
**Análise de Séries Temporais com uso de Redes
Neurais Artificiais em dados Meteorológicos
para Previsão de Chuva e Eventos Climáticos
Severos**

Augusto Carvalho Soares



UFU

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

FACULDADE DE COMPUTAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Uberlândia

2022

Augusto Carvalho Soares

**Análise de Séries Temporais com uso de Redes
Neurais Artificiais em dados Meteorológicos
para Previsão de Chuva e Eventos Climáticos
Severos**

Dissertação de mestrado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Ciência da Computação

Orientador: Prof. Dr Laurence Rodrigues do Amaral

Uberlândia

2022

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

S676
2022

Soares, Augusto Carvalho, 1981–
Análise de Séries Temporais com uso de Redes Neurais
Artificiais em dados Meteorológicos para Previsão de Chuva
e Eventos Climáticos Severos [recurso eletrônico] / Augusto
Carvalho Soares. – 2022.

Orientador: Laurence Rodrigues do Amaral.
Dissertação (Mestrado) – Universidade Federal de
Uberlândia, Pós-graduação em Ciência da Computação.
Modo de acesso: Internet.
Disponível em: <https://doi.org/10.14393/ufu.di.2022.680>
Inclui: bibliografia.
Inclui: ilustrações.

1. Computação. I. Amaral, Laurence Rodrigues do, 1978–,
(Orient.). II. Universidade Federal de Uberlândia. Pós-
graduação em Ciência da Computação. III. Título.

CDU: 681.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Ciência da Computação				
Defesa de:	Dissertação de Mestrado 25/2022, PPGCO				
Data:	22 de dezembro de 2022	Hora de início:	08:00	Hora de encerramento:	11:18
Matrícula do Discente:	12112CCP005				
Nome do Discente:	Augusto Carvalho Soares				
Título do Trabalho:	Análise de Séries Temporais com uso de Redes Neurais Artificiais em dados Meteorológicos para Previsão de Chuva e Eventos Climáticos Severos				
Área de concentração:	Ciência da Computação				
Linha de pesquisa:	Inteligência Artificial				
Projeto de Pesquisa de vinculação:	-				

Reuniu-se, por videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Ciência da Computação, assim composta: Professores Doutores: Flávio de Oliveira Silva - FACOM/UFU; Edimilson Batista dos Santos - UFSJ e Laurence Rodrigues do Amaral, orientador do candidato.

Os examinadores participaram desde as seguintes localidades: Edimilson Batista dos Santos - São João del Rei/MG; Laurence Rodrigues do Amaral - Patos de Minas/MG, Flávio de Oliveira Silva - Uberlândia/MG. O discente participou da cidade de Patos de Minas/MG.

Iniciando os trabalhos o presidente da mesa, Prof. Dr. Laurence Rodrigues do Amaral, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e

achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Flávio de Oliveira Silva, Professor(a) do Magistério Superior**, em 10/01/2023, às 10:08, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Laurence Rodrigues do Amaral, Professor(a) do Magistério Superior**, em 11/01/2023, às 08:50, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Edimilson Batista dos Santos, Usuário Externo**, em 13/01/2023, às 15:17, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4148738** e o código CRC **B6BE3D3A**.

Dedico este trabalho à minha mãe Vanilda (in memoriam), que devotou sua vida por mim, fonte de minha força, minha coragem e fé, que em seus últimos dias me incumbiu a tarefa de cursar Mestrado.

E à minha amada esposa Máyra, que soube compreender e tolerar as dificuldades, me dando suporte e apoio para que pudesse progredir e principalmente manteve a paciência.

Agradecimentos

Nessa jornada de inúmeros desafios, extenso estudo, dedicação e esforço, fico-me obrigado a agradecer alguns que de uma maneira ou outra foram fundamentais para que eu pudesse alcançar meus objetivos, permitindo-me realizar esse sonho. Assim, tento aqui, expressar em palavras o quão grato sou pelo fato de estarem comigo nesse tempo e a importância que tiveram.

A **Deus**, que pela dádiva da vida, permitiu que eu viesse a este mundo, presenteando-me com dons e talentos, os quais me são muito úteis, não só nos trabalhos acadêmicos, mas em todas as áreas de minha vida. Obrigado Senhor pai do céu.

A meus pais **Augusto** e **Vanilda** (*in memoriam*), que me criaram com todas as dificuldades inerentes e separações, mas que fizeram questão de fixar em mim a importância dos estudos, além de uma singular visão crítica da ciência.

A meu irmão **Tiago** (*in memoriam*), que apesar de nossa prematura separação, esteve em meus pensamentos todo o tempo, a cada função escrita, a cada linha de código. Não fosse pelo cedo chamado de Deus, certamente seria Doutor de notável competência.

Ao **Prof. Dr. Laurence Rodrigues do Amaral**, em especial, pela orientação, foi sem dúvidas meu melhor guia. As vezes nem tão merecido, mas elogiava-me para me manter motivado. Horas de dedicação ao meu acompanhamento, assistência e conselhos. Obrigado pela confiança a mim depositada.

Aos membros da banca examinadora, **Prof. Dr. Flávio de Oliveira Silva**, **Prof. Dr. Edimilson Batista dos Santos**, que de maneira muito gentil, aceitaram participar de minha avaliação, contar com nomes tão fortes nesta banca, traz maior credibilidade ao meu trabalho e o muito enaltecem.

Aos professores das disciplinas cursadas, que em momento extraordinário de pandemia não mediram esforços para transmitir o conhecimento canônico disciplinar e científico, trazendo aos alunos a reflexão das novas possibilidades de uso de novas tecnologias.

Ao **Prof. Dr. Matheus de Souza Gomes**, coordenador do Laboratório de Bioinformática e Análises Moleculares (LBAM), que cedeu em empréstimo uma potente máquina para a execução da bateria de testes, a qual foi fundamental para o sucesso deste trabalho.

Ao colega e amigo **Danilo César Pereira**, que em muito me ajudou, estudamos muito, escrevemos e publicamos em conjunto um artigo, compartilhamos experiências e aprendizados que serão levados por toda a vida. Obrigado pela parceria amigo.

Aos colegas do CTIC, por terem me ajudado, atendendo às Ordens de Serviço quando eu estava muito ocupado nas pesquisas.

Aos meus familiares por apoiarem e compreenderem minha falta de atenção e o meu isolamento nos estudos e pesquisas, atravessando madrugadas e finais de semana. Em especial ao tio **José Antônio Batista**, que suportou sozinho o trabalho na fazenda nos momentos que estive por este trabalho ocupado.

Por fim mas não menos importante, pelo contrário, à minha amantíssima esposa **Máyra**, que mesmo eu estando em casa por força da pandemia, não dava a ela a merecida atenção por estar tão concentrado, e que por noites infindáveis se deitou sem a minha companhia ao irritante som de teclas. Ainda assim, estive junto me auxiliando em todas as etapas (montagem de protótipos, testes, interpretação de resultados, escritas e revisões). Obrigado Nêga.

*“Todos os processos estáveis, devemos prever.
Devemos controlar todos os processos instáveis.”*

Descrevendo a aspiração de John von Neumann para a aplicação de computadores suficientemente grandes para resolver os problemas da meteorologia, apesar da sensibilidade do clima a pequenas perturbações.

(Freeman Dyson)

Resumo

A previsão do tempo e o prognóstico do clima se tornaram alguns dos mais úteis recursos do mundo moderno. O aquecimento global é um problema grave. As Normas Climatológicas no Brasil estão mudando de maneira preocupante. Relatório recente do INMET (2022) traz os estudos de alterações nos últimos 20 anos, mostrando uma elevação de 1,6° Celsius na temperatura média. Projeções a longo prazo, apontam para um cenário em que pode haver colapso de ecossistemas e cadeias produtivas. Estas mudanças já podem ser percebidas na crescente ocorrência de eventos climáticos severos. É imprescindível saber antecipadamente quando da ocorrência de tais eventos para melhor enfrentar suas consequências. A mitigação de desastres naturais pode ser alcançada através da antevista das condições climáticas e o prévio aviso à população pelas autoridades ante a um eminente evento severo. A ciência busca por novos e precisos métodos para a correta previsão do tempo, algumas soluções propostas indicam o uso de RNAs para a classificação, contudo, pouco ainda se tem nas tarefas de regressão por métodos de previsão não tradicionais. Este trabalho propõe a aplicação de RNAs regressivas para a tarefa de previsão do volume de chuva. Os modelos foram submetidos a uma bateria de testes no estilo “força bruta” para encontrar seus melhores parâmetros. Os resultados obtidos foram de 80% e 81% de acerto para LSTM e MLP respectivamente, comprovando a hipótese de ser possível a previsão do tempo pelo uso de IA e RNAs.

Palavras-chave: Séries Temporais. Redes Neurais Artificiais. LSTM. Previsão. Chuva.

Abstract

Weather forecasting and climate prediction have become some of the most useful resources in the modern world. Global warming is a serious problem. The Climatological Normals in Brazil are changing in a worrying way. A recent INMET report (2022) brings studies of changes in the last 20 years, showing an increase of 1.6° Celsius in the average temperature. Long-term projections point to a scenario in which ecosystems and production chains may collapse. These changes can already be seen in the increasing occurrence of severe weather events. It is essential to know in advance when such events will occur in order to better face their consequences. The mitigation of natural disasters can be achieved through the anticipation of climatic conditions and the previous warning to the population by the authorities before an imminent severe event. Science searches for new and accurate methods for correct weather forecasting, some proposed solutions indicate the use of ANNs for classification, however, there is still little known about regression tasks for non-traditional forecasting methods. This work proposes the application of regressive ANNs for the task of rainfall volume forecasting. The models were submitted to a battery of tests in “brute force” style, to find their best parameters. The results obtained were 80% and 81% of correct for LSTM and MLP ANNs respectively, proving the hypothesis that weather forecasting is possible using AI and ANNs.

Keywords: Time Series. Artificial Neural Networks. LSTM. Weather. Forecasting.

Lista de ilustrações

Figura 1 – Ilustração do equilíbrio energético	36
Figura 2 – Ilustração do funil escalar para as previsões	39
Figura 3 – Diagrama do modelo COSMO	40
Figura 4 – Componentes do sistema WRF + ARW	42
Figura 5 – Arquitetura de uma rede neural convolucional	45
Figura 6 – Ilustração de uma rede neural do tipo MLP	46
Figura 7 – ConvLSTM, camadas neurais e a retropropagação.	47
Figura 8 – Arquiteturas de redes neurais e suas aplicações nas pesquisas do clima.	50
Figura 9 – Fluxo das etapas de execução	53
Figura 10 – Arquitetura Dense	56
Figura 11 – Arquitetura LSTM	57
Figura 12 – Arquitetura MLP	58
Figura 13 – Ilustração da topologia de comunicação.	62
Figura 14 – Diagrama de blocos do microcontrolador ATmega328p.	64
Figura 15 – Diagrama de blocos da CPU AVR	66
Figura 16 – Processo de comunicação do sensor DHT	69
Figura 17 – Ilustração do mecanismo pluviométrico.	71
Figura 18 – Diagrama de blocos do módulo ESP8266.	71
Figura 19 – Diagrama de blocos do barramento I2C	72
Figura 20 – Esquema de comunicação usando o barramento I2C	73
Figura 21 – Diagrama de Blocos do barramento de comunicação SPI	74
Figura 22 – Comunicação do barramento SPI	74
Figura 23 – Projeção em 3 dimensões da placa do módulo de coleta.	76
Figura 24 – Circuito impresso em papel fotográfico para termo transferência.	77
Figura 25 – Processo de corrosão da placa de circuito	77
Figura 26 – Registros gravados no sistema de bando de dados	78
Figura 27 – Visão gráfica da oscilação das variáveis explicativas e explicada	82
Figura 28 – Visão gráfica por mapa de calor da correlação entre as variáveis	83

Figura 29 – Visão gráfica da distribuição pluviométrica por mês e por faixa de classificação	84
Figura 30 – Estabilidade dos métodos avaliados	88
Figura 31 – Desempenho dos métodos avaliados	88
Figura 32 – Predição modelo MLP (conjunto teste)	89
Figura 33 – Predição modelo LSTM (conjunto teste)	90

Lista de quadros

Quadro 1 – Especificações Técnicas DHT-22	69
Quadro 2 – Especificações Técnicas BME280	70
Quadro 3 – Pinagem para a unidade central	76

Lista de tabelas

Tabela 1 – Classificação das faixas de probabilidade	38
Tabela 2 – <i>Slice</i> temporal de registros (INMET)	54
Tabela 3 – <i>Slice</i> temporal de registros (base própria)	55
Tabela 4 – Comparação de métricas de desempenho	87
Tabela 5 – Comparação da previsão dos métodos com o realizado	91

Lista de siglas

AGs Algoritmos Genéticos

COSMO Consortium for Small-scale Modeling

EMBRAPA Empresa Brasileira de Pesquisa Agropecuária

GOES Geostationary Operational Environmental Satellite

IA Inteligência Artificial

IDE Integrated Development Environment

INMET Instituto Nacional de Meteorologia

INPE Instituto Nacional de Pesquisas Espaciais

IoT Internet of Things

LSTM Long Short Term Memory

ML Machine Learning

MLP Multilayer Perceptron

NWP Numerical weather prediction

RNAs Redes Neurais Artificiais

RNCs Redes Neurais Convolucionais

UART Universal Asynchronous Receiver/Transmitter

USB Universal Serial Bus

Lista de símbolos

Grandezas Físicas

°C	Celsius
"	polegada
µs	microsegundo
ms	milisegundo
GHz	Giga Hertz
MHz	Mega Hertz
DC	Corrente contínua
mm	mililitro
PPM	Partes por Milhão
v	Volts

Grandezas Computacionais

GB	Giga bytes
MB	Mega bytes
B	byte
b	bit
KB	kilobyte

Sumário

1	INTRODUÇÃO	29
1.1	Motivação	30
1.2	Objetivos e Desafios da Pesquisa	31
1.3	Hipótese	31
1.4	Contribuições	32
1.5	Organização da Dissertação	32
2	FUNDAMENTAÇÃO TEÓRICA	35
2.1	Bases Meteorológicas	35
2.1.1	Fenômenos e processos atmosféricos	36
2.1.2	Precipitação	37
2.1.3	Classificação, avisos e severidade	37
2.1.4	Previsibilidade	38
2.1.5	Modelos clássicos de previsão	39
2.2	Bases Matemáticas e Estatísticas	42
2.2.1	Séries Temporais	42
2.2.2	Regressões não lineares e regressão logística	43
2.3	Bases Computacionais	44
2.3.1	IA e Redes Neurais Artificiais	44
2.3.2	Redes Neurais Convolucionais	45
2.3.3	Multilayer Perceptron	45
2.3.4	LSTM e YConvLSTM	46
3	TRABALHOS CORRELATOS	49
4	PROPOSTA	53
4.1	Metodologia	53
4.1.1	Etapas de aquisição de dados	54

4.1.2	Apresentação das bases	54
4.1.3	Etapa de pré-processamento	55
4.1.4	Modelos avaliados	55
4.1.5	Temporalidade de observações consideradas	59
4.1.6	Etapa de predição	59
4.2	Otimizações de desempenho	59
5	ESTAÇÃO METEOROLÓGICA IOT	61
5.1	Visão da topologia	62
5.2	O nó de coleta de dados	63
5.2.1	O Arduino Nano	63
5.2.2	Módulo de relógio	68
5.2.3	Módulo de armazenamento	68
5.2.4	Módulo sensor DHT-22	68
5.2.5	Módulo sensor BME280	70
5.2.6	Módulo sensor pluviométrico	70
5.2.7	Módulo de rede WiFi	71
5.3	Protocolo de comunicação I2C	72
5.4	Protocolo de comunicação SPI	73
5.5	A central de armazenamento e processamento	74
5.6	A comunicação entre os nós de coleta e a central	75
5.7	O projeto eletrônico	75
5.8	Montagem	77
5.9	Implantação	78
6	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	81
6.1	Visualização	81
6.2	Método para a avaliação	84
6.2.1	Medidas de avaliação	85
6.3	Experimentos	85
6.3.1	Ambiente de testes	85
6.3.2	Otimização de parâmetros e hiperparâmetros	86
6.4	Avaliação dos Resultados	87
6.4.1	Testes de validação cruzada	90
6.4.2	Comparação com outras fontes preditoras	91
7	CONCLUSÃO	93
7.1	Objetivos alcançados	93
7.2	Hipóteses Verificadas	94
7.3	Principais Contribuições	94

7.4	Trabalhos Futuros	95
7.5	Contribuições em Produção Bibliográfica	95
REFERÊNCIAS		97
APÊNDICE A	DIAGRAMA ESQUEMÁTICO	103
APÊNDICE B	LAYOUT DAS TRILHAS DA PCB	104
APÊNDICE C	MOSAICO DO PROCESSO DE CONSTRUÇÃO	105
APÊNDICE D	PLACA DA ESTAÇÃO PRONTA	106
APÊNDICE E	PROGRAMA ALL TESTS	107
APÊNDICE F	PROGRAMA BEST SET FINDER	108
APÊNDICE G	VALIDAÇÃO CRUZADA	109
G.1	Validação 10-Fold para LSTM	109
G.2	Validação 10-Fold para MLP	110

Introdução

A previsão do tempo e o prognóstico do clima se tornaram alguns dos mais úteis recursos do mundo moderno. Eles condicionam nossas atividades no dia a dia e planejamentos futuros. As consultas a estas previsões ficam cada vez mais necessárias e as fazemos quase que instintivamente.

Desde a pré-história, no período neolítico, com o assentamento do homem em comunidades, a agricultura se tornou vital para a nossa sobrevivência. Dominar as técnicas de semente, cultivo, controle de pragas, colheita e armazenamento, tem sido um dos grandes desafios. O conhecimento do clima é uma peça chave para obtenção desse domínio.

Como uma das mais úteis ferramentas de gestão para o setor agropecuário, a meteorologia, pode antever os eventos climáticos, como períodos de estiagem e chuvosos, além de possíveis distúrbios da normalidade, permitindo melhor planejar e definir as diferentes etapas do processo agrícola como semente e colheita. As atividades de pecuária também são bastante impactadas pelos eventos climáticos.

Na idade contemporânea, a partir do fenômeno do êxodo rural, surgiram grandes conglomerados urbanos, destes, muitos não tiveram o devido planejamento estrutural, e fatores como a demasiada impermeabilização do solo, agravam o problema das inundações (TUCCI, 2007).

A Defesa Civil é um órgão centralizador e coordenador de ações que visam prevenção, mitigação, preparação, resposta e recuperação de riscos de desastres naturais, possui membros da sociedade civil e das três esferas administrativas.

Ferramentas de monitoramento e sistemas de auxílio à decisão são de suma importância para que a Defesa Civil seja capaz de emitir alertas para a população, em caso de risco de temporais que possam causar alagamentos e outros eventos desastrosos.

Como demonstram recentes relatórios dos principais órgãos meteorológicos mundiais (INMET, 2022; NASA, 2022), o fenômeno do aquecimento global causa grandes alterações climáticas como o desajuste no período das estações do ano, grandes períodos de estiagem, subida do nível do mar pelo derretimento das calotas polares, risco de extinção de inúmeras espécies da fauna e flora promovendo uma drástica redução da biodiversidade.

A Inteligência Artificial (IA) tem aberto novos horizontes em diversas áreas do conhecimento científico, trazendo possibilidades ainda não exploradas. Dentre essas áreas, a meteorologia pode se beneficiar fortemente dessas novas possibilidades. A aplicação de tecnologias como Redes Neurais Artificiais (RNAs), Algoritmos Genéticos (AGs), processamento paralelo e distribuído, permite patamares de previsibilidade jamais conseguidos.

A aplicação de IA por RNAs em problemas meteorológicos têm figurado em grande evidência nas universidades e centros de pesquisa aeroespacial e meteorológicos. Contudo, há muito o que evoluir, e neste contexto a antevisão de eventos de média e alta severidade ainda é relativamente pouco explorada.

Este trabalho traz a aplicação de métodos de RNAs na previsão de dados meteorológicos a fim de detectar eventos severos. Para isto, foi projetado e implementado um dispositivo eletrônico para a coleta automatizada dos dados meteorológicos. Este dispositivo de *hardware* utiliza plataforma *Internet of Things (IoT)*, e os dados coletados compõem um dos *datasets* utilizados nesta pesquisa. O outro *dataset* utilizado na pesquisa foi o banco de dados meteorológicos oficial do Instituto Nacional de Meteorologia (INMET). As RNAs foram aplicadas nos dois *datasets* e foram comparadas em termos de resultados e medidas de avaliação de eficácia e eficiência.

1.1 Motivação

A previsibilidade das condições do clima e do tempo são vitais para o setor agropecuário. Como exemplo, Assad e Pinto (2008) e Assad *et al.* (2020) da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) trazem estudos preocupantes. Muitos cientistas já elencam os fatores climáticos adversos como sendo a segunda maior causa de perdas na produção agrícola, ficando atrás somente do ataque de pragas e doenças. No cenário internacional a preocupação é também relatada em Fischer *et al.* (2021) e Hickel *et al.* (2021).

O aquecimento global é um problema grave. As Normais Climatológicas no Brasil estão mudando de maneira preocupante. Relatório recente do INMET (2022) traz os estudos de alterações nos últimos 20 anos, mostrando uma elevação de 1,6° Celsius na temperatura média. Projeções a longo prazo, apontam para um cenário em que pode haver colapso de ecossistemas e cadeias produtivas. Urgindo pronta adoção de medidas para o seu enfrentamento.

Nas grandes cidades, a ocorrência de chuvas tropicais causam alagamentos, que infringem grandes prejuízos à população, e até mortes. Tanto o livro de Tucci (2007) quanto seu artigo em 2008 destacam métodos de gestão e ocupação do solo urbano, visando um planejamento preventivo através da gestão integrada das águas urbanas. Mas para além do manejo correto da ocupação de espaços, há ainda que se pensar em maneiras de previsão de eventos climáticos de alta severidade, propagação alertas e planos de contingenciamento.

A importância de termos ferramentas capazes de prever eventos climáticos severos com o mínimo de antecedência necessária para que se possa tomar medidas a fim de evitar maiores prejuízos é incontestável.

Com o objetivo de obter tais ferramentas de prognóstico climático, um grande movimento de pesquisa e desenvolvimento tem se formado tanto nas universidades quanto nas empresas de agronegócio. Vários trabalhos estão na vanguarda das pesquisas nessa área. Alguns dos trabalhos atualmente em destaque são Culclasure (2013) e Hewage *et al.* (2020). Destaca-se ainda no cenário nacional, os trabalhos de Souto (2018) e de Porto *et al.* (2022).

Todavia, estes trabalhos buscam resolver as questões de previsibilidade, e em sua grande maioria o objetivo é apenas aumentar a certeza (acurácia) de previsão em determinado método para a ocorrência de algum evento específico. Não há um estudo profundo sobre a aplicação de RNAs, suas otimizações e configuração dos hiperparâmetros aplicados para dados meteorológicos.

Esses pontos ainda não abordados são de grande relevância para a tarefa de detecção de eventos severos.

1.2 Objetivos e Desafios da Pesquisa

O tema impõe grandes desafios como a grande quantidade de variáveis e a ausência de dados confiáveis e locais. Embora se tenha dados históricos de décadas, as bases de dados são esparsas e não padronizadas, tendo uma grande ocorrência de *missing values* e *outliers*, tornando-se obrigatório o pré-processamento dos dados. Uma dificuldade extra é o grande volume de dados, demandando alto custo computacional.

O objetivo geral deste trabalho é comparar a eficácia preditiva de RNAs aplicadas à tarefa de detecção de eventos severos em *datasets* com dados climatológicos.

Objetivos específicos:

- Construir um dispositivo de *hardware* IoT, para a coleta automatizada de dados;
- Fazer análise exploratória e estatística dos dados coletados;
- Aplicar técnicas de pré-processamento nas bases de dados;
- Implementar RNAs para regressão;
- Obter a previsão futura da ocorrência de chuva.
- Comparar os resultados preditivos obtidos com outras fontes.

1.3 Hipótese

Acredita-se ser possível prever eventos chuvosos por meio da aplicação de técnicas de IA em *datasets* locais de dados meteorológicos, cuja configuração se apresente na forma de séries temporais curtas.

- Através do uso de redes neurais artificiais, consegue-se obter taxas de previsibilidade da ocorrência de chuva, que sejam aceitáveis, isto é, com o mínimo de 50% de acerto.
- É possível determinar que os modelos de Inteligência Artificial consigam obter pelo menos a mesma eficácia preditiva dos modelos numéricos.
- A possibilidade é de que hajam padrões bem definidos de sazonalidade na ocorrência de um evento de grandes proporções, podendo-se assim estimar a data de novas ocorrências.
- Esses padrões, podem ser encontrados por ferramentas de agrupamento de dados e redes neurais artificiais.
- Existem padrões na ocorrência de eventos severos. E estes padrões apresentam alguma rigidez cronológica.

1.4 Contribuições

Como contribuição para a comunidade científica, este trabalho implementa redes neurais artificiais regressivas para a tarefa de previsão da ocorrência de chuvas, efetuando exaustivos testes para determinar as melhores configurações de seus parâmetros.

Outra contribuição é a definição de projeto e construção de um modelo de estação meteorológica automática de baixo custo que poderá beneficiar toda a cadeia de agricultura e pecuária, com a possibilidade de coleta de dados locais, e a Defesa Civil, auxiliando na tomada de decisões.

Destacam-se neste trabalho três principais contribuições computacionais, a redução da complexidade dos modelos pela simplificação e otimização dos *datasets* na fase de pré-processamento, um método de testes para encontrar os melhores parâmetros para os modelos usando técnica de “força bruta”, o ganho de performance pela integração de pacotes de *softwares* e bibliotecas, aliada à compilação nativa e personalizada.

Para além das contribuições computacionais e científicas, destaca-se ainda o alto fator de **impacto social**, pois a área-fim deste trabalho é de grande interesse e relevância para toda a população.

1.5 Organização da Dissertação

O restante deste trabalho está organizado para auxiliar a compreensão de conceitos e fundamentos básicos, o problema, as hipóteses levantadas, o estudo da literatura e trabalhos análogos, a proposta de contribuição para a solução e discussões sobre os resultados alcançados.

No Capítulo 2 apresentam-se conceitos e fundamentos teóricos nos quais este trabalho se ancorou. No Capítulo 3 são apresentados trabalhos correlatos e discussões sobre como o problema foi atacado por cada um. O Capítulo 4 apresenta o método proposto. O Capítulo 5 apresenta o projeto e implementação de uma estação meteorológica do tipo automática desenvolvida em plataforma IoT. O Capítulo 6 detalha os experimentos realizados, suas configurações e conduções, bem como os resultados obtidos. Por fim, o trabalho é concluído no Capítulo 7 que lista as principais contribuições e indica caminhos e possibilidades para trabalhos futuros.

Fundamentação Teórica

A meteorologia é uma ciência por vezes tida como um mero e simples olhar para a ocorrência de chuvas, mas que na verdade é bastante complexa. Envolve enorme gama de análises, a observação de muitas variáveis se torna necessária, desde a escala local até a escala global. Com isso, o volume de dados torna-se gigantesco e as dificuldades vêm na mesma proporção.

O problema da previsão do tempo não é de simples resolução, pois suas características matemáticas são altamente não lineares, além de fatores causais altamente mutáveis e não intimamente correlacionados do ponto de vista estatístico. Uma melhor estratégia de se resolver um problema assim complicado é a abordagem multidisciplinar, envolvendo algumas áreas do conhecimento, e a computação através dos métodos de IA, pela aplicação de RNA pode em muito contribuir.

Sendo assim, este capítulo divide as bases teóricas em meteorológicas, matemáticas e computacionais.

2.1 Bases Meteorológicas

A meteorologia é o estudo da atmosfera e seus fenômenos. O próprio termo remonta ao filósofo grego Aristóteles, que por volta de 340 a.C, escreveu um livro sobre filosofia natural intitulado “*Meteorologica*” (AHRENS; HENSON, 2018).

Em “*Meteorologica*”, Aristóteles tentou explicar os fenômenos atmosféricos de maneira filosófica e especulativa. Embora muitas de suas ideias fossem consideradas errôneas, o trabalho de Aristóteles permaneceu uma influência dominante no campo da meteorologia por quase dois mil anos (AHRENS; HENSON, 2018).

Na meteorologia alguns conceitos devem estar bem compreendidos para que se possa entender com clareza as causas de seus fenômenos.

Nesse sentido invocamos uma aula dos professores Sentelhas *et al.* da Escola Superior de Agricultura Luiz de Queiroz (ESALQ) que ajuda a distinguir tempo de clima.

[...]Denomina-se tempo à descrição instantânea, enquanto que a descrição média é denominada de clima. Logo, **tempo** é o estado da atmosfera num local e instante, sendo caracterizado pelas condições de temperatura, pressão, concentração de vapor, velocidade e direção do vento, precipitação; e **clima** é a descrição média, valor mais provável, das condições atmosféricas nesse mesmo local.[...]

[...] Clima é uma descrição estática que expressa as condições médias (geralmente, mais de 30 anos) do sequenciamento do tempo num local. O ritmo das variações sazonais de temperatura, chuva, umidade do ar, etc, caracteriza o clima de uma região.[...]

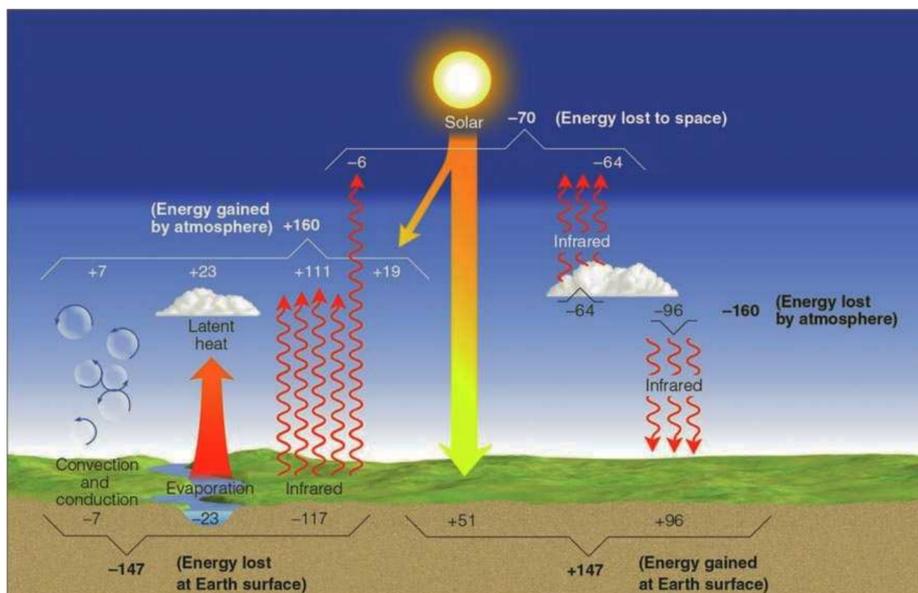
(SENTELHAS *et al.*, 2007, Meteorologia Agrícola, cap. 2, p. 4, grifo nosso)

2.1.1 Fenômenos e processos atmosféricos

O livro *Essentials of meteorology: an invitation to the atmosphere* de Ahrens e Henson (2018), descreve os processos físicos que desencadeiam as mudanças atmosféricas, forças que movimentam as massas, condensação, umidade e formação de nuvens, estações do ano e a influência da lua e de outros corpos celestes.

Segundo Ahrens e Henson (2018) o fator mais importante é a energia solar. Existe um equilíbrio energético da radiação emitida pelo sol que é absorvida pela terra e sua atmosfera (Figura 1). Tal equilíbrio é responsável por grande parte dos processos climáticos.

Figura 1 – Ilustração do equilíbrio energético



Fonte: Ahrens e Henson (2018)

As estações do ano, por exemplo, são reguladas pela quantidade de energia solar recebida na superfície terrestre. Esta quantidade é primariamente determinada pelo ângulo de incidência em que esta energia atinge a superfície, este ângulo varia pelo movimento de rotação e translação da terra. E isto define a natureza cíclica das estações.

2.1.2 Precipitação

Para a meteorologia, a precipitação é descrita como a queda de água do céu, estando em estado líquido ou estado sólido. Ocorrendo em várias formas como: chuvisco, chuva, neve, chuva congelada, chuva congelante, grãos de neve, pelotas de neve e granizo.

Para a maioria das pessoas, uma chuva ocorre quando há queda de gotas d'água líquida. Entretanto para os meteorologistas, estas gotas devem ter um diâmetro igual ou superior a 0,5 mm (0,02") para ser considerada chuva (AHRENS; HENSON, 2019).

Entretanto o tipo de precipitação não determina necessariamente o grau de severidade do evento. Pois, outros fatores como o tempo de duração e o volume acumulado também contribuem.

2.1.3 Classificação, avisos e severidade

De acordo com INMET a classificação das chuvas é dada pelo volume registrado das precipitações em um intervalo de uma hora, esta classificação é listada abaixo:

- 0,1mm - chuvisco;
- De 0,2mm a 9,9mm/h - chuva fraca;
- De 10 a 19mm/h - chuva moderada;
- De 20mm a 60mm/h - chuva forte.

Para efeitos de avisos meteorológicos emitidos pela instituição, considera-se o volume acumulado em um período de 24 horas, os avisos são categorizados em 3 níveis a saber:

- Aviso amarelo: entre 20 e 30mm/h e 50mm em 24h;
- Aviso laranja: entre 30 a 60mm/h ou 50 a 100mm em 24h;
- Aviso vermelho: superior a 100mm/dia.

O aviso amarelo não indica perigo, apenas informa a probabilidade de ocorrência de uma chuva mais volumosa, o aviso laranja indica perigo em potencial, enquanto o aviso vermelho indica um grande perigo. Medidas preventivas podem e devem ser tomadas nos dois últimos casos.

O evento severo, segundo o INMET, é qualquer evento climático destrutivo, mas normalmente se aplica a tempestades localizadas, nevascas, temporais intensos com trovoadas ou tornados. O evento severo pode ocorrer por mudanças bruscas em parâmetros atmosféricos, choque de massas de ar de diferentes propriedades causadas por ventos fortes. Alguns fatores como a impermeabilidade do solo nas grandes cidades são agravantes.

2.1.4 Previsibilidade

Segundo (AHRENS; HENSON, 2018), as previsões do tempo são normalmente agrupadas de acordo com a distância no futuro em que se pretende obter a previsão, explica: *nowcast* para previsões de poucas horas à frente (não mais que 6 horas), *short-range forecast* (de 12 a 72 horas ou 3 dias), *medium-range forecast* (de 3 até 8 dias). As previsões que estendem-se além de 3 dias também são chamadas de previsões estendidas, esse grupo tem o nome de *long-range forecast*.

A métrica de previsibilidade é uma questão bastante sensível, assim foi definido pelo *National Weather Service* dos Estados Unidos, uma classificação para descrever a probabilidade percentual de precipitação mensurável (0,01 polegada ou maior) para precipitação constante e para precipitação convectiva e chuvosa (AHRENS; HENSON, 2019), essa classificação é vista na Tabela 1.

Tabela 1 – Classificação das faixas de probabilidade

Intervalo percentual de probabilidade de precipitação	Previsão dada para precipitação estável ou contínua	Previsão dada para precipitação chuvosa ou tempestuosa
10 a 20 por cento	Pequena chance de precipitação	Chuvas isoladas
30 a 50 por cento	Boa chance de precipitação	Chuvas espalhadas
60 a 70 por cento	Precipitação provável	Chuvas numerosas
maior que 80 por cento	Precipitação quase certa, chuva	Chuvas generalizadas

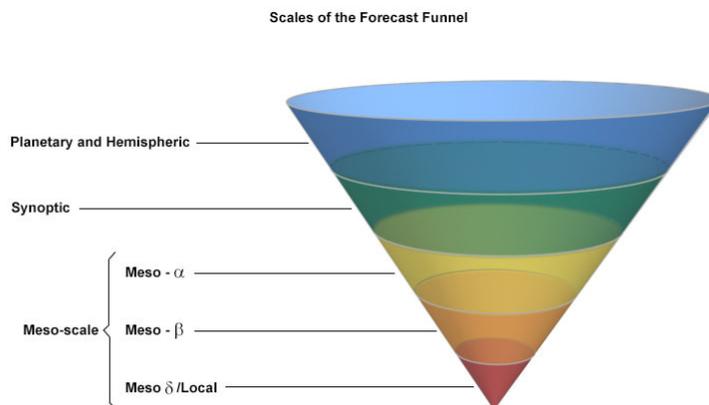
Fonte: Ahrens e Henson (2019).

O principal objetivo da previsão do tempo é fornecer informações ao público para que possa tomar decisões. Isso pode variar de usar protetor solar ao sair ou se preparar para o mau tempo que entra na área. Para fornecer esse suporte, os previsores precisam examinar uma miríade de recursos informacionais tais como dados de estações meteorológicas, de mapas e diferentes gráficos, todos fornecendo informações para criar uma previsão eficaz. Os mapas podem variar de imagens de satélite, mapas de pressão de superfície ou modelagem numérica (AHRENS; HENSON, 2019).

Os analistas devem escolher quais informações se aplicam melhor à situação envolvida. Por exemplo, uma área sob um sistema de alta pressão poderia esperar condições mais calmas, portanto, olhar para um mapa do Índice de Helicidade de Energia não seria aplicável. Para fazer isso, os meteorologistas podem usar um conceito de processo escalar chamado “funil de previsão” ou Funil de Snellman, ilustrado na Figura 2 para criar uma previsão. Este processo descreve como os meteorologistas começam do topo da atmosfera até o solo para desenvolver uma previsão.

Desenvolvido pelo meteorologista Leonard Snellman nas décadas de 1970 e 1980, esse modelo escalar tornou-se uma abordagem padrão na previsão diária para muitos meteorologistas do serviço meteorológico nacional americano e no setor privado. Definindo quais parâmetros a serem observados nas diferentes ordens de grandeza atmosféricas.

Figura 2 – Ilustração do funil escalar para as previsões



Fonte: Bohren e Albrecht (1998)

2.1.5 Modelos clássicos de previsão

Os modelos de previsão climática se dividem em dois grupos principais, os modelos numéricos onde se trabalha com as variáveis coletadas por estações de superfície, e os modelos de previsão por análise de imagens, que utilizam imagens coletadas de satélites e radares meteorológicos, ambos os tipos são processados através de complexas equações por supercomputadores.

Para cada grupo, existem diversos modelos com objetivos e abrangência distintas do ponto de vista escalar e temporal. Lista-se nessa subseção alguns modelos clássicos que ajudaram a compreender a dinâmica do processo preditivo, auxiliando assim o processo de escolha das ferramentas de IA.

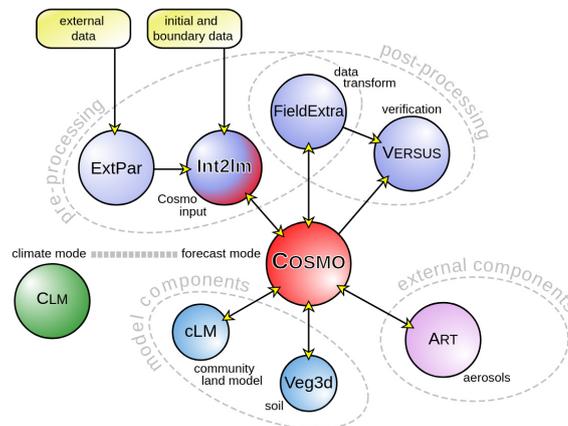
COSMO

Um dos principais modelos clássicos é definido por uma associação de pesquisadores de diversos países que trabalham no aprimoramento das ferramentas de previsão climática o *Consortium for Small-scale Modeling (COSMO)*. O objetivo geral do COSMO é desenvolver, melhorar e manter um modelo de previsão atmosférico não hidrostático de área limitada. O modelo COSMO é usado tanto para aplicações operacionais como de pesquisa pelos membros do consórcio e outros institutos licenciados. O modelo é bastante completo e abrange desde a coleta de dados até a aplicação de verificação de eficácia preditiva. A Figura 3 mostra o relacionamento dos diferentes módulos que o compõe e a integração com componentes externos.

Foi projetado para previsão numérica operacional de tempo *Numerical weather prediction (NWP)* e várias aplicações científicas na escala meso- β e meso- γ . O modelo COSMO é baseado nas equações termo-hidrodinâmicas primitivas que descrevem o fluxo compressível em uma atmosfera úmida. As equações do modelo são formuladas em coordenadas

geográficas rotacionadas e um terreno generalizado seguindo a coordenada de altura. Uma variedade de processos físicos são levados em consideração por esquemas de parametrização (DWD *et al.*, 1998).

Figura 3 – Diagrama do modelo COSMO



Fonte: DWD *et al.* (1998)

As equações básicas são escritas na forma de advecção (transmissão do calor pelo deslocamento de massa atmosférica no sentido horizontal) e a equação de continuidade é substituída por uma equação prognóstica (Equação 1) para a pressão de perturbação (ou seja, o desvio de pressão do estado de referência). As equações do modelo são resolvidas numericamente usando o método tradicional de diferenças finitas. A seguir, resume-se as principais características dinâmicas e numéricas do modelo COSMO.

$$T_0(z) = T_{00} + \Delta t EXP \cdot (-z/h_scal) \quad (1)$$

Na equação temos o prognóstico do perfil de temperatura $T_0(z)$ sendo igual a constante da temperatura ao nível do mar T_{00} somada à variável de tempo Δt multiplicada pela expressão $(-z/h_scal)$, onde z é variável de extensão do domínio vertical e h_scal extensão horizontal.

O modelo de previsão COSMO embora bastante conciso e sólido, carece de aperfeiçoamentos, pois a parte de software foi escrita em linguagem FORTRAN⁹⁰. Esforços tem sido feitos para portabilidade para linguagem C++, e para aumento da granularidade pelo aumento da resolução e o uso de instruções modernas dos atuais microprocessadores, GPUs e computação paralela como visto no projeto (OpenACC, 2021).

WRF

Como um modelo de próxima geração para a previsão numérica climática em meso escala foi criado o *Weather Research and Forecasting* (WRF). O modelo possui uma ampla gama de aplicações meteorológicas, devido à sua boa escalabilidade. O mesmo pode ser parametrizado em escalas de dezenas de metros a milhares de quilômetros.

O desenvolvimento do WRF começou no final da década de 1990 e foi uma parceria colaborativa do Centro Nacional de Pesquisas Atmosféricas (NCAR), da Administração Oceânica e Atmosférica Nacional (representada pelos Centros Nacionais de Predição Ambiental (NCEP) e o Laboratório de Pesquisa do Sistema Terrestre), a *U.S. Air Force*, o *Naval Research Laboratory*, a *University of Oklahoma* e a *Federal Aviation Administration* (FAA).

O WRF é capaz de produzir simulações com base nas condições atmosféricas reais (ou seja, a partir de observações e análises) ou condições idealizadas. Possibilita previsão operacional através de uma plataforma flexível e computacionalmente eficiente, enquanto reflete os avanços recentes em física numérica e assimilação de dados contribuídos por desenvolvedores da comunidade de pesquisa em expansão. O WRF está atualmente em uso operacional no NCEP e em centros meteorológicos distribuídos em todo o globo, bem como em configurações de previsão em tempo real em laboratórios, universidades e empresas (NCAR *et al.*, 1990).

O WRF é um sistema de modelagem atmosférica considerado “estado da arte”, foi projetado para pesquisas meteorológicas e previsão numérica do tempo. Ele oferece uma série de opções para processos atmosféricos e pode ser executado em uma variedade de plataformas de computação. Dentre suas capacidades e aplicações incluem-se as seguintes:

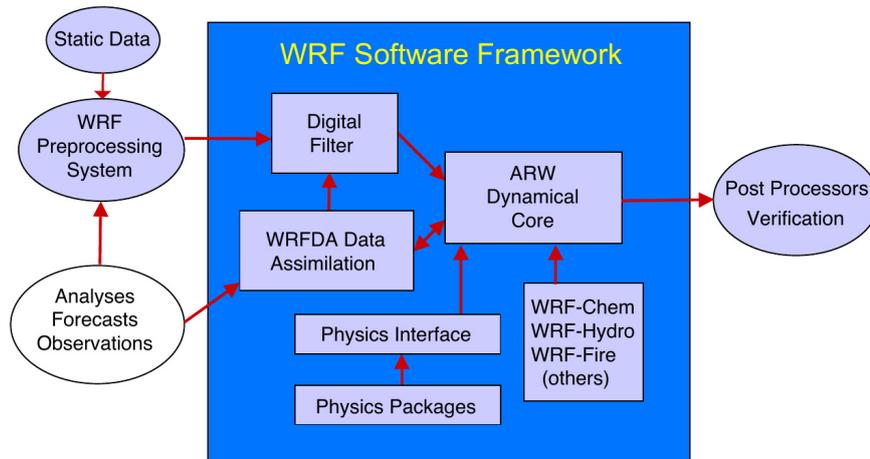
- Estudos meteorológicos;
- Previsão numérica em tempo real;
- Simulações idealizadas;
- Assimilação de dados;
- Acoplamento do modelo do sistema terrestre;
- Modelo de treinamento e suporte educacional.

Segundo Skamarock *et al.* (2019), o WRF ganha mais funcionalidades e flexibilidade quando aplicada a *Advanced Research WRF* (ARW). ARW é uma configuração do sistema WRF apresentando o solucionador de dinâmica ARW junto com outros componentes compatíveis para produzir uma simulação. O diagrama representativo do modelo vê-se na Figura 4.

Pela sua natureza o WRF também pode ser usado em aplicações de previsão não hídrica, o submódulo WRF-Fire se destina a previsões de incêndios e queimadas.

Para Powers *et al.* (2017) as direções futuras do WRF, poderiam ser a continuidade do trabalho de aprimorar a performance computacional, a aplicação e aceleração dos pacotes da análise física, a exemplo dos engenheiros de software da Universidade de Wisconsin que trabalharam nos pacotes de radiação de ondas longas e curtas de Goddard.

Figura 4 – Componentes do sistema WRF + ARW



Fonte: Skamarock *et al.* (2019)

Outros modelos

Outros modelos que recentemente estão incorporando ferramentas de IA como módulos de análise e previsão, são o *European Centre for Medium-range Weather Forecasting* (ECMWF), e o *Model for Ocean-Land-Atmosphere Prediction* (MONAN), este último é um programa nacional comunitário capitaneado pelo INPE que propõe um novo paradigma de modelagem do sistema terrestre para colocar o país no “estado da arte” em previsão de tempo, clima e ambiente.

2.2 Bases Matemáticas e Estatísticas

2.2.1 Séries Temporais

A série temporal é um importante tópico da matemática que permeia várias áreas como economia, estatística, matemática aplicada, epidemiologia, processamento de sinais e aqui em especial a meteorologia.

Uma série temporal é uma coleção de observações feitas sequencialmente ao longo do tempo (CHATFIELD; XING, 2019).

A coleção de observações pode ser descrita como conjuntos de dados (variáveis) que dispõem-se em função de uma equação ao longo de uma janela de tempo.

Em contraste com as regressões lineares em que a ordem é irrelevante, as séries temporais se caracterizam pela rigidez temporal, ou seja: a ordem dos dados é fundamental, e estes dados se correlacionam no tempo em uma determinada função em que X_t está de alguma forma relacionado a X_{t+1} ou X_{t+n} , encontrar estas correlações e as funções que as descrevem é a tarefa de análise em séries temporais. Como esses dados podem ser de

natureza determinística ou estocástica, pode ser uma tarefa bastante trabalhosa.

Para Ehlers (2007) um dos principais fatores complicadores desta tarefa é que a presença de tendências e variações sazonais ou cíclicas podem ser de difícil estimativa ou remoção, fazendo com que a seleção de modelos possa ser bastante complicada e ainda há dificuldades quando se tem observações perdidas e dados muito discrepantes.

Segundo Chatfield e Xing (2019) os modelos não lineares autoregressivos podem ser usados para estimar valores futuros de uma série e calcular seus coeficientes e taxas de acerto.

2.2.2 Regressões não lineares e regressão logística

Quando se tem uma série temporal, sendo ela simples (série univariável) ou composta por várias outras séries (série multivariável) e almeja-se estimar os valores futuros para uma dada variável, usa-se uma ferramenta estatística chamada de regressão. Seu uso é bastante comum nas áreas de ciências médicas e sociais e na análise de tendências para o mercado futuro.

Em uma regressão, o conjunto de observações é dividido entre variáveis explicativas e variáveis explicadas, sendo as últimas as que se deseja obter a previsão de seus valores.

Onde busca-se entender, no conjunto de variáveis explicadas, o quanto o conjunto das explicativas definem seus valores, se existe alguma correlação ou causalidade entre elas.

Na estatística, existem dois tipos básicos de métodos de regressão, a regressão linear e a regressão não linear.

A estimativa de parâmetros desempenha um papel importante nas ciências naturais, engenharia e muitas outras disciplinas. A idéia chave é estimar parâmetros desconhecidos p_1, \dots, p_n de um modelo matemático que descreve uma situação da vida real, minimizando a distância de alguns dados experimentais conhecidos de valores teoricamente previstos de uma função de modelo em determinados valores de tempo. (SCHITTKOWSKI, 2002)

Segundo Chatfield e Xing (2019), é difícil a tarefa de distinguir entre modelos lineares e não lineares, justifica dando o exemplo de que alguns modelos de memória longa são mais lineares do que não lineares, enquanto para modelos não estacionários, a propriedade de não estacionariedade geralmente é mais importante do que se o modelo é linear. Ainda, uma complicação adicional é que é possível ter modelos que são localmente lineares, mas globalmente não lineares. Assim, pode não ser viável definir a linearidade com precisão.

Ainda, uma variável, que pode ser descrita por um modelo linear, torna-se não linear após a aplicação de uma transformação não linear. Existem modelos não lineares aos

quais pode ser aplicada alguma reparametrização que torne a função $f(X, \theta)$ linear nos parâmetros θ (CHATFIELD; XING, 2019).

Como um tipo de regressão não linear a regressão logística em sua saída preditiva fornece variáveis categóricas.

O modelo de regressão logística é melhor indicado quando o fenômeno a ser estudado apresenta-se de forma qualitativa, sendo portanto categorizável, e o intuito é o de estimar a probabilidade de ocorrência destes fenômenos e, para tanto, usa-se da regressão logística binária (FÁVERO; BELFIORE, 2017).

Como se trata de uma predição probabilística, calcula-se a probabilidade do evento estudado generalizando a equação da regressão linear (Equação 2), em que α representa uma constante, β_j ($j = 1, 2, \dots, k$) cada elemento do vetor de parâmetros estimados, X_j são as variáveis explicativas e o subscrito i representa cada observação da amostra ($i = 1, 2, \dots, n$, em que n é o tamanho da amostra), e assim obter a chance de ocorrência positiva ou negativa de determinado evento.

$$P_i = \frac{1}{1 + e^{-(\alpha + \beta_1 \cdot X_{1i} + \beta_2 \cdot X_{2i} + \dots + \beta_k \cdot X_{ki})}} \quad (2)$$

2.3 Bases Computacionais

2.3.1 IA e Redes Neurais Artificiais

Inteligência Artificial (IA), é um campo da ciência que objetiva construir programas de computador, máquinas ou dispositivos “inteligentes”, que sejam dotados da capacidade de executar uma tarefa ou responder a um problema de maneira a imitar a inteligência humana. Podendo assim adquirir de forma autônoma novas informações e aprimorar seus conhecimentos, melhorando sua eficácia em respostas futuras.

As redes neurais são uma parte da IA que buscam resolver os problemas simulando o funcionamento do cérebro humano, utilizando estruturas como neurônios e suas ligações (axônios). Desta maneira, cria-se uma rede entrelaçada em que cada neurônio analisa uma vertente ou variável do problema, assim, uma vez tendo o resultado de cada um, esse resultado é ponderado usando-se pesos definidos para cada grupo ou cada etapa de avaliação.

O termo IA foi proposto por John McCarthy, professor de matemática, ao convocar um grupo de cientistas para um seminário no *Dartmouth College*, em *Hanover*, no estado americano de *New Hampshire* no ano de 1956. O estudo proposto no seminário era para prosseguir com a conjectura básica de que cada aspecto da aprendizagem ou qualquer outra característica da inteligência humana pode, em princípio, ser descrita tão precisamente a

ponto de ser construída uma máquina para simulá-la (RUSSELL; NORVIG, 2016).

Do ponto de vista de uma máquina de Turing, os programas e métodos da IA são em grande parte, parcialmente ou totalmente não determinísticos. Isto é, para uma dada pergunta ou conjunto problema, o caminho de resolução dificilmente será percorrido da mesma maneira em uma nova execução mas trará sempre um resultado semelhante.

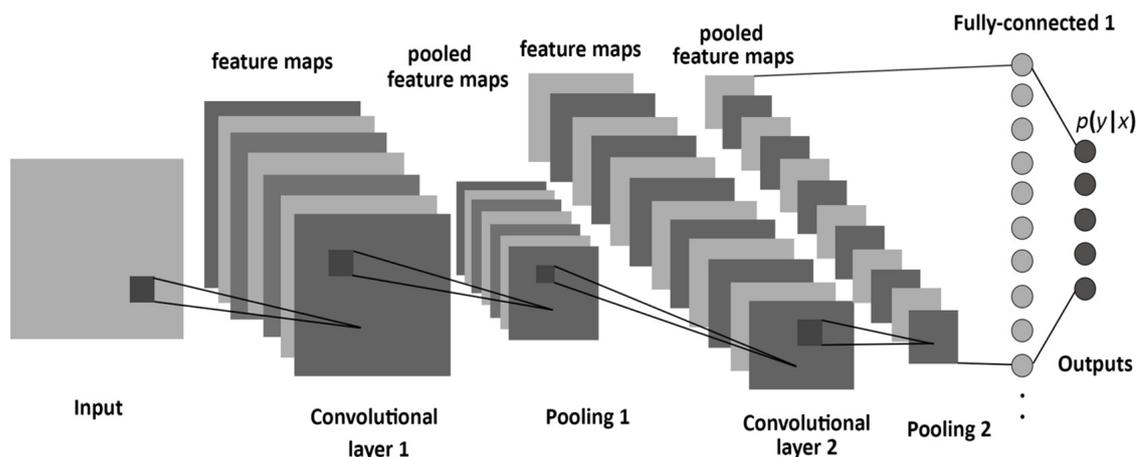
É uma área de estudos multidisciplinar que envolve principalmente a computação e robótica, mas que vem ganhando novas vertentes como a bioinformática e a nanotecnologia. Algumas novas e promissoras tecnologias surgiram a partir da IA, como o aprendizado de máquina, aprendizagem profunda, processamento de linguagem natural e ciência de dados.

2.3.2 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (RNCs) são um subgrupo de redes neurais criadas por LeCun e Bengio (1995) com a proposta de aplicar operações lineares e não lineares por meio de filtros convolucionais dispostos entre as camadas da rede neural, modelo visto na Figura 5.

Esses modelos de redes recentemente vêm ganhando destaque nas etapas de processamento e análise de imagens devido à capacidade de extrair características e avaliar nativamente as informações espaciais.

Figura 5 – Arquitetura de uma rede neural convolucional



Fonte: Albelwi e Mahmood (2017)

A rede neural parte de um conjunto de neurônios artificiais agrupados em diversas camadas com ou sem subníveis, e instanciados com pesos aleatórios que são ajustados a cada época de treinamento com base na retro propagação do erro calculado entre a saída da rede e valor do rótulo que deveria ser obtido (LECUN; BENGIO, 1995).

2.3.3 Multilayer Perceptron

Uma Multilayer Perceptron (MLP) é uma categoria de rede neural artificial cuja suas camadas internas estão totalmente conectadas.

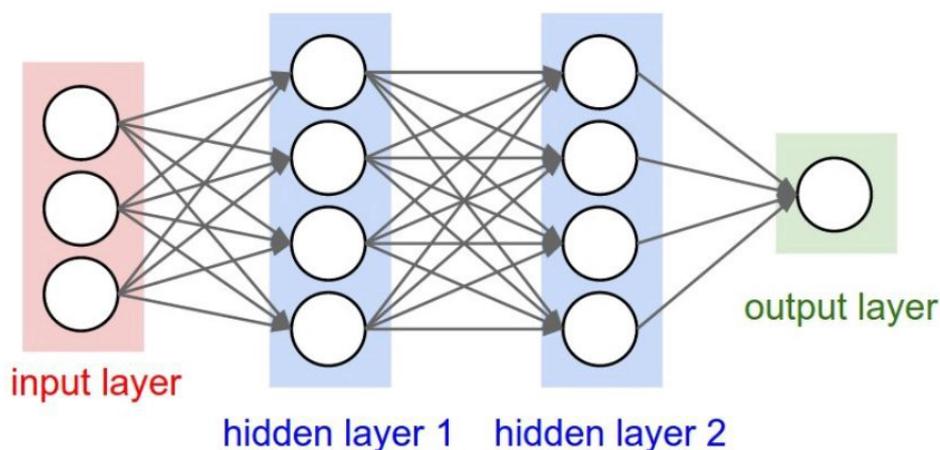
De forma ambígua, o termo é usado para significar qualquer rede neural artificial que implemente o recurso de *feedforward*, às vezes estritamente para se referir a redes compostas de múltiplas camadas de perceptrons.

A primeira ideia de “Perceptron” foi cunhada por Rosenblatt (1961) para descrever uma estrutura de “modelo cerebral”. Entendendo ser esse modelo como qualquer sistema teórico que tente explicar o funcionamento psicológico de um cérebro em termos de leis conhecidas da física e da matemática, e fatos conhecidos da neuroanatomia e da fisiologia.

Posteriormente, Minsky e Papert (1972) em reconhecimento ao trabalho pioneiro de Frank Rosenblatt, continuaram a nomenclatura perceptron, porém eram formas modificadas dos perceptrons introduzidos por Rosenblatt em 1961, restringindo a ordem, ou o número máximo de conexões de entrada, de seus perceptrons.

Rumelhart *et al.* (1988) treinaram uma rede neural com várias camadas e unidades sigmoidais em vez de unidades de limite (como no Perceptron de Minsky e Papert), e introduzindo o conceito de *backpropagation* dando origem a uma rede multicamadas totalmente conectadas (Figura 6).

Figura 6 – Ilustração de uma rede neural do tipo MLP



Fonte: Rumelhart *et al.* (1988)

As MLPs são úteis em pesquisa por sua capacidade de resolver problemas estocasticamente, o que geralmente permite soluções aproximadas para problemas extremamente complexos.

2.3.4 LSTM e YConvLSTM

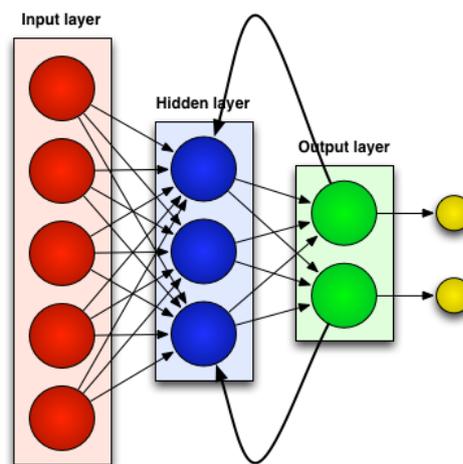
Um método novo e eficiente baseado em gradiente, denominado *Long Short Term Memory (LSTM)* proposto por (HOCHREITER; SCHMIDHUBER, 1997) é a base de ferramentas atuais de previsão que usam redes neurais.

Uma das principais vantagens elencadas por Hochreiter e Schmidhuber é que em seu método, a retropropagação de erro constante dentro das células de memória resulta na capacidade do LSTM de superar defasagens de tempo muito longas em caso de problemas referentes ao tamanho da série.

ConvLSTM é um tipo de rede neural recorrente para predição espaço-temporal que possui estruturas convolucionais nas transições de entrada para estado e estado para estado (SHI *et al.*, 2015). Este modelo de rede faz uso de uma propriedade importante de séries temporais em que o valor de uma variável também é dependente nos valores desta no passado, propriedade conhecida como autocorrelação. Os modelos que operam sobre séries temporais precisam não só usar as variáveis no presente, mas também seus valores no passado.

Esse é um modelo bem conhecido que considera essa propriedade sendo chamado de rede recorrente, esta é constituída de vários blocos recorrentes, mostrados na Figura 7. Em que cada bloco recorrente permite que um processo anterior seja considerado como influência para os dados processados no passo t da rede.

Figura 7 – ConvLSTM, camadas neurais e a retropropagação.



Fonte: Shi *et al.* (2015)

YConvLSTM é portanto uma adaptação feita por Souto (2018) para o uso da rede ConvLSTM em tarefas de previsão do tempo. Outro trabalho recente que aplica a rede ConvLSTM para tarefas de previsão marítima é Zhou *et al.* (2021), que concluiu ser possível a aplicação da rede com precisão e eficiência.

A arquitetura YConvLSTM é composta de 3 elementos principais, uma camada convo-

lucional bidimensional para se observar elementos espaciais, uma camada LSTM de forma a se capturar elementos temporais, e por fim, a operação de convolução tridimensional que irá agregar o conhecimento extraído de forma a obter o tensor que contém os elementos de predição (SOUTO, 2018).

Considerações finais

Pelo visto na literatura levantada, percebe-se que os modelos clássicos evoluíram e conseguem bem desempenhar a tarefa de previsão. Contudo, com o surgimento da IA e suas novas técnicas como as RNAs, novas fronteiras se abrem para a meteorologia. As novas ferramentas computacionais têm contribuído significativamente para o alcance de resultados ainda melhores.

Trabalhos Correlatos

Recentemente, vários estudos em IA têm investido na tarefa de previsão do tempo de modo geral (KUMAR; JHA, 2013; Meera Narvekar *et al.*, 2017; FENTE; SINGH, 2018; HEWAGE *et al.*, 2019; KAREEM *et al.*, 2021). As propostas vão desde a classificação de eventos até a previsão estimada por meio de cálculos regressivos. Aqui, o autor deste trabalho pontua ser árdua a tarefa de selecionar e estabelecer o estado da arte, pois, na grande maioria dos trabalhos encontrados na literatura, os dados, os métodos e até mesmo os experimentos probatórios são divergentes entre si.

Dentre esses estudos, foram selecionados os que mais mantinham pertinência ao assunto aqui abordado. Assim, discute-se neste capítulo, alguns dos trabalhos relacionados que de alguma maneira serviram de apoio e inspiração a este trabalho.

Os clássicos modelos de previsão meteorológica tanto os numéricos quanto os de análise por imagens de satélites têm evoluído ao longo dos anos. Os modelos numéricos, se beneficiaram com aumento da quantidade de estações e da substituição dos tipos de estações convencionais pelas estações automáticas, enquanto os modelos de imagem contam hoje com satélites de alta resolução de espaço e de tempo, obtidas pelas atuais gerações de satélites *Geostationary Operational Environmental Satellite (GOES)*. Outro fator importante é a capacidade computacional dos supercomputadores atuais, que permite cálculos de equações preditivas na escala continental e até mesmo global. Com isso, esses modelos têm se consolidado e obtido resultados satisfatórios.

Pode-se perguntar: porque investir pesquisas e esforços em novos métodos em detrimento do aperfeiçoamento dos modelos clássicos existentes já tão bem estabelecidos?

Para Schultz *et al.* (2021) em seu trabalho “*Can deep learning beat numerical weather prediction?*”, é perfeitamente possível que as ferramentas de IA e *Deep Learning* consigam resultados melhores que os obtidos pelos modelos clássicos. Segundo Schultz *et al.* (2021) diversas arquiteturas de redes neurais artificiais podem ser usadas na tarefa de previsão, seja para classificação ou regressão. Uma compilação dessas arquiteturas e seus modelos de

redes está organizada na Figura 8, por este compilado, pode-se estimar as possibilidades.

Figura 8 – Arquiteturas de redes neurais e suas aplicações nas pesquisas do clima.

architecture	introduced for the first time (original references)	early weather and climate applications (current state in July 2020)
convolutional neural network (CNN)	AlexNet (Alex <i>et al.</i> 2012 [8])	VGG (Shi <i>et al.</i> 2018 [66])
	VGG (Simonyan & Zisserman, 2013 [67])	ResNet (Pothineni <i>et al.</i> 2019 [68])
	ResNet (He <i>et al.</i> 2015 [69])	Vgg, ResNet (Wen <i>et al.</i> 2020 [70])
	GoogLeNet (Szegedy <i>et al.</i> 2015 [71])	Inception blocks (Kleinert <i>et al.</i> 2021 [72])
long short-term memory network (LSTM)	RNN (Bengio <i>et al.</i> 1994 [73])	LSTM (Gómez <i>et al.</i> 2003 [74])
	LSTM (Hochreiter and Schmidhuber, 1997 [43])	LSTM (Qing & Niu, 2018 [75])
		PhyDNet (Le Guen, 2020 [76])
deep belief network (DBN)	Smolensky, 1986 [77], Hinton & Salakhutdinov [78]	Grover <i>et al.</i> 2015 [16]
variational autoencoder (VAE)	Vanilla VAE, 2013 [47]	None
generative adversarial neural network (GAN)	Vanilla GAN (Goodfellow <i>et al.</i> 2014 [48])	MD-GAN (Xiong, 2018 [79])
		conditional GAN (Schmidt <i>et al.</i> 2020 [80])
convolutional long short-term memory network (ConvLSTM)	convLSTM (Shi <i>et al.</i> 2015 [46])	ConvLSTM* (Shi <i>et al.</i> 2015 [46]),
		PredRNN (Wang <i>et al.</i> 2017 [81]); MIM (Wang <i>et al.</i> 2019 [82])
stochastic adversarial video prediction (SAVP*)	SAVP (Lee <i>et al.</i> 2018 [13])	Gong <i>et al.</i> (A. B. Gong, unpublished manuscript, 2020)

Fonte: Schultz *et al.* (2021)

Um trabalho interessante é o de Porto *et al.* (2022), que explorou aplicação de modelos de aprendizado de máquina na previsão de eventos climáticos extremos, utilizando uma abordagem multimodelo para redes neurais como o SOM, LSTM, S2S, definindo *ensembles* híbridos SOMLSTM, YconvLSTM e StconvS2S. Foram 7 *datasets* provenientes de coleta de estações meteorológicas na cidade do Rio de Janeiro submetidos aos *ensembles*. O aproveitamento dos trabalhos de Souto (2018) e Castro *et al.* (2021) permitiu a integração das soluções propostas em uma arquitetura composta. Os autores indicam que apesar do fato dos estudos estarem em fase inicial, os resultados preliminares são promissores. Os autores ainda destacam a necessidade de combinação de várias modalidades de dados e aperfeiçoamento dos modelos de aprendizado de máquina.

No trabalho de Culclasure (2013), foi usando uma base de coleta de dados pessoal, com resolução temporal de 15 minutos durante um período de 1 ano, aplicou ferramentas de redes neurais artificiais para regredir e classificar variáveis meteorológicas de temperatura mínima e rajadas de vento máximas. Realizando a limpeza e normalização de dados aplicadas a este conjunto por *scripts* Python. Este conjunto foi carregado em um SGBD MySQL, a fim de derivar subsequentemente três conjuntos de dados separados representando intervalos de tempo de 1 hora, 6 horas e 24 horas. Aplicou três estruturas de redes neurais diferentes para a tarefa de regressão, e posteriormente outras redes para a classifi-

cação. Foram usadas a RPROP, PSO e RBF. Obtendo 10% de variação média na métrica RMSE para as regressões e 70% na métrica HSS para as classificações.

O trabalho de Song *et al.* (2020) propôs uma nova abordagem para previsão de curta duração para precipitações de verão, com base na aplicação do método de aprendizado de máquina. Utilizou uma rede neural artificial do tipo *multiple linear regression* (MLR) em uma base local dos Alpes Austríacos. No estudo de caso apresentado em seu trabalho, Song *et al.* (2020) comparou os resultados do seu modelo com modelos do tipo NWP, INCA e MLR, obtendo as melhores pontuações para as métricas MAE, BIAS, RMSE, CC e CSI.

Construindo seu próprio modelo de estação meteorológica local, através de dispositivos IoT, Hewage *et al.* (2020) distribuiu essas estações por 6 diferentes cidades, coletando 10 parâmetros climáticos. Comparou o desempenho de dois modelos para previsão local de curto prazo. Foram implementadas uma rede de convolução temporal (TCN) e uma de memória de longo prazo curto (LSTM). Estes modelos foram treinados em duas etapas sendo em múltiplas entradas e uma saída (MISO) e múltiplas entradas e múltiplas saídas (MIMO).

Em um projeto iniciado em 2017, Schumacher *et al.* publicaram um artigo em 2021 na American Meteorological Society, em que desenvolveram um sistema probabilístico de aprendizado de máquina com base em previsões de conjunto, observações de precipitação e algoritmos do tipo floresta aleatória. O trabalho visou detectar o potencial para chuvas excessivas que refletem o risco de alagamento em 1, 2 e 3 dias à frente. O modelo proposto foi comparado com o *Excessive Rainfall Outlooks* (EROs) do *Weather Prediction Center* (WPC), conseguindo superá-lo, tanto que o modelo proposto foi transferido para uso operacional no WPC.

Considerações finais

Pela pesquisa abrangente a cerca dos trabalhos que envolvem técnicas de aprendizado de máquina para a tarefa de previsão do tempo, foi visto o potencial dessas abordagens. Em contraste com os modelos clássicos, os modelos de Machine Learning (ML) são superiores, tanto no custo computacional, pois, em vez de resolver um conjunto de equações físicas complexas dos modelos NWP, usam redes neurais regressivas em que consomem apenas uma fração do poder de computação exigido por tais modelos, quanto em acurácia preditiva o que demonstram os resultados.

Proposta

Este capítulo apresenta a proposta de metodologia utilizada para a comprovação das hipóteses levantadas e alcance dos objetivos.

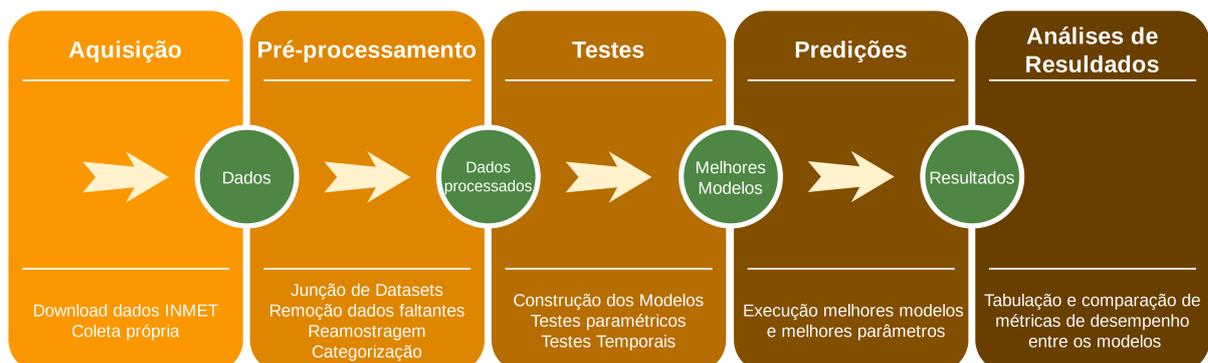
As sessões subsequentes descrevem a etapa de aquisição dos dados, a etapa de pré-processamento, os modelos avaliados com um breve comentário de suas características básicas e a arquitetura usada como base para encontrar suas melhores configurações e suas parametrizações na fase de testes, e as divisões temporais averiguadas. Descrevendo também a etapa de predição e como foram extraídas suas métricas de avaliação.

Por fim, a estratégia usada na otimização para melhor desempenho.

4.1 Metodologia

A metodologia científica aplicada neste trabalho segue etapas sequencialmente dependentes, dessa forma, um fluxo de execução foi estabelecido para garantir a exequibilidade e a correta apuração dos resultados. Este fluxo é ilustrado na Figura 9.

Figura 9 – Fluxo das etapas de execução



Fonte: o autor (2022).

4.1.1 Etapa de aquisição de dados

Para verificar e certificar a capacidade de resiliência dos modelos, estes foram submetidos a dois *datasets* distintos, um proveniente do INMET, outro de coleta própria do autor através de um aparelho construído pelo mesmo, que tem seu projeto detalhado no Capítulo 5.

4.1.2 Apresentação das bases

Foram utilizadas duas bases distintas para análise dos métodos, a fim de garantir que estes métodos sejam funcionais para quaisquer *datasets* meteorológicos. A primeira é o banco de dados meteorológicos do INMET referente à estação situada na Fazenda Sertãozinho da EPAMIG, em Patos de Minas-MG. A segunda é uma base de coleta própria do autor, instalada nas proximidades do prédio de laboratórios da UFU em Patos de Minas-MG, para este trabalho¹.

As bases contêm dados meteorológicos extraídos de estações sinóticas do tipo automáticas através de instrumentos com sensores eletrônicos que coletam os dados.

Características Base INMET

- Localização geográfica: Lat: -18,520; Lon: -46,440
- Intervalo de coleta: 05/2017 ~ 10/2022
- Resolução amostral: hora
- Número de Instâncias: 47.976
- Número de Atributos: 20

A base do INMET apresenta resolução temporal horária, seus registros contêm valores de temperatura, umidade, pressão atmosférica, altitude (calculada em função da pressão) Tabela 2.

Tabela 2 – *Slice* temporal de registros (INMET)

	time	temp	umid	pres	alti	pluv
0	2022-01-01 00:00:00	19.60	95.00	905.10	942.02	0.80
1	2022-01-01 01:00:00	19.60	94.00	905.40	939.28	0.00
2	2022-01-01 02:00:00	19.30	95.00	905.30	940.19	2.00
3	2022-01-01 03:00:00	19.20	95.00	904.90	943.84	7.00
4	2022-01-01 04:00:00	19.00	95.00	904.30	949.32	4.00
5	2022-01-01 05:00:00	18.40	96.00	904.20	950.23	8.60

Fonte: o autor (2022).

¹ A justificativa e demais detalhes se encontram discutidos no Capítulo 5

Características Base própria

- Localização geográfica: Lat: -18,582; Lon: -46,514
- Intervalo de coleta: 07/2021 ~ 11/2022
- Resolução amostral: minuto
- Número de Instâncias: 278.548
- Número de Atributos: 5

A base própria do autor, se assemelha em características à base do INMET, porém a resolução temporal escolhida para os registros foi por minuto, dessa forma pode ser possível uma análise de fino grão Tabela 3.

Tabela 3 – *Slice* temporal de registros (base própria)

	time	temp	umid	pres	alti	pluv
0	2022-01-01 00:00:00	20.27	98.61	915.98	843.27	0.00
1	2022-01-01 00:02:00	20.27	98.63	916.02	842.95	0.25
2	2022-01-01 00:04:00	20.29	98.25	916.05	842.64	0.25
3	2022-01-01 00:06:00	20.35	98.29	916.01	843.03	0.50
4	2022-01-01 00:08:00	20.33	98.51	916.07	842.84	0.25
5	2022-01-01 00:10:00	20.34	98.42	916.03	842.79	0.00

Fonte: o autor (2022).

4.1.3 Etapa de pré-processamento

Nesta etapa foi efetuada a junção dos diversos arquivos de dados em um único *dataset*, a limpeza dos registros com dados faltantes e valores fora do intervalo esperado, para isto foi utilizada a função “dropna” da biblioteca pandas. Além disso, foram realizados dois tipos de reamostragem temporal, um para amostragem horária e outro para amostragem diária, utilizando funções agregadoras de média e soma. Também foram inseridas informações de rotulagem.

4.1.4 Modelos avaliados

Esta seção apresenta os modelos que foram implementados e as variações temporais usadas, para a verificação das hipóteses. Esses modelos foram escolhidos com base na indicação feita por Schultz *et al.* (2021) apresentada no Capítulo 3.

Os modelos que são descritos a seguir, foram usados como base para uma etapa de testes. Esta etapa buscou encontrar as melhores configurações e parâmetros para os modelos propostos, através de uma bateria exaustiva de testes, que foi construída com o uso de uma função combinatória (produto cartesiano).

A função combinatória variou parâmetros como a quantidade de unidades de processamento em cada camada, a função de ativação dessas camadas, a função de otimização

da rede, a quantidade de épocas de treinamento e a largura da janela deslizante de observações consideradas. Com isso, o volume de testes chegou a milhares de execuções.

Os modelos submetidos aos testes foram o modelo Linear, o modelo Dense, o modelo LSTM e o modelo MLP.

4.1.4.1 Baseline para comparação

Foi necessário a definição de uma linha de base para comparação de desempenho dos modelos, a fim de verificar o quão eficazes são em comparação uns aos outros.

Para tanto, foi definido um “pseudo-modelo” em que sua função apenas retorna os valores atuais no passo de tempo seguinte, prevendo “Sem alteração”, isto é razoável na maior parte do tempo, pois, os períodos sem chuva costumam ser longos em alguns meses.

4.1.4.2 Modelo (Linear)

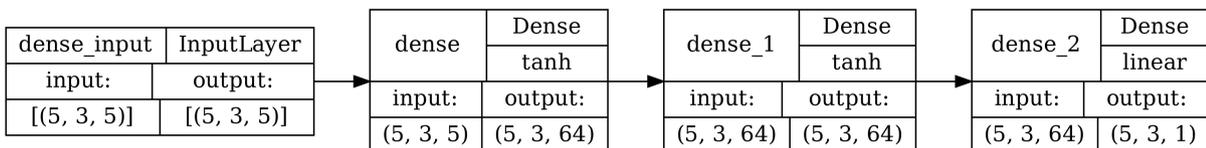
O modelo linear é um dos modelos mais simples que pode ser usado, aplica uma função de transformação linear entre a entrada e a saída para a previsão de valores futuros, possui apenas uma única camada e não utiliza função de ativação, não tendo variações em suas demais parametrizações nos testes executados.

4.1.4.3 Modelo base (Dense)

O modelo Dense se assemelha ao modelo Linear, exceto pelo fato de que empilha várias camadas entre a entrada e a saída.

O modelo Dense foi construído com 2 camadas internas, sendo que a primeira possui 64 neurônios e função de ativação “tanh”, a segunda possui 64 neurônios e função de ativação “tanh”, a última camada apenas 1 neurônio e função de ativação “linear”. A arquitetura da rede é vista na Figura 10.

Figura 10 – Arquitetura Dense



Fonte: o autor (2022).

Abaixo, lista-se o formato de entrada e saída e o sumário deste modelo.

```
Input shape: (5, 3, 5)
Output shape: (5, 3, 1)
Model: "model_dense"
```

Layer (type)	Output Shape	Param #
dense (Dense)	(5, 3, 64)	384
dense_1 (Dense)	(5, 3, 64)	4160
dense_2 (Dense)	(5, 3, 1)	65

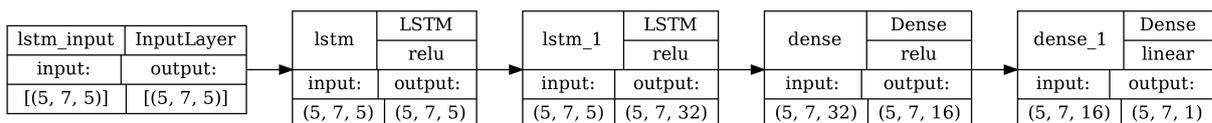
Total params: 4,609
Trainable params: 4,609
Non-trainable params: 0

4.1.4.4 Modelo base (LSTM)

O modelo LSTM é um tipo de rede neural artificial recorrente, sendo melhor adequado à aplicação em séries temporais, pois, consegue manter em memória um estado interno entre suas camadas isto permite ao modelo ser treinado em várias etapas de tempo simultaneamente e estabelecer relações entre estas etapas.

O modelo LSTM foi construído com 3 camadas internas, sendo que a primeira possui 5 neurônios e função de ativação “relu”, a segunda possui 32 neurônios e função de ativação “relu”, a terceira possui 16 neurônios e função de ativação “relu”, a última camada apenas 1 neurônio e função de ativação “linear”. A arquitetura da rede é vista na Figura 11.

Figura 11 – Arquitetura LSTM



Fonte: o autor (2022).

Abaixo, lista-se o formato de entrada e saída e o sumário deste modelo.

Input shape: (5, 7, 5)

Output shape: (5, 7, 1)

Model: "model_LSTM"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(5, 7, 5)	220
lstm_1 (LSTM)	(5, 7, 32)	4864
dense (Dense)	(5, 7, 16)	528

```
dense_1 (Dense)                (5, 7, 1)                17
```

```
=====  
Total params: 5,629
```

```
Trainable params: 5,629
```

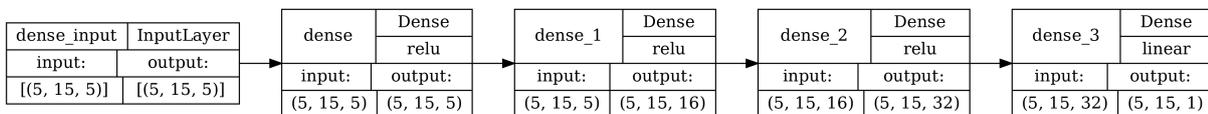
```
Non-trainable params: 0  
-----
```

4.1.4.5 Modelo base (MLP)

O modelo MLP proposto por Rumelhart *et al.* (1988) utiliza o recurso de retropropagação para um aprendizado supervisionado em uma rede neural artificial totalmente conectada, sua função de ativação nas camadas internas é não linear. Assim, tem a capacidade de distinguir dados que não são linearmente separáveis.

O modelo MLP foi construído com 3 camadas internas, sendo que a primeira possui 5 neurônios e função de ativação “relu”, a segunda possui 16 neurônios e função de ativação “relu”, a terceira possui 32 neurônios e função de ativação “relu”, a última camada apenas 1 neurônio e função de ativação “linear”. A arquitetura da rede é vista na Figura 12.

Figura 12 – Arquitetura MLP



Fonte: o autor (2022).

Abaixo, lista-se o formato de entrada e saída e o sumário deste modelo.

```
Input shape: (5, 15, 5)
```

```
Output shape: (5, 15, 1)
```

```
Model: "model_MLP"
```

```
-----  
Layer (type)                Output Shape                Param #  
-----  
dense (Dense)                (5, 15, 5)                  30  
dense_1 (Dense)              (5, 15, 16)                 96  
dense_2 (Dense)              (5, 15, 32)                 544  
dense_3 (Dense)              (5, 15, 1)                  33  
=====
```

```
Total params: 703
```

```
Trainable params: 703
```

```
Non-trainable params: 0  
-----
```

4.1.5 Temporalidade de observações consideradas

Para a previsão de valores no tempo T futuro, foram testadas variações de $T-1$, $T-3$, $T-7$ e $T-15$ passos no passado, estas variações são configuradas como janelas deslizantes que percorrem toda a série temporal no conjunto de treinamento.

4.1.6 Etapa de predição

Com a bateria de testes concluída, encontrou-se os melhores parâmetros e configurações de cada modelo, assim, estes foram executados com seus melhores parâmetros para a comparação de suas eficácias, a bateria de testes é detalhada na 6.3.2.

4.1.6.1 Métricas de avaliação para comprovação de eficácia

Foram extraídas as principais métricas de avaliação de modelos regressivos da execução da função de avaliação no conjunto de teste. Estas métricas foram comparadas para obter o modelo com melhor desempenho preditivo. Na seção 6.2.1 encontram-se discutidas tais métricas.

4.2 Otimizações de desempenho

Devido à grande quantidade de dados, a complexidade computacional envolvida e ainda a indisponibilidade de uma máquina suficientemente adequada, alguns componentes de *software* foram compilados a partir do código fonte para um melhor desempenho.

Buscando extrair a máxima performance dos modelos, para a execução das redes neurais, o pacote Python TensorFlow foi compilado contra a CUDA *toolchain* da NVIDIA[®] incluindo o CUDA Toolkit e a CUDNN. Também o pacote NumPy foi compilado contra a biblioteca matemática OpenBLAS, para otimizar e agilizar os cálculos com matrizes.

Estação meteorológica IoT

Uma estação meteorológica é o local em que se faz a coleta/aferição e registro das variáveis climáticas. As estações podem ser do tipo convencionais ou automáticas. Para ambos os tipos, as estações são compostas de sensores capazes de coletar a temperatura do ar, velocidade e direção do vento, umidade do ar, radiação solar, volume de precipitação, pressão atmosférica, entre outras variáveis.

As estações automáticas têm substituído gradativamente as convencionais. Entre as vantagens estão a precisão de sensores que possuem maior granularidade e sensibilidade. Podemos citar também as leituras automáticas que possibilitam maior resolução temporal.

Entre os principais órgãos meteorológicos oficiais brasileiros, estão o INMET e o Instituto Nacional de Pesquisas Espaciais (INPE). Atualmente, estas instituições enfrentam grandes dificuldades orçamentárias, e passam por problemas de falta de manutenção adequada de suas instalações.

Diante deste cenário, pela prévia análise exploratória dos dados oficiais disponíveis, constatou-se não ser raro a ocorrência de imprecisões e até falhas na correta leitura dos sensores e instrumentos. As consequências são as mais diversas como *datasets* não confiáveis devido à alta taxa de *outliers* e/ou *missing values*, resultando em falsas análises.

Justificou-se desse modo a construção de um projeto e protótipo de estação de baixo custo em plataforma *Internet of Things* (IoT) capaz de coletar as variáveis meteorológicas com o mínimo de confiabilidade. E que também pudesse ser distribuído em larga escala pelos órgãos públicos, a fim de dar acesso tecnológico à população de baixa renda, fomentando o interesse na pesquisa e desenvolvimento em meteorologia e computação.

Este capítulo detalha o projeto de construção de uma estação meteorológica automática feita à partir de dispositivos IoT, com ênfase para a parte de arquitetura e comunicação do *hardware*.

Para isso, técnicas de construção eletroeletrônicas conforme descritas por (HUSSEIN *et al.*, 2020; OUSSAMA, 2020; cactusio, 2016; ADEPOJU *et al.*, 2020; TORRES *et al.*,

2015; GUTH *et al.*, 2018) entre outros, foram combinadas para a construção de uma placa de circuito eletrônico.

A placa tem funcionalidades e recursos de uma estação meteorológica automática, que pode se comunicar com uma central de armazenamento e processamento de dados para alimentar sistemas capazes de auxiliar a emissão de alertas de forma automatizada pela Defesa Civil.

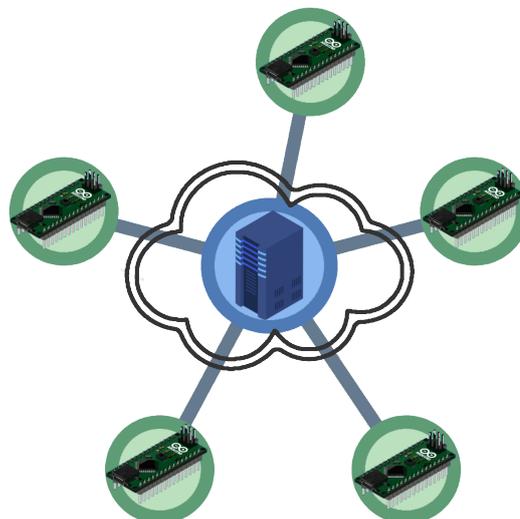
Esse capítulo ainda detalha as arquiteturas usadas, os pinos para a conexão dos dispositivos, os barramentos que serão utilizados para troca de dados entre sensores e dispositivo de armazenamento além da pormenorização de seus componentes. Também serão descritos esquemáticos eletrônicos e *layouts* para a confecção das placas e posicionamento dos componentes no circuito.

5.1 Visão da topologia

O modelo de organização desenvolvido, pressupõe uma topologia de comunicação em estrela como vê-se a seguir, onde podem existir vários pontos de coleta (chamados aqui de nós de coleta) que fazem a leitura dos sensores e enviam estes dados para um elemento central que faz o armazenamento e o processamento desses dados a fim de extrair informações sobre previsões climáticas.

Na Figura 13 temos os nós de coleta (círculos em verde) que são dispositivos montados em placa de circuito impresso, composta por uma unidade central de processamento (Arduino Nano), sensores de temperatura, pressão, umidade, entre outros que são conectados a esta unidade por meio de conexões do tipo SPI e I2C, e o servidor (círculo em azul).

Figura 13 – Ilustração da topologia de comunicação.



Fonte: o autor (2021).

Todos os valores aferidos pelos sensores são armazenados em cada nó de coleta em uma unidade de armazenamento local do tipo *SD card* e são transmitidos para o elemento central da rede para processamento por meio de uma rede de comunicação de dados do tipo *WiFi*, em uma frequência de 30 vezes por hora.

Para o projeto e confecção dos nós de coleta de dados meteorológicos, será apresentado nas próximas seções, detalhes técnicos (computacionais e eletrônicos) como diagramas de blocos e esquemas elétricos de conexão e protocolos de comunicação, além dos detalhes organizacionais e arquiteturas.

5.2 O nó de coleta de dados

O que chama-se de nó de coleta de dados é um equipamento composto por uma placa de circuito impresso que abriga uma unidade de processamento central, módulo de relógio, módulo de armazenamento local, conectores para os diversos módulos de sensores e módulo de conexão de rede sem fio.

Como se trata de um equipamento de baixo custo, a melhor estratégia é usar conectores para os diversos componentes e sensores, permitindo assim a fácil substituição caso algum módulo apresente falha ou mal funcionamento. Além do fato de que uma estrutura modular permite o uso de sensores intercambiáveis. Os diversos componentes desse nó serão detalhados nas próximas subseções.

5.2.1 O Arduino Nano

Arduino é uma plataforma de desenvolvimento para projetos em eletrônica de código aberto que se baseia no fácil uso de *hardware* e *software*, muito utilizada em prototipagem tanto por hobistas como por cientistas.

Uma grande vantagem sobre as plataformas anteriores é a ideia de *Breakout Boards* que são mini placas “quebradas” que possibilitam a montagem dos sistemas em módulos que se encaixam de acordo com a necessidade de cada projeto.

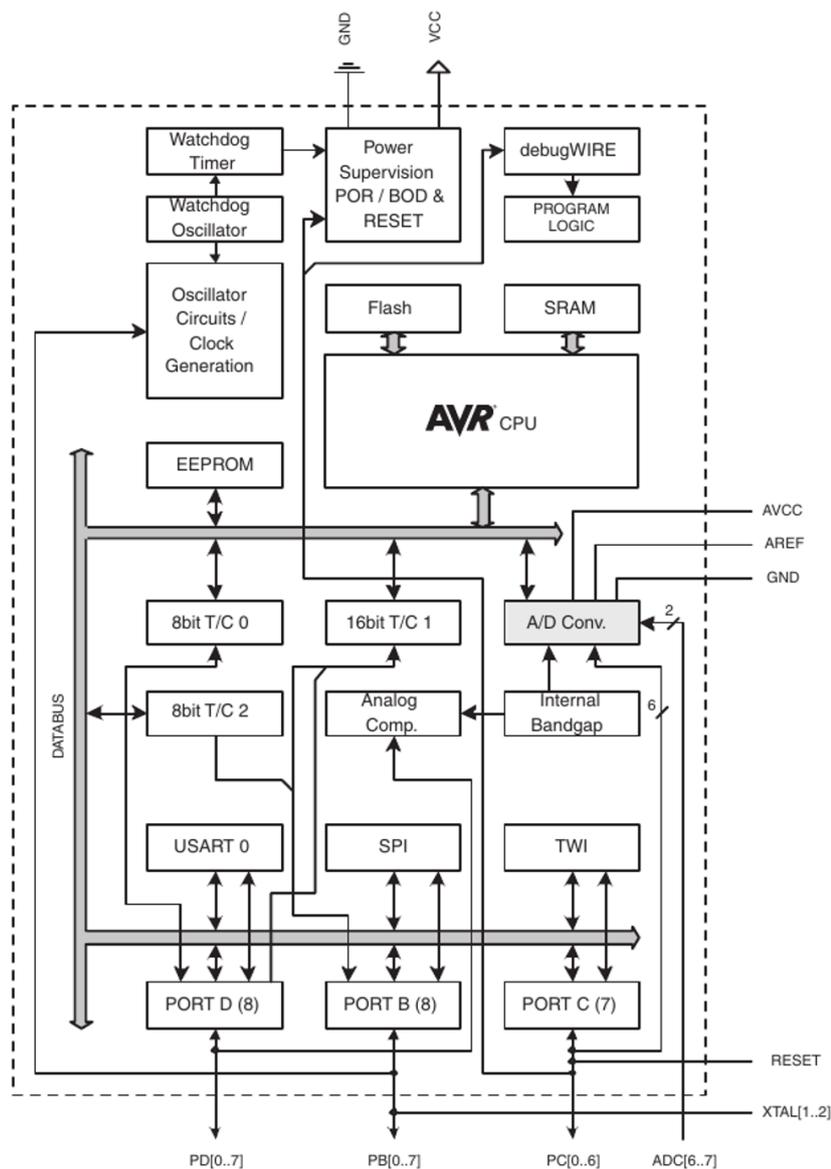
Um outro ponto positivo é que o Arduino não precisa de um hardware separado (chamado de programador) para carregar um novo código na placa, tornando a tarefa mais fácil por usar um cabo *Universal Serial Bus (USB)* e um conversor interno para serial *Universal Asynchronous Receiver/Transmitter (UART)*.

As placas do Arduino utilizam um microcontrolador da família Atmel AVR como núcleo principal e uma linguagem de programação reduzida e simplificada baseada em C/C++. O *Integrated Development Environment (IDE)* é amigável e intuitivo.

5.2.1.1 O microcontrolador ATmega328p

O Atmel ATmega328P é um microcontrolador que oferece os seguintes recursos: 32KB de memória *flash* programável do sistema com recursos de leitura durante a gravação, 1KB de memória EEPROM, 2KB de memória SRAM, 23 linhas de entradas e saídas de uso geral, 32 registradores de trabalho de uso geral. O diagrama de blocos do ATmega328P é ilustrado na Figura 14.

Figura 14 – Diagrama de blocos do microcontrolador ATmega328p.



Fonte: Atmel (2015).

O microcontrolador ainda contém três temporizadores/contadores flexíveis com modos de comparação, interrupções internas e externas, um USART serial programável, uma interface serial de 2 fios orientada por byte, uma porta serial SPI, um conversor analógico digital de 6 canais e 10 bits (8 canais em pacotes TQFP e QFN/MLF) e um temporizador

de *watchdog* programável com oscilador interno e cinco modos de economia de energia selecionáveis por software (Atmel, 2015).

O modo inativo para a CPU permite que a SRAM, Timer/Contadores, USART, interface serial de 2 fios, porta SPI e sistema de interrupção continuem funcionando (Atmel, 2015).

O modo de desligamento salva o conteúdo do registro e congela o oscilador desabilitando todas as outras funções do chip até a próxima interrupção ou reinicialização do hardware. No modo de economia de energia o cronômetro assíncrono continua a funcionar permitindo que o usuário mantenha uma base de cronômetro enquanto o resto do dispositivo está em modo de hibernação (Atmel, 2015).

O modo de redução de ruído ADC interrompe a CPU e todos os módulos de entrada e saída, exceto o temporizador assíncrono e ADC, para minimizar o ruído de comutação durante as conversões ADC (Atmel, 2015).

No modo de espera, o oscilador de cristal/ressonador está funcionando enquanto o resto do dispositivo está hibernando. Isso permite uma inicialização muito rápida combinada com baixo consumo de energia (Atmel, 2015).

O dispositivo é fabricado com a tecnologia de memória não volátil de alta densidade. O *flash* ISP *on-chip* permite que a memória do programa seja reprogramada no sistema por meio de uma interface serial SPI, por um programador de memória não volátil convencional ou por um programa de *boot on-chip* rodando no núcleo do AVR (Atmel, 2015).

O programa de inicialização pode usar qualquer interface para baixar o programa aplicativo na memória *flash* do aplicativo. O *software* na seção de *flash* de inicialização continuará a ser executado enquanto a seção de *flash* do aplicativo é atualizada, fornecendo uma operação real de leitura durante a gravação (Atmel, 2015).

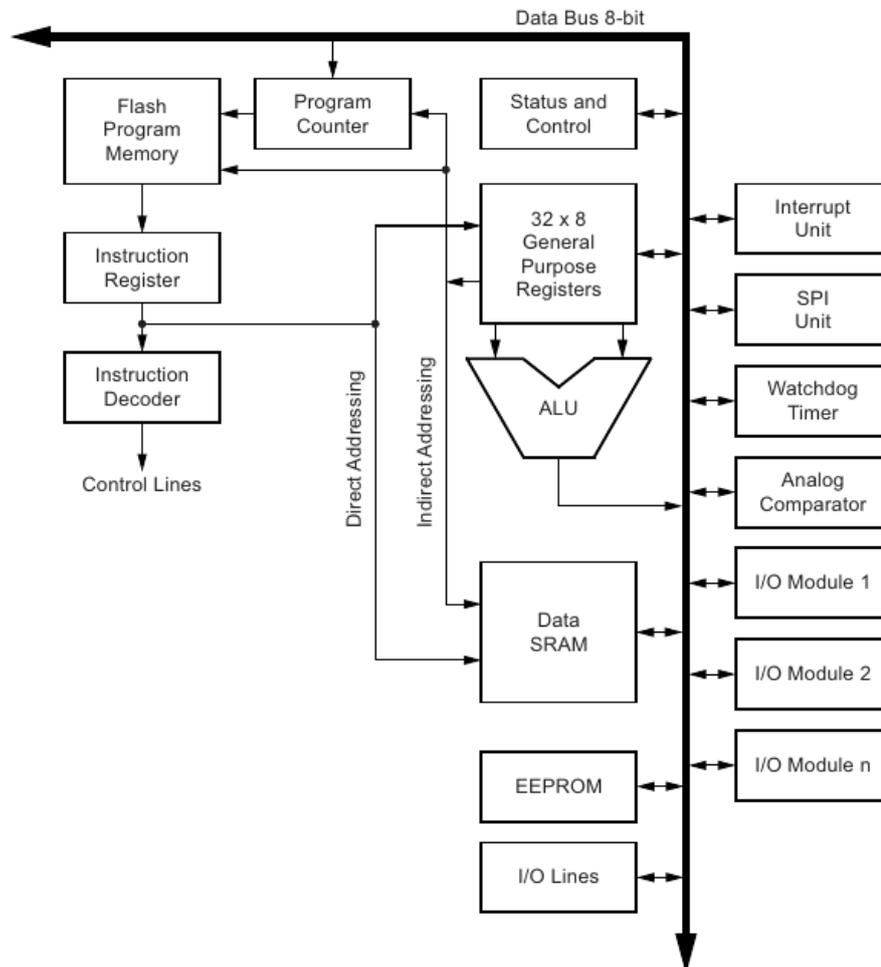
5.2.1.2 A arquitetura de CPU AVR

A CPU AVR utiliza a arquitetura de Harvard - com as memórias e o barramento de programa e de dados separados - para maximizar o desempenho e o paralelismo.

As instruções na memória do programa são executadas com um simples nível de pipeline. Enquanto uma instrução está em execução a próxima está sendo buscada na memória de programa, o que possibilita cada instrução ser executada em um ciclo de *clock*. A memória de programa está na memória flash reprogramável, conforme a Figura 15.

O arquivo para acesso rápido contém registros de trabalho de propósito geral de 32x8 bits com um único tempo de acesso de ciclo de *clock*. Isso permite a operação da unidade lógica aritmética (ALU) de ciclo único. Em uma operação ALU típica, dois operandos são produzidos a partir do arquivo de registro, a operação é executada e o resultado é

Figura 15 – Diagrama de blocos da CPU AVR



Fonte: Atmel (2011).

armazenado de volta no arquivo de registro - em um ciclo de *clock* (Atmel, 2011).

Três registradores dos 32 disponíveis podem ser usados como modo de endereçamento indireto com ponteiro de registros de 16 bits, permitindo cálculos de endereços eficientes. Um deles pode ser usado como um ponteiro de endereço para as tabelas de pesquisa na memória de programa *flash*. Esses registradores de função geral são os registradores X, Y e Z de 16 bits (Atmel, 2011).

A ALU suporta operações aritméticas e lógicas entre registradores ou entre uma constante e um registrador. As operações de registro único também podem ser executadas na ALU. Após uma operação aritmética, o registrador de estados é atualizado para refletir as informações sobre o resultado da operação (Atmel, 2011).

O fluxo do programa é fornecido por instruções de salto e chamada condicionais e incondicionais, capazes de endereçar diretamente todo o espaço de endereços. A maioria das instruções do AVR tem um único formato de palavra de 16 bits. Cada endereço de memória de programa contém uma instrução de 16 ou 32 bits. O espaço da memória flash

do programa é dividido em duas seções, a seção do programa de inicialização e a seção do programa aplicativo. Ambas as seções têm bits de bloqueio dedicados para proteção contra gravação e leitura/gravação (Atmel, 2011).

A instrução SPM que grava na seção de memória flash do aplicativo deve residir na seção do programa de inicialização. Durante as interrupções e chamadas de sub-rotina, o contador do programa de endereço de retorno (PC) é armazenado na pilha. A pilha é efetivamente alocada na SRAM de dados geral e, conseqüentemente, o tamanho da pilha é limitado apenas pelo tamanho total da SRAM e pelo uso da SRAM (Atmel, 2011).

Todos os programas do usuário devem inicializar o SP na rotina de *reset* (antes que as sub-rotinas ou interrupções sejam executadas). O *stack pointer* (SP) é acessível para leitura/gravação no espaço de entrada e saída. Os dados SRAM podem ser facilmente acessados através dos cinco modos de endereçamento diferentes suportados na arquitetura (Atmel, 2011).

Os espaços de memória na arquitetura AVR são todos mapas de memória lineares e regulares. Um módulo de interrupção flexível tem seus registros de controle no espaço de entrada e saída com um bit adicional de habilitação de interrupção global no registro de estados. Todas as interrupções têm um vetor de interrupção separado na tabela de vetor de interrupção (Atmel, 2011).

As interrupções têm prioridade de acordo com sua posição do vetor de interrupção. Quanto menor o endereço do vetor de interrupção, maior a prioridade. O espaço de memória de entrada e saída contém 64 endereços para funções periféricas da CPU como registradores de controle, SPI e outras funções de entrada e saída. Portanto, essa memória pode ser acessada diretamente, ou por meio das localizações do espaço de dados seguindo aquelas do arquivo de registro, 0x20 - 0x5F. Além disso, o ATmega328P estendeu o espaço de entrada e saída de 0x60 - 0xFF em SRAM, onde apenas as instruções ST / STS / STD e LD / LDS / LDD podem ser usadas (Atmel, 2011).

O AVR ALU de alto desempenho opera em conexão direta com todos os 32 registros de trabalho de uso geral. Dentro de um único ciclo de *clock* são executadas operações aritméticas entre registradores de propósito geral ou entre um registrador e um imediato. As operações da ALU são divididas em três categorias principais - funções aritméticas, lógicas e de bits. Algumas implementações da arquitetura também fornecem um multiplicador poderoso que suporta multiplicação com ou sem sinal e formato fracionário (Atmel, 2011).

O registrador de estados contém informações sobre o resultado da instrução aritmética executada mais recentemente. Essas informações podem ser usadas para alterar o fluxo do programa a fim de realizar operações condicionais. Portanto, o registrador de estados é atualizado após todas as operações da ALU, conforme especificado na referência do

conjunto de instruções. Em muitos casos, isso eliminará a necessidade de usar as instruções de comparação dedicadas, resultando em um código mais rápido e compacto (Atmel, 2011).

5.2.2 Módulo de relógio

O DS-3231 é um módulo de baixo custo e extremamente exato na geração de *clocks* de tempo real para módulos I2C com um oscilador de cristal compensado por temperatura e cristal. O dispositivo incorpora uma entrada para bateria e mantém o cronometro preciso mesmo se alimentação principal do dispositivo é interrompida (Maxim Integrated, 2015).

O módulo de tempo real gera informações de segundos, minutos, horas, dia, data, mês e ano. A data no final do mês é ajustada automaticamente para meses com menos de 31 dias, incluindo correções para ano bissexto (Maxim Integrated, 2015).

O relógio interno opera no formato de 12 ou 24 horas com um indicador AM / PM. O endereço e os dados são transferidos serialmente por meio do barramento bidirecional I2C, onde o DS-3231 atua como escravo. Durante a comunicação, os bits mais significantes são transferidos primeiramente (Maxim Integrated, 2015).

5.2.3 Módulo de armazenamento

O módulo de cartão de memória usa um micro controlador ATmega328p para operações de leitura e escrita em cartões do tipo *SD Card* (SparkFun, 2016).

O módulo atua como dispositivo escravo em uma comunicação por meio da interface SPI e do *driver* do sistema de arquivos para completar a leitura e gravação de arquivos do cartão Micro-SD (SparkFun, 2016).

Esse módulo possui um total de seis pinos(GND, VCC, MISO, MOSI, SCK, CS), GND é o pino de referência, VCC é a fonte de alimentação, MISO, MOSI, SCK são as linhas de comunicação SPI e CS é pino de seleção do módulo. O nível de tensão que o módulo trabalha é a 3.3 Volts tanto durante a leitura quanto na gravação de dados (SparkFun, 2016).

O cartão de memória é facilmente acoplado ao módulo por um compartimento de encaixe que o envolve possibilitando uma inserção e remoção rápida (SparkFun, 2016).

5.2.4 Módulo sensor DHT-22

O módulo DHT-22 modelo AM2302 é um sensor que agrega a leitura da temperatura e umidade relativa em um único bloco. A comunicação desse sensor com o nó de coleta ocorre por meio de um pino digital. A alimentação pode ser configurada dentro do intervalo de 3.3 volts a 6 volts em corrente contínua. As demais especificações estão no Quadro 1.

Quadro 1 – Especificações Técnicas DHT-22

Parâmetro	Características
Fonte de alimentação	3.3~6VDC
Sinal de saída	sinal digital via 1-wirebus
Elemento sensor	capacitor de polímero para umidade
Escala de operação	umidade 0~100%RH; temperatura -40~80 Celsius
Exatidão	umidade $\pm 2\%RH$ (Max $\pm 5\%RH$); temperatura ± 0.5 Celsius
Resolução ou sensibilidade	umidade 0.1%RH; temperatura 0.1 Celsius
Reprodutibilidade	umidade $\pm 1\%RH$; temperatura ± 0.2 Celsius
Umidade histerese	$\pm 0.3\%RH$
Estabilidade de longo termo	$\pm 0.5\%RH$ /ano
Intercambialidade	Totalmente intercambiável

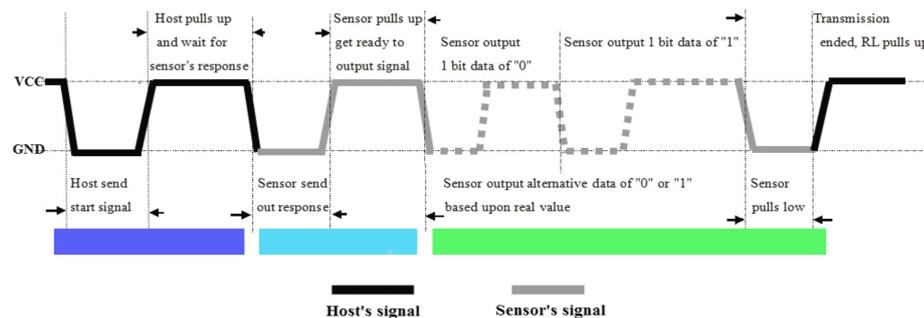
Fonte: Aosong (2015).

A motivação de uso desse sensor é o seu baixo consumo energético, tamanho pequeno e a grande distância de transmissão (até 20 metros) por cabo, o que possibilita a instalação em abrigo próprio.

A comunicação inicia-se a partir do envio do sinal de inicial do nó de coleta para o AM2302. Nesse momento, o AM2302 muda do estado de espera - baixo consumo de energia - para o estado de execução e a seguir inicia o envio do sinal de resposta de dados de 40 bits - 16 bits correspondendo ao valor da umidade relativa, 16 bits para o valor da temperatura e 8 bits para checagem de erros - que refletem a umidade relativa e a temperatura para o nó de coleta (Aosong, 2015).

Na Figura 16 tem-se o diagrama que ilustra o processo de comunicação do nó de coleta com o sensor AM2302. É possível observar nessa imagem que o nó de coleta precisa gerar uma mudança de tensão no pino VCC do AM2303 de nível lógico alto para baixo. Após um ciclo de instrução (1~10ms), o AM2302 identifica a mudança de tensão fornecida e responde voltando o nível lógico para alto no pino VCC (20~40 μ s) destacado pela linha azul. Após esse processo, o AM2302 prepara para a transmissão (linha ciano) que posteriormente se inicia com o envio dos dados (linha verde), sendo que cada bit de dados é enviado em um ciclo de instrução (80 μ s).

Figura 16 – Processo de comunicação do sensor DHT



Fonte: adaptada de Aosong (2015).

No processo descrito acima os bits de mais alta significância são enviados primeiramente e por último os bits de menor significância. Após finalizada a transmissão, o AM2302 volta ao estado de espera se não houver nenhuma solicitação de dados do nó de coleta.

5.2.5 Módulo sensor BME280

O módulo BME280 é uma das opções mais versáteis de baixo custo para estações meteorológicas, pois conta com sensores de temperatura, umidade e pressão atmosférica, além de possuir baixo consumo energético.

Combina sensores de alta linearidade e alta precisão, estabilidade a longo prazo e alta robustez. O sensor de umidade oferece um tempo de resposta extremamente rápido sendo perfeitamente viável para aplicações de extração de dados atmosféricos.

O Bosch BME280 é hoje considerado um dos mais precisos sensores combinados do mercado (Quadro 2).

Quadro 2 – Especificações Técnicas BME280

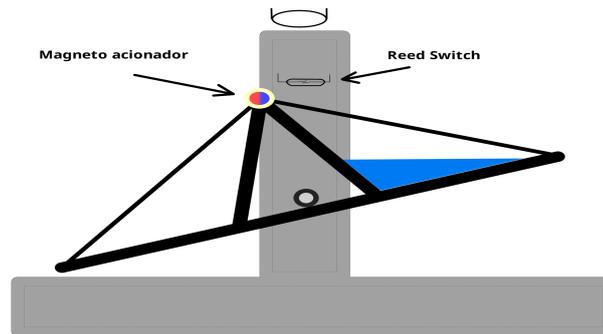
Parâmetro	Características
Fonte de alimentação	1.7~3.3VDC
Interface	I ² C and SPI
Elemento sensor	capacitor de polímero para umidade
Escala de operação	umidade 0~100%RH; temperatura -40~80 Celsius
Exatidão	umidade $\pm 2\%$ RH(Max $\pm 5\%$ RH); temperatura ± 0.5 Celsius
Resolução ou sensibilidade	umidade 0.1%RH; temperatura 0.1 Celsius
Reprodutibilidade	umidade $\pm 1\%$ RH; temperatura ± 0.2 Celsius
Umidade histerese	$\pm 0.3\%$ RH
Estabilidade de longo termo	$\pm 0.5\%$ RH/ano
Intercambialidade	Totalmente intercambiável

Fonte: Bosch (2022).

5.2.6 Módulo sensor pluviométrico

O sensor pluviométrico é um medidor de precipitação (Figura 17), sua função é medir a quantidade de chuva acumulada em um determinado período de tempo. Seu funcionamento se baseia em um simples sistema mecânico composto de um funil coletor e uma balança em forma de gangorra, onde o movimento desta gangorra aciona um *reed switch* alimentado em 5vdc, que envia pulsos ao sistema de contagem (aqui nó de coleta) que contabiliza e registra o volume de chuva na razão de 0.25 mm por pulso.

Figura 17 – Ilustração do mecanismo pluviométrico.



Fonte: o autor (2022).

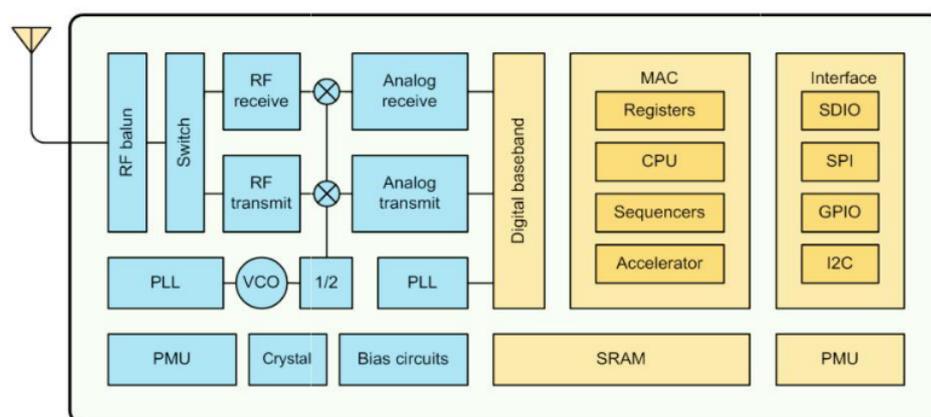
5.2.7 Módulo de rede WiFi

O módulo ESP8266, também conhecido como ESP-01 encapsula uma micro cpu de 32 bits com baixíssima potência e com modo curto de 16-bits. Essa cpu suporta clocks de 80 e 160 MHz, RTOS integrado com uma antena wifi (Microchip, 2015).

Os padrões suportados de rede wifi são os IEEE802.11 g/b/n com frequência de operação de 2.4 GHz a 2.5 GHz e já agrega a pilha TCP/IP. Ainda suporta os padrões de segurança WPA e WPA2 e de criptografia WEB, TKIP e AES (Microchip, 2015).

Os protocolos de rede suportados são: IPV4, TCP, UDP, HTTP e FTP e as interfaces de acesso ao módulo são do tipo SPI/SDIO ou I2C/UART conforme verifica-se na Figura 18 (Microchip, 2015).

Figura 18 – Diagrama de blocos do módulo ESP8266.



Fonte: Microchip (2015).

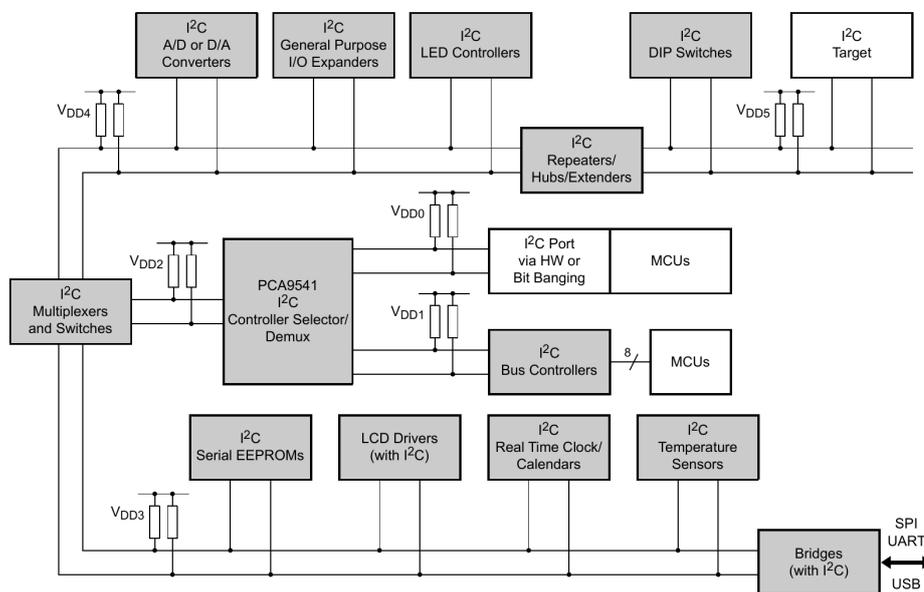
O esp8266 possui oito pinos sendo os mais importantes o pino 4 para recepção, o 8 para transmissão de dado, o 5 para alimentação e o 6 para reiniciar externamente o módulo. Para armazenamento, o módulo possui um banco de memória somente de leitura (ROM) e outro com uma RAM do tipo estática com capacidade de 32 kB (Microchip, 2015).

Para concluir, há internamente um módulo de clock que suporta frequências de 24, 26 ou 40 MHz com precisão do cristal de oscilação na casa de ± 10 PPM (Microchip, 2015).

5.3 Protocolo de comunicação I2C

O I2C é um protocolo de comunicação criado pela empresa Philips Semiconductors (agora NXP Semiconductors) desenvolvido em cima de um barramento bidirecional simples de 2 fios com controle eficiente Inter-IC Figura 19.

Figura 19 – Diagrama de blocos do barramento I2C



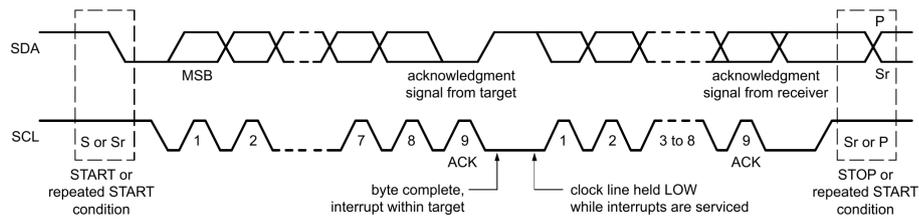
Fonte: NXP Semiconductors (2014).

Todos os equipamentos compatíveis com o barramento I2C incorporam uma interface dentro do chip que os permite comunicar diretamente com outros dispositivos via o protocolo I2C (NXP Semiconductors, 2014).

As informações entre os dispositivos ocorre por meio de dois fios por onde um se envia os dados seriais (SDA) e o outro o sinal de sincronização (SCL). A cada equipamento é atribuído um endereço único que o permite operar tanto como transmissor quanto receptor. Além de transmitir e receber, equipamentos podem também ser considerados como mestres ou escravos durante a transferência dos dados. Um mestre é o equipamento que inicia a transmissão dos dados na rede e gera o sinal de sincronização. Já todos os demais equipamentos endereçados na rede são considerados escravos (NXP Semiconductors, 2014).

Todas as transações começam com um sinal de início *START* e são encerradas por *STOP* (fim), Figura 20.

Figura 20 – Esquema de comunicação usando o barramento I2C



Fonte: NXP Semiconductors (2014).

Uma transição de sinal alto para baixo na linha SDA enquanto o barramento SCL encontra-se em nível alto define uma condição de início da transmissão. Por outro lado, uma transição de baixo para alto na linha SDA enquanto SCL encontra-se em nível lógico alto define uma condição de finalização (NXP Semiconductors, 2014).

As condições de início e fim são sempre geradas pelo mestre. O barramento é considerado ocupado após a condição de partida. O barramento é considerado livre novamente um certo tempo após a condição de parada (NXP Semiconductors, 2014).

Cada *byte* colocado na linha SDA deve ter oito bits de comprimento. O número de *bytes* que podem ser transmitidos por transferência é irrestrito. Cada *byte* deve ser seguido por um bit de reconhecimento. Os dados são transferidos com o bit mais significativo (MSB) primeiro. Se um escravo não puder receber ou transmitir outro byte completo de dados até que tenha executado alguma outra função, por exemplo, atendendo a uma interrupção interna, ele pode manter a linha do relógio SCL em nível lógico baixo para forçar o mestre a um estado de espera. A transferência de dados continua quando o escravo está pronto para enviar outro *byte* e libera a linha de relógio SCL (NXP Semiconductors, 2014).

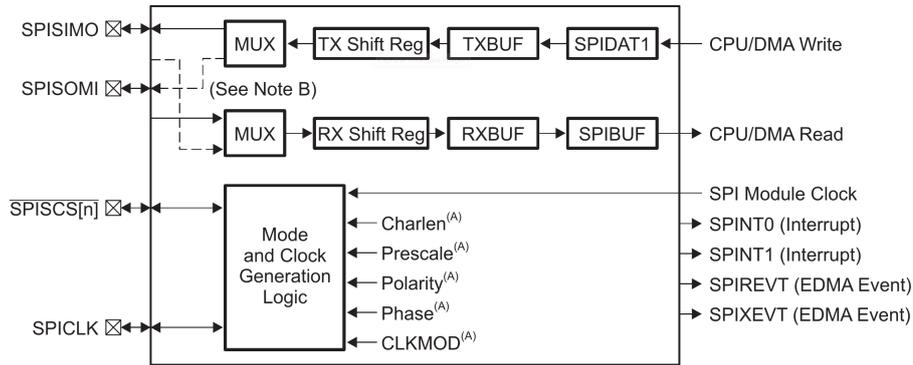
5.4 Protocolo de comunicação SPI

O SPI é protocolo de comunicação que permite tanto a entrada quanto a saída de dados serial de forma sincronizada de alta velocidade que permite deslocar um fluxo de bits serial de comprimento programado (2 a 16 bits) para dentro e para fora do dispositivo em uma taxa de transferência de bits programada Figura 21. No diagrama de blocos verifica-se a presença de dois multiplexadores, um para a transferência dos dados e outro para a recepção bem como um módulo gerador de sincronização (Texas Instruments, 2012).

O protocolo SPI é normalmente usado para comunicação entre o dispositivo e periféricos externos. As aplicações típicas incluem interface para entrada e saída externa ou expansão periférica por meio de dispositivos como registradores de deslocamento, *drivers* de vídeo, SPI EPROMS e conversores analógico para digitais (Texas Instruments, 2012).

O SPI permite a operação em modo mestre com 3 pinos para comunicação unidirecional (SPICLK para sincronização, SPISIMO e SPISOMI para transferência de dados)

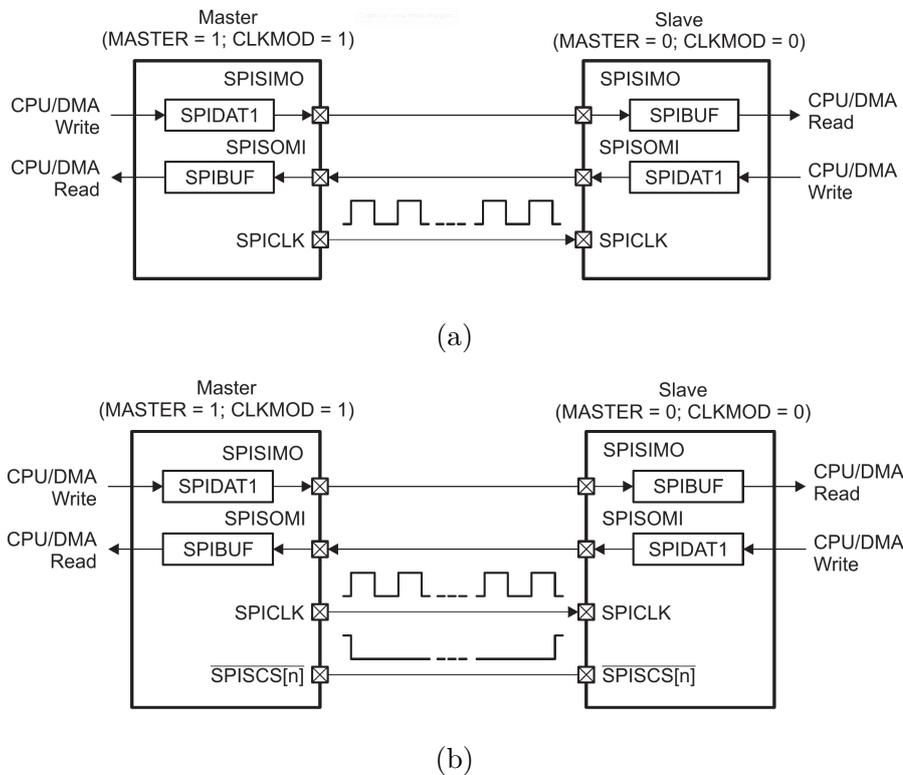
Figura 21 – Diagrama de Blocos do barramento de comunicação SPI



Fonte: Texas Instruments (2012).

Figura 22(a); ou com 4 pinos, para comunicação bidirecional (SPISCS[n] pino de seleção, SPICLK para sincronização, SPISIMO e SPISOMI para transferência de dados) Figura 22(b) (Texas Instruments, 2012).

Figura 22 – Comunicação do barramento SPI



Fonte: Texas Instruments (2012).

Nota: Comunicação do barramento SPI, esquema mestre \leftrightarrow escravo(s), em (a) unidirecional com 3 fios, em (b) bidirecional com 4 fios

5.5 A central de armazenamento e processamento

Foi usado como servidor para receber as requisições HTTP e armazenar os dados, um computador do tipo Desktop com as seguintes especificações: processador Intel(R) Core(TM) i7-8700 CPU @3.20 GHz, memória RAM de 16 GB, comunicação de barramento DMI 3.0, placa gráfica (GPU) NVIDIA GP106 [GeForce GTX 1060 6 GB], disco rígido do tipo SSD com taxas de leitura e escritas sequenciais de 550 e 490 MBps, respectivamente.

Embora estas especificações não sejam exatamente as de uma máquina servidora, que tem o propósito de funcionamento ininterrupto (24/7/365), o uso se justifica pela não disponibilidade de um equipamento próprio, e por ser um ambiente de desenvolvimento.

Recomenda-se que em ambientes de produção, sejam avaliadas questões de desempenho e alta disponibilidade, uma vez que os nós de coleta enviam os dados a esse servidor central.

5.6 A comunicação entre os nós de coleta e a central

Os nós de coleta dispõem de interfaces de rede padrão IEEE 802.11 (ESP-01) que se conectam através de rede sem fio *wireless*. Nessa interface usa-se a pilha de protocolos TCP/IP para a comunicação em nível de rede, assim é configurado um *client* que dispara pacotes HTTP *request* do tipo GET passando como parâmetros os diversos sensores e seus valores. Essa requisição alcança o servidor que recebe-a em um serviço HTTP, processa por meio de um programa *server side include* (PHP) e faz a inclusão dos dados em um sistema gerenciador de bando de dados (MariaDB).

5.7 O projeto eletrônico

A placa de circuito do módulo de coleta foi projetada com vistas a uma arquitetura modular, onde cada módulo sensor pudesse ser substituído caso apresente mal funcionamento.

Assim temos um bloco de fonte de alimentação, bloco da unidade central de processamento, bloco dos sensores e bloco de armazenamento e comunicação listados a seguir:

- a) **Alimentação:** o projeto prevê a alimentação em tensão de 12v DC, onde pode-se usar uma bateria carregada por painel solar como fonte de energia. As tensões exigidas pelos diversos componentes é baixa, por isso, é necessária uma etapa de conversão que ocorre por meio de um regulador de tensão (LM2596), também conhecido como conversor DC-DC *step down*. Esse dispositivo transforma 12v em 9v no primeiro estágio. Em seguida, usa-se o regulador de tensão LM7805 para obter-se tensão de 5v, e outro regulador LM1117T para 3,3v.

- b) **Conectores:** um conector para a unidade central (Arduino Nano) do tipo *dual in-line package* (DIP) de 30 pinos e outros conectores do tipo *pin socket header* fêmea para a interligação dos diversos módulos.

O Quadro 3 relaciona a ligação pino a pino entre o módulo de processamento (arduino Nano) e os diversos módulos componentes.

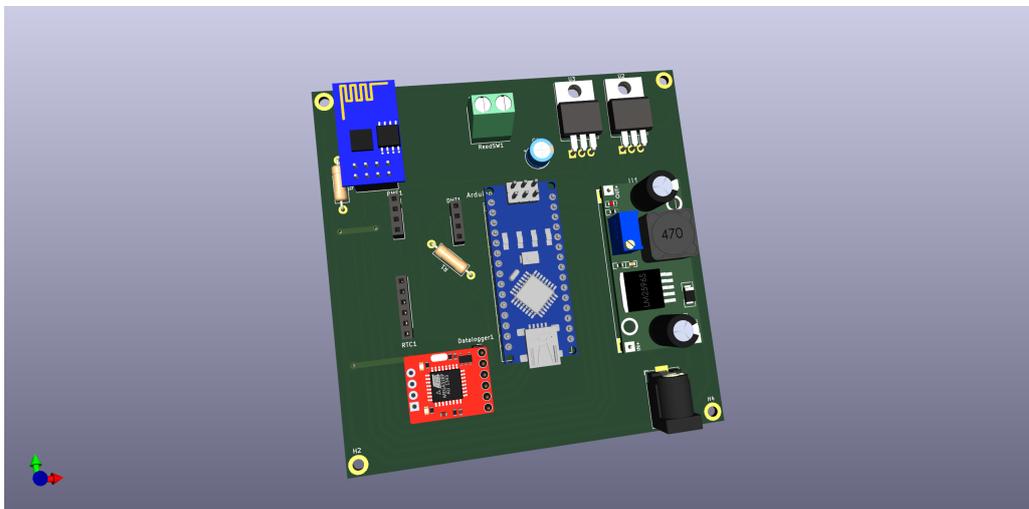
Quadro 3 – Pinagem para a unidade central

Arduino Nano	Relógio (DS-3231)	Sensor DHT22	Sensor BME280	ESP-01	Datalogger
Pino 1					Pino 5
Pino 2					Pino 4
Pino 3					Pino 6
Pino 4	Ao GND				
Pino 5		Pino 2			
Pino 23	Pino 3		Pino 4		
Pino 24	Pino 4		Pino 3		
Pino 25				Pino 2	
Pino 26				Pino 7	
Pino 29	Ao GND				
Pino 30	Ao +9v				

Fonte: o autor (2021).

O projeto foi desenhado usando o *software* KiCad EDA (BAUTISTA, 2022), onde fez-se o diagrama esquemático que descreve os componentes. Seus valores e suas ligações são uma espécie de pegada na PCB onde são definidas as áreas de contato de cobre onde serão soldados os componentes, e o desenho das *tracks*, que são as trilhas ou caminhos de ligação entre os componentes. O diagrama esquemático pode ser visto no Apêndice A, bem como o *layout* das trilhas visto no Apêndice B. Uma projeção em 3D foi renderizada para auxiliar na conferência dos tamanhos e posições dos componentes, visto na Figura 23.

Figura 23 – Projeção em 3 dimensões da placa do módulo de coleta.

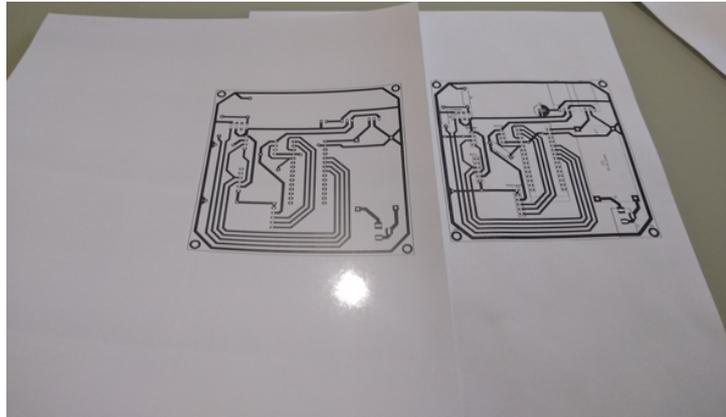


Fonte: o autor (2021).

5.8 Montagem

Após a obtenção do *layout* definitivo, foi feita a impressão em papel fotográfico alto-brilho, como mostra a foto da Figura 24.

Figura 24 – Circuito impresso em papel fotográfico para termo transferência.



Fonte: o autor (2021).

Em seguida o impresso foi transferido para a placa virgem através de método de transferência térmica utilizando um ferro de passar simples. Com a transferência das trilhas e pegadas dos componentes para a placa, foi feita a corrosão (Figura 25).

Esse processo consiste em submeter a placa virgem marcada com o *layout* do circuito a uma solução de percloroato de ferro que ao reagir com o cobre vai dissolvê-lo e retirá-lo da placa, sobrando assim somente o circuito em cobre protegido pela impressão.

Figura 25 – Processo de corrosão da placa de circuito



Fonte: o autor (2021).

Nota: a lâmina de cobre vai ficando mais fina pela ação do agente corrosivo.

dulo de armazenamento local *SD card*, a fim de demonstrar como pode ser realizada a integração destes componentes.

Após levantada a hipótese, estudos feitos, definição de modelo, projeto e protótipo implementado o funcionamento foi atestado e validado.

Concluiu-se ser possível o uso de dispositivos *IoT* para a tarefa de coleta de dados meteorológicos. Podendo-se baratear consideravelmente os custos de implementação para estações automáticas.

Experimentos e Análise dos Resultados

Os experimentos seguiram rigorosamente padrões científicos, para cada teste ou conjunto de testes, conduzidos para a validação das hipóteses, os parâmetros foram devidamente anotados e seus respectivos resultados anexados.

Este capítulo apresenta a etapa inicial de exploração dos dados com técnicas de visualização e estatística para descrever as suas características básicas. Esta é uma etapa importante do processo científico, o objetivo é melhor compreender a natureza desses dados, como a existência de correlação entre as variáveis, padrões e inferências de alto nível que não seriam possíveis ao olhar os dados “puros”.

Posteriormente, a descrição dos métodos e o detalhamento dos experimentos conduzidos, com suas justificativas e parametrizações. Por fim, a análise e interpretação dos resultados alcançados.

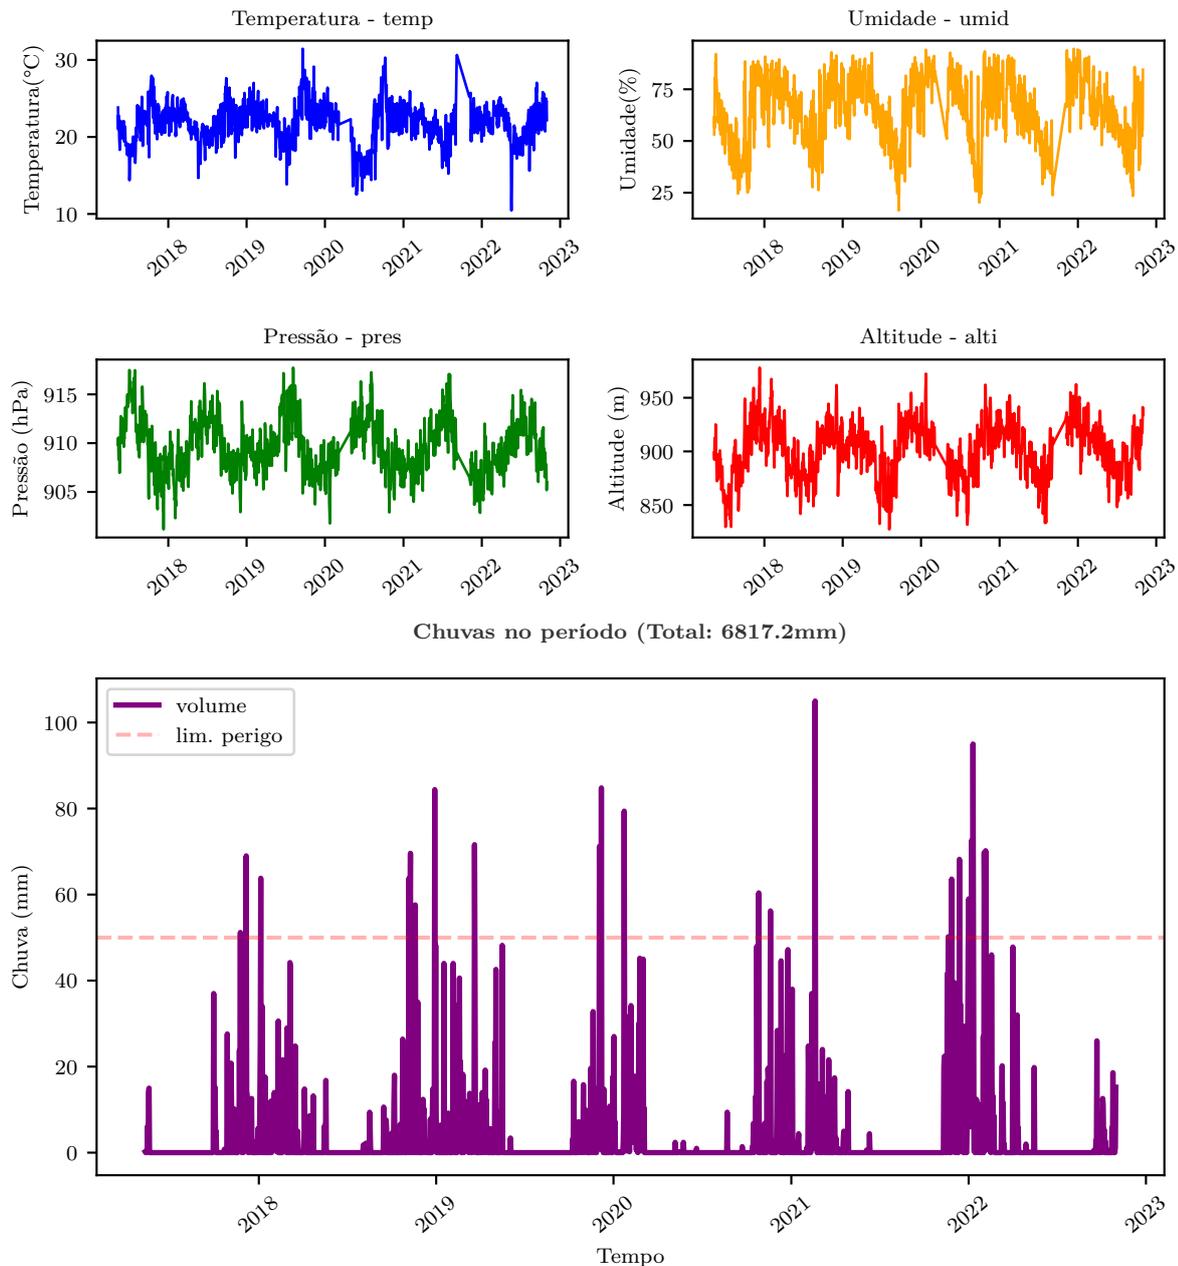
Para as duas bases usadas neste trabalho, a quantidade de registros fica aquém do que seria estatisticamente ideal, pois um máximo temporal de 5 anos é insuficiente para métodos de previsões regressivas tradicionais. Ainda pondera-se o fato da natureza não linear para dados meteorológicos de eventos de chuva. Contudo, os métodos aplicados obtiveram resultados satisfatórios na tarefa de previsão do volume de chuva.

6.1 Visualização

Uma tarefa simples porém bastante útil no estudo de séries temporais, é a plotagem das variáveis em gráficos para identificar visualmente características componentes como sazonalidades, tendências, ciclos e aleatoriedade. A Figura 27 apresenta esta plotagem para o *dataset* INMET.

Pela observação da oscilação das variáveis, percebe-se forte indicação cíclica. Por exemplo, para a umidade existe um ciclo bem definido em que esta declina logo após meados dos anos, a natureza cíclica também é observada no gráfico em barras (volume de chuva).

Figura 27 – Visão gráfica da oscilação das variáveis explicativas e explicada



Fonte: o autor (2022).

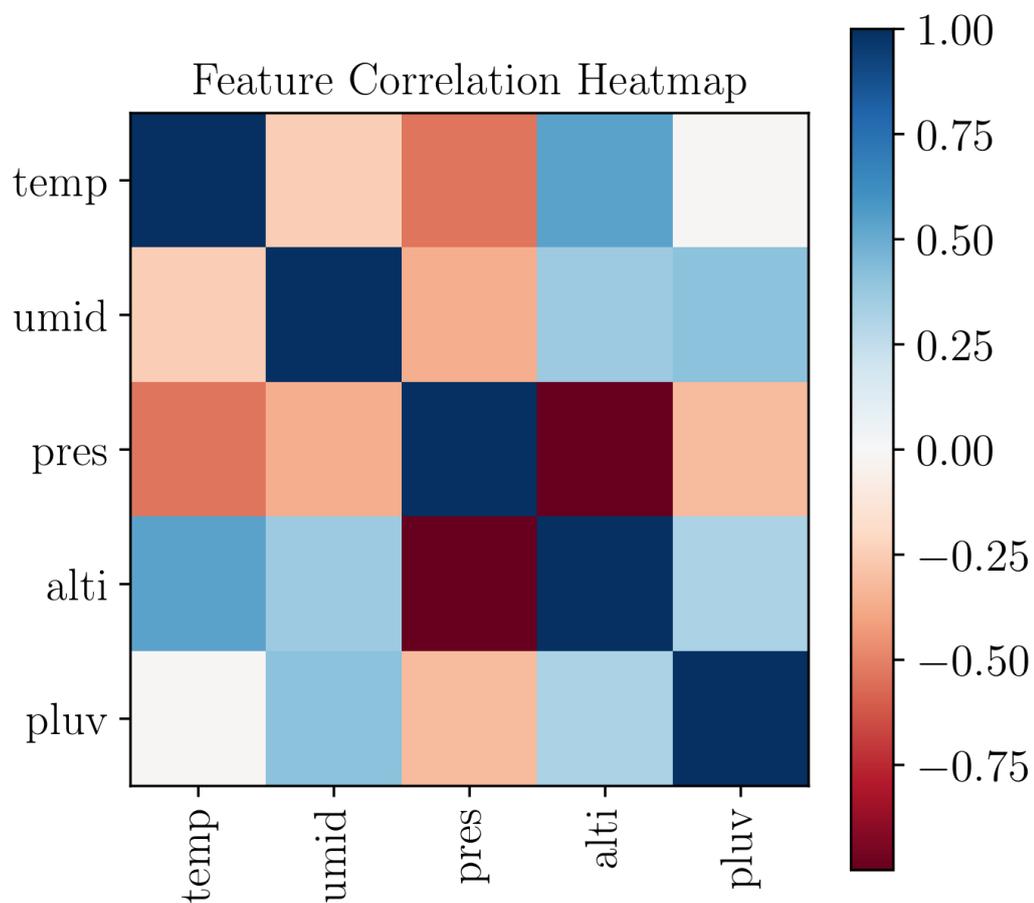
Uma característica de proporcionalidade é vista nos gráficos de pressão e altitude (que são valores inversamente proporcionais). As linhas retas nos gráficos menores indicam períodos sem registro. São exemplos de inferências que podem ser feitas.

Em especial para este estudo, no gráfico de barras que representa o volume de chuva para o período, observa-se claro ciclo. Uma linha tracejada foi plotada para indicar o limite de 50mm de chuva, o que para o INMET é um sinal de alerta e perigo eminente de ocorrência de um evento severo. Um bom observador também notará uma leve tendência de aumento de chuvas demasiadamente volumosas ao longo dos últimos anos.

Em estatística é interessante visualizar graficamente a correlação entre as variáveis de estudo. Isso pode ser feito através da plotagem de um gráfico do tipo mapa de calor.

Na Figura 28 observa-se que existe forte correlação negativa entre a pressão e a altitude, fraca correlação negativa entre temperatura e pressão, e nenhuma entre temperatura e volume pluviométrico.

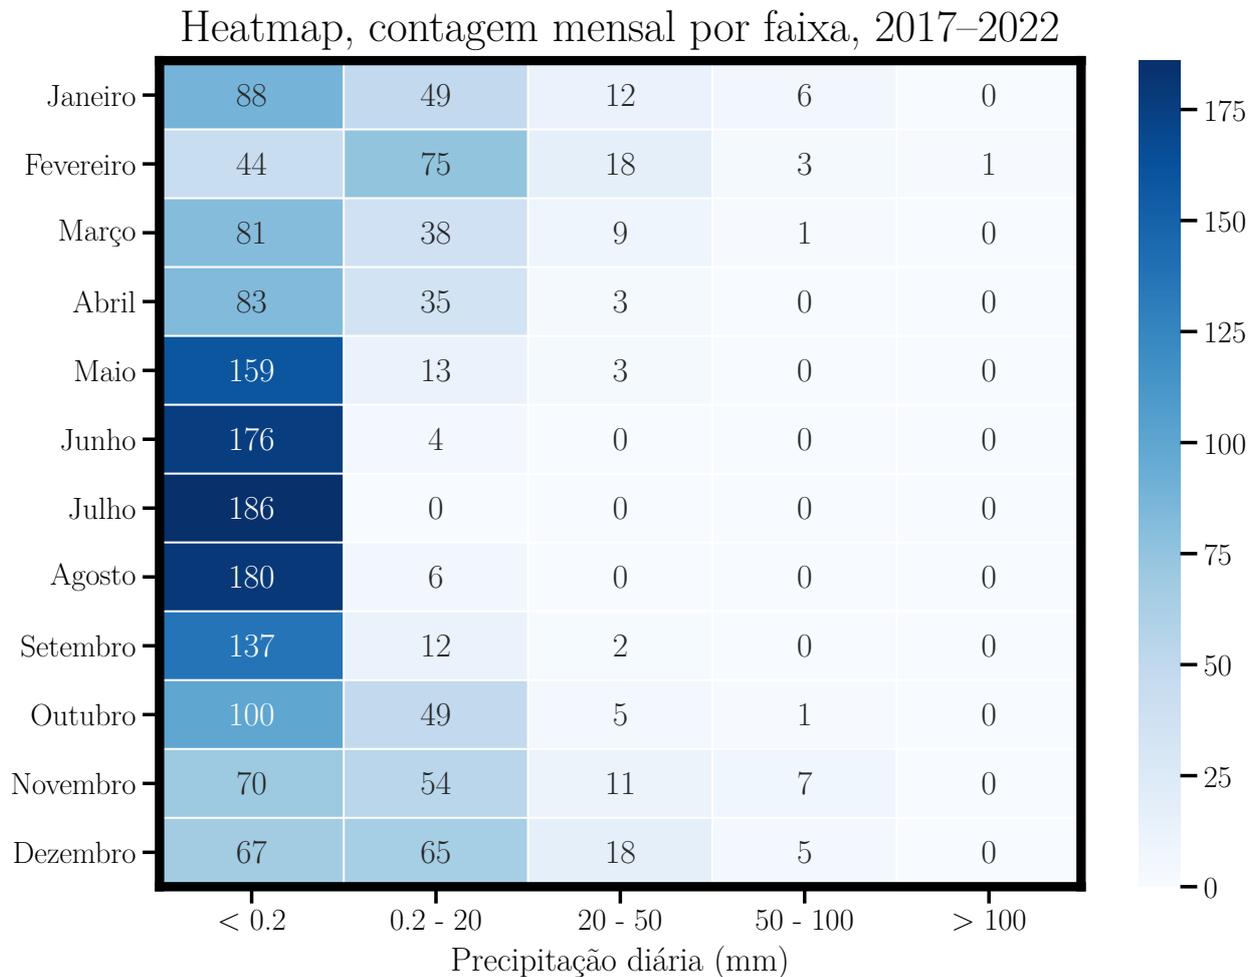
Figura 28 – Visão gráfica por mapa de calor da correlação entre as variáveis



Fonte: o autor (2022).

Outro mapa de calor interessante para as análises é o da Figura 29, desta vez trazendo a distribuição diária de precipitação, agrupada por mês, ao longo do período registrado, com a contagem de dias em função do volume pluviométrico. As faixas de volume foram estabelecidas com base na classificação do INMET. No mapa de calor, podemos ver que as cores mais escuras nas primeiras colunas representam a predominância de dias sem chuva. Também pela contagem vemos claramente que a ocorrência de chuva é mais comum na primavera e verão entre os meses de outubro e abril.

Figura 29 – Visão gráfica da distribuição pluviométrica por mês e por faixa de classificação



Fonte: o autor (2022).

6.2 Método para a avaliação

Para a validação das hipóteses, foram implementados 5 modelos computacionais sendo eles, 1 modelo de base para comparação e 4 redes neurais. Para cada uma das redes neurais foi criado um esquema para selecionar os melhores parâmetros de configuração, conseguindo assim o melhor *set* de configuração para cada rede. Este esquema é descrito na seção 6.3.2.

As medidas de avaliação foram extraídas de cada rede e comparadas para verificar qual rede neural teria melhor desempenho na tarefa de regressão para o caso da previsão do volume de chuva.

Assim, uma vez selecionadas as melhores configurações de cada modelo, estes foram executados, seus desempenhos comparados e suas habilidades preditivas testadas.

6.2.1 Medidas de avaliação

Foram usadas quatro das principais medidas de avaliação de desempenho para métodos de regressão, onde a saída predita é o valor de uma variável numérica contínua.

Mean Square Error (MSE) é a média do erro das previsões ao quadrado ou seja, a diferença entre o valor predito pelo modelo e o valor real ao quadrado, sua fórmula pode ser escrita da seguinte maneira:

$$MSE = \left(\frac{1}{n}\right) \sum_{i=1}^D (x_i - y_i)^2 \quad (3)$$

Root Mean Square Error (RMSE) é extraída a raiz quadrada do erro quadrático médio, sua fórmula pode ser escrita da seguinte maneira:

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{i=1}^D (x_i - y_i)^2} \quad (4)$$

Tanto MSE quanto RMSE acabam por penalizar previsões muito distantes da real.

Mean Absolute Error (MAE) é a média das distâncias entre valores preditos e reais, sua fórmula pode ser escrita da seguinte maneira:

$$MAE = \left(\frac{1}{n}\right) \sum_{i=1}^n |x_i - y_i| \quad (5)$$

Mean Absolute Percentage Error (MAPE): é a divisão da diferença entre predito e real pelo valor obtido, sua fórmula pode ser escrita da seguinte maneira:

$$MAPE = \left(\frac{1}{n}\right) \sum_{i=1}^n \left| \frac{y_i - x_i}{y_i} \right| \quad (6)$$

Já o MAE e o MAPE não penalizam as previsões muito distantes da real. E por serem medidas mais intuitivas, pois trabalham nas mesmas unidades de grandeza das variáveis de entrada, serão escolhidas como principais neste trabalho.

6.3 Experimentos

6.3.1 Ambiente de testes

Os experimentos conduzidos neste trabalho foram executados em um computador padrão IBM PC do tipo Desktop com processador Intel(R) Core(TM) i7-8700 CPU @ 3.20 GHz de 6 *cores* e 12 *threads*, memória RAM de 16 GB, placa gráfica (GPU) NVIDIA GP106 [GeForce GTX 1060 6 GB], disco rígido do tipo SSD com taxas de leitura e escritas sequenciais de 550 e 490 MBps, respectivamente.

Para a bateria de testes em que o número de execuções se tornou notavelmente grande, foi usada uma segunda máquina para esta etapa dos experimentos. Tendo as seguintes especificações: computador padrão IBM PC do tipo Desktop com processador AMD(R) Ryzen(TM) 9 5900X @ 3.60 GHz de 12 *cores* e 24 *threads*, memória RAM de 64 GB, placa gráfica (GPU) NVIDIA GA106-A [GeForce RTX 3060 12 GB], disco rígido do tipo SSD com taxas de leitura e escritas sequenciais de 550 e 490 MBps, respectivamente.

O sistema operacional usado foi o GNU/Linux Slackware, versão 15.0. Para o desenvolvimento alguns componentes foram escritos em BASH *shell script*, como linguagem principal de desenvolvimento utilizou-se Python versão 3.9 e conjunto de pacotes associados como JSON, YAML, NumPy, pandas, TensorFlow, Keras, matplotlib, dentre outros.

6.3.2 Otimização de parâmetros e hiperparâmetros

Um ponto crucial no trabalho com redes neurais é a otimização de seus parâmetros. Pois assim entendendo, foi montado uma bateria de testes com a intenção de encontrar o melhor conjunto de parâmetros para cada rede.

Foi implementado um *script*, que para cada modelo configurou-se um conjunto de parâmetros e seus possíveis valores, através de uma função combinatória (produto cartesiano). Assim, para cada combinação um arquivo de configuração foi obtido, executado, e suas métricas de desempenho extraídas (Apêndice E).

A quantidade de parâmetros e total de combinações que foram geradas para cada rede são listados a seguir:

- Modelo Baseline: 1 parâmetro, 1 combinação
- Modelo Linear: 4 parâmetros, 300 combinações
- Modelo Dense: 6 parâmetros, 2400 combinações
- Modelo LSTM: 7 parâmetros, 4050 combinações
- Modelo MLP: 7 parâmetros, 4050 combinações

O total de execuções na bateria de testes foi de 10805. Outro *script*, encontrou as combinações com as melhores métricas de desempenho, o Apêndice F ilustra o *script*.

Com as melhores combinações encontradas para gerar os melhores resultados, os modelos foram executados com seus respectivos melhores conjuntos de parâmetros, que são listados abaixo.

Melhor configuração modelo Linear

- **window__width**: 3
- **max__epochs**: 300
- **optimizer**: adagrad
- **activation**: linear

Melhor configuração modelo Dense

- **window_width:** 3
- **max_epochs:** 100
- **optimizer:** adam
- **units layer1:** 5
- **units layer2:** 32
- **activation:** tanh

Melhor configuração modelo LSTM

- **window_width:** 7
- **max_epochs:** 1000
- **optimizer:** adam
- **units layer1:** 5
- **units layer2:** 32
- **units layer3:** 16
- **activation:** relu

Melhor configuração modelo MLP

- **window_width:** 3
- **max_epochs:** 300
- **optimizer:** adam
- **units layer1:** 5
- **units layer2:** 32
- **units layer3:** 8
- **activation:** tanh

6.4 Avaliação dos Resultados

Uma comparação das métricas de desempenho para cada modelo nos conjuntos de treinamento (*train*) e teste (*test*) vê-se na Tabela 4, os valores nessa tabela fazem referência ao melhor caso de cada um.

Tabela 4 – Comparação de métricas de desempenho

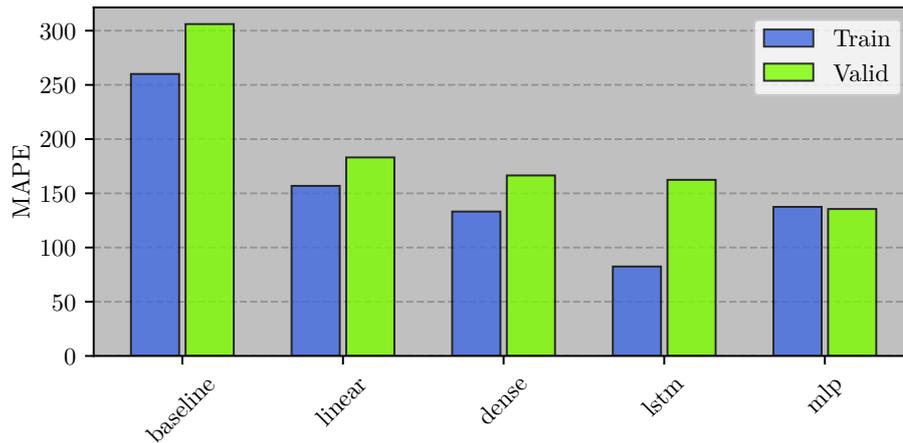
	MSE		RMSE		MAE		MAPE	
	train	test	train	test	train	test	train	test
Baseline	4.170899	0.185611	2.042278	0.430826	1.093266	0.116933	306.103%	32.5350%
Linear	2.783840	0.126192	1.668484	0.355236	0.985689	0.244352	183.101%	70.4379%
Denso	2.836008	0.090422	1.684045	0.300703	0.935087	0.107889	160.606%	27.9619%
LSTM	3.258921	0.080215	1.805248	0.283223	0.974529	0.079201	162.419%	19.8531%
MLP	3.041392	0.091313	1.743958	0.302182	0.956819	0.077934	135.544%	18.9137%

Fonte: o autor (2022).

A métrica MAPE mede o quanto em percentual médio o modelo regressivo distanciou a predição da variável alvo esperada. Seus valores são zero ou maior. Sua interpretação é feita da seguinte forma: quanto menor o valor percentual, melhor será a eficácia preditiva.

Para fins de comparação da estabilidade entre os modelos, extraiu-se as métricas na fase de treinamento, para os conjuntos de Treinamento e Validação Figura 30.

Figura 30 – Estabilidade dos métodos avaliados

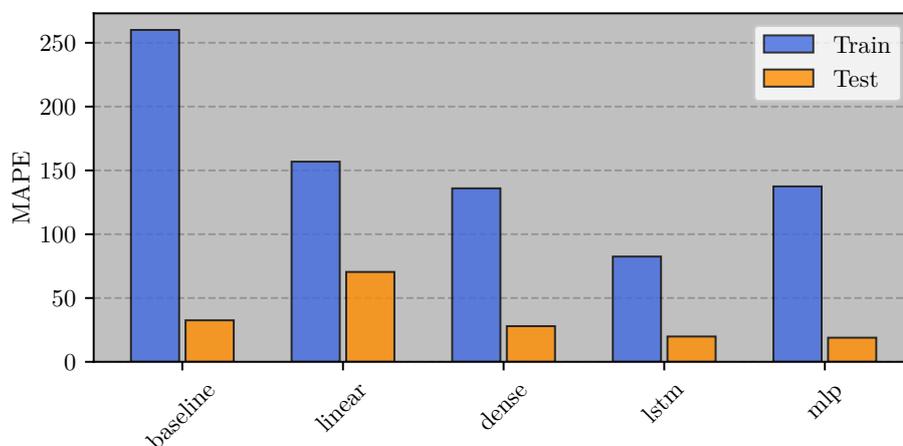


Fonte: o autor (2022).

Nota: O modelo MLP obteve a melhor estabilidade, pois a distância da função perda (configurada para MAPE) entre os conjuntos de treinamento e a validação é mínima entre os modelos comparados.

Embora as métricas de desempenho para o melhor caso de cada modelo foram aceitáveis no conjunto de teste, houve uma certa discrepância entre as fases de treinamento e testes, isto sugere a ocorrência de sobreajuste (*overfitting*)¹, visto no gráfico da Figura 31.

Figura 31 – Desempenho dos métodos avaliados

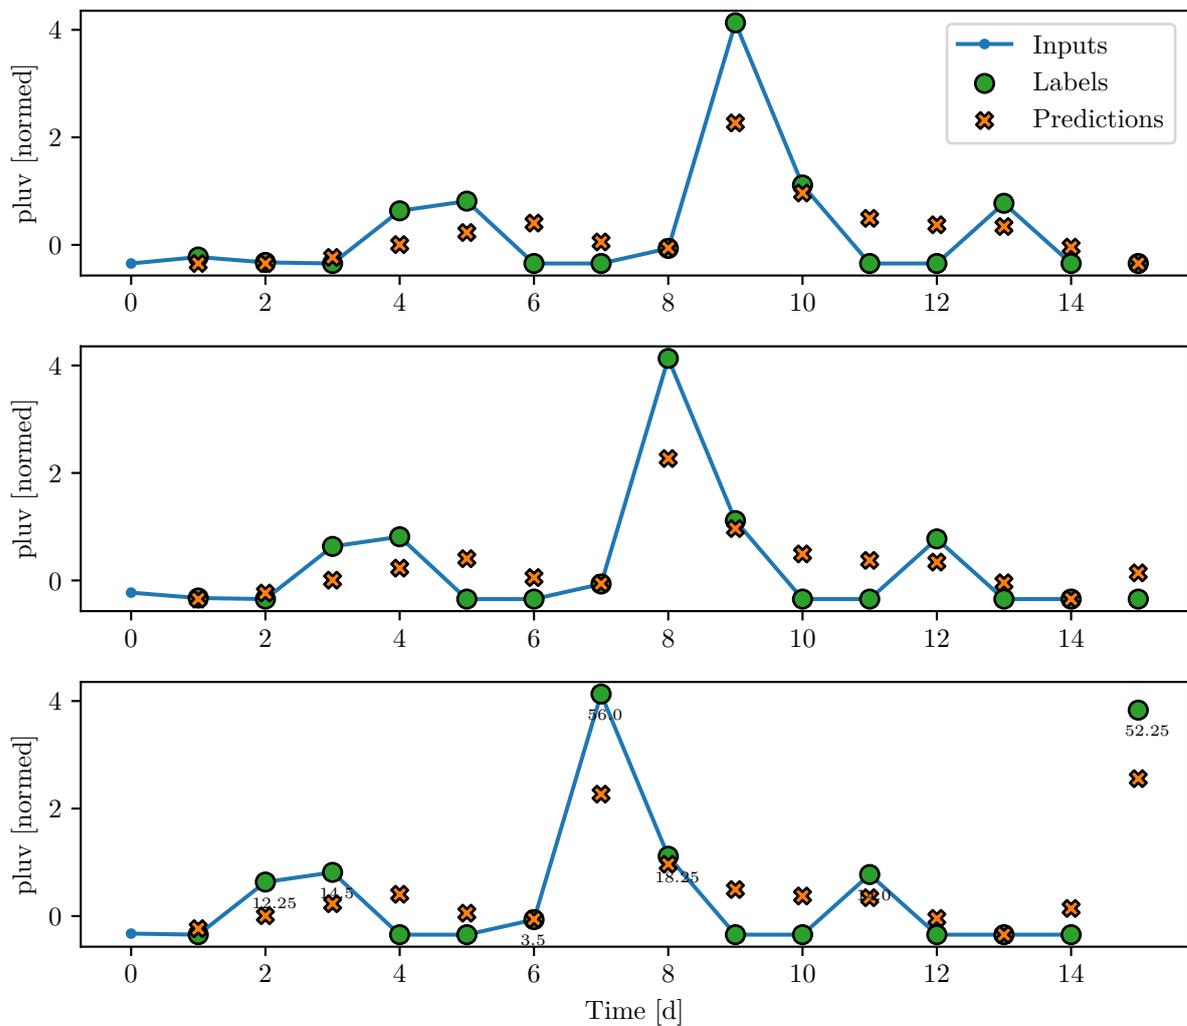


Fonte: o autor (2022).

¹ O sobreajuste nesse caso é perfeitamente entendido, pois o espaço amostral da série temporal dos *datasets* aqui trabalhados é muito curto para a complexidade de uma regressão multi-variada.

A despeito da discrepância no aprendizado, os modelos de IA atingiram boa performance preditiva para o conjunto de teste, o qual não foi visto pelos modelos na fase de treinamento, observadas nas Figura 32 e Figura 33, onde conseguiram prever o volume de chuva com certa acurácia.

Figura 32 – Predição modelo MLP (conjunto teste)

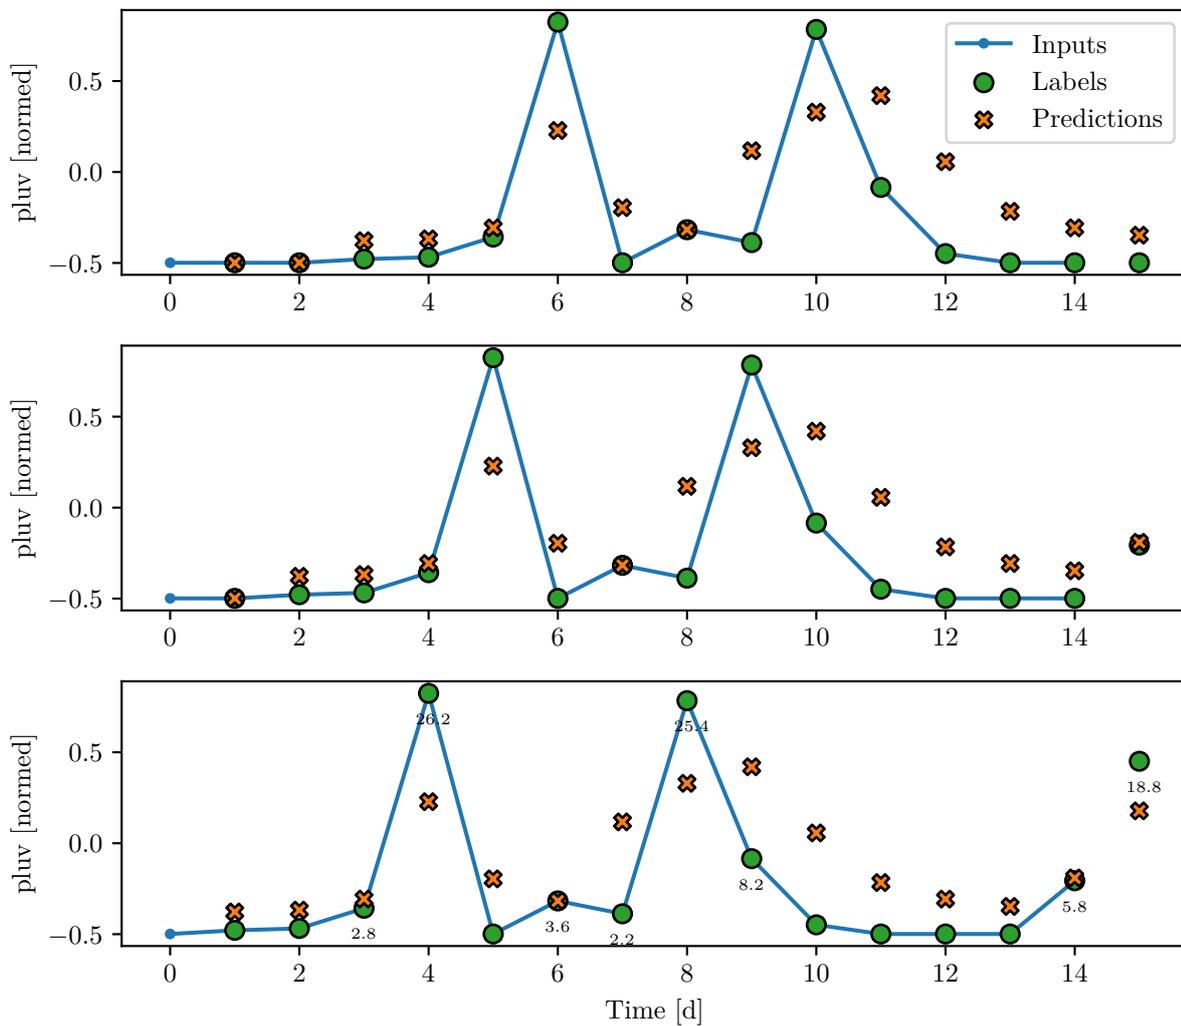


Fonte: o autor (2022).

Pela leitura da Figura 32 é possível observar o bom desempenho do modelo MLP, este alcançou nível máximo de acurácia entre os modelos testados, na parte de baixo do gráfico os dois pontos mais altos demonstram eventos chuvosos importantes com 56mm e 52,25mm de volume, também a Figura 33, já em outro intervalo de tempo apresenta bom resultado sendo ligeiramente menor.

Os modelos LSTM e MLP obtiveram 80,15% e 81,09% de acerto respectivamente de acordo com o erro registrado na Tabela 4 (coluna em destaque), porém, como se trata de uma regressão, o erro e o residual pode levar o valor predito tanto para cima quanto para baixo do valor alvo real esperado.

Figura 33 – Predição modelo LSTM (conjunto teste)



Fonte: o autor (2022).

Nota: O modelo foi capaz de capturar tendências de alta e baixa no volume de chuva, embora não tenha acertado todos os valores, as previsões em X, ficaram muito próximas do alvo esperado em círculo.

O maior desafio dos experimentos neste trabalho foi não contar com uma série temporal mais extensa. Além de muito curta, dados faltantes e fora do intervalo esperado foram excluídos, a fim de não atrapalhar os cálculos dos modelos.

De modo geral, os experimentos se mostraram valiosos e reveladores, acredita-se ser possível a tarefa de previsão do tempo através das ferramentas de IA em especial as RNAs.

6.4.1 Testes de validação cruzada

Testes de validação cruzada do tipo \mathcal{K} -fold foram feitos para determinar o nível percentual de garantia de acerto para os métodos, o número \mathcal{K} de partições de divisão para o conjunto teste foi 10, os resultados são vistos no Apêndice G.

6.4.2 Comparação com outras fontes preditoras

O método do autor conseguiu superar as previsões dos institutos confrontados na Tabela 5, estas previsões foram obtidas por meio de *web scraper* nos respectivos sites oficiais.

Tabela 5 – Comparação da previsão dos métodos com o realizado

Data	Climatepo		Autor		Real
	garantia(%)	volume(mm)	garantia(%)	volume(mm)	volume(mm)
2022-11-23	90	10	50	38.25	52.25
2022-11-24	90	20	50	0	2.25
2022-11-25	90	8	50	6.38	17.50
2022-11-26	90	6	50	2.86	0
2022-11-27	90	8	50	0	0.50
2022-11-28	67	15	50	0	0
2022-11-29	90	10	50	0	0.50
2022-11-30	67	15	50	2.71	0
2022-12-01	90	8	50	9.83	16.50
2022-12-02	83	15	50	17.59	10.00
2022-12-03	90	8	50	22.61	33.25
2022-12-04	90	8	50	0	3.00
2022-12-05	80	20	50	0	1.75
2022-12-06	90	14	50	7.89	26.75
2022-12-07	90	20	50	2.00	5.75
					$\Sigma = 170.00$
Distância Manhattan	211.5		86.2		

Fonte: o autor (2022).

Nota: O percentual de garantia do método do autor é dado pelo percentual de garantia aferido pelos testes de validação cruzada, por isso é fixo.

Conclusão

Este trabalho teve por objetivo principal a comparação da eficácia preditiva de RNAs aplicadas à tarefa de previsão de eventos de chuva em datasets com dados climatológicos. A comparação foi feita estabelecendo uma linha de base comparativa que apenas repetia os valores anteriores em cada etapa de tempo, os modelos foram implementados e uma bateria de testes foi executada para identificar as melhores configurações e parâmetros de cada um. Tendo os melhores modelos e suas respectivas configurações, as métricas de desempenho foram extraídas e comparadas, os percentuais dos melhores modelos foram 80,15% e 81,09%, um resultado considerável tendo em vista o baixo número de atributos observados.

7.1 Objetivos alcançados

Os objetivos específicos alcançados neste trabalho foram:

- Construção de um dispositivo de hardware IoT, para a coleta automatizada de dados, que permitiu a obtenção de dados íntegros e sem lapsos temporais para a correta tarefa de regressão.
- Análise exploratória e estatística dos dados coletados, por meio de técnicas de visualização computacional.
- Aplicação de técnicas de pré-processamento nas bases de dados, usando funções de junção de datasets, remoção de dados faltantes, reamostragem horária e diária e normalização numérica.
- Implementação de RNAs para regressão, utilizando a linguagem Python e pacotes de bibliotecas TensorFlow, Keras, NumPy, pandas entre outras.
- Obtenção da previsão futura da ocorrência de chuva, pelas RNAs implementadas.

7.2 Hipóteses Verificadas

Após a realização dos experimentos deste trabalho, lista-se a verificação das hipóteses levantadas na seção 1.3.

A principal hipótese levantada, de ser possível prever eventos chuvosos por meio da aplicação de técnicas de IA em *datasets* locais de dados meteorológicos, cuja configuração se apresente na forma de séries temporais curtas, se mostrou verdadeira.

- Pelo uso de RNAs consegue-se obter taxas de previsibilidade da ocorrência de chuva, que sejam aceitáveis, isto é, com o mínimo de 50% de acerto, se mostrou verdadeira.
- Possibilidade de que os modelos de Inteligência Artificial consigam obter pelo menos a mesma eficácia preditiva dos modelos numéricos, se mostrou verdadeira.

Para as outras hipóteses levantadas o diagnóstico é inconclusivo, e indica-se para a investigação na seção 7.4.

7.3 Principais Contribuições

Definição de projeto e construção de um modelo de estação meteorológica automática de baixo custo permitindo a coleta de dados locais, a aplicação de modelos de redes neurais artificiais que podem ser usados para prever eventos chuvosos em mesoescala e microescala.

O potencial descoberto poderá beneficiar toda a cadeia de agricultura e pecuária, permitindo a antevissão de eventos, assim podendo programar atividades de sementeio, colheita e outras. Também destaca-se que essa solução pode ser adotada pelos municípios e pela defesa civil, para monitorar áreas de risco e prever eventos de potencial catastrófico, alertando previamente a população e dirimindo os riscos de desastres.

Este trabalho traz três contribuições computacionais a saber:

- A redução da complexidade dos modelos pela simplificação e otimização dos *datasets* na fase de pré-processamento;
- Um método de testes para encontrar os melhores parâmetros para os modelos usando técnica de “força bruta”;
- O ganho de performance pela integração de pacotes de softwares e bibliotecas, aliada à compilação nativa e personalizada.

7.4 Trabalhos Futuros

Muito ainda há o que ser pesquisado e desenvolvido para a tarefa de previsão de chuva e eventos de grande severidade. Indica-se aqui algumas possibilidades de investigação como: estratégias que busquem evitar a ocorrência de sobreajuste nas fases de treinamento dos modelos.

Buscar por padrões que descrevam temporalmente a ocorrência de eventos climáticos severos ou extremos, e se estes padrões apresentam alguma rigidez cronológica/temporal em que se possa estabelecer intervalos curtos de períodos anuais onde a probabilidade de tal ocorrência é acima de 80%, por exemplo.

A implementação de outras arquiteturas de rede neural artificial, bem como um amplo estudo comparativo de desempenho através do método de força bruta citado neste trabalho, para se obter as melhores configurações de cada um.

A aplicação de algoritmos genéticos aos modelos de redes neurais para averiguar as possíveis melhorias de desempenho na precisão que esses podem propiciar.

7.5 Contribuições em Produção Bibliográfica

Um artigo científico foi publicado na Revista Brasileira de Computação Aplicada (RBCA) qualificada nos critérios CAPES, intitulado “Aplicação de classificador binário por RNC na detecção de acidentes de trânsito”.

Ao longo do processo de desenvolvimento desta pesquisa, obteve-se vasto acervo analítico de modelos e suas características de aprendizagem. Visando aproveitar esse material, um artigo científico em fase final de escrita está sendo preparado para discutir sobre uma abordagem “neolítica” pelo uso de força bruta na seleção de hiperparâmetros e o impacto da mesma em tarefas classificativas e regressivas.

Outro possível tema para publicação é o estudo da aplicação de Algoritmos Genéticos aos modelos regressivos para averiguar se há e o quanto se consegue melhorar tais modelos, a intenção é submeter esse estudo ao “Congress on Evolutionary Computation” (CEC).

Referências

ADEPOJU, Temilola *et al.* Development of a Low-Cost Arduino-Based Weather Station. **FUOYE Journal of Engineering and Technology**, v. 5, set. 2020. Disponível em: <<https://journal.engineering.fuoye.edu.ng/index.php/engineer/article/view/508>>.

AHRENS, C. Donald; HENSON, Robert. **Essentials of meteorology: an invitation to the atmosphere**. Eighth edition. Boston, MA: Cengage Learning, 2018. ISBN 978-1-305-62845-8.

_____. **Meteorology today: an introduction to weather, climate, and the environment**. Twelfth edition. Boston, MA: Cengage, 2019. ISBN 978-1-337-61666-9 978-1-337-61667-6 978-1-337-61668-3.

ALBELWI, Saleh; MAHMOOD, Ausif. A Framework for Designing the Architectures of Deep Convolutional Neural Networks. **Entropy**, v. 19, 2017. ISSN 1099-4300. Disponível em: <<https://www.mdpi.com/1099-4300/19/6/242>>.

Aosong. **Digital-output relative humidity & temperature sensor/module**. [S.l.], 2015. Disponível em: <<https://cdn-shop.adafruit.com/datasheets/Digital+humidity+and+temperature+sensor+AM2302.pdf>>.

ASSAD, Eduardo Delgado; PINTO, Hilton Silveira. **Aquecimento global e a nova geografia da produção agrícola no Brasil**. São Paulo, 2008. 82 p. Disponível em: <https://www.agritempo.gov.br/climaeagricultura/CLIMA_E_AGRICULTURA_BRASIL_300908_FINAL.pdf>.

ASSAD, Eduardo Delgado *et al.* Efeito das mudanças climáticas na agricultura do Cerrado. In: **Dinâmica agrícola no cerrado: análises e projeções**. Brasília: Embrapa Informática Agropecuária (CNPTIA), 2020. v. 1, p. 213–228. ISBN 978-85-7035-951-3. Disponível em: <<http://www.alice.cnptia.embrapa.br/handle/doc/1121719>>.

Atmel. **8-bit AVR Microcontroller with 32KBytes In-System Programmable Flash**. [S.l.], 2011. Disponível em: <<https://ww1.microchip.com/downloads/en/DeviceDoc/doc2503.pdf>>.

_____. **8-bit AVR Microcontroller with 32K Bytes In-System Programmable Flash**. [S.l.], 2015. Disponível em: <https://ww1.microchip.com/downloads/en/DeviceDoc/Atmel-7810-Automotive-Microcontrollers-ATmega328P_Datasheet.pdf>.

BAUTISTA, Roberto Fernandez. **KiCad EDA**. 2022. A Cross Platform and Open Source Electronics Design Automation Suite. Disponível em: <<https://www.kicad.org/>>.

BOHREN, Craig F.; ALBRECHT, Bruce A. **Atmospheric thermodynamics**. New York: Oxford University Press, 1998. ISBN 978-0-19-509904-1.

Bosch. **BME280 Combined Digital Humidity, Pressure and Temperature Sensor**. [S.l.], 2022. Disponível em: <<https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bme280-ds002.pdf>>.

cactusio. **Arduino Weather Station Project**. 2016. Disponível em: <<http://cactus.io/projects/weather/arduino-weather-station/>>.

CASTRO, Rafaela *et al.* STConvS2S: Spatiotemporal Convolutional Sequence to Sequence Network for weather forecasting. v. 426, p. 285–298, fev. 2021. ISSN 0925-2312. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925231220315794>>.

CHATFIELD, Christopher; XING, Haipeng. **The analysis of time series: an introduction with R**. Seventh edition. Boca Raton London New York: CRC Press, Taylor & Francis Group, 2019. (Chapman & Hall/CRC texts in statistical science series). ISBN 978-1-4987-9563-0 978-1-138-06613-7.

CULCLASURE, Andrew. **Using Neural Networks to Provide Local Weather Forecasts**. abr. 2013. Dissertação (Mestrado) — Georgia Southern University, Albany, Georgia, USA, abr. 2013. Disponível em: <<https://digitalcommons.georgiasouthern.edu/etd/32>>.

DWD *et al.* **Consortium for Small-scale Modelling weather prediction**. 1998. A non-hydrostatic limited-area atmospheric model. Disponível em: <<https://www.cosmo-model.org/>>.

EHLERS, Ricardo Sandes. **Análise de Séries Temporais**. 4^a ed.. ed. Laboratório de Estatística e Geoinformação – UFPR, 2007. Disponível em: <<http://www.each.usp.br/rvicente/AnaliseDeSeriesTemporais.pdf>>.

FÁVERO, Luiz Paulo Lopes; BELFIORE, Patrícia Prado. **Manual de análise de dados: estatística e modelagem multivariada com excel, SPSS e stata**. [S.l.]: Elsevier, 2017.

FENTE, Dires Negash; SINGH, Dheeraj Kumar. Weather Forecasting Using Artificial Neural Network. In: **2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT)**. Coimbatore: IEEE, 2018. p. 1757–1761. ISBN 978-1-5386-1974-2. Disponível em: <<https://ieeexplore.ieee.org/document/8473167/>>.

FISCHER, E. M. *et al.* Increasing probability of record-shattering climate extremes. **Nature Climate Change**, v. 11, n. 8, p. 689–695, ago. 2021. ISSN 1758-678X, 1758-6798. Disponível em: <<https://www.nature.com/articles/s41558-021-01092-9>>.

GUTH, Jasmin *et al.* A Detailed Analysis of IoT Platform Architectures: Concepts, Similarities, and Differences. In: MARTINO, Beniamino Di *et al.* (Ed.). **Internet of Everything**. Singapore: Springer Singapore, 2018. p. 81–101. ISBN 978-981-10-5860-8

978-981-10-5861-5. Disponível em: <http://link.springer.com/10.1007/978-981-10-5861-5_4>.

HEWAGE, Pradeep *et al.* Long-Short Term Memory for an Effective Short-Term Weather Forecasting Model Using Surface Weather Data. In: MACINTYRE, John *et al.* (Ed.). **Artificial Intelligence Applications and Innovations**. Cham: Springer International Publishing, 2019. v. 559, p. 382–390. ISBN 978-3-030-19822-0 978-3-030-19823-7. Series Title: IFIP Advances in Information and Communication Technology. Disponível em: <http://link.springer.com/10.1007/978-3-030-19823-7_32>.

_____. Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station. **Soft Computing**, v. 24, n. 21, p. 16453–16482, nov. 2020. ISSN 1432-7643, 1433-7479. Disponível em: <<https://link.springer.com/10.1007/s00500-020-04954-0>>.

HICKEL, Jason *et al.* Urgent need for post-growth climate mitigation scenarios. **Nature Energy**, v. 6, n. 8, p. 766–768, ago. 2021. ISSN 2058-7546. Disponível em: <<https://www.nature.com/articles/s41560-021-00884-9>>.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long Short-Term Memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, nov. 1997. ISSN 0899-7667, 1530-888X. Disponível em: <<https://direct.mit.edu/neco/article/9/8/1735-1780/6109>>.

HUSSEIN, Zaid Khudhur *et al.* Low cost smart weather station using Arduino and Zig-Bee. **TELKOMNIKA (Telecommunication Computing Electronics and Control)**, v. 18, n. 1, p. 282, fev. 2020. ISSN 2302-9293, 1693-6930. Disponível em: <<http://journal.uad.ac.id/index.php/TELKOMNIKA/article/view/12784>>.

INMET. **Normais Climatológicas do Brasil**. Brasília - DF, 2022. 27 p. Disponível em: <<https://portal.inmet.gov.br/uploads/normais/NORMAISCLIMATOLOGICAS.pdf>>.

KAREEM, Shahab *et al.* An evaluation of CNN and ANN in prediction weather forecasting: A review. **Sustainable Engineering and Innovation**, v. 3, p. 148–159, out. 2021. ISSN 2712-0562. Disponível em: <<https://sei.ardascience.com/index.php/journal/article/view/146>>.

KUMAR, Neeraj; JHA, Govind Kumar. Time Series ANN Approach for Weather Forecasting. **International Journal of Control Theory and Computer Modeling**, v. 3, n. 1, p. 19–25, jan. 2013. ISSN 23194138. Disponível em: <<http://www.airccse.org/journal/ijctcm/papers/3113ijctcm02.pdf>>.

LECUN, Yann; BENGIO, Yoshua. Convolutional Networks for Images, Speech, and Time-Series. In: ARBIB, M. A. (Ed.). **The Handbook of Brain theory and Neural Networks**. [S.l.]: MIT Press, 1995.

Maxim Integrated. **Extremely Accurate I2C-Integrated RTC/TCXO/Crystal**. [S.l.], 2015. Disponível em: <<https://datasheets.maximintegrated.com/en/ds/DS3231.pdf>>.

Meera Narvekar *et al.* Weather Forecasting Using ANN with Error Backpropagation Algorithm. In: SATAPATHY, Suresh Chandra *et al.* (Ed.). **Proceedings of the International Conference on Data Engineering and Communication Technology**.

Singapore: Springer Singapore, 2017. v. 468, p. 629–639. ISBN 978-981-10-1674-5 978-981-10-1675-2. Series Title: Advances in Intelligent Systems and Computing. Disponível em: <http://link.springer.com/10.1007/978-981-10-1675-2_62>.

Microchip. **ESP-01 WiFi module**. [S.l.], 2015. Disponível em: <<https://www.microchip.ua/wireless/esp01.pdf>>.

MINSKY, Marvin; PAPERT, Seymour A. **Perceptrons: an introduction to computational geometry**. 2. print. with corr. ed. Cambridge/Mass.: The MIT Press, 1972. ISBN 978-0-262-63022-1 978-0-262-13043-1.

NASA. **GISS Surface Temperature Analysis (GISTEMP)**. NASA Goddard Institute for Space Studies, 2022. Disponível em: <<https://data.giss.nasa.gov/gistemp/>>.

NCAR *et al.* **The Weather Research and Forecasting (WRF) model**. 1990. Weather Research and Forecasting Model | MMM: Mesoscale & Microscale Meteorology Laboratory. Disponível em: <<https://www.mmm.ucar.edu/weather-research-and-forecasting-model>>.

NXP Semiconductors. **I2C-bus specification and user manual**. [S.l.], 2014. Disponível em: <<https://www.nxp.com/docs/en/user-guide/UM10204.pdf>>.

OpenACC. **OpenACC: A user-driven directive-based performance-portable parallel programming model**. 2021. Disponível em: <<https://www.openacc.org>>.

OUSSAMA, Hecini. **Internet of Things (IoT) Automatic Weather Station**. 2020. Dissertação (Mestrado) — Université de Biskra, 2020. Disponível em: <<http://rgdoi.net/10.13140/RG.2.2.25803.41760>>.

PORTO, Fabio *et al.* Machine Learning Approaches to Extreme Weather Events Forecast in Urban Areas: Challenges and Initial Results. **Supercomputing Frontiers and Innovations**, v. 9, p. 49–73, maio 2022. Section: Articles. Disponível em: <<https://superfri.org/index.php/superfri/article/view/418>>.

POWERS, Jordan G. *et al.* The Weather Research and Forecasting Model: Overview, System Efforts, and Future Directions. **Bulletin of the American Meteorological Society**, v. 98, n. 8, p. 1717–1737, ago. 2017. ISSN 0003-0007, 1520-0477. Disponível em: <<https://journals.ametsoc.org/doi/10.1175/BAMS-D-15-00308.1>>.

ROSENBLATT, F. **Principles of neurodynamics: Perceptions and the theory of brain mechanism**. Washington, DC: Spartan Books, 1961.

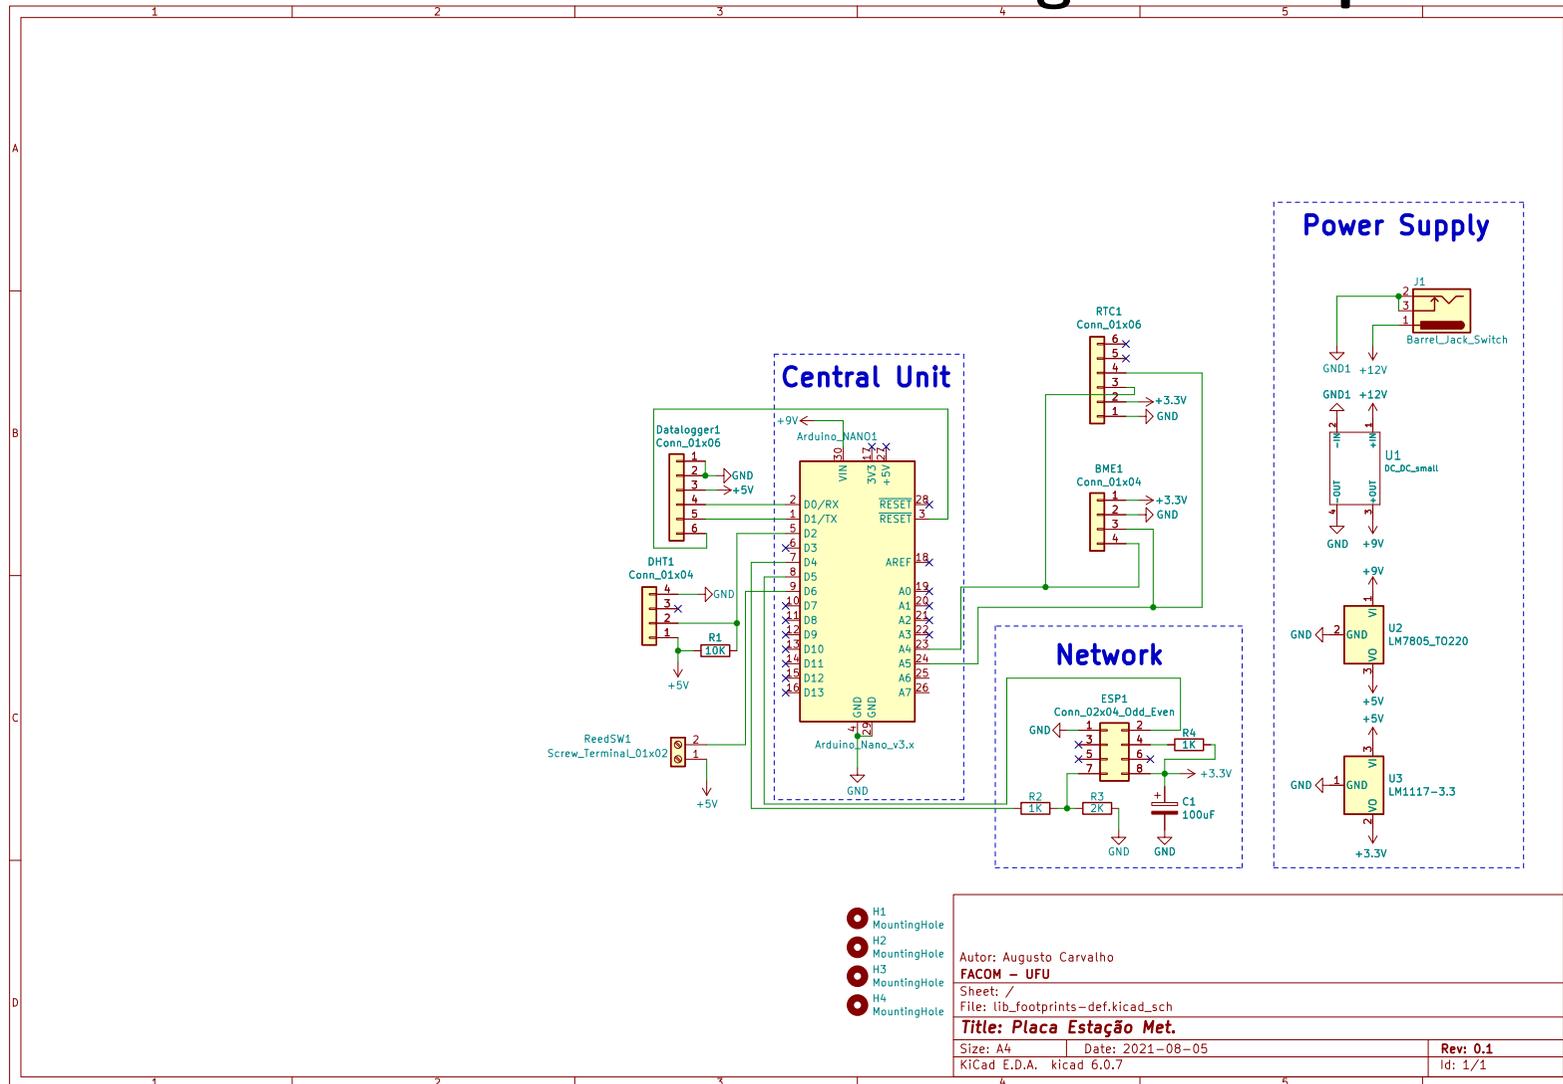
RUMELHART, David E *et al.* **Parallel distributed processing**. [S.l.]: IEEE New York, 1988. v. 1.

RUSSELL, Stuart J.; NORVIG, Peter. **Artificial intelligence: a modern approach**. Third edition, global edition. Boston Columbus Indianapolis: Pearson, 2016. (Prentice Hall series in artificial intelligence). ISBN 978-0-13-604259-4 978-1-292-15396-4.

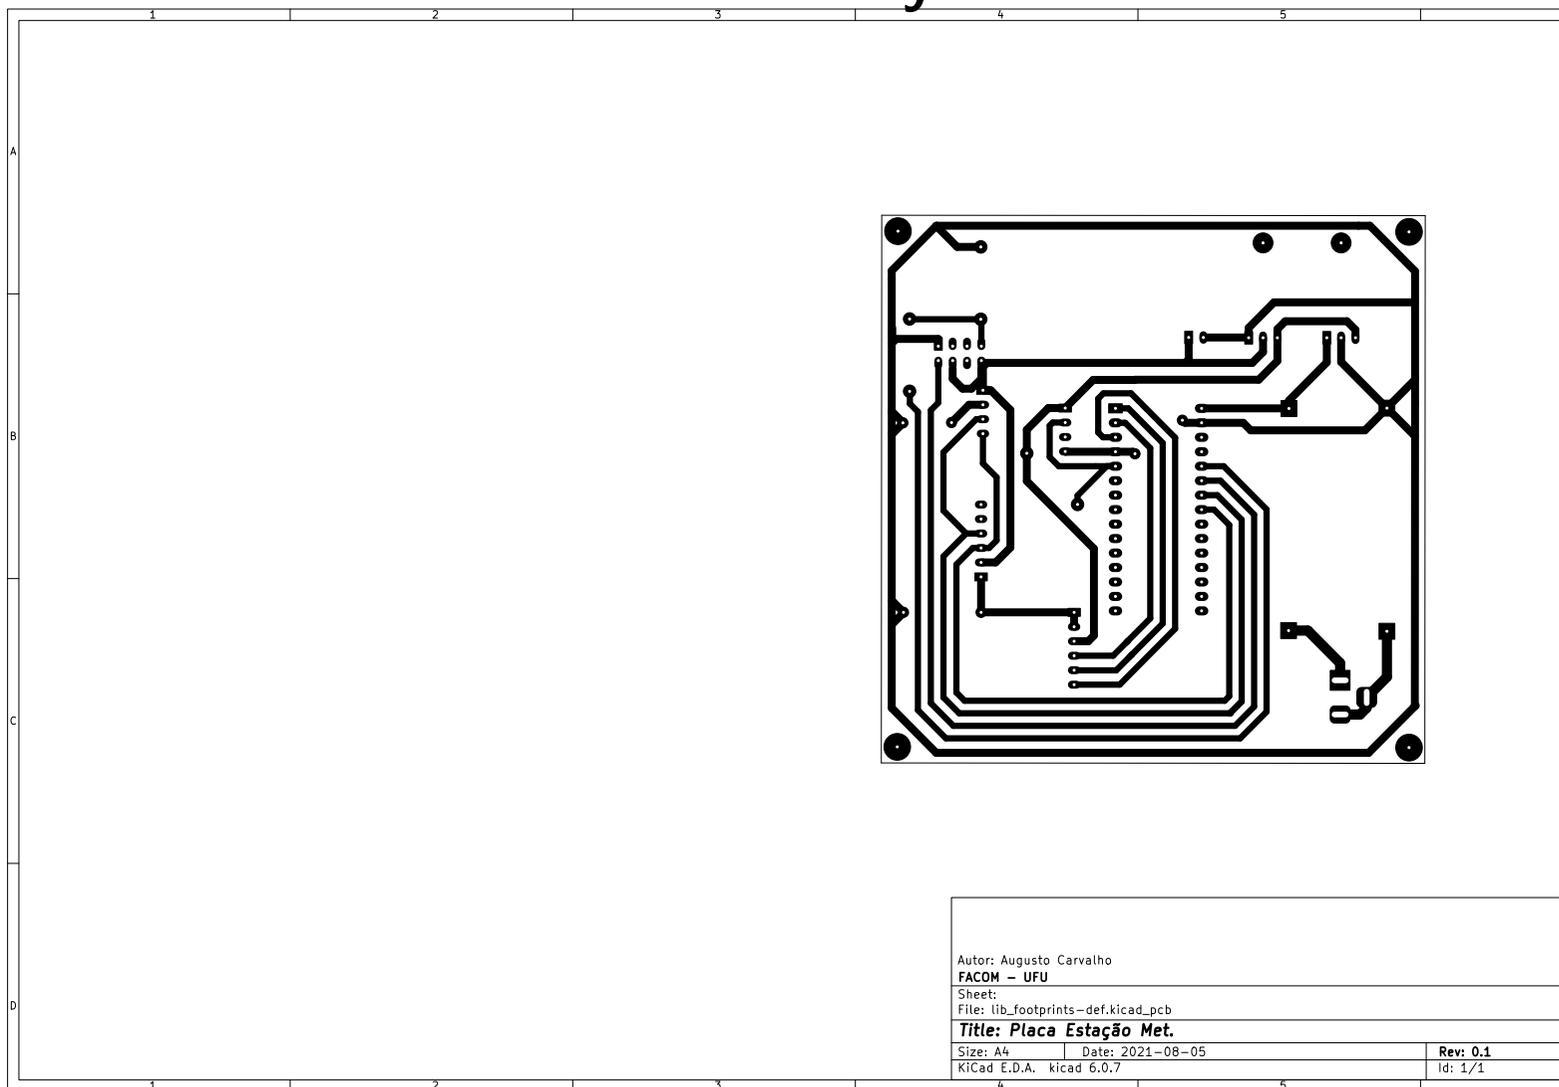
SCHITTKOWSKI, Klaus. **Numerical data fitting in dynamical systems: a practical introduction with applications and software**. Dordrecht: Kluwer Academic Publishers, 2002. OCLC: 861705955. ISBN 978-1-4419-5762-7.

- SCHULTZ, M. G. *et al.* Can deep learning beat numerical weather prediction? **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 379, n. 2194, p. 20200097, abr. 2021. ISSN 1364-503X, 1471-2962. Disponível em: <<https://royalsocietypublishing.org/doi/10.1098/rsta.2020.0097>>.
- SCHUMACHER, Russ S. *et al.* From Random Forests to Flood Forecasts: A Research to Operations Success Story. **Bulletin of the American Meteorological Society**, v. 102, n. 9, p. E1742–E1755, set. 2021. ISSN 0003-0007, 1520-0477. Disponível em: <<https://journals.ametsoc.org/view/journals/bams/102/9/BAMS-D-20-0186.1.xml>>.
- SENTELHAS, Paulo César *et al.* **Meteorologia Agrícola**. Piracicaba: Escola Superior de Agricultura Luiz de Queiroz, 2007. Disponível em: <<http://www.leb.esalq.usp.br/leb/aulas/lce306/lce306.html>>.
- SHI, Xingjian *et al.* Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. In: . Cambridge, MA, USA: MIT Press, 2015. (NIPS'15), p. 802–810. Event-place: Montreal, Canada.
- SKAMAROCK, William C. *et al.* **A Description of the Advanced Research WRF Model Version 4**. [S.l.], 2019. Disponível em: <<https://opensky.ucar.edu/islandora/object/opensky:2898>>.
- SONG, Linye *et al.* Machine Learning Approach to Summer Precipitation Nowcasting over the Eastern Alps. **Meteorologische Zeitschrift**, v. 29, n. 4, p. 289–305, out. 2020. Place: Stuttgart, Germany. Disponível em: <<http://dx.doi.org/10.1127/metz/2019/0977>>.
- SOUTO, Yania Molina. **Uma abordagem espaço-temporal para aprendizado em conjunto usando redes ConvLSTM**. jun. 2018. Tese (Doutorado em Modelagem Computacional) — Laboratório Nacional de Computação Científica (LNCC), Petrópolis, RJ, jun. 2018. Disponível em: <<https://tede.lncc.br/handle/tede/296>>.
- SparkFun. **OpenLog Hookup Guide**. [S.l.], 2016. Disponível em: <<https://learn.sparkfun.com/tutorials/openlog-hookup-guide>>.
- Texas Instruments. **KeyStone Architecture Serial Peripheral Interface (SPI)**. [S.l.], 2012. Disponível em: <<https://www.ti.com/lit/ug/sprugp2a/sprugp2a.pdf>>.
- TORRES, João Delfino *et al.* Aquisição de dados meteorológicos através da plataforma Arduino: construção de baixo custo e análise de dados. **Scientia Plena**, v. 11, n. 2, fev. 2015. ISSN 1808-2793. Disponível em: <<https://scientiaplena.emnuvens.com.br/sp/article/view/1742>>.
- TUCCI, Carlos Eduardo Morelli. **Inundações Urbanas**. 1^a. ed. Porto Alegre: ABRH / Rhama, 2007. ISBN 978-85-88686-21-2.
- TUCCI, Carlos E. M. Águas urbanas. **Estudos Avançados**, v. 22, n. 63, p. 97–112, 2008. ISSN 0103-4014. Disponível em: <<https://www.scielo.br/j/ea/a/SfqYWrhrtvkxybFsjYQtx7v/?lang=pt>>.
- ZHOU, Shuyi *et al.* ConvLSTM-Based Wave Forecasts in the South and East China Seas. v. 8, p. 680079, jun. 2021. ISSN 2296-7745. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fmars.2021.680079/full>>.

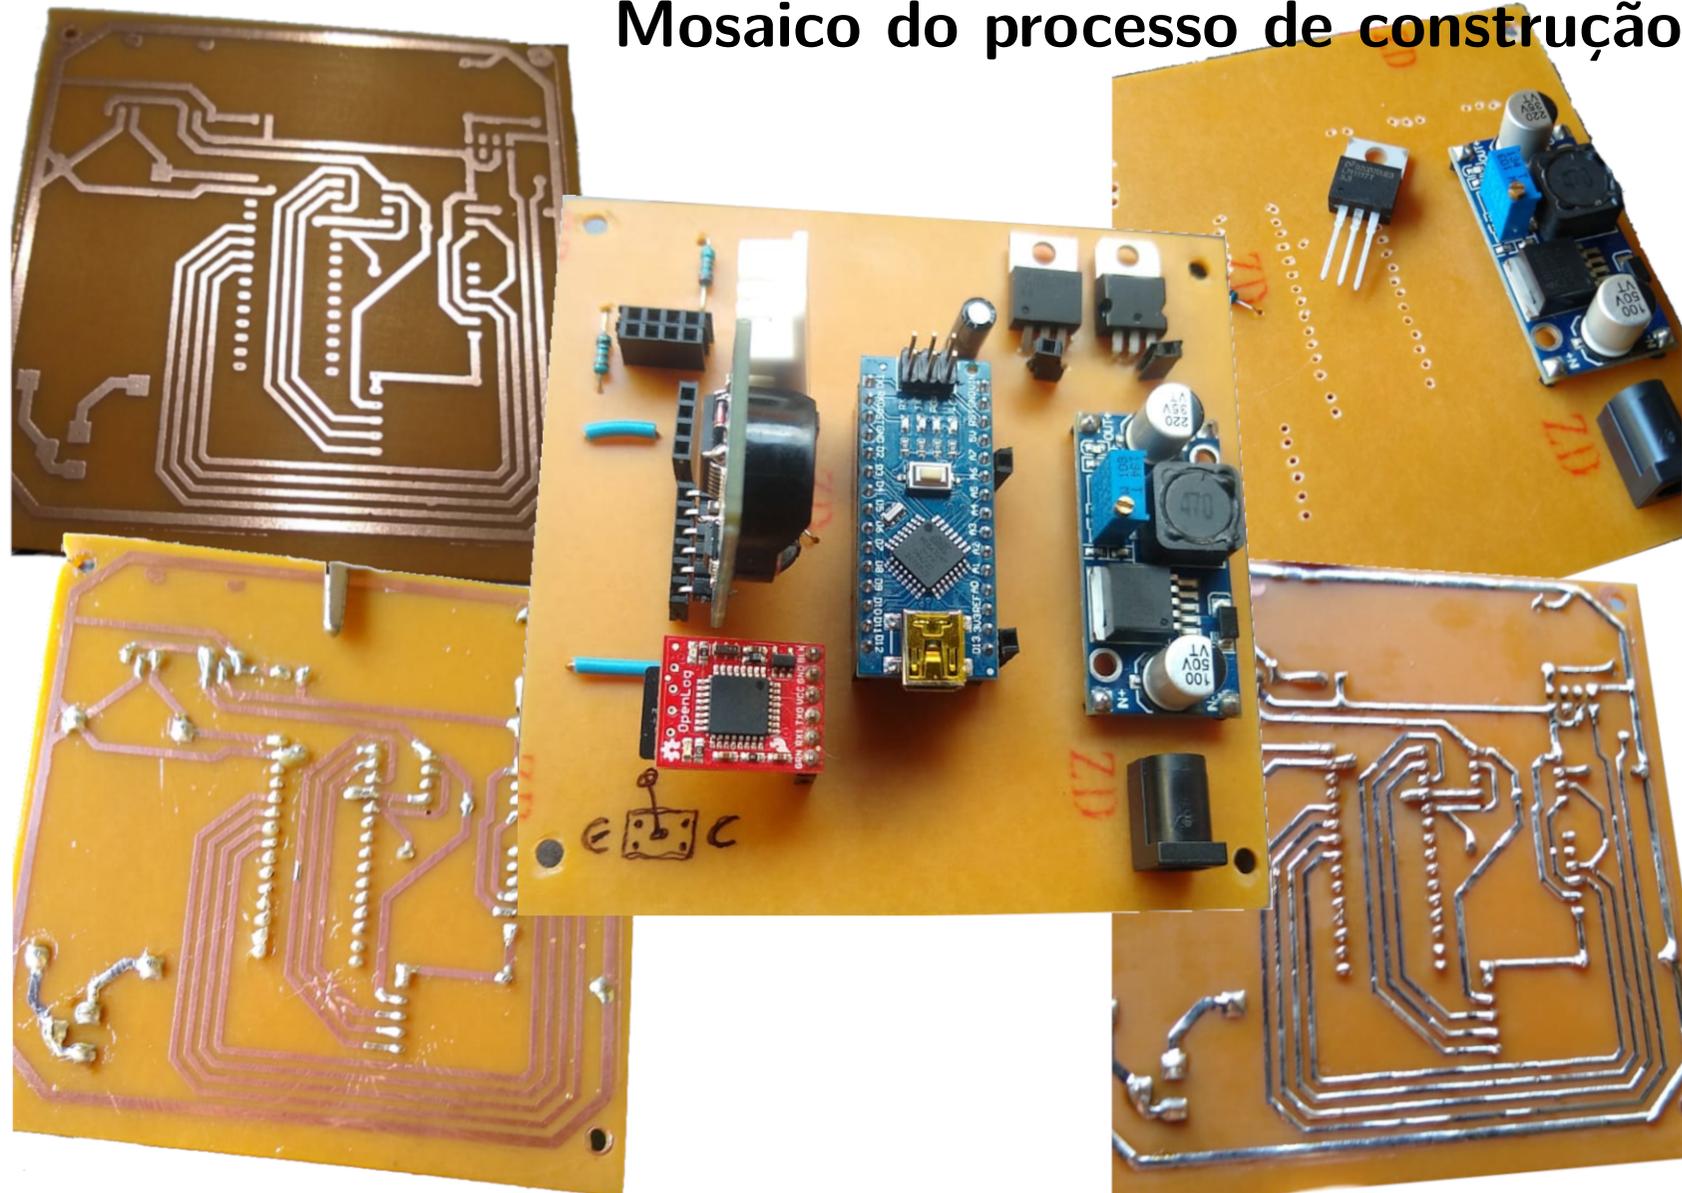
Diagrama Esquemático



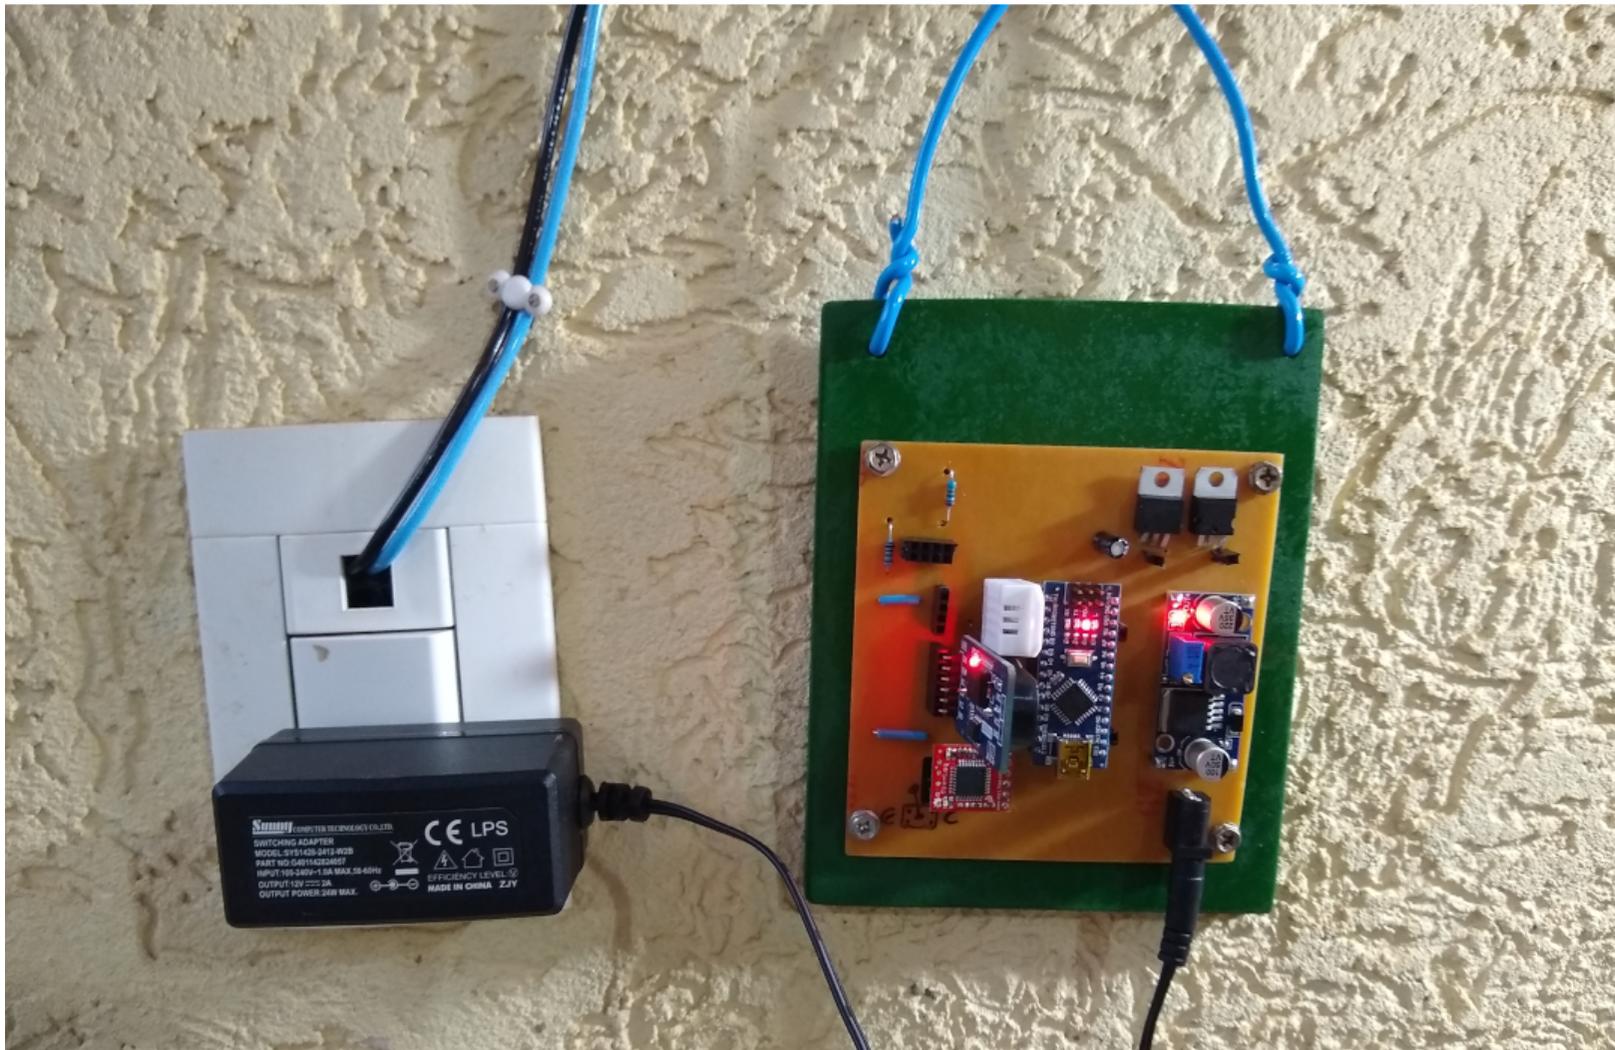
Layout das trilhas da PCB



Mosaico do processo de construção



Placa da Estação pronta



```
piloto : python3 — Konsole
Arquivo  Editar  Exibir  Favoritos  Plugins  Configurações  Ajuda
Programa all tests
gts@HADES7:~/piloto$ python3 all_tests.py
+-----+
|           Program -> All tests           |
+-----+
#> Total combinations (lstm): 4050
#> Initiating sequence of combinations for Neural Network: lstm
##> Combination (1/4050) params sequence: (1, 100, 'adam', 5, 8, 8, 'relu')
python3 ./networks/lstm/lstm.py --config_file ./outputs/configs/lstm/lstm_0001.yaml
Running network... OK (19.09s)
##> Combination (2/4050) params sequence: (1, 100, 'adam', 5, 8, 8, 'tanh')
python3 ./networks/lstm/lstm.py --config_file ./outputs/configs/lstm/lstm_0002.yaml
Running network... OK (20.54s)
##> Combination (3/4050) params sequence: (1, 100, 'adam', 5, 8, 16, 'relu')
python3 ./networks/lstm/lstm.py --config_file ./outputs/configs/lstm/lstm_0003.yaml
Running network... OK (19.20s)
##> Combination (4/4050) params sequence: (1, 100, 'adam', 5, 8, 16, 'tanh')
python3 ./networks/lstm/lstm.py --config_file ./outputs/configs/lstm/lstm_0004.yaml
Running network... |
```

```
piloto : bash — Konsole
Arquivo Editar Exibir Favoritos Plugins Configurações Ajuda
Programa best Set Finder
gts@HADES7:~/piloto$ python3 best_set_finder.py outputs/stats/performance_lstm.json
+-----+
|           Program -> Best set finder           |
+-----+
#> Metric table: model (lstm)
      MSE      RMSE      MAE      MAPE
1      0.276668  0.525992  0.197281  148.726578
2      0.278831  0.528045  0.213004  147.973465
3      0.275055  0.524457  0.200914  139.814102
4      0.280792  0.529898  0.213998  142.577698
5      0.283166  0.532133  0.221387  162.684601
...
4046   0.306303  0.553447  0.234580  69.451958
4047   0.303333  0.550757  0.208561  58.427425
4048   0.302049  0.549590  0.217324  68.196709
4049   0.303524  0.550930  0.201593  55.770061
4050   0.306980  0.554058  0.223788  74.719604

[4050 rows x 4 columns]
##> Best set for Metric MSE is: [2614] with value: [0.07328337]
##> Best set for Metric RMSE is: [2614] with value: [0.27070901]
##> Best set for Metric MAE is: [3911] with value: [0.07920194]
##> Best set for Metric MAPE is: [3911] with value: [19.85313416]
Found best set(s)!
Set(s) with more than one best metric: {2614, 3911}
gts@HADES7:~/piloto$
```

Validação cruzada

G.1 Validação 10-Fold para LSTM

Score per fold, model: lstm

> Fold 1 - Loss: 0.0779 - MAPE: 21.266%

> Fold 2 - Loss: 0.0994 - MAPE: 38.818%

> Fold 3 - Loss: 0.1430 - MAPE: 35.020%

> Fold 4 - Loss: 0.0995 - MAPE: 23.196%

> Fold 5 - Loss: 0.1205 - MAPE: 38.107%

> Fold 6 - Loss: 0.1065 - MAPE: 31.119%

> Fold 7 - Loss: 0.0883 - MAPE: 31.487%

> Fold 8 - Loss: 0.1154 - MAPE: 36.530%

> Fold 9 - Loss: 0.1146 - MAPE: 26.802%

> Fold 10 - Loss: 3.9086 - MAPE: 224.062%

Average scores for all folds:

> MAPE: 50.641% (+- 58.092)

> Loss: 0.4874

G.2 Validação 10-Fold para MLP

Score per fold, model: mlp

> Fold 1 - Loss: 0.0932 - MAPE: 20.809%

> Fold 2 - Loss: 0.1084 - MAPE: 49.775%

> Fold 3 - Loss: 0.1134 - MAPE: 32.480%

> Fold 4 - Loss: 0.0759 - MAPE: 21.181%

> Fold 5 - Loss: 0.0975 - MAPE: 39.154%

> Fold 6 - Loss: 0.1060 - MAPE: 29.122%

> Fold 7 - Loss: 0.0849 - MAPE: 38.792%

> Fold 8 - Loss: 0.1223 - MAPE: 42.254%

> Fold 9 - Loss: 0.1072 - MAPE: 31.516%

> Fold 10 - Loss: 3.0047 - MAPE: 189.605%

Average scores for all folds:

> MAPE: 49.469% (+- 47.495)

> Loss: 0.3913