórios de Leste (DOLs) (Kouadio et al., 2012; Chaves; Cavalcanti, 2001; De Albuquerque Cavalcanti, 2015; Gomes et al., 2015). Em estudo recente, do Santos et al. (2023) identificaram que a Oscilação Decadal do Pacífico (PDO) exerce maior controle sobre a modulação dos padrões climáticos no NEB e revelaram outras influências diferenciais a partir de teleconexões como a Oscilação Multidecadal do Atlântico (*Atlantic Multidecadal Oscillation*), Índice Multivariado do ENSO (*Multivariate ENSO Index*) e da Oscilação do Atlântico Norte (*North Atlantic Oscillation*) na precipitação nas quatro sub-regiões do NEB. Os padrões de circulação do Atlântico influenciam fortemente a precipitação interanual e interdecadal nas regiões do Agreste, Sertão e Centro-Norte, possivelmente associados à posição da ZCIT.

No Leste do Nordeste Brasileiro (ENEB) está localizada a cidade de Recife, no estado de Pernambuco, e essa apresenta período chuvoso predominantemente entre março a agosto, com uma média anual de precipitação de 2290,55 mm (Silva Junior et al., 2020). No entanto, a variabilidade interanual em alguns casos pode ocasionar eventos extremos, os quais impactam de forma significativa as áreas urbanas mais vulneráveis. Por ser uma cidade

litorânea frequentemente afetada por eventos extremos de chuva, Recife ocupa a 16^a posição entre as cidades mais ameaçadas no mundo pelas mudanças climáticas (Baltar De Souza Leão; Silveira Andrade; Felipe Nascimento, 2021).

Recife passou por alguns grandes eventos climáticos extremos nos últimos 15 anos, como em 2010 e em 2022. Em 2010 os DOLs resultaram em inundações severas que atingiram 45 municípios em Pernambuco, incluindo a capital, Recife, causando danos generalizados (Luiz do Vale Silva et al., 2018). Já em 2022 dois grandes eventos de DOLs, no período entre 25 a 28 de maio, resultaram na precipitação acumulada superior a 500 mm o que levou à morte de mais 130 pessoas entre os estados de Pernambuco, Alagoas e Paraíba (Marengo et al., 2023).

A previsão de eventos extremos causados por DOLs em Recife é um desafio, devido à variabilidade interanual, que está ligada a mudanças na TSM no ATS. Anomalias positivas da TSM podem intensificar os eventos de precipitação. Em 2010, por exemplo, a TSM na costa do ENEB esteve acima da média por três meses consecutivos, fornecendo vapor de água para os sistemas de DOLs (Luiz do Vale Silva et al., 2018; Amorim; Chaves; Silva, 2014). Esse vapor é transportado pelos ventos alísios de sudeste, resultando em chuvas intensas na costa de Pernambuco, incluindo Recife.

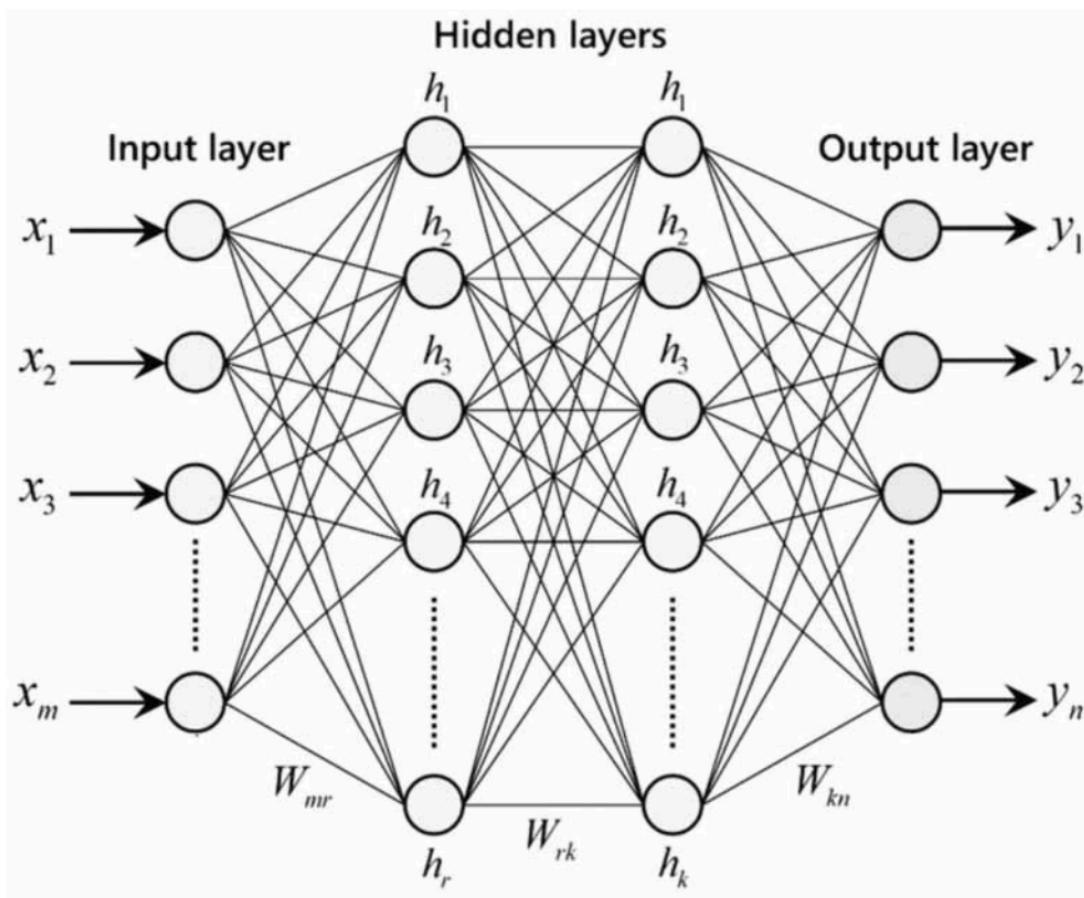
Portanto, a previsão do tempo da cidade é de extrema importância para a preservação de vidas humanas e desempenha um papel crítico no planejamento de ações de defesa civil, especialmente nas áreas de risco como nas margens dos rios ou encostas com risco de deslizamento (Dos Santos; Puppim De Oliveira, 2024).

A otimização da previsão de curto e médio prazo para Recife é crucial para mitigar os impactos de eventos extremos, como os DOLs. Os eventos climáticos extremos de 2010 e 2022 evidenciam a necessidade da melhora na velocidade com a qual as previsões são realizadas em modelos numéricos para aumentar a capacidade de previsão quando se coloca em foco os efeitos das mudanças climáticas vigentes. Por isso se faz necessário a utilização de ferramentas que aprimorem a velocidade da geração dessas previsões para evitar tragédias em eventos futuros.

Apesar dos modelos numéricos regionais representarem bem os fenômenos atmosféricos e preverem com uma certa eficiência, cada vez mais temos o desenvolvimento e

aperfeiçoamento de modelos baseados em Redes neurais artificiais que são capazes de gerar resultados confiáveis de forma mais rápida (ANN - *Artificial Neural Networks*). As ANNs (Figura 1.1) são modelos computacionais capazes de aprender a partir de grandes volumes de dados, sendo estas inspiradas pelas conexões encontradas em neurônios biológicos (Basheer e Hajmeer et al., 2000). *Machine learning*, por sua vez, refere-se à capacidade das máquinas de aprender padrões e tomar decisões baseadas nesses dados, sem a necessidade de instruções explícitas (Pandey et al., 2023). Essas tecnologias têm se destacado pela sua capacidade de resolver problemas complexos em diversas áreas do conhecimento (Abiodun et al., 2018).

Figura 1.1. Desenho esquemático de uma rede neural artificial de multicamadas feedforward. Fonte: PIRES et al, 2023.



Dentro das redes neurais existe uma categoria das mesmas denominada redes neurais profundas (DNN - *Deep Neural Networks*), sendo estas capazes de melhor compreender

relações complexas e hierárquicas dos dados de entrada, traduzindo-se em maior capacidade de aprendizado, além da possibilidade de serem utilizadas em diversas áreas, como visão computacional, processamento de linguagem natural, sistemas de recomendação, análise de séries temporais e diagnósticos médicos, permitindo avanços significativos em tarefas que exigem alto nível de precisão e generalização (Agarwall, 2018).

O uso de redes neurais tem se expandido rapidamente em setores como a indústria automobilística, alimentícia, e metalúrgica, bem como na área da saúde e no setor financeiro (Habehh e Goel, 2021; Nousias et al., 2023; Smith, 2020; Tkáč e Verner, 2016). Elas oferecem soluções para otimização de processos, como na produção industrial e detecção de fraudes (Bin Sulaiman et al., 2022; Sudha et al., 2016), além de possibilitarem inovações em áreas como diagnósticos médicos e sistemas de recomendação (Latha e Rao, 2024; Nguyen et al., 2022).

Uma das áreas de maior aplicação das redes neurais é na análise de séries temporais, essenciais para prever fenômenos que se desenvolvem ao longo do tempo (Kourentzes et al., 2014). Esse tipo de análise é particularmente relevante no estudo da climatologia e meteorologia, onde a previsão de eventos como precipitação, temperaturas extremas e padrões atmosféricos pode impactar setores como a agricultura, a geração de energia e a gestão de desastres naturais (Scher e Messori, 2018).

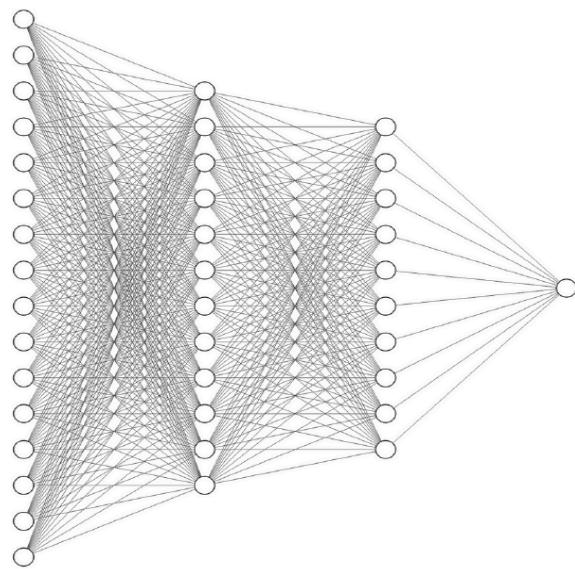
A utilização de ANNs para a solução de problemas tem sido de grande interesse no meio acadêmico, industrial e empresarial, oferecendo respostas mais rápidas e, por vezes, mais precisas do que modelos estatísticos tradicionais (Alon et al., 2001). A análise de séries temporais, essenciais para o estudo da climatologia e meteorologia de uma região, é chave para muitas das redes neurais utilizadas ao redor do mundo (Citakoglu e Coşkun et al., 2022).

Estudos recentes têm desenvolvido e utilizado modelos de machine learning para melhorar e agilizar as previsões de curto prazo meteorológicas (Guo et al., 2024; Xie et al., 2023). Pinheiro Gomes et al (2024) utilizou de modelos de redes neurais para auxiliar na melhoria da previsão da precipitação na região da Amazônia Legal através da obtenção de dados de estações pluviométricas da região, enquanto que em outras regiões do globo como na Etiópia (Kebede et al, 2024) foram utilizados dados de modelos climáticos e agências internacionais em busca de respostas mais robustas e confiáveis em uma região de grande

incerteza meteorológica devido a sua configuração geográfica além das variações espaço temporais de uma latitude sob o efeito da ZCIT. Outros estudos buscam a melhoria da previsibilidade de padrões climáticos como o El Niño (ENSO) sendo este um evento de alta imprevisibilidade (Ham et al, 2019; Chen et al, 2023), melhorias na obtenção de dados e previsibilidade de regiões com potencial para usinas eólicas e geração de energia solar e hidráulica (Ferrero Bermejo et al, 2019; Marugán et al, 2018).

As ANNs são formadas por camadas de neurônios interconectados, onde cada neurônio recebe valores de entrada, processa os mesmos utilizando uma função de combinação, uma soma ponderada, e uma função de ativação que introduz não linearidade ao modelo. Essas redes neurais podem ser configuradas com diferentes números de camadas e conexões o que permite desde arquiteturas simples, uma única camada, a complexas, com múltiplas camadas (Botelho Pires et al., 2025). O *Multilayer Perceptron* (MLP) é uma subclasse das ANNs e possui uma arquitetura *feedforward*, que significa que os dados fluem em uma única direção, das camadas de entrada para as camadas ocultas e, por fim, para a camada de saída. O MLP é composto por uma ou mais camadas ocultas (Figura 1.2), sendo considerado uma rede neural profunda quando possui mais de uma camada oculta, sendo seu diferencial sua capacidade de modelar relações não lineares a partir da aplicação de funções de ativação em cada camada oculta. Algumas das funções de ativação são a Unidade Linear Retificada (ReLU), a função sigmoide logística (sigmoid) e a função hiperbólica tangente (tanh).

Figura 1.2. Desenho esquemático de uma MLP. Fonte: ALBUQUERQUE, 2024.



2. OBJETIVOS

2.1 Objetivo Geral

Este trabalho tem como objetivo analisar o papel de diferentes forçantes climáticas na variabilidade de chuvas na Região Metropolitana de Recife através do uso de modelos de redes neurais, com o intuito de melhorar a previsibilidade de eventos extremos de chuva.

2.2 Objetivos Específicos

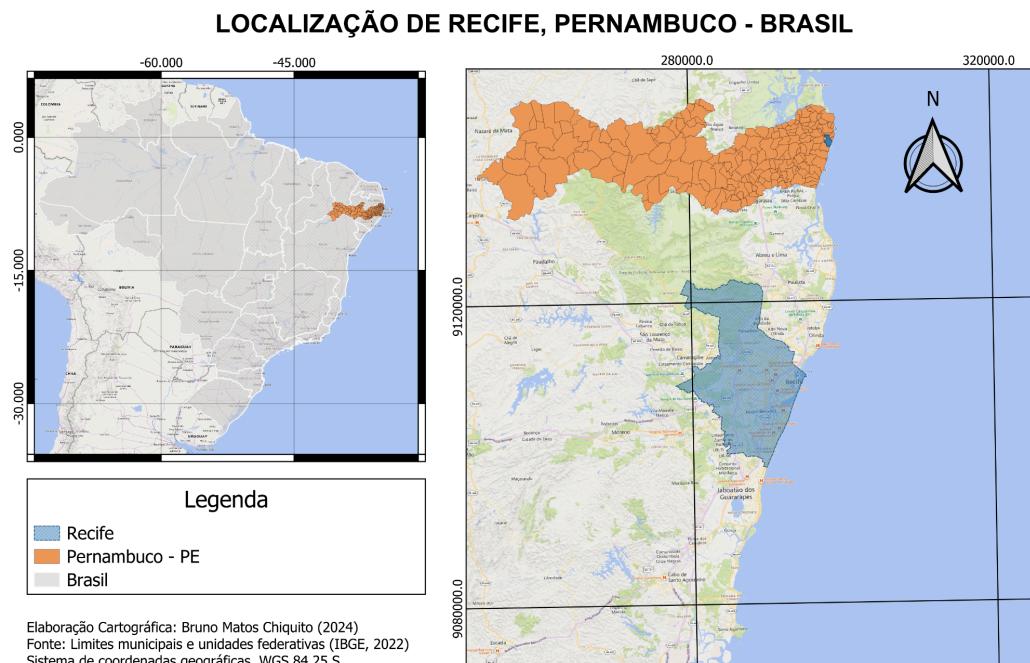
- Analisar as relações entre as variáveis escolhidas;
- Identificar padrões climatológicos na região estudada;
- Desenvolver e aplicar modelo de rede neural para aprimorar a previsão de eventos de chuvas extremas na região metropolitana de Recife.

3. METODOLOGIA

3.1 ÁREA DE ESTUDO

A cidade de Recife ($8^{\circ}04'03''$ S e $34^{\circ}52'16''$ W) é habitada por 1.48 milhões de pessoas, sendo a nona cidade mais populosa do país, com uma extensão territorial de 218,843 km² e densidade demográfica de 6.803,60 hab/km² (IBGE, 2024). Sua geomorfologia se caracteriza como uma planície aluvional, composta por ilhas e manguezais, cortada por diversos rios como o Capibaribe, Beberibe e Tejipió, além de apresentar marés com amplitudes de até 2 metros. (Figura 3.1).

Figura 3.1. Área de Estudo. Fonte: IBGE, <https://www.ibge.gov.br>.



3.2 Base de Dados

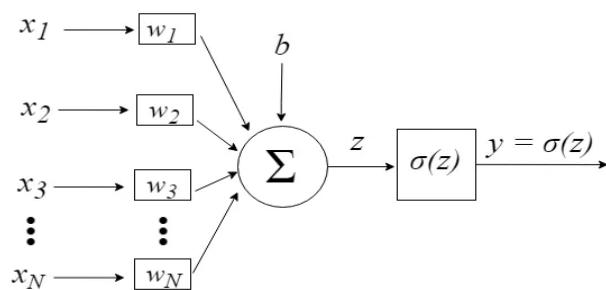
Os conjuntos de dados horários para a região do leste do nordeste foram obtidos através da base de dados de reanálise do ERA5 que pertence ao ECMWF (European Centre

for Medium-Range Weather Forecasts). O acrônimo ERA5 vem da abreviação de ECMWF Reanalysis v5, esta base é a quinta geração de reanálise atmosférica do ECMWF do clima global, abrangendo o período de janeiro de 1941 até o presente. Esta base tem resolução de $0,25^\circ \times 0,25^\circ$, disponível em <https://cds.climate.copernicus.eu/>. Esta base tem sido comparada com dados de radiossonda e mostra um ajuste melhorado para temperatura, vento e umidade na troposfera. A resolução temporal e espacial aprimorada permite uma evolução detalhada dos sistemas meteorológicos. Para precipitação, a correlação média global com dados GPCP médios mensais é aumentada de 67% para 77% (Hersbach et al., 2020). As variáveis a serem consideradas para treinamento são dados diários de temperatura da superfície do mar, temperatura a 2 metros, pressão ao nível do mar e precipitação total.

3.3 Modelo de aprendizado profundo

O modelo desenvolvido neste estudo é o MLP, este é um tipo de rede neural artificial que consiste em várias camadas de neurônios. O MLP é uma rede neural semelhante ao perceptron simples, porém possui mais de uma camada de neurônios. Os neurônios do MLP normalmente usam funções de ativação não lineares, permitindo que a rede aprenda padrões complexos nos dados (Lightbody e Irwin 1996). Inspirando-se no funcionamento dos neurônios biológicos do sistema nervoso dos animais, estabeleceu-se na área da Inteligência Artificial um modelo computacional de um neurônio conforme ilustrado na figura 3.2.

Figura 3.2. Modelo computacional de um neurônio.



Os sinais da entrada no neurônio são representados pelo vetor $x = [x_1, x_2, x_3, \dots, x_N]$, podendo corresponder aos pixels de uma imagem, por exemplo. Ao chegarem ao neurônio, são multiplicados pelos respectivos pesos sinápticos, que são os elementos do vetor $w = [w_1, w_2, w_3, \dots, w_N]$, gerando o valor z , comumente denominado potencial de ativação. O termo

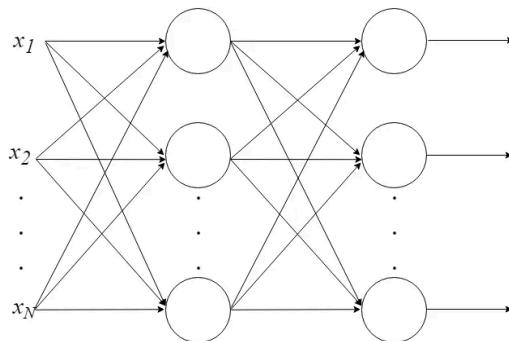
adicional b provê um grau de liberdade a mais, que não é afetado pela entrada nessa expressão, correspondendo tipicamente ao “bias”, de acordo com a equação 01 abaixo:

$$\sum_{i=1}^N x_i w_i + b \quad (01)$$

O valor z passa então por uma função matemática de ativação σ , com a característica de ser não linear, responsável por limitar tal valor a um certo intervalo, produzindo o valor final de saída e do neurônio.

Podemos combinar uma estrutura de camadas, cada uma com número diferente de neurônios, formando uma rede neural denominada Perceptron Multicamadas, “Multilayer Perceptron”. Os perceptrons multicamadas consistem em múltiplas camadas de neurônios, cada uma totalmente conectada às da camada inferior (da qual recebem informações) e às superiores (Zhang et al., 2023). O vetor de valores de entrada x passa pela camada inicial, cujos valores de saída são ligados às entradas da camada seguinte, e assim por diante, até que a rede forneça como resultado os valores de saída da última camada. Pode-se arranjar a rede em várias camadas, tornando-a profunda e capaz de aprender relações cada vez mais complexas (Figura 3.3).

Figura 3.3. Neurônios combinados formando uma rede.



A modelagem consiste dos seguintes passos:

- A. Inicialização de todos os pesos da rede com pequenos valores aleatórios.

- B. Fornecimento de dados de entrada à rede e calcular o valor da função de erro obtida, ao comparar com o valor de saída esperado.
- C. A minimização do valor da função de erro, calculando os valores dos gradientes para cada peso da rede.
- D. Uma vez que temos o vetor gradiente calculado, atualiza-se cada peso de modo iterativo, sempre recalculando os gradientes em cada passo de iteração, até o erro diminuir e chegar abaixo de algum limiar preestabelecido, ou o número de iterações atingir um valor máximo, quando enfim o algoritmo termina e a rede está treinada (Poulton, 2001).

Este modelo utiliza 5 variáveis como entrada e realiza uma previsão de sete dias à frente. Baseado na série temporal de 3.681.720 valores, são utilizados os dados de 1941 até 2009 para treinar o modelo e os dados de 2010 até 2023 são utilizados para validar o modelo. Quatro métricas estatísticas serão aplicados para quantificar a precisão e qualidade da previsão do modelo, são elas:

- MAE (Erro Médio Absoluto): descreve a magnitude média dos erros.
- MSE (Erro Quadrático Médio): penaliza mais fortemente grandes desvios pontuais.
- RMSE (Raiz do Erro Quadrático Médio): sendo tipicamente mais interpretável na mesma escala da variável.
- R^2 (Coeficiente de Determinação): indicando quanto por cento da variação da precipitação no conjunto de validação foi explicada pelo modelo.

4. RESULTADOS

Os resultados aqui apresentados estão divididos em análises dos dados de entrada do modelo e resultados da modelagem. A seção 4.1 mostra as séries temporais utilizadas nesta pesquisa. A partir destas séries são estimadas as médias climatológicas mensais e anuais. Para identificar variações interanuais são estimadas as anomalias. A seção 4.2 ilustra o resultado da modelagem de aprendizado profundo e validação do modelo com os dados de reanálise.

4.1. Análise de variabilidade temporal das variáveis assimiladas pelo modelo

Nas Figuras 4.1.1 a 4.1.4, apresenta-se a análise da temperatura do ar a 2 metros, na qual é possível observar uma tendência de aumento ao longo dos anos. Essa tendência é evidenciada tanto pela média móvel na série temporal quanto pela linha de tendência no gráfico de anomalias, que indica variações positivas alcançando até 1°C. A climatologia mensal revela um padrão sazonal bem definido, com o pico de temperatura ocorrendo em março e o mês mais frio sendo agosto. Adicionalmente, a climatologia anual reforça essa tendência de aumento da temperatura ao longo do período analisado.

Figura 4.1.1. Série mensal da temperatura do ar a 2 metros, de 1941 até 2023.

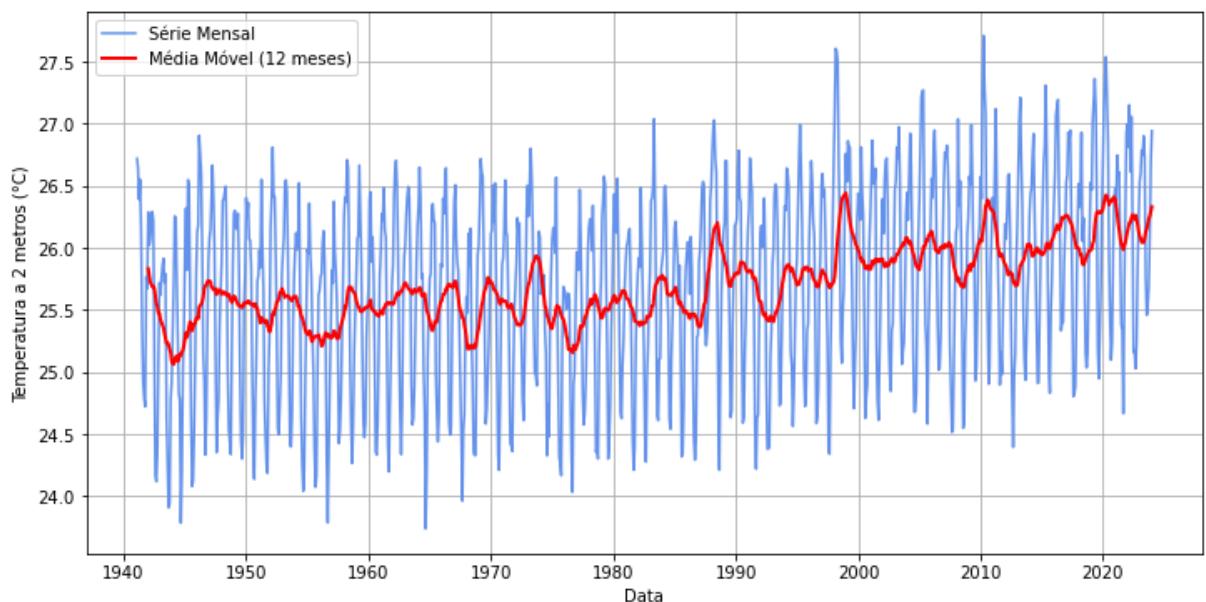


Figura 4.1.2. Climatologia mensal da temperatura do ar a 2 metros, de 1941 até 2023.

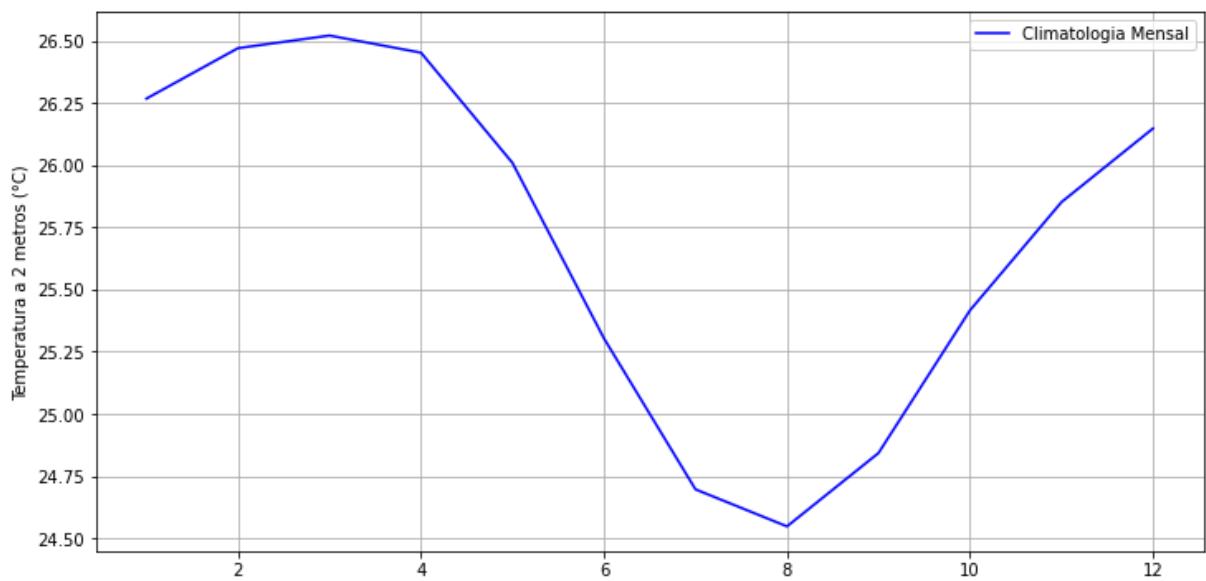


Figura 4.1.3. Série da média anual da temperatura do ar a 2 metros, de 1941 até 2023.

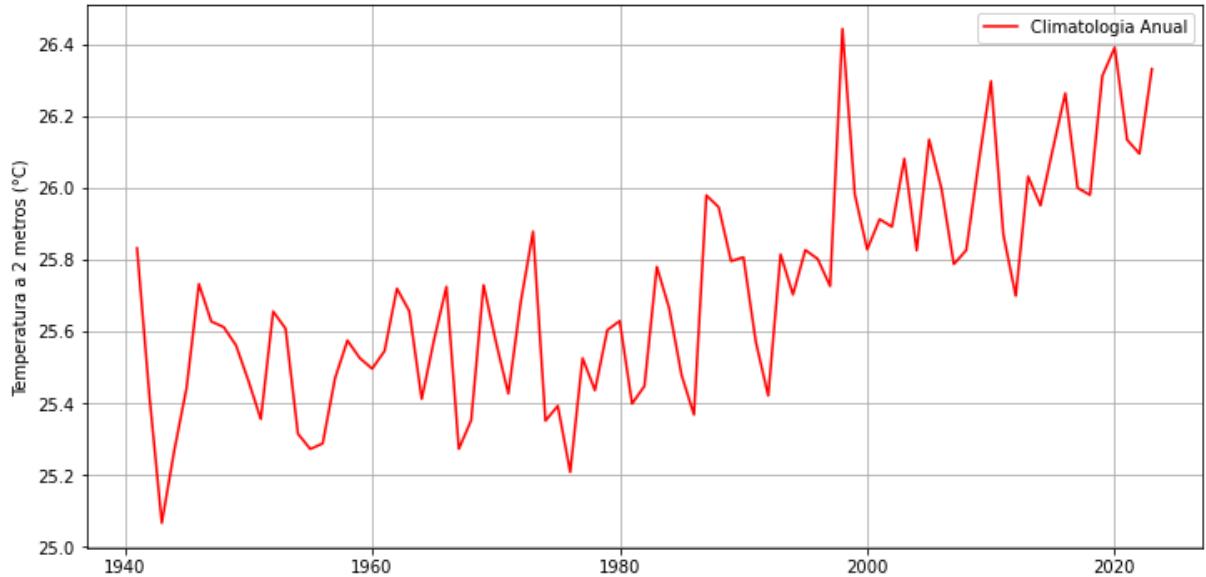
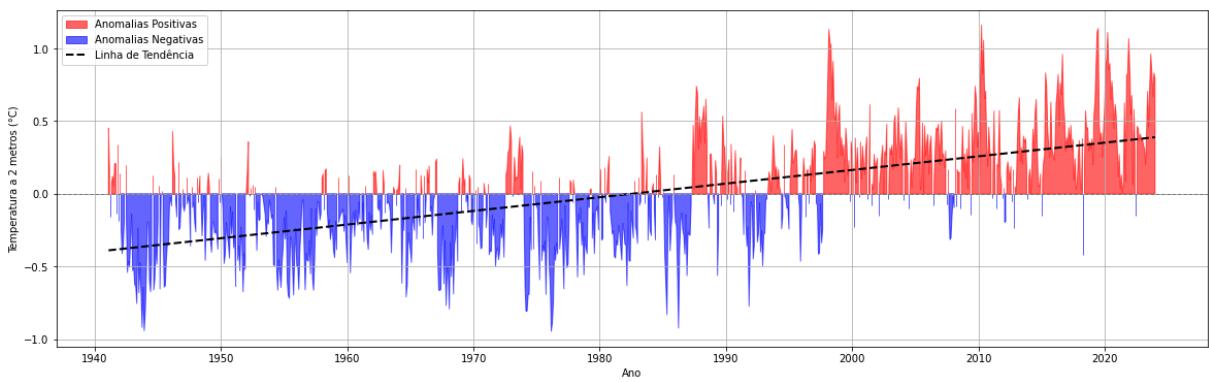


Figura 4.1.4. Anomalia mensal da temperatura a 2 metros, de 1941 até 2023.



As Figuras 4.1.5 a 4.1.8, que representam a análise da pressão atmosférica na superfície, não evidenciam, à primeira vista, uma tendência clara de aumento. No entanto, ao considerar a linha de tendência das anomalias, observa-se um leve crescimento ao longo do período analisado. A série temporal e a climatologia anual permitem visualizar a evolução dessa variável ao longo do tempo, enquanto a climatologia mensal evidencia sua variabilidade sazonal, caracterizada por um pico em agosto e um valor mínimo em março.

Figura 4.1.5. Série mensal da Pressão atmosférica na superfície, de 1941 até 2023.

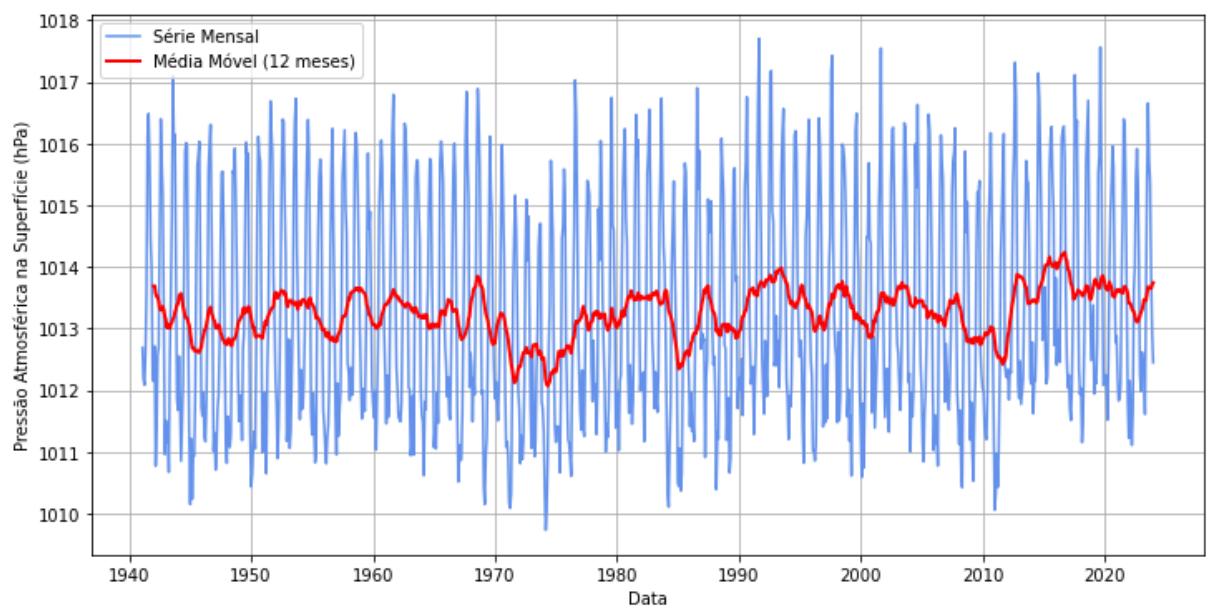


Figura 4.1.6. Climatologia mensal da Pressão atmosférica na superfície, de 1941 até 2023.

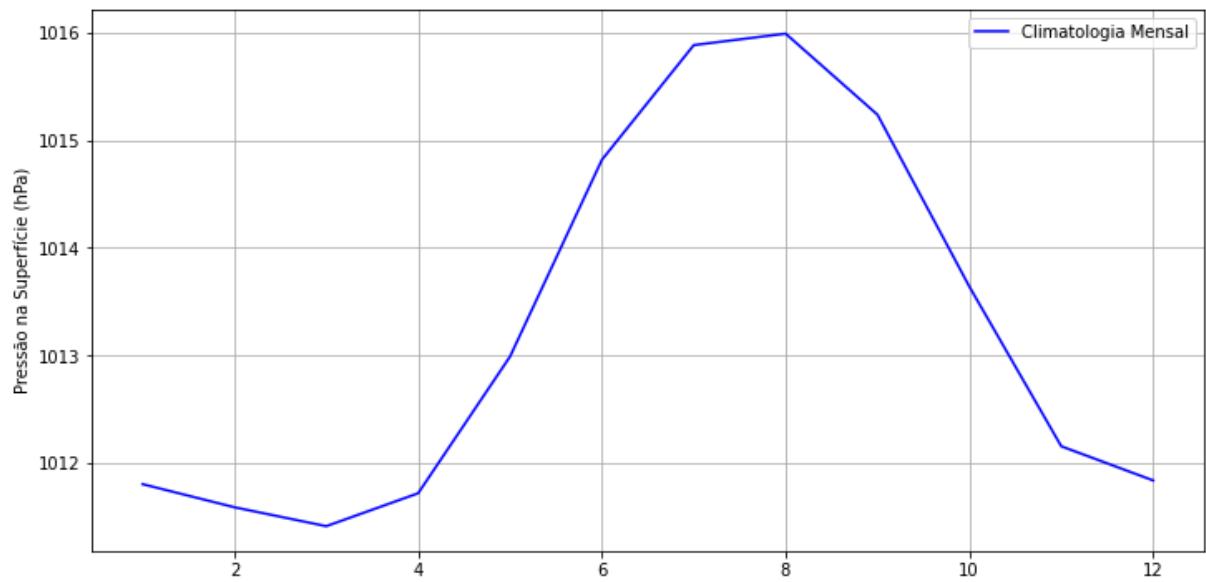


Figura 4.1.7. Série da média anual da Pressão atmosférica na superfície, de 1941 até 2023.

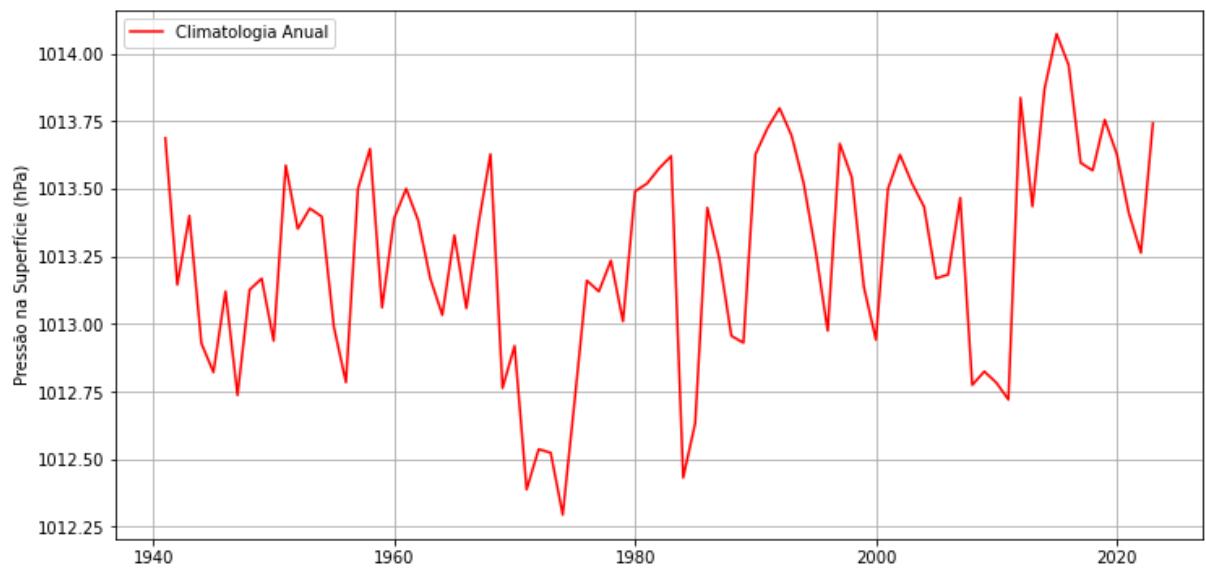
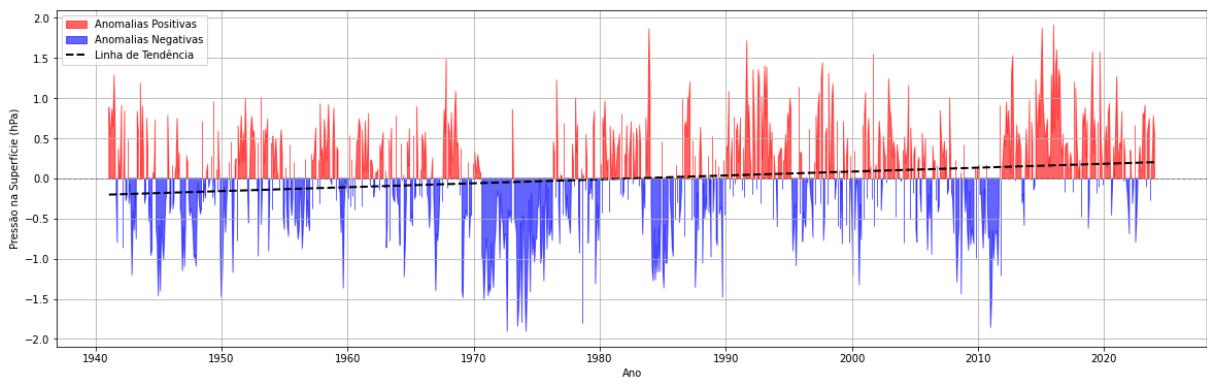


Figura 4.1.8. Anomalia mensal da Pressão atmosférica na superfície, de 1941 até 2023.



Nas Figuras 4.1.9 a 4.1.12, apresenta-se a análise da temperatura da superfície do mar, na qual os gráficos da série temporal mensal, da climatologia anual e das anomalias indicam uma tendência de elevação ao longo do período analisado. As anomalias registradas atingiram valores de até 1°C, evidenciando um aumento significativo na temperatura da superfície oceânica. A climatologia mensal revela um padrão sazonal bem definido, com o menor valor dessa variável ocorrendo em agosto e o pico máximo registrado em abril.

Figura 4.1.9. Série mensal da temperatura da superfície do mar, de 1941 até 2023

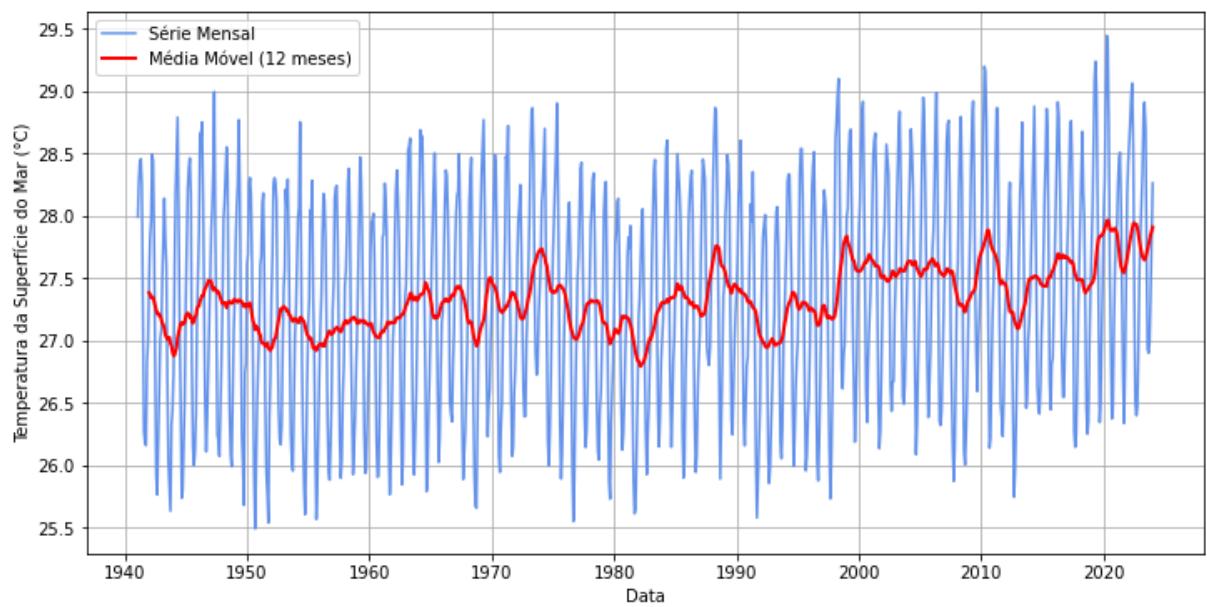


Figura 4.1.10. Climatologia mensal da temperatura da superfície do mar, de 1941 até 2023.

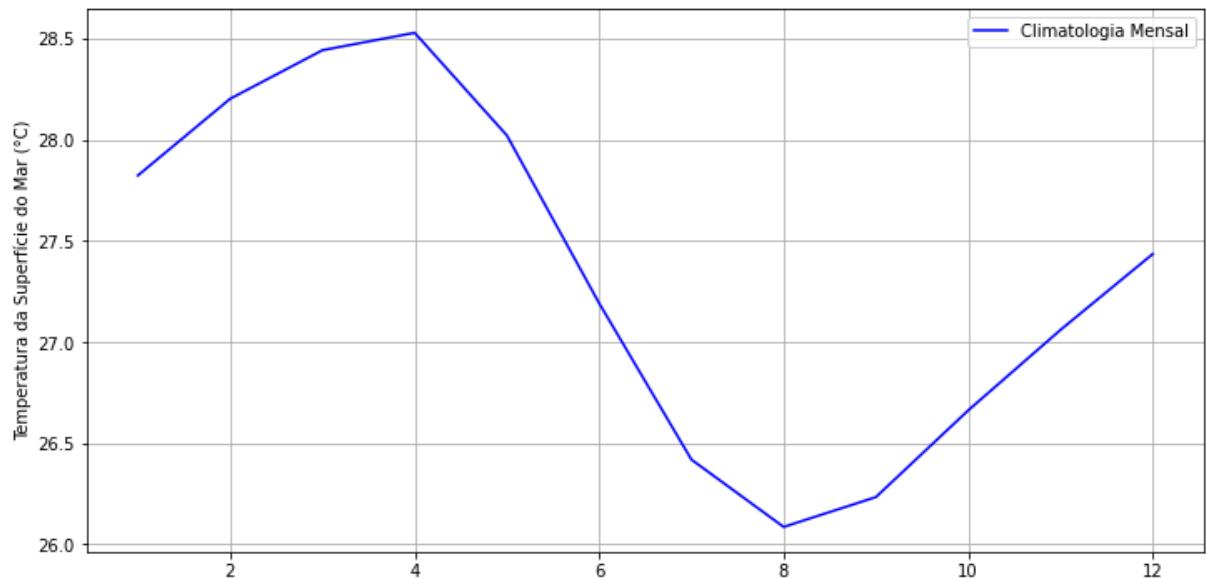


Figura 4.1.11. Série da média anual da temperatura da superfície do mar, de 1941 até 2023.

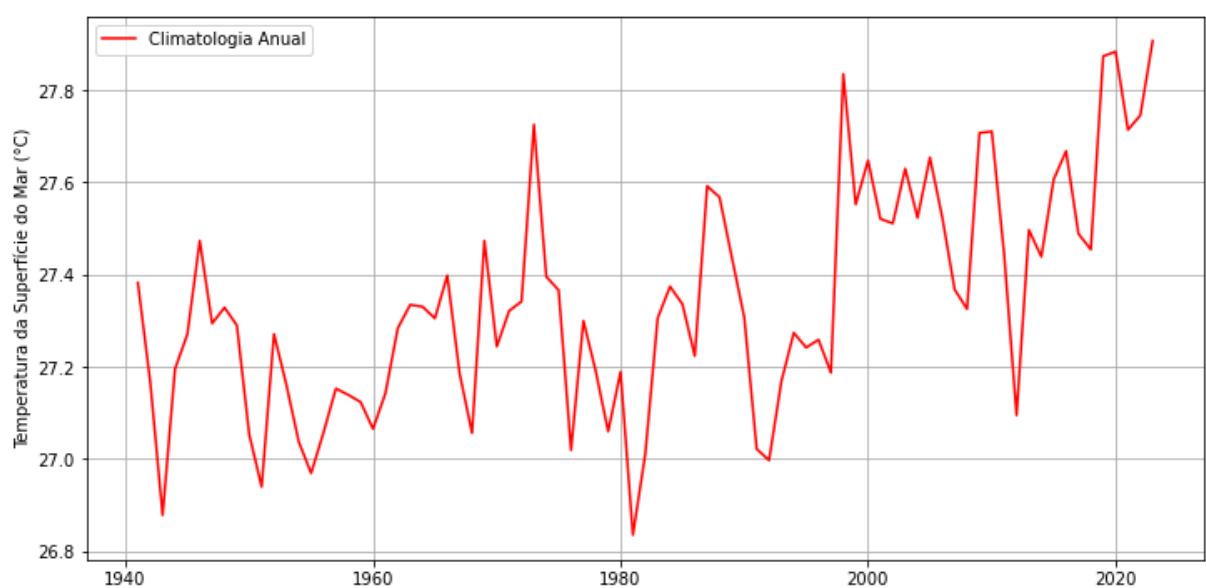
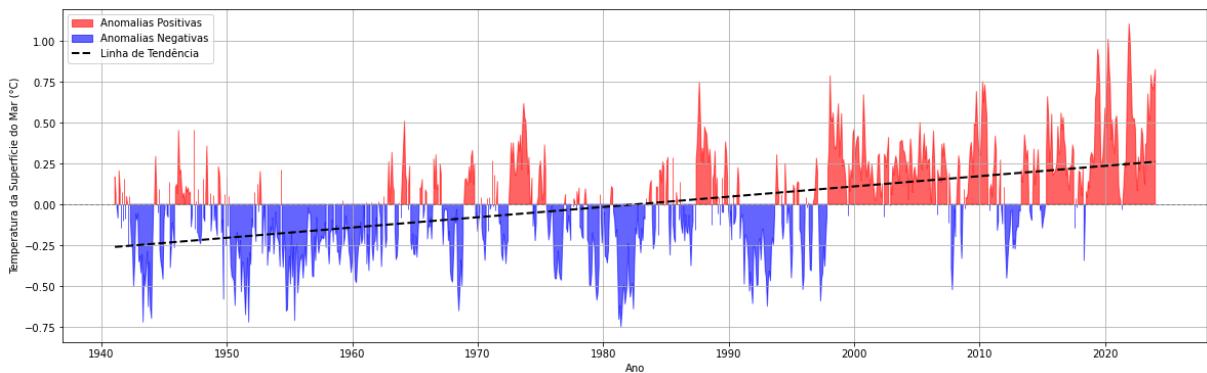


Figura 4.1.12. Anomalia mensal da temperatura da superfície do mar, de 1941 até 2023.



As Figuras 4.1.13 a 4.1.16 apresentam a variabilidade da pressão ao nível médio do mar, evidenciando uma tendência de aumento ao longo do período analisado, conforme indicado pela linha de tendência das anomalias. No entanto, a série temporal mensal e a climatologia anual revelam um comportamento relativamente disperso dentro de um intervalo específico evidenciado pela média móvel. Por sua vez, a climatologia mensal destaca a sazonalidade dessa variável, com um pico máximo em agosto e um mínimo em março.

Figura 4.1.13. Série mensal da Pressão ao Nível Médio do Mar, de 1941 até 2023.

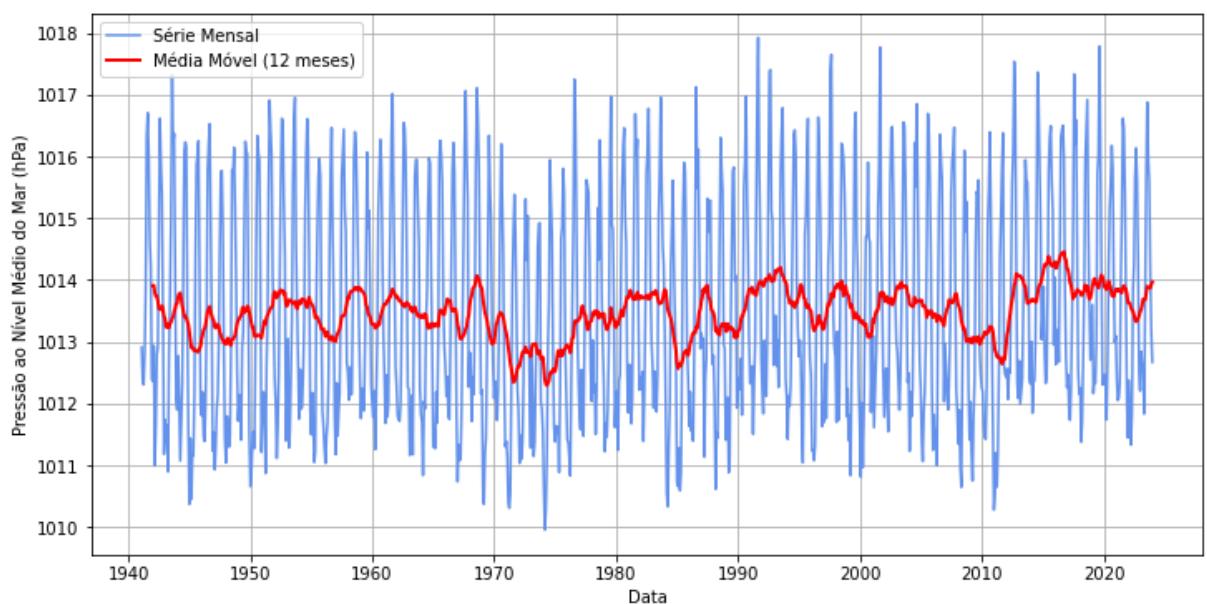


Figura 4.1.14. Climatologia mensal da Pressão ao Nível Médio do Mar, de 1941 até 2023.

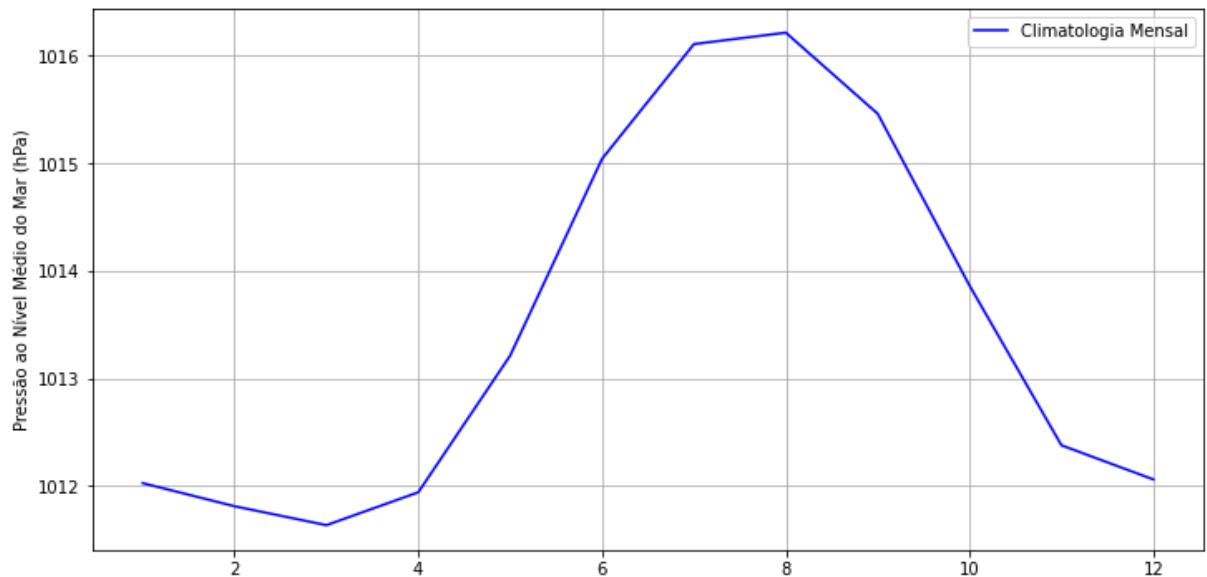


Figura 4.1.15. Série da média anual da Pressão ao Nível Médio do Mar, de 1941 até 2023

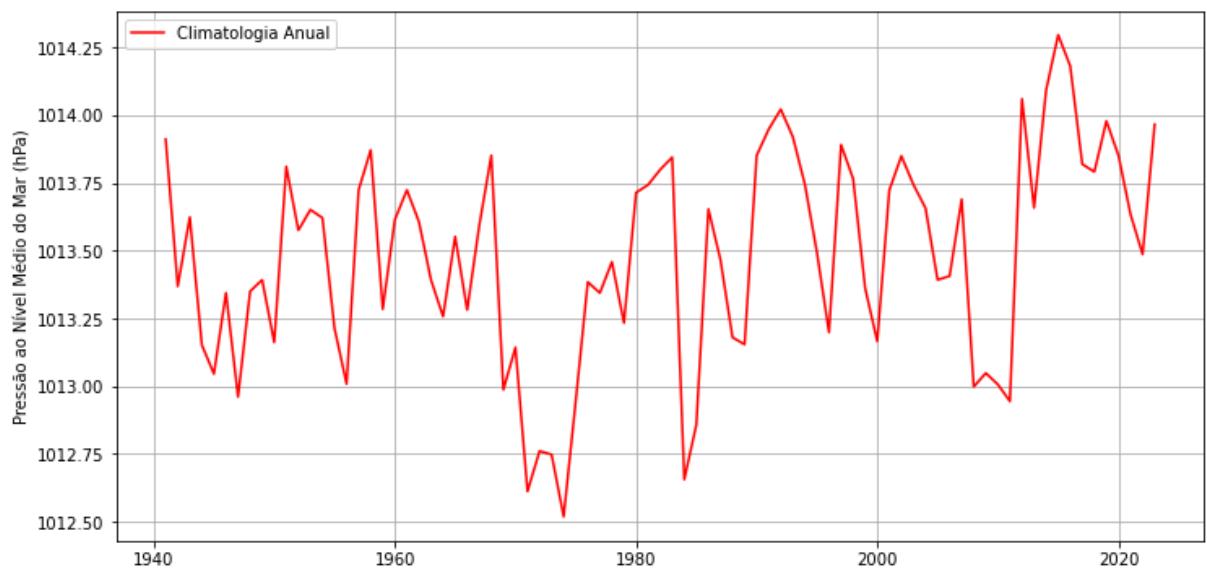
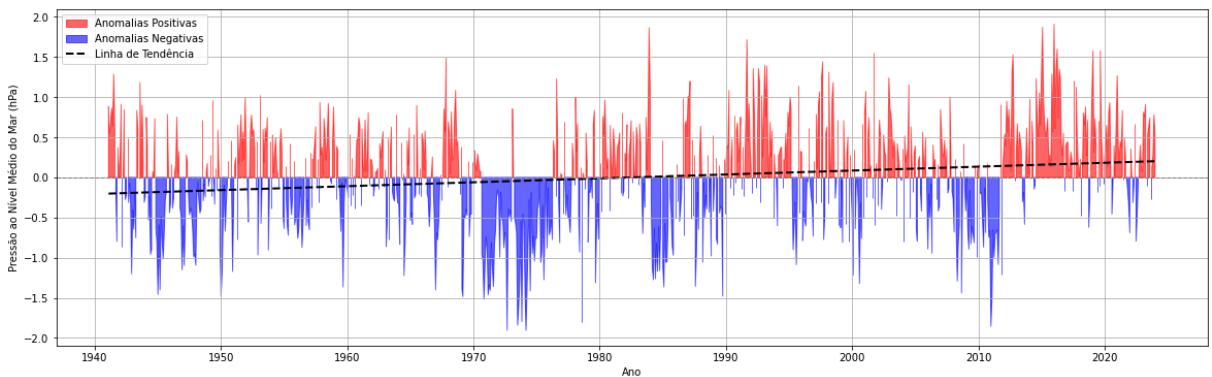


Figura 4.1.16. Anomalia mensal da Pressão ao Nível Médio do Mar, de 1941 até 2023.



As Figuras 4.1.17 a 4.1.20 representam a análise da precipitação total. Os gráficos da série temporal mensal, da climatologia anual e das anomalias não evidenciam, a princípio, uma tendência clara de variação ao longo do tempo. No entanto, ao observar a linha de tendência das anomalias, verifica-se um leve aumento na precipitação total ao longo do período analisado. A climatologia mensal destaca a sazonalidade do regime pluviométrico, com o maior volume de precipitação registrado em julho e o menor em novembro.

Figura 4.1.17. Série mensal da Precipitação Total, de 1941 até 2023.

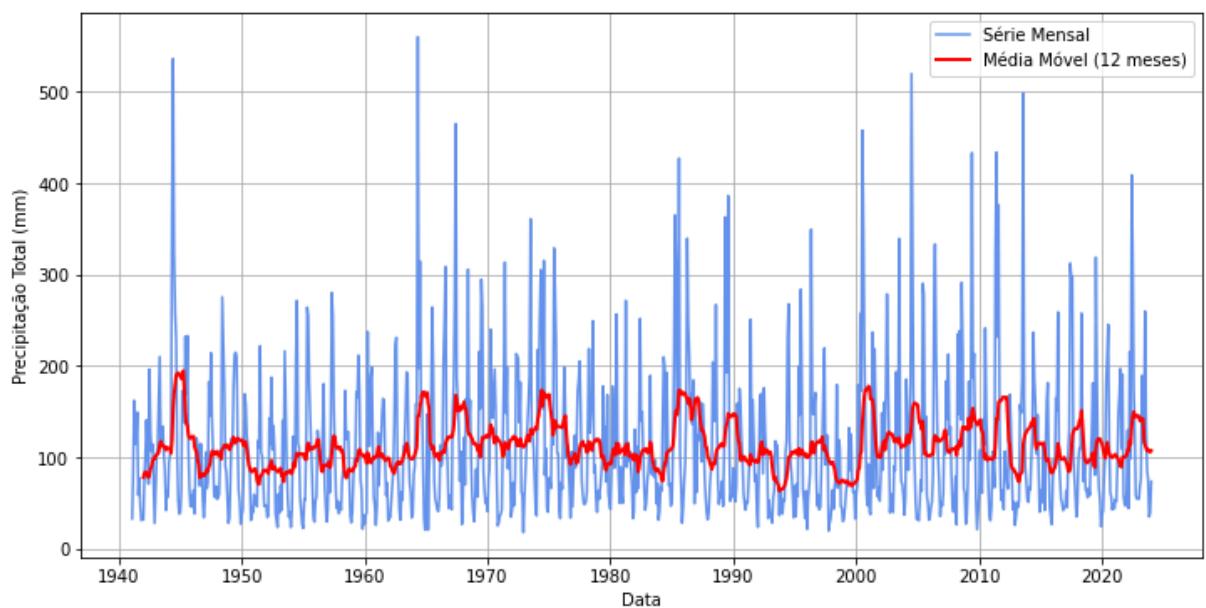


Figura 4.1.18. Climatologia mensal da Precipitação Total, de 1941 até 2023.

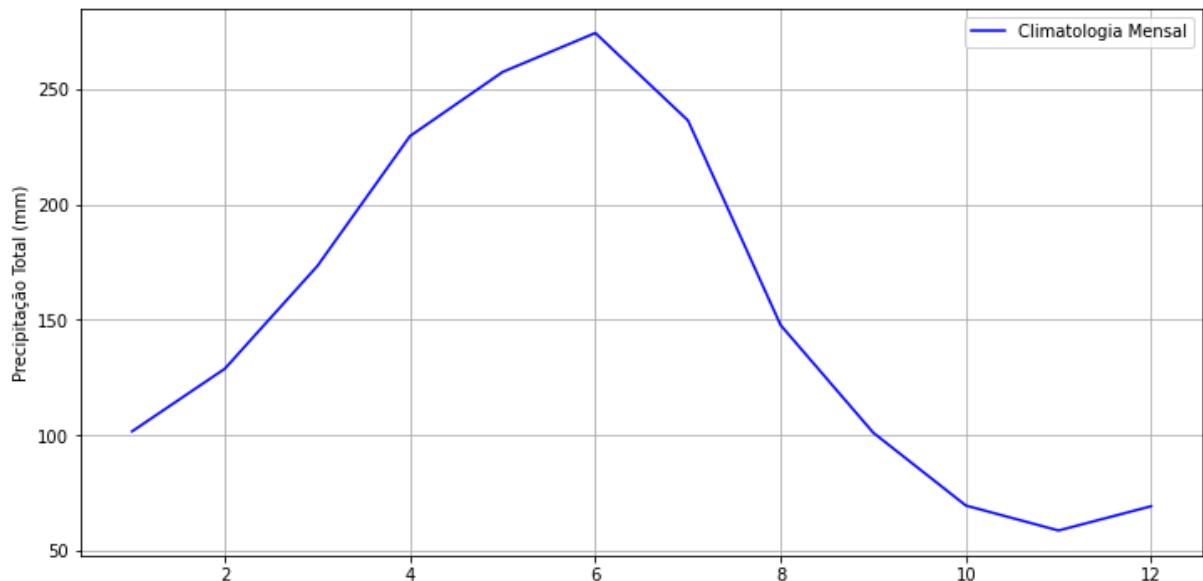


Figura 4.1.19. Série da média anual da Precipitação Total, de 1941 até 2023.

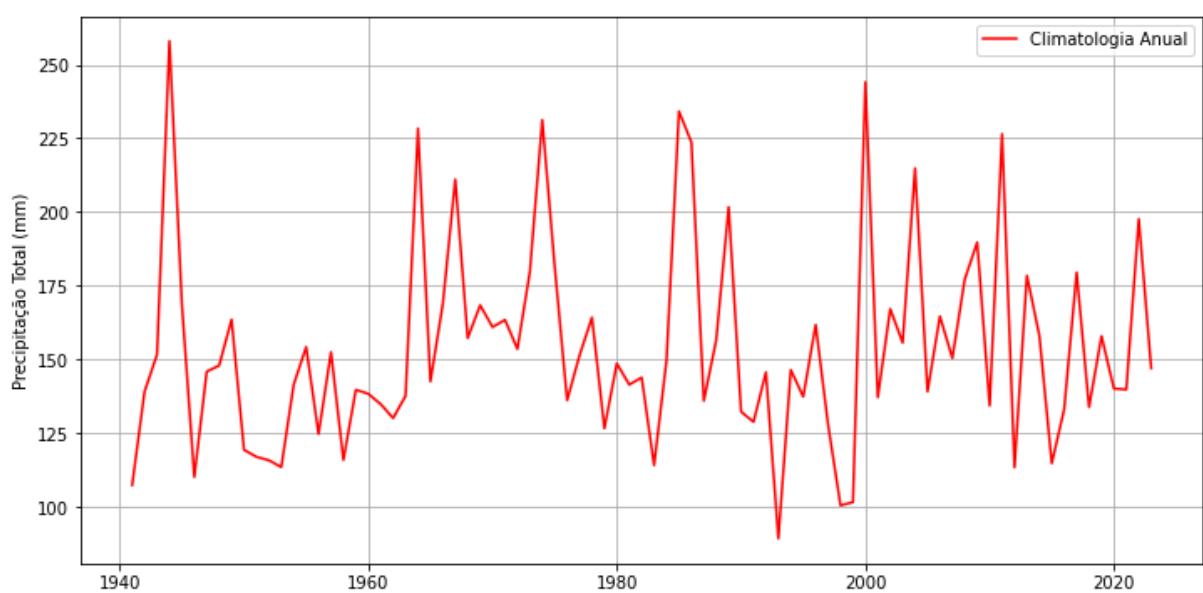
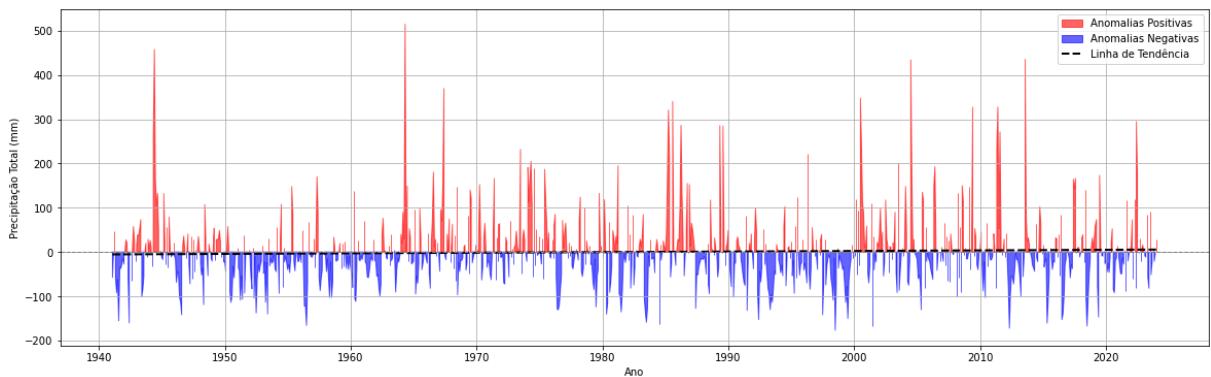


Figura 4.1.20. Anomalia mensal da Precipitação Total, de 1941 até 2023.



É possível observar que ao longo das últimas décadas, uma tendência de aquecimento tanto sobre áreas continentais quanto na superfície oceânica, em concordância com as projeções de mudanças climáticas realizadas pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC). A análise dos gráficos de temperatura (Figuras 4.1.1 a 4.1.4) mostra anomalias que podem alcançar até +1 °C acima da média ao longo de 82 anos, reforçando um cenário de elevação gradual das temperaturas. Embora as climatologias mensais evidenciam sobretudo a variação sazonal — com máximas em torno de fevereiro–março e mínimas em agosto, as séries de anomalias revelam oscilações mais intensas que não são inteiramente capturadas por esses valores médios.

A identificação de picos positivos da anomalia na Figura 4.1.4 sugere possível associação como nos episódios de El Niño dos anos 1983, 1997 e 2016, indicando mudanças significativas na circulação atmosférica global através do índice positivo do "Oceanic Niño Index". Em períodos recentes, algumas projeções apontam para aquecimento adicional em 2024, resultado potencial da combinação entre El Niño e o efeito de ilhas de calor urbanas na Região Metropolitana do Recife (COSTAS VAROTSOS et al., 2024).

As análises da pressão atmosférica, tanto sobre a superfície do continente quanto do oceano, (Figuras 4.1.5 a 4.1.8 e 4.1.13 a 4.1.16) mostraram alterações discretas, mas com capacidade de influenciar a convergência de umidade e geração de chuvas. Na região da área de estudo a Alta Pressão Subtropical do Atlântico Sul e ZCIT se destacam como mecanismos fundamentais que controlam o regime de chuvas, principalmente entre março e agosto. Pequenas variações nesses campos de pressão podem intensificar ou impedir a formação de

nuvens, influenciando diretamente sobre a precipitação, especialmente quando combinadas a anomalias positivas da TSM no Atlântico.

No que diz respeito à precipitação (Figuras 4.1.17 a 4.1.20), não foram verificadas tendências de elevação ou redução tão acentuadas quanto as observadas na TSM ou na temperatura a 2 metros. Entretanto, há picos de anomalia distribuídos ao longo da série histórica. Na cidade de Recife que pode apresentar média anual de chuvas com valores de até 2000mm, esses picos anômalos positivos geralmente são resultantes da combinação de sistemas meteorológicos, como o posicionamento da ZCIT e a atuação de DOLs e, variações em forçantes oceânicas como uma maior disponibilidade de vapor d'água devido a anomalias positivas da TSM.

O aquecimento, tanto continental quanto oceânico, pode favorecer a intensificação de eventos climáticos e o aumento da incerteza em relação a projeções e previsões das variáveis oceano-atmosféricas como a precipitação, ventos, TSM, etc. Em Recife, a proximidade com o oceano, associada às condições regionais, faz com que o regime de chuvas e a ocorrência de eventos climáticos sejam altamente sensíveis a pequenas alterações na dinâmica oceano-atmosfera. As evidências atuais apontam que pequenas variações de pressão e elevação consistente da temperatura sobre o continente e o oceano Atlântico podem ter efeitos significativos no regime de chuvas locais, reforçando a necessidade de aperfeiçoar as previsões e manter o monitoramento da região, considerando o histórico de eventos extremos e as estimativas de intensificação desses eventos em cenários de mudanças climáticas.

4.2. Modelagem e validação

A modelagem consistiu na execução do modelo MLP e validação para a previsão de precipitação para um ponto na Região Metropolitana do Recife considerando diversos conjuntos de hiperparâmetros para se alcançar o melhor resultado possível. Além disso, é discutido a qualidade do ajuste obtido e possíveis melhorias.

4.2.1 Configuração do Modelo e Pré-processamento

O MLP foi configurado com três camadas ocultas, cada uma contendo 64 neurônios, e função de ativação do tipo *LeakyReLU* com *negative_slope* = 0,01. Foi aplicado *dropout* de 20% em cada camada para reduzir a chance de *overfitting*, além de *callbacks* de

EarlyStopping e *LearningRateMonitor* para interromper o treinamento quando o erro de validação não apresentasse melhorias significativas em 15 épocas.

Hiperparâmetros principais do modelo:

- Input_size: 240 (resultado da combinação de 5 variáveis em 48 timesteps passados);
- Output_size: 6 (previsão para 6 timesteps futuros);
- Hidden_size: 64;
- Número de camadas ocultas: 3;
- Taxa de aprendizado (learning_rate): 1×10^{-4} ;
- Batch_size: 32;
- Função de ativação: LeakyReLU;
- Dropout: 20%.

Divisão temporal dos dados:

- Período de treinamento: 1941 até 31/12/2009;
- Período de validação: 01/01/2010 até 2023.

Normalização e tratamento das variáveis:

- A precipitação total (TP) foi convertida para milímetros (quando necessário) e, em conjunto com TSM, SP (*Surface Pressure*), MSL (*Mean Sea Level Pressure*) e T2M (*Temperature at 2 meters*), normalizada com o *MinMaxScaler* no intervalo [0,1].
- Cada variável foi escalonada individualmente, evitando que alguma assumisse maior peso simplesmente por diferença de ordem de magnitude.

Essa padronização tem como objetivo facilitar a convergência do modelo, pois a homogeneidade de escala entre as variáveis de entrada costuma acelerar e estabilizar o processo de ajuste dos parâmetros (HAYKIN, 2001).

4.2.2 Avaliação do Desempenho

Após o treinamento, o desempenho do modelo foi avaliado por meio de quatro métricas de regressão: Erro Médio Absoluto (MAE), Erro Quadrático Médio (MSE), Raiz do Erro Quadrático Médio (RMSE) e Coeficiente de Determinação (R^2). A Tabela 4.1 apresenta os valores obtidos (exemplo representativo após algumas rodadas de treinamento):

Tabela 4.1 - Valores obtidos a partir de um exemplo representativo de treinamento e validação.

Métrica	Valor
MAE	79,3
MSE	94,9
RMSE	281,7
R^2	0,48

O R^2 inferior a 0,50, embora não seja desprezível e sugere que há ainda é necessário um maior treinamento dos dados, uma vez que pouco mais da metade da variabilidade não está sendo capturada. A Figura 4.2.1 ilustra a evolução do *loss* (perda) de treinamento e validação ao longo das épocas, mostrando tendência de convergência. Já a Figura 4.2.2 compara a curva das previsões com os valores reais de precipitação em um período de validação, revelando que o modelo acerta em linhas gerais a dinâmica de variação, mas apresenta desvios significativos em alguns picos de chuva.

Figura 4.2.1. Evolução do loss do treinamento e validação ao longo das épocas de treinamento.

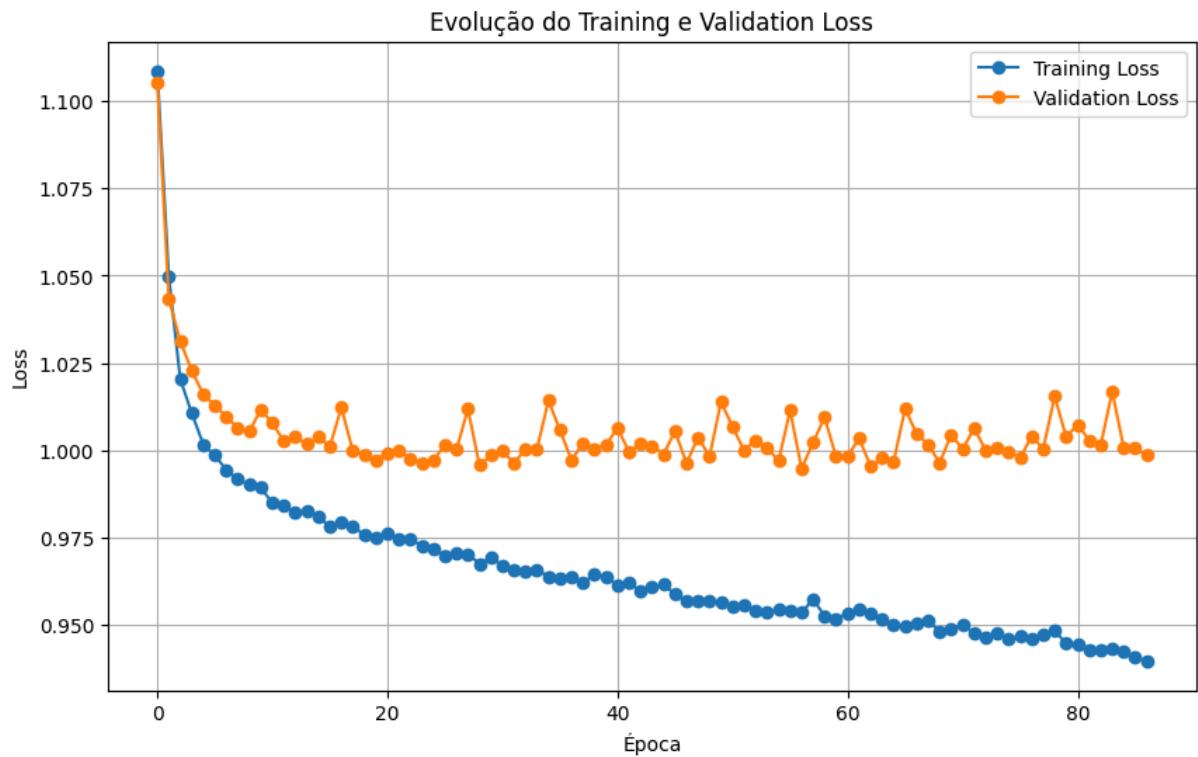
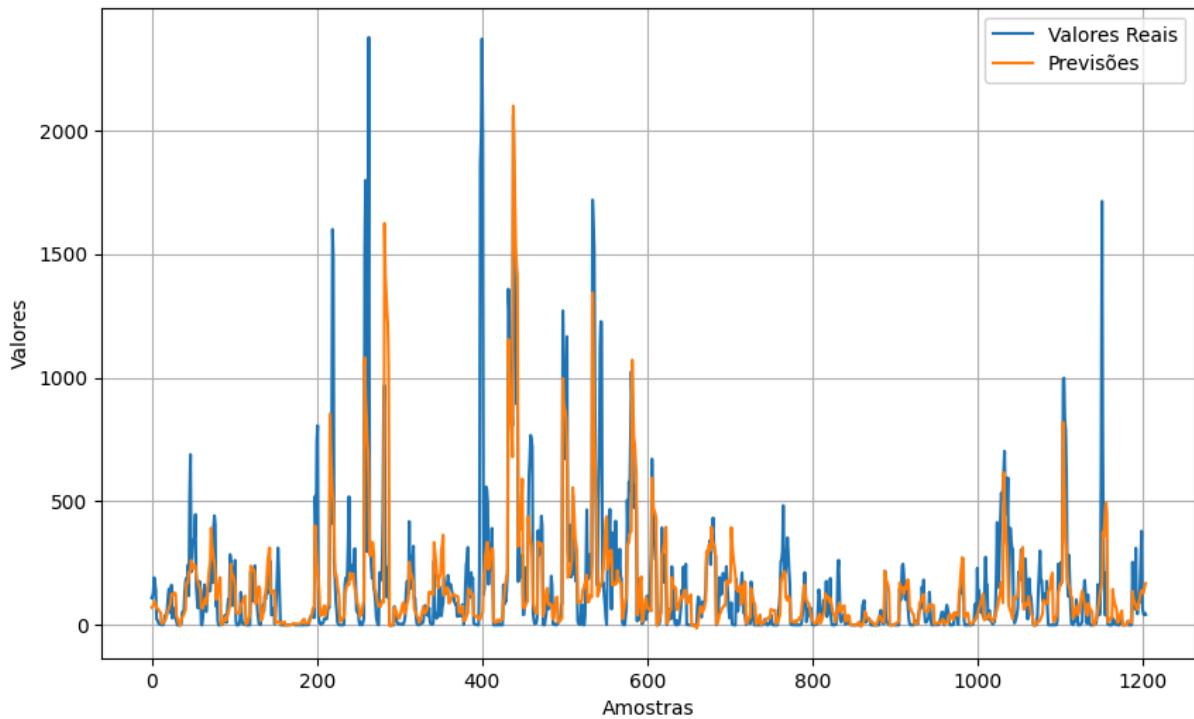


Figura 4.2.2 Comparação entre Valores Reais e Previsões do Modelo



4.2.2.1 Análise Qualitativa das Previsões

A comparação entre valores previstos e valores observados mostra que o MLP consegue seguir, em termos gerais, a tendência de alta ou baixa na precipitação. Entretanto, a dispersão dos erros tende a aumentar em eventos extremos, como chuvas muito intensas ou períodos muito secos. Esse comportamento é frequente em previsões meteorológicas baseadas em *machine learning*, pois os modelos podem ter dificuldade em capturar variações muito abruptas, resultantes de fenômenos de escala sinótica ou de mesoescala que não estejam devidamente representados em todas as variáveis de entrada.

Adicionalmente, a simplicidade do modelo pode limitar a identificação de padrões temporais complexos — por exemplo, períodos de persistência de tempo chuvoso modulados pela posição da ZCIT ou pela atuação de DOLs. Por isso, mesmo que o MLP consiga identificar tendências gerais, podem ocorrer desvios pontuais na amplitude da precipitação.

4.2.2.2 Limitações na Comparaçāo com Dados Observacionais

O conjunto de dados de reanálise ERA5 fornece uma base consistente e ampla de variáveis atmosféricas, mas é importante ressaltar que, em aplicações locais, podem ocorrer

discrepâncias em relação a observações reais obtidas por estações meteorológicas próximas à área de estudo. Essas diferenças podem ser atribuídas a fatores como:

Resolução espacial do ERA5: O intervalo de $0,25^\circ \times 0,25^\circ$ tende a suavizar microclimas, principalmente em cidades costeiras e densamente urbanizadas, onde efeitos locais — como ilhas de calor ou circulação de brisa — podem influenciar a precipitação de forma mais intensa e pontual.

Efeitos de urbanização: Regiões com grande concentração de edificações, vias asfaltadas e áreas impermeabilizadas apresentam maior propensão a acúmulo de calor, além de alterações nos fluxos de umidade. Tais condições podem não ser integralmente capturadas por reanálises de abrangência global.

Eventos de mesoescala e sub-diários: Fenômenos como as linhas de instabilidade, sistemas convectivos localizados e DOLs podem gerar picos de chuva de difícil representação em bases de dados globais ou em modelos de baixa resolução.

Em decorrência desses fatores, para modelos futuros com capacidades mais avançadas de previsão, se faz necessário a utilização de séries temporais de estações meteorológicas locais ou outros produtos de observação direta (por exemplo, dados de radar e pluviômetros automáticos), de modo a aferir e aprimorar a precisão dos resultados do MLP em capturar picos de precipitação e eventos extremos. Dessa forma, seria possível avaliar a robustez dos modelos em representar a variabilidade microclimática da cidade e, caso necessário, incorporar ajustes ou melhorias em sua arquitetura ou no conjunto de variáveis de entrada.

4.2.3 Discussão dos Resultados e Perspectivas

Os resultados apresentados mostram que o MLP consegue capturar parcialmente a variabilidade da precipitação, mas com desempenho que ainda pode ser melhorado. Algumas reflexões e pontos adicionais podem ser destacados:

1. Influência de forçantes de larga escala

A análise exploratória (Seção 4.1) evidenciou tendências de aquecimento no Atlântico e no continente, bem como variações de pressão relativamente sutis, porém significativas. Em anos com El Niño ou quando a TSM do Atlântico está acima da

média, a precipitação em Recife tende a mostrar desvios consideráveis, ora reforçando episódios intensos, ora reduzindo a quantidade de chuva. Essas condições podem ser mais bem capturadas com informações dinâmicas adicionais (por exemplo, índices como o Dipolo do Atlântico, a Oscilação Decadal do Pacífico ou o Multivariate ENSO Index).

2. Escalabilidade do modelo

Modelos MLP puros não levam em conta a correlação temporal de modo explícito, dependendo unicamente das janelas de entrada definidas (48 dias neste trabalho). Em estudos futuros, arquiteturas mais apropriadas para séries temporais, como LSTM, GRU, TCN ou até *Transformers* (Temporal Fusion Transformer – TFT), podem melhorar o aprendizado de longo prazo e o desempenho em eventos extremos (Lim et al., 2021).

3. Resolução espacial e dados locais

A adoção de reanálises globais (ERA5) com resolução de $0,25^\circ \times 0,25^\circ$ implica em perda de detalhes espaciais que podem ser decisivos para a precipitação em uma cidade costeira e densamente urbanizada. Integração com *downscaling* dinâmico ou estatístico, bem como a assimilação de dados de radar meteorológico, poderia aumentar a precisão local.

4. Impacto na tomada de decisão

Apesar de algumas limitações, a modelagem aqui demonstrada tem potencial para auxiliar sistemas de monitoramento e alerta da Defesa Civil. Mesmo um coeficiente de determinação na faixa de $\sim 0,48$ pode indicar utilidade prática em alertas de tendência de aumento de chuva, desde que haja complementação com outras ferramentas de previsão numérica e observações em tempo real (Guo et al., 2024).

5. Melhorias e trabalho futuro

- Aumento no número de variáveis: incluir vento, irradiação solar e cobertura de nuvens, entre outras, pode melhorar a identificação de cenários de convecção.

- Técnicas de *Ensemble*: combinar diferentes redes neurais ou métodos estatísticos pode aumentar a robustez da previsão.
- Balanceamento de dados extremos: dado que eventos de chuva muito intensa podem ser raros em comparação ao total de dias, podem-se empregar técnicas específicas de *resampling* ou ponderação de erro focadas em picos de chuva, contribuindo para reduzir os erros de previsão exatamente nos casos mais críticos (Scher e Messori, 2018).

Por fim, o MLP apresentou desempenho moderado explicando aproximadamente 48% da variabilidade da precipitação no período de validação. Ainda que seja um índice relativamente modesto para um problema tão complexo como a previsão de chuva em escala local, ele indica um caminho promissor para estudos de previsão baseados em *machine learning*. Os ajustes finos de arquitetura, o aperfeiçoamento dos dados de entrada (tanto em qualidade quanto em abrangência de variáveis) e a adoção de outras arquiteturas desenvolvidas especialmente para lidar com séries temporais são melhorias necessárias para o futuro desenvolvimento de modelos com maior capacidade de previsão.

5. CONCLUSÃO

Este trabalho teve como objetivo principal quantificar o papel de diferentes forçantes climáticas na variabilidade de chuvas na Região Metropolitana do Recife, por meio do uso de um modelo de rede neural para aprimorar a previsibilidade de eventos extremos de chuva. Para isso, foi desenvolvida uma abordagem que utilizou dados de reanálise (ERA5), envolvendo variáveis como temperatura a 2 metros, temperatura da superfície do mar, pressão ao nível do mar e precipitação.

Durante o desenvolvimento do trabalho, ficou evidente a influência da interação oceano-atmosfera sobre o regime de chuvas do Recife, especialmente no período chuvoso de março a agosto. As análises da variabilidade dessas variáveis ao longo do tempo mostraram tendências de aquecimento da atmosfera e do oceano, em consonância com as previsões de aquecimento global e mudanças climáticas. A precipitação, por sua vez, não apresentou um aumento acentuado em sua tendência, mas, ao longo das décadas, foram observados diversos eventos extremos e picos de anomalia relacionados a fenômenos sinóticos e de mesoescala, como os DOLs.

O modelo de rede neural profunda empregado foi o MLP, que buscou capturar a evolução da precipitação em curtos intervalos de previsão. Os resultados indicam que o modelo conseguiu explicar cerca de 48% da variação dos dados de validação ($R^2 \approx 0,48$), apresentando acertos na tendência geral de alta e baixa da precipitação, porém com dificuldades em reproduzir a intensidade dos eventos extremos.

Essa limitação se deve a diversos fatores, como a resolução espacial relativamente baixa em comparação com a complexidade de uma região litorânea e densamente urbanizada, a representação insuficiente de fenômenos de mesoescala e a própria arquitetura do MLP, que não modela explicitamente as dependências de longo prazo. Ainda assim, os resultados sinalizam que o uso de mais variáveis correlacionadas, a melhoria na qualidade dos dados e a adoção de arquiteturas avançadas de séries temporais (como Long Short-Term Memory e Temporal Fusion Transformers) podem ampliar a capacidade de previsão.

O desenvolvimento e o uso de modelos de aprendizagem profunda, que fazem parte do campo da inteligência artificial, têm impacto direto na gestão de riscos, especialmente em

áreas de alta vulnerabilidade e suscetíveis a eventos climáticos extremos. Uma previsão mais robusta permite que os órgãos governamentais e a sociedade em geral tomem decisões adequadas frente a eventos extremos, por meio de ações da Defesa Civil. A tendência global é que haja um aumento na quantidade de eventos extremos, bem como na sua intensidade, o que reforça a urgência em aprimorar técnicas de previsão.

Assim, as análises realizadas e a aplicação do MLP configuram um passo inicial relevante na busca por modelos de rede neural capazes de predizer, a partir de variáveis climáticas e informações locais, eventos de precipitação e possíveis anomalias positivas. Faz-se necessária a continuidade da pesquisa para aperfeiçoar os resultados.

AGRADECIMENTOS

O autor, a orientadora e co-orientador agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo financiamento dos Projetos SIMOPEC - Sistema operacional de modelagem acoplada oceano-atmosfera para o monitoramento e previsão de extremos climáticos nas zonas vulneráveis do Nordeste do Brasil, CNPq 406707/2022 e ao Projeto Análise climática e modelagem acoplada oceano-atmosfera de eventos extremos em resposta ao aquecimento da Região da Confluência Brasil-Malvinas (CBM), CNPq 421049/2023-5. O autor agradece as bolsas de Iniciação Científica, Processos 180116/2023-1 e 180991/2023-0 (Projeto SIMOPEC), concedidas de 01/01 a 30/10/2023 e Processo 177282/2023-1 (Projeto CBM).

REFERÊNCIAS

ALBUQUERQUE, Lucas Pontes de. DQ-Mesh: Fotografia 3D com imagem única em dispositivos mobile. 2024. **Dissertação (Mestrado em Ciência da Computação)** — Universidade Federal de Pernambuco, Recife, 2024.

AMORIM, Ana Cleide Bezerra; CHAVES, Rosane Rodrigues; SILVA, Cláudio Moisés Santos. Influence of the Tropical Atlantic Ocean's Sea Surface Temperature in the Eastern Northeast Brazil Precipitation. **Atmospheric and Climate Sciences**, v. 4, n. 5, p. 874–883, 2014. DOI: 10.4236/acs.2014.45077.

BALTAR DE SOUZA LEÃO, Eduardo; SILVEIRA ANDRADE, José Célio; FELIPE NASCIMENTO, Luís. Recife: A climate action profile. **Cities**, v. 116, p. 103270, 2021. DOI: 10.1016/j.cities.2021.103270.

BASHEER, I. A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods**, v. 43, n. 1, p. 3–31, 2000. DOI: 10.1016/S0167-7012(00)00201-3.

BIN SULAIMAN, Rejwan; SCHETININ, Vitaly; SANT, Paul. Review of Machine Learning Approach on Credit Card Fraud Detection. **Human-Centric Intelligent Systems**, v. 2, n. 1–2, p. 55–68, 2022. DOI: 10.1007/s44230-022-00004-0.

BOTELHO PIRES, Paulo; SANTOS, José Duarte; CASTRO, Pedro. Artificial Neural Networks and Discrete Choice Models: Comparing and Contrasting. In: **Encyclopedia of Information Science and Technology**, 6th ed. Hershey, PA: IGI Global, 2025. p. 1–25. DOI: 10.1007/978-981-97-1552-7_5.

CHIANG, J. C. H.; KUSHNIR, Y.; GIANNINI, A. Desconstruindo a variabilidade da Zona de Convergência Intertropical Atlântica: influência do gradiente de temperatura da superfície do mar transequatorial local e força remota do Pacífico equatorial oriental. **J Geophys**, 107(D1): 3–19, 2002. DOI: [10.1029/2000JD000307](https://doi.org/10.1029/2000JD000307).

CITAKOGLU, Hatice; COŞKUN, Ömer. Comparison of hybrid machine learning methods for the prediction of short-term meteorological droughts of Sakarya Meteorological Station in

Turkey. **Environmental Science and Pollution Research**, v. 29, n. 50, p. 75487–75511, 2022. DOI: 10.1007/s11356-022-21083-3.

COSTA, Rafaela Lisboa; GOMES, Heliofábio Barros; SILVA, Fabrício Daniel dos Santos; BAPTISTA, Gabriela Maria de Medeiros; GOMES, Helber Barros. Cenários de Mudanças Climáticas para a Região Nordeste do Brasil por meio da Técnica de Downscaling Estatístico. **Revista Brasileira de Meteorologia**, v. 36, n. 1, p. 81–92, 2021. Disponível em: http://old.scielo.br/scielo.php?script=sci_arttext&pid=S0102-77862020000500785. Acesso em: 14 fev. 2025.

COSTAS VAROTSOS et al. A Composite Tool for Forecasting El Niño: The Case of the 2023–2024 Event. **Forecasting**, v. 6, n. 1, p. 187–203, 7 mar. 2024.

DA SILVA, Vicente de Paulo Rodrigues. On climate variability in Northeast of Brazil. **Journal of Arid Environments**, v. 58, n. 4, p. 575–596, 2004. DOI: 10.1016/j.jaridenv.2003.12.002.

DE ALBUQUERQUE CAVALCANTI, Iracema F. The influence of extratropical Atlantic Ocean region on wet and dry years in North-Northeastern Brazil. **Frontiers in Environmental Science**, v. 3, 2015. DOI: 10.3389/fenvs.2015.00034.

DOS SANTOS, Daris Correia; SANTOS, Celso Augusto Guimarães; BRASIL NETO, Reginaldo Moura; DA SILVA, Richard Marques; DOS SANTOS, Carlos Antonio Costa. Precipitation variability using GPCC data and its relationship with atmospheric teleconnections in Northeast Brazil. **Climate Dynamics**, v. 61, n. 11–12, p. 5035–5048, 2023. DOI: [10.1007/s00382-023-06838-z](https://doi.org/10.1007/s00382-023-06838-z).

FERREIRA, Antonio Geraldo; MELLO, Namir Giovanni da Silva. Principais sistemas atmosféricos atuantes sobre a Região Nordeste do Brasil e a influência dos oceanos Pacífico e Atlântico no clima da região. **Revista Brasileira de Climatologia**, Fortaleza, v. 1, n. 1, p. 15–28, dez. 2005.

FERRERO BERMEJO, Jesús; GÓMEZ FERNÁNDEZ, Juan F.; OLIVENCIA POLO, Fernando; CRESPO MÁRQUEZ, Adolfo. A Review of the Use of Artificial Neural Network

Models for Energy and Reliability Prediction. **Applied Sciences**, v. 9, n. 9, p. 1844, 2019. DOI: 10.3390/app9091844.

GIANNINI, A.; SARAVANAN, R.; CHANG, P. O papel de pré-condicionamento da variabilidade do Atlântico Tropical na previsão da precipitação do Nordeste durante eventos ENSO. **Climate Dynamics**, v. 22, n. 8, p. 839–855, 2004. DOI: [10.1007/s00382-004-0420-2](https://doi.org/10.1007/s00382-004-0420-2).

GOMES, Heliofábio Barros; HERDIES, Dirceu Luis; ROCHA JÚNIOR, Rodrigo Lins da; SILVA, Fabrício Daniel dos Santos; COSTA, Rafaela Lisboa. Analysis of the Space–Temporal Trends of Wet Conditions over the Brazilian Northeast Region. **Journal of Applied Meteorology and Climatology**, v. 54, n. 12, p. 2551–2567, 2015.

GUO, Qingchun; HE, Zhenfang; WANG, Zhaosheng. Monthly climate prediction using deep convolutional neural network and long short-term memory. **Scientific Reports**, v. 14, n. 1, p. 17748, 2024. DOI: 10.1038/s41598-024-68906-6.

HASTENRATH, Stefan; LAMB, Peter. **Atlas Climático dos Oceanos Atlântico Tropical e Pacífico Oriental**. Madison: University of Wisconsin Press, 1977.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2. ed. Porto Alegre: Bookman, 2001.

Hersbach, H.; Sino, B.; Berrisford, P. *et al.* The ERA5 global reanalysis. **Quarterly Journal of the Royal Meteorological Society**, v. 146, p. 1999–2049, 2020. DOI: [10.1002/qj.3803](https://doi.org/10.1002/qj.3803).

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Recife (PE) | Cidades e Estados**. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/pe/recife.html>. Acesso em: 14 fev. 2025.

LIGHTBODY, Gordon; IRWIN, George W. Multi-layer perceptron based modelling of nonlinear systems. **Fuzzy Sets and Systems**, v. 79, n. 1, p. 31–44, 1996. DOI: [10.1016/0165-0114\(95\)00293-6](https://doi.org/10.1016/0165-0114(95)00293-6).

LIM, Bryan; ZOHREN, Stefan; ROBERTS, Stephen. Time-series forecasting with deep learning: a survey. **Philosophical Transactions of the Royal Society A**, v. 379, n. 2194, 2021. DOI: 10.1098/rsta.2020.0209

LUIZ DO VALE SILVA, T.; VELEDA, D.; ARAUJO, M.; TYAQUIÇÃ, P. Ocean–Atmosphere Feedback during Extreme Rainfall Events in Eastern Northeast Brazil. **Journal of Applied Meteorology and Climatology**, v. 57, p. 1211–1229, 2018. DOI: [10.1175/JAMC-D-17-0232.1](https://doi.org/10.1175/JAMC-D-17-0232.1).

MARENGO, José A. *et al.* Flash floods and landslides in the city of Recife, Northeast Brazil after heavy rain on May 25–28, 2022: Causes, impacts, and disaster preparedness. **Weather and Climate Extremes**, v. 39, p. 100545, 2023. DOI: 10.1016/j.wace.2022.100545.

MARUGÁN, Alberto Pliego; MÁRQUEZ, Fausto Pedro García; PEREZ, Jesus María Pinar; RUIZ-HERNÁNDEZ, Diego. A survey of artificial neural network in wind energy systems. **Applied Energy**, v. 228, p. 1822–1836, 2018. DOI: 10.1016/j.apenergy.2018.07.084.

NGUYEN, Dong; NGUYEN, Hoang; ONG, Hong; LE, Hoang; HA, Huong; DUC, Nguyen Thanh; NGO, Hoan Thanh. Ensemble learning using traditional machine learning and deep neural network for diagnosis of Alzheimer’s disease. **IBRO Neuroscience Reports**, v. 13, p. 255–263, 2022. DOI: 10.1016/j.ibneur.2022.08.010.

NOUSIAS, Stavros; PIKOULIS, Erion-Vasilis; MAVROKELALIDIS, Christos; LALOS, Aris S. Accelerating Deep Neural Networks for Efficient Scene Understanding in Multi-Modal Automotive Applications. **IEEE Access**, v. 11, p. 28208–28221, 2023. DOI: 10.1109/ACCESS.2023.3258400.

PANDEY, Vinay Kumar *et al.* Machine Learning Algorithms and Fundamentals as Emerging Safety Tools in Preservation of Fruits and Vegetables: A Review. **Processes**, v. 11, n. 6, p. 1720, 2023. DOI: 10.3390/pr11061720.

PIRES, Paulo Botelho; SANTOS, José Duarte; PEREIRA, Inês Veiga. Artificial Neural Networks: History and State of the Art. In: **Encyclopedia of Information Science and Technology**, 6. ed. IGI Global, 2023.

PINHEIRO GOMES, Evanice; PROGÊNIO, Mayke Feitosa; DA SILVA HOLANDA, Patrícia. Modeling with Artificial Neural Networks to estimate daily precipitation in the Brazilian Legal Amazon. **Climate Dynamics**, 2024. DOI: 10.1007/s00382-024-07200-7.

POULTON, Mary M. Chapter 3 Multi-layer perceptrons and back-propagation learning. In: **Computational neural networks for geophysical data processing**. [S.l.]: Pergamon, 2001. p. 27–53. DOI: 10.1016/S0950-1401(01)80017-3.

RAO, V. Brahmananda; CHAPA, Srinivasa R.; FRANCHITO, Sergio H. Decadal Variation of Atmosphere-Ocean Interaction in the Tropical Atlantic and its Relationship to the Northeast Brazil Rainfall. **Journal of the Meteorological Society of Japan**, v. 77, n. 1, p. 63–75, 1999. DOI: 10.2151/jmsj1965.77.1_63.

SCHER, Sebastian; MESSORI, Gabriele. Predicting weather forecast uncertainty with machine learning. **Quarterly Journal of the Royal Meteorological Society**, v. 144, n. 717, p. 2830–2841, 2018. DOI: 10.1002/qj.3410.

SILVA, Bruce Kelly N.; AMORIM, Ana Cleide B.; SILVA, Cláudio M. S.; LUCIO, Paulo S.; BARBOSA, Lara M. Rainfall-related natural disasters in the Northeast of Brazil as a response to ocean-atmosphere interaction. **Theoretical and Applied Climatology**, v. 138, n. 3–4, p. 1821–1829, 2019. DOI: 10.1007/s00704-019-02930-9.

SILVA JUNIOR, Marcos Antonio Barbosa da; FONSECA NETO, Gastão Cerquinha da; CABRAL, Jaime Joaquim da Silva Pereira. Análise estatística para detecção de tendências em séries temporais de temperatura e precipitação no Recife-PE. **Revista de Geografia**, v. 37, n. 1, p. 222, 2020. DOI: 10.51359/2238-6211.2020.239373.

SMITH, J. L. Advances in neural networks and potential for their application to steel metallurgy. **Materials Science and Technology**, v. 36, n. 17, p. 1805–1819, 2020. DOI: 10.1080/02670836.2020.1839206.

SOUZA, Itamara Parente de; ANDREOLI, Rita Valéria; KAYANO, Mary Toshie; VARGAS, Franci Flores; CERÓN, Wilmar L.; MARTINS, Jorge Alberto; FREITAS, Edmilson; DE SOUZA, Rodrigo Augusto Ferreira. Seasonal precipitation variability modes over South America associated to El Niño-Southern Oscillation (ENSO) and non-ENSO components during the 1951–2016 period. **International Journal of Climatology**, v. 41, n. 8, p. 4321–4338, 2021. DOI: 10.1002/joc.7075.

SUDHA, L.; DILLIBABU, R.; SRIVATSA SRINIVAS, S.; ANNAMALAI, A. Optimization of process parameters in feed manufacturing using artificial neural network. **Computers and Electronics in Agriculture**, v. 120, p. 1–6, 2016. DOI: 10.1016/j.compag.2015.11.004.

TKÁČ, Michal; VERNER, Robert. Artificial neural networks in business: Two decades of research. **Applied Soft Computing**, v. 38, p. 788–804, 2016. DOI: 10.1016/j.asoc.2015.09.040.

XIE, Wenhong; XU, Guangjun; ZHANG, Hongchun; DONG, Changming. Developing a deep learning-based storm surge forecasting model. **Ocean Modelling**, v. 182, p. 102179, 2023. DOI: 10.1016/j.ocemod.2023.102179.

ZHANG, Wei; LI, Xiaoyan; WANG, Peng; LIU, Jian. Short-Term Rainfall Forecasting Using Multi-Layer Perceptron. **Water**, v. 12, n. 9, p. 2599, 2020. Disponível em: <https://www.mdpi.com/2073-4441/12/9/2599>. Acesso em: 14 fev. 2025.