UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM EM CIÊNCIAS DA TERRA E DO AMBIENTE

Mestrado em Modelagem em Ciências da Terra e do Ambiente

Dissertação de Mestrado

MODELAGEM DE VARIÁVEIS METEOROLÓGICAS: UM ESTUDO DE CASO DO BRASIL

Apresentada por: Joice de Jesus Santos
Orientador: Dr. Gilney Figueira Zebende
Co-orientador: Dr[a]. Andrea de Almeida Brito

Fevereiro 2025

MODELAGEM DE VARIÁVEIS METEOROLÓGICAS: UM ESTUDO DE CASO DO BRASIL

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Modelagem em Ciências da Terra e do Ambiente, Curso de Mestrado em Modelagem em Ciências da Terra e do Ambiente da UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA, como requisito parcial para a obtenção do título de **Mestra em Ciências Ambientais**.

Área de conhecimento: Estudos Ambientais e Geotecnologias

Orientador: Dr. Gilney Figueira Zebende

UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Co-orientadora: Dr[a]. Andrea de Almeida Brito

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA BAHIA

Feira de Santana, BA
UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA
2025

Ficha catalográfica - Biblioteca Central Julieta Carteado - UEFS

Santos, Joice de Jesus
S235m Modelagem de variáveis meteorológicas: um estudo de caso do Brasil / Joice de Jesus Santos. - 2025.
81f.: il.

Orientador: Gilney Figueira Zebende
Coorientadora: Andrea de Almeida Brito

Dissertação (mestrado) - Universidade Estadual de Feira de Santana. Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente, 2025.

1. Modelagem meteorológica. 2. Radiação. 3. Tempo. 4. Variações meteorológicas. 5. Correlação – Variáveis climáticas. I. Zebende, Gilney Figueira, orient. II. Brito, Andrea de Almeida, coorient. III. Universidade Estadual de Feira de Santana. Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente. IV. Título.

CDU: 551.5

Rejane Maria Rosa Ribeiro – Bibliotecária CRB-5/695

Nota sobre o estilo do PPGM-UEFS

Esta dissertação de mestrado foi elaborada considerando as normas de estilo propostas e aprovadas pelo colegiado do Programa de Pós-graduação em Modelagem em Ciências da Terra e do Ambiente e estão disponíveis no formato eletrônico ou no formato impresso para consulta.

UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Programa de Pós-graduação em Modelagem em Ciências da Terra e do Ambiente

Mestrado em Modelagem em Ciências da Terra e do Ambiente

A Banca Examinadora, constituída pelos professores listados abaixo, leu e recomenda a aprovação da Dissertação de Mestrado, intitulada "MODELAGEM DE VARIÁVEIS METEOROLÓGICAS: UM ESTUDO DE CASO DO BRASIL", apresentada no dia 20 de fevereiro de 2025 por **Joice de Jesus Santos**, como requisito parcial para a obtenção do título de **Mestra em Ciências Ambientais**.

Orientador:

GILNEY FIGUEIRA ZEBENDE:02239627751

Digitally signed by GILNEY FIGUEIRA ZEBENDE:02239627751
Date: 2025.02.21 11:15:13 -03'00'

Prof. Dr. Gilney Figueira Zebende

UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Co-Orientadora:

gov.br Documento assinado digitalmente
ANDREA DE ALMEIDA BRITO
Data: 21/02/2025 11:43:15-0300
Verifique em https://validar.iti.gov.br

Prof.ª Dra. Andrea de Almeida Brito

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA BAHIA

Membro externo da Banca:

gov.br Documento assinado digitalmente
PAULO HENRIQUE ZANELLA DE ARRUDA
Data: 21/02/2025 14:42:05-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Paulo Henrique Zanella de Arruda

UNIVERSIDADE FEDERAL DO MATO GROSSO

Membro interno da Banca:

gov.br Documento assinado digitalmente
ANA TEREZA COSTA SILVA
Data: 21/02/2025 15:12:06-0300
Verifique em https://validar.iti.gov.br

Prof.ª Dra. Ana Tereza Costa Silva

UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Dedico este trabalho a Deus, a minha família e a todos que acreditaram em meu potencial e que me apoiaram em cada passo desta jornada.

"Não fui eu que ordenei a você? Seja forte e corajoso! Não se apavore nem desanime, pois o Senhor, o seu Deus, estará com você por onde você andar". (Josué 1:9)

Agradecimentos

Este trabalho representa não apenas o esforço e dedicação investidos ao longo desses dois anos, mas também o apoio e a colaboração de muitas pessoas que, de alguma forma, contribuíram para a sua realização.

Em primeiro lugar, agradeço a Deus por me conceder tantas vitórias inenarráveis e a Virgem Maria por sempre interceder por mim!

Agradeço aos meus pais, Lucinete e Jenival cujo amor incondicional, incentivo e apoio foram fundamentais para a minha formação e para que eu pudesse chegar até aqui. A minha irmã Fernanda e a minha irmã de coração Joane. De forma conjunta agradeço a toda a minha família pelo apoio.

Aos meus orientadores, expresso minha profunda gratidão pela paciência, orientação e pelos valiosos conhecimentos compartilhados. Suas críticas construtivas e seu apoio contínuo foram cruciais para o desenvolvimento desta dissertação. Ao professor Dr. Gilney Zebende pela orientação e dedicação ao tema escolhido, e por ter acreditado na pesquisa, a Profa. Dra. Andréa Brito por todo cuidado e atenção, obrigada pela coorientação.

Agradeço também aos meus amigos e amigas, que estiveram ao meu lado nos momentos mais difíceis, oferecendo palavras de encorajamento e ombro amigo. Em especial a minha amiga Hismilei que nesses últimos anos tem sido como uma irmã para mim, obrigada por todo companheirismo de sempre, por me motivar e pelos bons conselhos. Vocês tornaram esta jornada mais leve e significativa.

Não posso deixar de mencionar os colegas de curso e os professores que, direta ou indiretamente, contribuíram para o meu crescimento acadêmico e pessoal. Suas discussões, ideias e colaborações enriqueceram esta pesquisa. Gostaria de agradecer imensamente ao grupo de pesquisa de Sistemas Complexos.

Agradeço a FAPESB pelo fomento da pesquisa, ao PPGM por ser um programa de excelência e por todos os recursos proporcionados. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Por fim, agradeço a todos que, de alguma forma, participaram deste processo, seja com uma palavra de apoio, um sorriso ou um gesto de carinho.

Feira de Santana, Bahia, Brasil — Joice de Jesus Santos

Fevereiro 2025

Resumo

Essa dissertação investiga a variabilidade climática e seus impactos no Brasil, destacando a diversidade de padrões climáticos regionais e a relevância da previsão de eventos extremos, como secas e inundações, que afetam diretamente o país. E com o intuito de discorrer sobre esta questão, nesta pesquisa temos como objetivo principal estudar correlações de variáveis meteorológicas no Brasil por meio dos coeficientes de correlação cruzada ρ_{DCCA} e DMC_x^2. A fundamentação teórica inclui uma revisão de modelos estatísticos aplicados a dados meteorológicos e séries temporais, enfatizando o uso de análises de correlação cruzada e métodos de memória de longo alcance, como a análise de flutuação sem tendência (DFA). Esses métodos são essenciais para o desenvolvimento de soluções estratégicas que visam mitigar os impactos das mudanças climáticas e melhorar a compreensão e previsão de eventos meteorológicos extremos no Brasil. O estudo abordou a variabilidade climática no Brasil, enfatizando a importância da análise das condições meteorológicas em diferentes regiões do país, que apresentam características climáticas distintas. A pesquisa utilizou dados do Instituto Nacional de Meteorologia (INMET), selecionando 26 estações ativas entre 2009 e 2019, permitindo um panorama abrangente da radiação solar, temperatura, umidade e velocidade do vento. A metodologia incluiu o tratamento de dados e a aplicação de métodos estatísticos, como correlações cruzadas, para investigar as relações entre as variáveis. Resultados preliminares indicaram correlações significativas, especialmente entre radiação solar e temperatura, com a expectativa de que as análises contribuam para o planejamento e tomada de decisões em diversas áreas do conhecimento. A análise estatística dos dados meteorológicos revelou grandes variações nas variáveis radiação solar, temperatura do ar, umidade relativa e velocidade do vento em diferentes capitais brasileiras. Utilizando o método do diagrama de caixas de Tukey, observou-se que cidades como Natal e João Pessoa apresentaram altos valores de radiação solar, enquanto a umidade relativa variou consideravelmente entre regiões. A correlação cruzada entre radiação solar e temperatura do ar mostrou uma relação forte em várias estações, exceto em Cuiabá e Teresina. A análise ρ_{DCCA} destacou correlações significativas entre radiação solar e umidade relativa, especialmente em regiões como Norte e Nordeste. O coeficiente DMC_x^2 permitiu uma compreensão mais abrangente das interações entre as variáveis, essencial para especialidaes como o manejo sustentável e a adaptação as mudanças climáticas, considerando as particularidades de cada bioma e suas influências nas condições climáticas regionais. Embora a pesquisa tenha mostrado resultados relevantes, limitações como o tempo de coleta e o número de variáveis dificultam conclusões definitivas sobre o aquecimento global e suas causas.

Palvras-chave: Correlações; Modelagem; Radiação; Tempo.

Abstract

This dissertation investigates climatic variability and its impacts in Brazil, highlighting the diversity of regional climate patterns and the relevance of forecasting extreme events, such as droughts and floods, that directly affect the country. The primary objective of this research is to study correlations of meteorological variables in Brazil through the cross-correlation coefficients ρ_{DCCA} and DMC_x^2. The theoretical foundation includes a review of statistical models applied to meteorological data and time series, emphasizing the use of cross-correlation analyses and long-range memory methods, such as detrended fluctuation analysis (DFA). These methods are essential for developing strategic solutions aimed at mitigating the impacts of climate change and improving the understanding and forecasting of extreme weather events in Brazil. The study addressed climatic variability in Brazil, emphasizing the importance of analyzing meteorological conditions in different regions of the country, which present distinct climatic characteristics. The research utilized data from the National Institute of Meteorology (INMET), selecting 26 active stations between 2009 and 2019, allowing a comprehensive overview of solar radiation, temperature, humidity, and wind speed. The methodology included data processing and the application of statistical methods, such as cross-correlations, to investigate the relationships between the variables. Preliminary results indicated significant correlations, especially between solar radiation and temperature, with the expectation that the analyses will contribute to planning and decision-making in various fields of knowledge. The statistical analysis of the meteorological data revealed large variations in solar radiation, air temperature, relative humidity, and wind speed in different Brazilian cities. Using Tukey's boxplot method, it was observed that cities like Natal and João Pessoa exhibited high solar radiation values, while relative humidity varied considerably between regions. The cross-correlation between solar radiation and air temperature showed a strong relationship in several stations, except in Cuiabá and Teresina. The ρ_{DCCA} analysis highlighted significant correlations between solar radiation and relative humidity, especially in regions like the North and Northeast. The DMC_x^2 method allowed for a more comprehensive understanding of the interactions between the variables, essential for specialties such as sustainable management and adaptation to climate change, considering the particularities of each biome and their influences on regional climatic conditions. Although the research showed relevant results, limitations such as the collection time and the number of variables hinder definitive conclusions about global warming and its causes.

Keywords: Correlations; Modeling; Radiation; Weather.

Sumário

1 INTRODUÇÃO **1**

2 FUNDAMENTAÇÃO TEÓRICA **5**
2.1 Modelagem Meteorológica . . . 5
2.1.1 Aspectos Históricos e Organizacionais . . . 5
2.2 Aplicações da Modelagem de Variáveis Meteorológicas no Brasil . . . 9
2.3 Variáveis Meteorológicas . . . 11
2.4 Séries Temporais, Métodos de Análise e Coeficientes ρ_{DCCA} e DMC_x^2 . . . 16
2.4.1 Definição de Série Temporal . . . 16
2.4.2 Tendências em Séries Temporais . . . 18
2.4.3 Periodicidade em Séries Temporais . . . 19
2.4.4 Função de Autocorrelação . . . 20
2.5 Modelos para Análise de Memória de Longo Alcance em Séries Não estacionárias . . . 21
2.5.1 Estatística de Hurst (Modelo R/S) . . . 21
2.5.2 Método DFA (Detrended Fluctuation Analysis) . . . 25
2.5.3 Método DCCA (*Detrended Cross-Correlation Analysis*) . . . 27
2.5.4 Coeficiente De Correlação Cruzada ρ_{DCCA} . . . 28
2.5.5 Coeficiente De Correlação Cruzada Múltiplo - DMC_x^2 . . . 29
2.5.6 Método do Diagrama de Caixas (Box Plot) . . . 31

3 METODOLOGIA **33**
3.1 Área de Estudo . . . 33
3.1.1 Descrição Geral da Área em Estudo . . . 33
3.2 Base de Dados . . . 36
3.3 Tratamento de Dados . . . 38
3.4 Processamento de Dados . . . 39
3.5 Análise de Dados . . . 39

4 RESULTADOS **41**
4.1 Análise Estatística . . . 41
4.2 Análise por meio do coeficiente ρ_{DCCA} . . . 47
4.3 Análise por meio do coeficiente DMC_x^2 . . . 52

5 CONSIDERAÇÕES FINAIS **57**

A Anexo I **58**

Referências **72**

Lista de Tabelas

2.1 Propriedade do expoente de Hurst 23
2.2 Expoente de autocorrelação α_{DFA} e suas característica. 26
2.3 ρ_{DCCA}, coeficiente de correlação cruzada de Zebende, e suas propriedades. . 29
2.4 Possíveis intervalos para o Coeficiente de Correlação Cruzada ρ_{DCCA} 29
2.5 DMC_x^2 , coeficiente de correlação cruzada múltiplo e possíveis níveis de correlação cruzada. 30

3.1 Coordenadas geográficas das estações meteorológicas do INMET. 36

4.1 Valores máximos e mínimos para todas as estações com: Radiação Solar (Rad), Temperatura do Ar (T), Umidade Relativa do Ar (RH) e Velocidade do Vento (WS). 41
4.2 Condição do ρ_{DCCA} para a radiação solar x temperatura do ar. 48
4.3 Condição do ρ_{DCCA} para a radiação solar x velocidade do vento. 50
4.4 Condição do ρ_{DCCA} para a radiação solar x umidade relativa. 51
4.5 Condição do DMC_{xz}^2 54

Lista de Figuras

2.1 Exemplo de Estação Meteorológica. Estação Meteorológica Centenária de Passo Fundo (RS) atualmente. ECP Passo Fundo/RS-83914 (Inaugurada em 1912.) Foto: Bruna Sampaio do Amaral. Fonte: (INMET, 2024). . . . 14
2.2 Mapa de localizações das Estações Meteorológicas do Instituto Nacional de Meteorologia, no Brasil. Fonte: (INMET, 2024). 15
2.3 Sistema dinâmico. Fonte: Adaptado de Pereira (1997). 17
2.4 Modelo do reservatório de Hurst para o cálculo do R/S. Fonte:Fractals (FEDER, 1988) 22
2.5 Modelo do Reservatório de Hurst (1951). Fonte: Fractals (FEDER, 1988). 23
2.6 Algorítmo para o cálculo da Função de Flutuação DFA. Fonte: Fractals (ZEBENDE, 2011). 26
2.7 Estatísticas Utilizadas no Box Plot. Fonte: (BUSSAB; MORETIN, 2002). . 31
2.8 Esquema do diagrama de Tukey. Fonte: (BUSSAB; MORETIN, 2002). . . 32

3.1 Classificação das regiões brasileiras e localização das estações meteorológicas do INMET. 35
3.2 Imagem ilustrativa da base de dados das variáveis meteorológicas em planilhas eletrônicas. 37
3.3 (a) Radiação Solar, (b) Temperatura do ar, (c) Humidade relativa do ar e velocidade do vento em função do tempo (horas). 38
3.4 Imagem ilustrativa do processamento no RHO-DCCA-MATRIX das correlações (ρ_{DCCA}) e (DMC_x^2). O termo dependent variable y representa a radiação solar, independent variable x1 a temperatura do ar, independent variable x2 a umidade relativa e a independent variable x3 a velocidade do vento. 39

4.1 Diagrama de caixas para a variável radiação solar. 43
4.2 Diagrama de caixas para a variável temperatura do ar. 44
4.3 Diagrama de caixas para a variável umidade relativa do ar. 45
4.4 Diagrama de caixas para a variável umidade relativa do ar. 46
4.5 Análise do ρ_{DCCA} para as estações meteorológicas. 47
4.6 Análise do DMC_x^2 para as estações meteorológicas. 53

A.1 Correlações cruzadas para a região Sul. 58
A.2 Correlações cruzadas para a região Sudeste. 59
A.3 Correlações cruzadas para a região Centro-Oeste. 60
A.4 Correlações cruzadas para a região Norte. 61
A.5 Correlações cruzadas para a região Nordeste. 62
A.6 Correlações cruzadas para a região Nordeste. 63
A.7 Correlações cruzadas para a região Sul. 64
A.8 Correlações cruzadas para a região Sudeste. 65
A.9 Correlações cruzadas para a região Centro-Oeste. 66
A.10 Correlações cruzadas para a região Norte. 67
A.11 Correlações cruzadas para a região Nordeste. 68
A.12 Correlações cruzadas para a região Nordeste. 69

A.13 Estações meteorológicas distribuídas nos biomas brasileiros. 70
A.14 RHO-DCCA-MATRIX, sob número BR 51 2016 000375 - 8, que calcula em diferentes escalas de tamanhos os expoentes de autocorrelação, α_{DFA}, o expoente de correlação cruzada, λ_{DFA} e o coeficiente de correlação cruzada, ρ_{DCCA}. 71

Lista de Siglas

ARMA	Modelo Auto Regressivo de Médias Móveis
BRAMS	Brazilian Developments on Regional Atmospheric Modelling System
CENAD	Centro Nacional de Gestão de Riscos e Desastres
CEMADEN .	Centro Nacional de Monitoramento e Alerta de Desastres Naturais
COLA	Center for Ocean-Land Atmosphere Studies
CONAME ..	Comissão Nacional de Meteorologia
CO_2	Dióxido de Carbono
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
CPTEC	Centro de Previsões de Tempo e Estudos Climáticos
CCST	Centro de Ciências do Sistema Terrestre
CTA	Centro Técnico Aeronáutico
DCCA	Detrended Cross-Correlation Analysis
DFA	Detrended Fluctuation Analysis
DMC_x^2	Coeficiente de Correlação Cruzada Múltiplo
EMA	Estação Meteorológica Automática
ENOS	Oscilação Sul-El Niño
ETA	Estimated Time of Arrival
FAC	Função de Autocorrelação
FINEP	Financiadora de Estudos e Projetos
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
MCT	Ministério da Ciência e Tecnologia
MCTI	Ministério da Ciência, Tecnologia e Inovação
NCEP	National Centers for Environmental Prediction
nm	Nanômetro
ODS	Objetivos do Desenvolvimento Sustentável
PAC	Programa de Aceleração do Crescimento
PNMC	Plano Nacional de Mudanças Climáticas
PPGM	Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente
OMM	Organização Meteorológica Mundial
ρ_{DCCA}	Coeficiente de Correlação Cruzada
SSI	Solar Spectral Irradiance
ST	Série Temporal
UA	Unidade Astronômica
UEFS	Universidade Estadual de Feira de Santana
UTC	Universal Time Coordinated
WRF	Weather Research Forecasting
WWW	World Wide Web

Capítulo Um

INTRODUÇÃO

A alta variabilidade climática, por meio de ciclos anuais, gera deficiência e/ou excesso de chuvas em todo o mundo, que por sua vez produz secas ou inundações. Os eventos climáticos extremos assumem importância significativa no cotidiano das sociedades, seja por sua frequência e intensidade de ocorrência (DAVIDSON etal. , 2012; MARENGO et al., 2013; BRANDO et al., 2014; DOUGHTY et al., 2015).

No Brasil, encontra-se uma grande variedade de padrões climáticos. Na região Norte, verifica-se um clima equatorial chuvoso, praticamente sem estação seca. No Nordeste, a estação chuvosa, com baixos índices pluviométricos, restringe-se a poucos meses, caracterizando um clima semiárido e apresentando previsibilidade climática. As regiões Sudeste e Centro-Oeste sofrem influências tanto de sistemas tropicais quanto de latitudes médias, com estação seca bem definida no inverno e estação chuvosa no verão com chuvas convectivas. Ambas regiões apresentam baixa previsibilidade devido à menor dependência em relação as condições dos oceanos e a grande variedade dos sistemas meteorológicos que as atingem. Finalmente, a região Sul do Brasil é caracterizada com média previsibilidade, e devido a sua localização latitudinal, sofre mais influência dos sistemas de latitudes médias, onde os sistemas frontais são os principais causadores de chuvas durante o ano (SAMPAIO; SILVA, 2014).

A frequência de eventos meteorológicos extremos no país vem chamando a atenção de pesquisadores, que buscam compreender os mecanismos climáticos e atmosféricos associados a tais fenômenos (TEIXEIRA; SATYAMURTY, 2007; PSCHEIDT; GRIMM, 2009; LIMA; SATYAMURTY, 2010).

Desta forma, os estudos sobre observações de dados meteorológicos se tornam fundamentais, pois mesmo com os avanços tecnológicos e expansão das estações meteorológicas, no país ainda há carência de dados. Para a agricultura, que é uma das principais atividades econômicas do país o conhecimento sobre o comportamento das condições de tempo são de extrema importância, mesmo com o desenvolvimento de novas tecnologias para os sistemas agrícolas as condições de tempo ainda causam muitos prejuízos, pois muitos fatores adversos são difíceis de serem previstos (AYOADE, 2004; PEREIRA et al., 2002).

Conforme Pereira et al. (2002) os sistemas agrícolas são os que possuem maior dependência das condições meteorológicas, estas influenciam em todas as fases das atividades agrícolas, desde a escolha da época de semeadura até o armazenamento dos produtos. O planejamento de cidades, geração de energia e a segurança da população também depende da

previsão e análise de variáveis meteorológicas. Isso é particularmente relevante no contexto dos Objetivos de Desenvolvimento Sustentável (ODS), onde a compreensão detalhada das mudanças climáticas e seus impactos é fundamental para o desenvolvimento de políticas eficazes.

Em geral, essas variáveis que são medidas ou simuladas ao longo do tempo, formam séries temporais, que são analisadas no intuito de mensurar eventuais propriedades de escala. Segundo Filho (2014), devido ao grande volume de dados e informações produzidos nas diversas áreas científicas, faz-se necessário a modelagem e o desenvolvimento de métodos estatísticos no auxílio da tabulação e estatística dos mesmos.

A literatura oferece diversos métodos estatísticos para quantificar correlações entre séries temporais por exemplo. Entre eles, destacam-se a correlação cruzada para análise de séries temporais de variáveis distintas utilizando os coeficientes ρ_{DCCA} e DMC_x^2. Esses coeficientes especialmente robustos, superam o coeficiente de Pearson em determinadas situações, conforme observado por Kristoufek (2014).

Costa et al. (2024) mostra em seu trabalho a análise de correlação cruzada da variável climática temperatura do ar entre estacoes meteorológicas no estado da Bahia. O autor estuda dois tipos de variáveis através dos dados de 12 estações meteorológicas espalhadas pela Bahia, ele analisou que a variável temperatura do ar ao longo de toda a região estudada, possui interação positiva onde o coeficiente de correlação cruzada apresenta-se forte para diferentes escalas de tempo. Contudo, realçando a necessidade do desenvolvimento de propostas práticas para curto, médio e longo prazos a fim de que o impacto das mudanças climáticas sobre a região seja minimizado.

Resultados preliminares, obtidos por Brito (2016), mostraram características estatísticas distintas nas localidades de Salvador, Paulo Afonso, Cruz das Almas e Barreiras, analisando as variáveis temperatura do ar e umidade relativa do ar. O comportamento da temperatura do ar para uma mesma localidade varia ao longo do dia, bem como ao longo do ano. Tais variações dependem de outras variáveis meteorológicas, a exemplo, da radiação solar, deslocamento das massas de ar, correntes oceânicas, posição geográfica, altitude, umidade do ar, dentre outros.

Em novos estudos, Brito (2021) traz a perspectiva desses métodos de análise de correlação para três variáveis meteorológicas. Na sua análise, a autora diz que foi aplicada generalização do coeficiente ρ_{DCCA} para o estudo de múltiplas séries temporais meteorológicas, tendo a radiação solar como base de estudo, e desta forma, foi proposto uma nova modelagem para captação de energia solar. Para referendar a análise, simulou computacionalmente séries temporais com partes removidas (com memória de longo alcance), no intuito da verificação da robustez do coeficiente ρ_{DCCA}, para cortes e remoções. Desta

simulação, observou que o ρ_{DCCA} mostrou-se eficiente para até o limite de 50% de remoção da série temporal original.

Embora existam estudos sobre modelagem estatística meteorológica, poucos exploram a correlação cruzada de forma detalhada no contexto brasileiro. A presente pesquisa se justifica pela sensibilidade em relação aos desafios ambientais que se encontra rotineiramente no Brasil, empregando esses métodos de correlação para examinar e compreender quatro variáveis meteorológicas de forma mais precisa e abrangente, sendo elas a radiação solar, a temperatura do ar, a umidade relativa do ar e a velocidade do vento.

Partindo da hipótese de que existe uma correlação significativa entre dados meteorológicos e com o intuito de aprofundar a investigação e, assim, ampliar a exploração de possíveis decisões e soluções estratégicas, a pesquisa se deriva da seguinte pergunta: Como as variáveis meteorológicas podem ser correlacionadas e analisadas para melhorar a compreensão e previsão de eventos climáticos?

E com o intuito de discorrer sobre esta questão, nesta pesquisa temos como objetivo principal estudar correlações de variáveis meteorológicas no Brasil por meio dos coeficientes de correlação cruzada ρ_{DCCA} e DMC_x^2.

Para atender o objetivo geral desta dissertação, foi definido como objetivos específicos:

- Observar a variação temporal das variáveis meteorológicas entre os anos de 2009 e 2019;
- Avaliar estatisticamente as variáveis meteorológicas;
- Modelar e aplicar redes de correlações cruzadas para as variáveis meteorológicas;
- Estimar o nível de correlação cruzada das variáveis meteorológicas, via coeficientes ρ_{DCCA} e DMC_x^2.

Tendo em vista estes objetivos da pesquisa, a dissertação foi organizada em capítulos:

- **Capítulo 1 - INTRODUÇÃO**: Estabelece o contexto do problema, descrevendo a importância de sua resolução e delineando os objetivos da pesquisa;
- **Capítulo 2 - FUNDAMENTAÇÃO TEÓRICA**: Neste capítulo conduzimos uma análise bibliográfica abrangente, baseada em dados secundários, com o intuito

de apresentarmos uma visão detalhada da situação real relacionada ao problema em questão;

- **Capítulo 3 - METODOLOGIA**: Aqui são detalhadas as metodologias adotadas na condução da pesquisa, fornecendo uma visão abrangente dos procedimentos aplicados;
- **Capítulo 4 - RESULTADOS E CONCLUSÕES**: Por fim, apresenta-se os resultados obtidos, bem como as conclusões decorrentes da pesquisa. Além disso, são oferecidas recomendações pertinentes com base no trabalho desenvolvido ao longo deste estudo.

Capítulo Dois

FUNDAMENTAÇÃO TEÓRICA

Nesta seção será construída a base teórica e científica do estudo, dialogando com a literatura existente, definindo conceitos e teorias, identificando lacunas no conhecimento e estabelecendo as bases para a investigação da pesquisa.

2.1 Modelagem Meteorológica

Dentre os diversos avanços científicos que ocorreram no último século está a habilidade em simular complexos sistemas físicos meteorológicos utilizando modelos numéricos que constituem uma representação matemática aproximada da realidade. Nesse tópico será abordado o contexto do crescimento de estudos meteorológicos no Brasil.

O estudo dos fenômenos atmosféricos é realizado pela meteorologia e pela climatologia, onde, a climatologia nasce baseada nos estudos da meteorologia, estudando a atmosfera e seus fenômenos e preocupando-se com o registro e a medição destes fenômenos cuja finalidade seria determinar as condições físicas sob as quais foram produzidos (BARROS; ZAVATINI, 2009).

A pesquisa da meteorologia apresenta dois domínios: Meteorologia tradicional e a Meteorologia dinâmica. A meteorologia tradicional estuda os elementos atmosféricos de forma isolada sendo conhecida também como Meteorologia analítico-separativa; a meteorologia dinâmica considera todos os elementos do meio atmosférico (BARROS; ZAVATINI, 2009). A climatologia encontra-se dentro do campo da geografia, tendo como objeto de estudo os fenômenos da atmosfera em contato com a superfície terrestre e sua distribuição espacial. A climatologia surgiu de uma concepção atribuída pela meteorologia essas duas ciências contrapõem-se em bases conceituais como o conceito de clima e tempo, para a meteorologia o tempo seria o conjunto de valores que, em um dado momento e em um determinado lugar, caracterizam o estado atmosférico, enquanto para a climatologia o tempo seria é uma combinação passageira, efêmera, de curta duração dos fenômenos atmosféricos (BARROS; ZAVATINI, 2009).

2.1.1 Aspectos Históricos e Organizacionais

O campo da meteorologia operacional começou a ser redefinido na Europa e nos Estados Unidos no início da década de 1950, quando foram desenvolvidas as primeiras previsões meteorológicas com métodos numéricos. Em pouco tempo, os avanços na supercomputação, na modelagem e na infraestrutura de informação em centros de pesquisa meteo-

rológica na América do Norte e na Europa tornaram possível o uso da previsão numérica do tempo em escalas e resoluções cada vez mais temporárias, de modo que desde o início da década de 1990, o modelo computacional da estação climática substituiu completamente a antiga climatologia estatística nestes países (LYNCH, 2008; EDWARDS, 2010; HEYMANN, 2010).

No final da década de 1980, foi criado no Brasil o Centro de Previsões de Tempo e Estudos Climáticos (CPTEC), no Instituto Nacional de Pesquisas Espaciais (INPE). Este centro nasceu como uma proposta de modernização da meteorologia brasileira, que deveria passar a dominar a previsão numérica do tempo e a modelagem climática, como os centros europeus e americanos. Essa proposta, que expressava uma noção de desenvolvimento baseada na ideia de superação da dependência dos países desenvolvidos por meio do fortalecimento da ciência nacional, encontrou ambiente favorável no recém-criado Ministério da Ciência e Tecnologia (MCT) em 1985. Foi aberto em 1994 e hoje é considerado pela Organização Meteorológica Mundial (OMM) como um dos centros mais importantes da América Latina (FAPESP, 2008).

Nesse contexto, no início da década de 1970, meteorologistas e climatologistas do INPE iniciaram um processo que visava convencer o governo brasileiro a acabar com o atraso na previsão numérica do tempo, tentando sensibilizar lideranças do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Até o início da década de 1990, as previsões meteorológicas fornecidas pelo Instituto Nacional de Meteorologia (INMET), mas também pelo próprio INPE, eram elaboradas por meio de métodos estatísticos. O INMET, a mais antiga instituição meteorológica brasileira, tem se dedicado à instalação e manutenção da rede nacional de estações meteorológicas. Ele também foi responsável pelo sistema internacional de telecomunicações e informação para recebimento e envio de dados meteorológicos através da OMM (LEMES, 1973).

O Instituto de Atividades Espaciais do Centro Técnico Aeronáutico (CTA - hoje Departamento de Ciência e Tecnologia Aeroespacial) foi outra instituição de pesquisa meteorológica. No CTA realizou-se pesquisas climáticas com base empírico-estatística e dirigiu pelo menos dois grandes projetos: Moclima e Modart, que propõe modificações climáticas artificiais. Mas é na Meteorologia do INPE, no início da década de 1970, que a criação de um moderno centro de previsão numérica do tempo começou a ser concebida por lideranças internas (MOURA;LEMES, 1980).

No final dos anos 1970, as atenções do governo brasileiro para os problemas relacionados ao tempo e ao clima dirigiam-se aos impactos das chuvas intensas e geadas no Sul e Sudeste do país e, principalmente, à seca na região Nordeste. A possibilidade de previsões meteorológicas mais precisas era vislumbrada pelos governos federal e estaduais como um instrumento poderoso ao monitoramento desses riscos. A modernização dos serviços mete-

orológicos deveria atender a demandas sociais e de setores econômicos, como agricultura, transporte e energia (PARADA; MEIRA, 1980).

Também foi preciso alterar a legislação sobre a CONAME – Comissão Nacional de Meteorologia, passando a vinculá-la agora ao Ministério da Ciência, Tecnologia e Inovação (MCTI). O mesmo decreto incluiu entre as responsabilidades do MCTI o desenvolvimento e operação de modelos de previsão meteorológica de curto, médio e longo prazo, a distribuição de informação meteorológica aos órgãos setoriais operacionais da meteorologia nacional (MIGUEL; ESCADA, 2016).

A partir deste momento, iniciou-se um período de transição no qual se definiu e planejou a implementação do CPTEC, incluindo a especificação do supercomputador que deveria ser utilizado para fornecer as previsões de tempo. Com o objetivo de solucionar os entraves de importação de supercomputadores e outros recursos para a construção do novo centro de previsão do INPE, o próximo passo foi enviar uma equipe de especialistas do CPTEC para o COLA (Center for Ocean-Land Atmosphere Studies), nos Estados Unidos, no início de 1994. O COLA apresentou o seu modelo global e ofereceu formação exemplar (MIGUEL; ESCADA, 2016).

A experiência adquirida em modelagem ao longo de duas décadas, em associação a uma forte base em física atmosférica e matemática, constituída a partir da formação de uma massa crítica de cientistas produziu alicerces para o desenvolvimento da previsão numérica no CPTEC/INPE (MIGUEL; ESCADA, 2016).

Os financiamentos obtidos para a compra de supercomputadores em 1998 e 2004, foram facilitados por uma urgência percebida pelo governo federal na época: o risco das crises energéticas devido à falta de chuva, os chamados apagões. De modo geral, as demandas por previsões climáticas e monitoramento Hidrometeorológicos por conta dos apagões deram grande atenção à Meteorologia brasileira naquele período. Graças a novos investimentos em infraestrutura de supercomputação, foram feitos progressos significativos no modelo CPTEC. Em 1996, foi implementado o modelo regional de ETA - Estimated Time of Arrival, abrangendo a América do Sul. Este modelo foi desenvolvido na Universidade de Belgrado, na Iugoslávia, e refinado no NCEP - National Centers for Environmental Prediction, nos EUA. Novos desenvolvimentos foram feitos no modelo COLA. Em 2002, novas técnicas numéricas foram aplicadas ao modelo geral, introduzindo equações de dinâmica de fluidos em linguagem computacional (modelo dinâmico) e representações de campos atmosféricos e climatológicos, como precipitação, pressão, fluxo de vento, temperatura do ar e geopotencial (configurações físicas). Com isso, o modelo passou a se chamar CPTEC/COLA (FLEMING; JANKOVIC, 2006).

Em 2004, o modelo foi totalmente modificado em sua parte dinâmica e física, pas-

sando a se chamar MCGA CPTEC/INPE, o primeiro adaptado às condições brasileiras e sul-americanas. Outro modelo regional desenvolvido no CPTEC foi o BRAMS (Brazilian Developments on Regional Atmospheric Modelling System) um modelo de previsão climática com características ambientais que integra emissões de partículas e gases devido a incêndios e poluição dos centros urbanos (DIAS, 2013). Além disso, um sistema de monitoramento operacional em tempo real foi implementado em 2003 usando o modelo de transporte CATT–BRAMS acoplado ao modelo de previsão do tempo e qualidade do ar. Este modelo é capaz de prever a trajetória de plumas de gases e partículas associadas a queimadas em floresta tropical, cerrado e pastagem (DIAS, 2013).

Um outro modelo numérico mais difundido no Brasil e no mundo é o WRF (Weather Research Forecasting), utilizado não apenas na previsão temporal de precipitação pluviométrica mais para diversas outras componentes atmosféricas (MACEDO; HENKES, 2011; RAMOS et al., 2013; MOLLMANN et al., 2013; OLIVEIRA; ROBAINA, 2004).

Após a conferência Rio 92, o governo assinou a Convenção-Quadro das Nações Unidas sobre Alterações Climáticas. Porém, somente em 2007 surgiu o Plano Nacional de Mudanças Climáticas (PNMC – Decreto 6.263) e o anúncio, em 2009, da Lei 12.187, que institui a Política Nacional de Mudanças Climáticas. Aliado a esta política, foi criado o Fundo Nacional sobre Mudanças do Clima (Fundo Clima) (Lei n° 12.114/2009), com a finalidade de financiar projetos, estudos e empreendimento para a mitigação e adaptação aos efeitos das mudanças climáticas. Entendendo que a mudança global do clima é um dos mais significativos desafios da atualidade, o PNMC e o Fundo Clima estabeleceram metas a diversos setores da economia e também às instituições de ensino e pesquisa (MIGUEL; ESCADA, 2016).

Aliado a essa política, o MCTI junto à FINEP - Financiadora de Estudos e Projetos, lançou em 20 de novembro de 2007 o projeto da Rede Clima. Segundo o primeiro edital do projeto, as atribuições da Rede incluem a articulação das várias instituições brasileiras e internacionais em um trabalho cooperativo com vistas à mitigação e adaptação às mudanças climáticas (MIGUEL; ESCADA, 2016).

Essa nova leva de políticas científicas e programas de incentivo às pesquisas sobre mudanças climáticas provocou modificações institucionais dentro do INPE que afetaram o CPTEC. Fato que sinalizou um incentivo à reconfiguração das áreas de pesquisa de tempo e clima na instituição. Uma das primeiras ações do MCTI foi a criação do Centro de Ciências do Sistema Terrestre (CCST) na sede do INPE em 2008. Esse centro foi criado para o desenvolvimento da modelagem das mudanças climáticas na escala de dezenas a centenas de anos (MIGUEL; ESCADA, 2016).

Uma segunda ação do MCTI foi a criação do Centro Nacional de Monitoramento e Alerta

de Desastres Naturais (CEMADEN) em 2011. A grande justificativa e motivação para a criação deste Centro foi o ocorrido em 12 de janeiro de 2011, causando centenas de mortes e os moradores de rua da região serrana do estado do Rio de Janeiro. Posteriormente, o Governo Federal lançou o Plano Nacional de Gestão e Resposta a Desastres com financiamento de infraestrutura por meio do Programa de Aceleração do Crescimento (PAC), que prevê a atuação integrada do CEMADEN no MCTI e no Centro Nacional de Gestão de Riscos e Desastres (CENAD) para monitoramento e ações de resposta (MIGUEL; ESCADA, 2016).

Além disso, o surgimento do CEMADEN na área de monitoramento meteorológico, previsão numérica e modelagem climática é percebido por pesquisadores que se dedicam a desenvolvimentos em modelagem relacionados às previsões de curto e médio prazo como uma duplicação de operações dentro do contexto da Meteorologia nacional. Os avanços científicos e tecnológicos do CPTEC foram condicionados pelas particularidades institucionais internas e pelo contexto político maior no qual a política científica do MCTI se insere atualmente. Nesse contexto, as mudanças climáticas globais ganharam a atenção do governo, criando uma janela de oportunidade para que grupos científicos do INPE dedicados a essas pesquisas alinhassem seus interesses de pesquisa aos novos interesses de setores do governo federal (MIGUEL; ESCADA, 2016).

2.2 Aplicações da Modelagem de Variáveis Meteorológicas no Brasil

É notório que o início das previsões meteorológicas no Brasil se deu em meio a eventos extremos climáticos. Em síntese, o naufrágio do navio Rio–Apa em 11 de julho de 1887, durante uma terrível tempestade no litoral do Rio Grande do Sul, revelou a precariedade da meteorologia no Brasil, que ainda não possuía um serviço de previsão do tempo. Na época, países europeus e os Estados Unidos já utilizavam redes de estações meteorológicas interligadas por telégrafo para prever tempestades. No Brasil, instituições como o Imperial Observatório do Rio de Janeiro e a Repartição Hidrográfica faziam observações meteorológicas, mas ainda estavam em fases iniciais de organização de uma rede meteorológica (FLEMING, 1990; NEBEKER, 1995; BARBOZA, 2005).

Henrique Morize, jovem funcionário do Observatório, publicou um estudo após o naufrágio, afirmando que, mesmo com mais estações, seria difícil prever tempestades na costa brasileira. Vinte anos depois, em 1917, outra tempestade atingiu o litoral, desta vez no Rio de Janeiro. Nesse período, o Observatório havia se consolidado e liderava a criação de uma rede meteorológica nacional, interligada pelo telégrafo. Morize, agora diretor do Observatório, analisou a tempestade de 1917 utilizando mapas sinópticos e afirmou que a

meteorologia dinâmica permitia prever mudanças de tempo com maior precisão, refletindo um avanço significativo em relação ao ceticismo de 1887 (MORIZE, 1887).

Diante desse contexto, cabe mostrar o quanto a aplicação de modelagem meteorológica no Brasil implementou meios de ação contra desastres e ajudou na construção de novos meios tecnológicos.

Estudos como o de Maria et al. (2008), vem mostrar a importância desse tipo de aplicação em curto prazo, no seu texto a autora fala sobre a modelagem numérica em alta resolução para a previsão de energia eólica no Ceará. Diferentes resoluções espaciais e parametrizações foram testadas, sendo a comparação entre as simulações feita com base em uma metodologia estatística. Tal metodologia foi aplicada para escolha das melhores opções de espaçamento de grade horizontal, parametrização de turbulência e peso do relaxamento newtoniano na representação dos campos de vento do litoral cearense em quatro dias do período de transição entre as estações seca e chuvosa. Os testes revelam que, dentre as opções testadas, a configuração que melhor reproduz as observações ao longo do litoral, conta com espaçamento de grade horizontal de 1 km, turbulência parametrizada com a versão anisotrópica do esquema proposto por Smagorinsky e escala de tempo do relaxamento newtoniano de 12 h (MARIA et al., 2008).

O estudo de Albuquerque (2015), já traz a perspectiva de estudo de séries históricas, a modelagem em séries temporais aplicados a dados climatológicos no sertão paraibano. O autor mostra que nos últimos anos, a análise de dados meteorológicos tornou–se uma tarefa importante devido as mudanças climáticas. Sendo assim, importante utilizar uma metodologia capaz de analisar dados distribuídos ao longo do tempo/espaço, isto é, uma análise de séries temporais. No seu trabalho, o autor utilizou técnicas para verificar possíveis comportamentos anômalos das séries de precipitação. Com isso os modelos auto regressivos de médias móveis (ARMA) mostraram-se eficientes. A escolha do modelo que melhor representou os dados em estudo, procedeu–se com a previsão para os próximos anos já que o sertão paraibano é caracterizado por suas secas severas, esse tipo de estudo contribui intimamente para o planejamento de quem reside nessa localidade (ALBUQUERQUE, 2015).

Sobre os eventos de fortes precipitações o estudo de Farias; Mendonça (2019), vem mostrar a modelagem e mapeamento de áreas de perigo de inundação urbana na cidade de Francisco Beltrão, município do Paraná (Brasil). Na Região Sul do país a ocorrência de eventos Hidrometeorológicos extremos tem gerado preocupação nas instituições públicas e privadas, uma vez que as inundações vêm causando, a cada ano, elevados prejuízos à população, à infraestrutura e aos serviços localizados nas áreas de risco. Nesse contexto, o trabalho apresenta os procedimentos metodológicos de modelagem utilizados no mapeamento das áreas de perigo natural de inundação, ou seja, daquelas afetadas pelo espraiamento das

cheias dos rios e canais urbanos devido a fortes chuvas (FARIAS; MENDONÇA, 2019).

Um outro fator importante é que a modelagem meteorológica é crucial para a compreensão e previsão dos eventos El Niño e La Niña (Oscilação Sul-El Niño - ENOS), que têm impactos significativos em escala global e são fases opostas de um padrão de clima natural em todo o Oceano Pacífico tropical que oscila a cada 3 a 7 anos em média. O ciclo ENOS é um termo científico que descreve as flutuações de temperatura entre o oceano e a atmosfera no leste central do Pacífico Equatorial (NOAA, 2024; KEVIN, 1997).

A fase quente (El Niño) e fase fria (La Niña) levam a diferenças significativas em relação à temperatura média dos oceanos, ventos, pressão superficial e precipitação em partes do Pacífico tropical. A fase Neutra indica que as condições estão próximas de sua média de longo prazo. Esse tipo de modelagem permite prever com maior precisão as alterações nos padrões climáticos associados ao ENOS. Isso possibilita a preparação antecipada para mitigar os efeitos adversos, como secas, inundações e impactos na agricultura, fornecendo informações essenciais para a tomada de decisões em setores como gestão de recursos hídricos, agricultura e prevenção de desastres (NOAA, 2024; KEVIN, 1997).

Com o advento da tecnologia e sua crescente capacidade do processamento de dados de forma interdisciplinar, tem sido cada vez mais eficiente a utilização dos modelos meteorológicos na tarefa de representar com a máxima exatidão a condição do tempo. Limitações na resolução do modelo podem trazer incertezas significativas nas previsões realizadas com modelos atmosférico, bem como comparações descuidadas das variáveis meteorológicas numa coordenada geográfica específica (EMA – Estação Meteorológica Automática) com uma área (modelo atmosférico), podem trazer incertezas significativas na avaliação na qualidade das previsões realizadas (SILVA et al., 2019).

2.3 Variáveis Meteorológicas

As variáveis climáticas estão entre os fatores que mais afetam a vida na Terra e por isso constituem uma das maiores preocupações da atualidade, tanto por parte dos investigadores como da população em geral. Nesse sentido, as pesquisas em clima têm ganhado cada vez mais importância no cenário atual, devido às tendências das mudanças climáticas no planeta. Segundo o Painel Brasileiro de Mudanças Climáticas (PBMC2013, 2013), devido às mudanças climáticas podem ocorrer alterações nos padrões comportamentais, principalmente de temperatura e precipitação, eventos extremos relacionados a essas variáveis tendem a aumentar, causando disfunções em todos os setores da sociedade global(PBMC2013, 2013).

Sabe-se que as variáveis meteorológicas passam por um ciclo diário, que se deve ao mo-

vimento de rotação da Terra. A radiação solar por exemplo, é o fluxo de energia emitida pelo Sol e transmitida sob a forma de radiação eletromagnética. No entanto, observações contínuas desde o final da década de 70 demonstraram variação em escalas de tempo de minutos até décadas (FROHLICH, 2006). As medidas de radiação são denominadas como Irradiância Solar Total (TSI – Total Solar Irradiance) e Irradiância Solar Espectral (SSI – Solar Spectral Irradiance). A Irradiância Solar Total é definida como a potência total da energia proveniente do Sol por unidade de área a 1 UA (distância entre o Sol e a Terra conhecida como Unidade Astronômica). As medidas podem ser realizadas em função do comprimento de onda [W m $^{-2}$ nm $^{-1}$] e integradas para determinar a TSI. Além disso, a quantidade de radiação solar que a Terra recebe é influenciada por diversos fatores, como a latitude, a estação do ano, a transparência da atmosfera e a duração do dia. As variações na inclinação orbital também podem provocar pequenas alterações na TSI (Irradiância Solar Total) (VIEIRA; SOLANKI, 2012).

A radiação solar, segundo Angelocci et al. (2002), é a maior fonte de energia da Terra, sendo também o principal elemento meteorológico, pois é ela que desencadeia todo o processo meteorológico afetando todos os outros elementos (temperatura, pressão, vento, chuva, umidade, etc). A energia solar é a fonte primária de energia para todos processos terrestres, desde a fotossíntese, responsável pela produção vegetal e manutenção da vida na presente forma, até o desenvolvimento de furacões, tempestades, enfim, pela circulação geral da atmosfera e oceanos. Além da sua importância em Meteorologia, a energia radiante do Sol é um elemento fundamental em estudos ecológicos e de disponibilidade energética, pois a maior parte da energia disponível na Terra tem origem na radiação solar.

A temperatura do ar apresenta um ciclo diário relacionado com a radiação solar, que aquece o solo e consequentemente o ar, geralmente a temperatura mais alta ocorre entre 14 e 15 horas, e a mais baixa antes do sol nascer (VIANELLO ; ALVES, 2000; PEREIRA et al., 2002). A temperatura é definida em termos relativos com base no calor de um corpo. Assim, é determinado pelo equilíbrio entre a radiação que entra e a que sai, sua conversão em calor latente e sensível. A temperatura é a condição que determina o fluxo de calor que passa de uma substância para outra. É importante saber que o calor passa de um corpo mais quente para um corpo mais frio. A temperatura é o elemento da atmosfera que se distribui de forma variada no tempo e na escala espacial e que as pessoas confundem com o próprio clima. As escalas usadas para expressar a temperatura incluem Fahrenheit, Celsius e Kelvin, ou a escala de temperatura absoluta (AYOADE, 1986).

A temperatura do ar é influenciada pela movimentação das massas de ar na atmosfera, sendo natural o processo físico em que as correntes de convecção acontecem pelo fato de o vento soprar de uma área mais fria (alta pressão) para uma área mais quente(baixa pressão). A movimentação de correntes oceânicas também influencia a temperatura am-

biente, ou seja, as correntes frias migram dos Polos para o equador, enquanto as correntes quentes fazem o caminho inverso. Essa movimentação das correntes oceânicas afeta a velocidade, direção e sentido dos ventos, causando uma interferência direta na temperatura local. Outro fator também determinante na temperatura ambiente é a posição geográfica da localidade. Percebe-se que em regiões costeiras, onde os ventos são dirigidos do mar para o continente, a temperatura do ar pode ser diferente de uma localidade continental em que o vento não obedeça a essa direção. Nota-se também que as regiões com menor influência da brisa marítima, sofrem uma maior variação de temperatura entre as estações do inverno e do verão. O relevo, por sua vez, influenciam de forma significativa na variável temperatura, a exemplo de cadeias montanhosas que pode dificultar ou, até mesmo, alterar, a circulação do vento, influenciando diretamente na temperatura local (SILVA, 2006).

Segundo estudos realizados por Brito (2016), a umidade relativa do ar é uma variável muito utilizada na climatologia, pois ela indica a proximidade que o ar se encontra em sua saturação, ou seja, 100% , percentual que ocorrem as precipitações. No entanto, a quantidade de umidade necessária para ocorrer a saturação do ar dependerá também da temperatura em que o ar se encontra. Em síntese, o comportamento da variação da umidade relativa do ar está relacionado a variação da temperatura ambiente ao longo do dia, ao movimento horizontal da massa de ar e movimento vertical do ar pelas correntes de convecção.

O vento, dentre muitas definições, pode ser conceituado como sendo o ar em movimento. Este deslocamento do ar atmosférico se deve às diferenças de pressão atmosférica, entre duas regiões distintas, influenciadas por efeitos locais, seja por rugosidade da superfície ou pela orografia do local. O que gera estas diferenças báricas é a distribuição diferencial da radiação solar pelo globo, e outros fatores, tais como, continetalidade, altitude e latitude, que influenciam diretamente os processos de aquecimento das massas de ar atmosférico. Os ventos se deslocam das altas para as baixas pressões, sofrem influências também da rotação da terra, da força de coriolis e da força centrífuga ao seu movimento, bem como, da interação com a superfície terrestre representada pelo atrito (MUNHOZ; GARCIA, 2008).

A caracterização espacial das variáveis meteorológicas de uma região pode ser realizada por meio da interpolação dos valores medidos em estações meteorológicas, onde, são registradas e analisadas através de equipamentos como, termômetros, higrômetros, anemômetros, pluviômetros, entre outros. Nestas estações, o trabalho é realizado pelos meteorologistas, profissionais que estudam as condições atmosféricas. Os meteorologistas utilizam as informações captadas por aparelhos terrestres, por satélites meteorológicos e radiossondas (aparelhos que emitem sinais de rádio, transportados por balões, com a função de medir a pressão, a umidade, e a temperatura das camadas altas da atmosfera)

(VASSOLER, 2012).

A rede meteorológica nacional (Fig. 2.1)operada pelo Instituto Nacional de Meteorologia (INMET) apresenta variação significativa em termos de densidade de estações por unidades federativas. Estes dados das condições do tempo coletados nas estações meteorológicas são enviados por técnicos para os institutos meteorológicos, a fim de realizar as previsões do tempo para as diversas regiões. Atualmente, existe um grande número de estações meteorológicas automáticas, que realizam medições programadas de variáveis climáticas, ou seja, sistemas informatizados que gerenciam a coleta de dados em intervalos de tempo, que pode ocorrer por minuto, hora, dia, ou outro intervalo de tempo predeterminado (VASSOLER, 2012).

Figura 2.1: Exemplo de Estação Meteorológica. Estação Meteorológica Centenária de Passo Fundo (RS) atualmente. ECP Passo Fundo/RS-83914 (Inaugurada em 1912.) Foto: Bruna Sampaio do Amaral. Fonte: (INMET, 2024).

Os dados climáticos coletados nas estações meteorológicas do INMET (Fig. 2.2) acompanham um padrão mundial. E estes valores, quando adquiridos por intervalos de hora, o fazem, por meio do Tempo Universal Coordenado (UTC, do inglês Universal Time Coordinated), conhecido como fuso horário de referência a partir do qual são calculadas todas as zonas horárias do mundo (GIVONI, 1976).

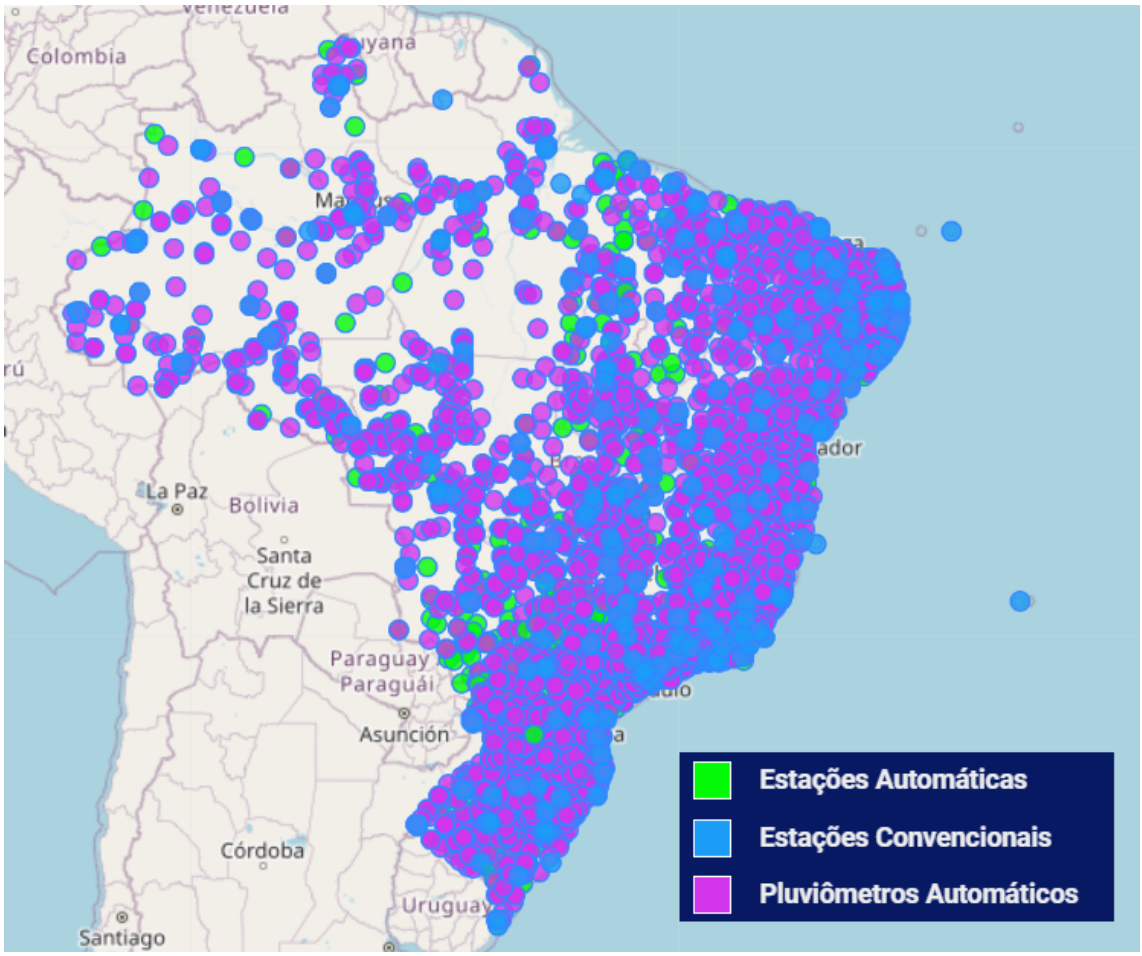

Figura 2.2: Mapa de localizações das Estações Meteorológicas do Instituto Nacional de Meteorologia, no Brasil. Fonte: (INMET, 2024).

O cenário de escassez de dados em algumas regiões conduz a dificuldades e incertezas no desenvolvimento de malhas interpoladas a partir de dados observados (AMINI et al., 2019), independente da complexidade ou da quantidade de informação adicional utilizada no processo de interpolação (NEWMAN et al., 2015).

A verificação da qualidade das previsões de tempo e clima tem sido feita com auxílio de ferramentas estatísticas, para comprovar a validação do modelo em representa a atmosfera e suas variações de forma espacial e temporal. Assim, reanálises climáticas são produtos que têm gerado interesse cada vez maior (HERSBACH et al., 2020) em função de sua aplicabilidade e consistência ao combinar uma ampla variedade de dados observados em superfície ou detectados remotamente dentro de um modelo numérico dinâmico de base física (TAREK; BRISSETTE, 2020) em escala continental ou global.

2.4 Séries Temporais, Métodos de Análise e Coeficientes ρ_{DCCA} e DMC_x^2

2.4.1 Definição de Série Temporal

Uma série temporal é qualquer conjunto de observações ordenadas no tempo (MORETTIN; TOLOI, 2004). Uma série temporal pode ser denotada por S_1, S_2, S_3,..., S_T, onde S_i indica a variável em questão e T o seu tamanho. Existem diversos tipos de séries temporais, como:

I: Valores diários de temperatura e índices de radiação coletadas em estações meteorológicas;

II: Valores diários de Umidade e Velocidade do vento coletados em estações meteorológicas;

III: Dados mensais hidrológicos coletados pelo Brasil;

De acordo com Brito (2021), a série temporal pode ser classificada como:

- contínua, quando as observações são realizadas continuamente no tempo, ou seja, T é um intervalo finito.

- discreta, quando as observações são realizadas em tempos específicos, tempo igualmente espaçado.

- multivariada, quando a série é discreta ou contínua, ou seja, $Y_1(t), \cdots, Y_k(t)$, t $\in$ T ou Y (t), t $\in$ T.

- multidimensional, quando temos Z(t), t $\in$ T (um vetor), por exemplo temos Z(t, r, l) com t $\in$ T onde Z é o valor da temperatura em um determinado instante de tempo t, a latitude r e a longitude l.

A finalidade da análise de séries temporais consiste em elucidar o padrão histórico da série, visando compreender seu comportamento passado e, por conseguinte, antecipar movimentos futuros para fins de previsão.

Brito (2021) ainda diz que, dada uma série temporal Z_{t1} , Z_{t2} , Z_{t3},..., Z_{tN} observada nos instantes t_1, t_2,..., t_N, podemos estar interessados em:

- investigar seu mecanismo gerador;

- procurar comportamentos relevantes nos dados;

- fazer previsões a partir de valores passados, que podem ser de curto, médio e longo prazo;

- descrever o seu comportamento através da construção de gráficos, construção de histogramas e diagramas de dispersão, obtenção da estatística descritiva e verificação de tendências, ciclos e sazonalidades.

Segundo Pereira (1997), as mais diversas situações em ciências físicas, biológicas e sociais, assim como na engenharia, envolvem o conceito de sistema dinâmico, caracterizado por uma série de entrada X(t), uma série de saída Z(t) e uma função de transferência v(t), ver Fig. (2.3).

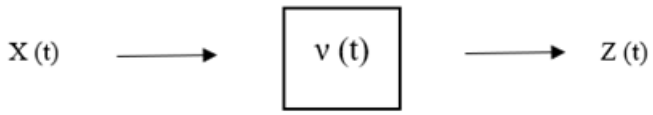

Figura 2.3: Sistema dinâmico. Fonte: Adaptado de Pereira (1997).

Assim, uma característica relevante destacada por Pereira (1997) e por Morettin;Toloi (2004) é a presença de sistemas lineares, nos quais a saída está vinculada à entrada por meio de uma relação linear que envolve v(t). Um exemplo desse tipo de modelo é representado pela função de transferência proposta por Box et al. (2008), cuja expressão é formulada na Equação 2.1.

$$Z(t) = \sum v(t)x(t-u) \tag{2.1}$$

Na função de transferência, com u sendo a defasagem no tempo, temos como interesses:

- estimar a função de transferência v(t), conhecendo-se as séries de entrada X(t) e saída Z(t);

- fazer previsões da série Z(t), com o conhecimento de observações da série de entrada X(t) e v(t);

- estudar o comportamento do sistema, simulando-se a série de entrada;

- controlar a série de saída Z(t), de modo a trazê-la o mais próximo possível de um valor desejado, ajustando-se convenientemente a série de entrada X(t). Este controle é necessário, devido a perturbações que normalmente afetam um sistema dinâmico.

2.4.2 Tendências em Séries Temporais

A tendência refere-se ao padrão de comportamento a "longo prazo"de uma série, determinando se ela permanece estável, cresce ou decresce, e também aponta a velocidade dessas variações. As tendências predominantes incluem aquelas que são constantes, lineares e quadráticas (GUTIERREZ, 2003).

Entre os vários métodos destinados a estimação de tendência T_t . Os mais utilizados destinam-se a:

(I) ajustar uma função do tempo, com um polinômio, uma função exponencial ou outra função de t;

(II) suavizar (ou filtrar) as observações da série ao redor de um ponto, visando a estimação da tendência naquele ponto;

(III) suavizar, através de sucessivos ajustes de retas de mínimos quadrados ponderados ("lowess"), as observações da série.

Aplicando um dos procedimentos citados acima, podemos estimar a tendência através de T_t obtendo uma série ajustada ou livre de tendência, ou seja,

$$Y_t = Z_t - T_t \tag{2.2}$$

Uma abordagem empregada para estimar a tendência (T_t) em uma série temporal em uma série temporal (ST) envolve o ajuste de uma curva aos valores observados da série para realizar previsões. As funções comumente utilizadas para esse propósito incluem a exponencial, a logística e um polinômio de grau m. Assim, pressupondo que a tendência (T_t) de uma série pode ser expressa pelo seguinte polinômio de grau m (MORETTIN; TOLOI, 2004).

$$T_t = \beta_0 + \beta_1 + \beta_2 + \cdots + \beta_{m^{t^m}} \tag{2.3}$$

onde o grau m do polinômio é consideravelmente menor que o número de observações N. Na determinação dos parâmetros β_j, o método comumente empregado é o Método dos Mínimos Quadrados. Dessa forma, é possível realizar previsões para valores futuros de uma série por meio de um modelo estimado usando o método dos mínimos quadrados para T_t, utilizando $\hat{T}_t$ como estimador linear para a série.

Outra abordagem reconhecida para remover a tendência de uma série é o procedimento de diferenciação, geralmente utilizando a primeira diferença (MORETTIN; TOLOI, 2004).

$$\Delta Z_t = Z_t - Z_{t-1} \tag{2.4}$$

2.4.3 Periodicidade em Séries Temporais

Na série temporal, a sazonalidade refere-se às oscilações de ascensão e declínio que ocorrem em um período específico de tempo. Essa componente sazonal compreende duas partes distintas: a cíclica e a sazonal. A diferença fundamental entre elas reside no fato de que a componente cíclica exibe movimentos previsíveis, ocorrendo em intervalos regulares de tempo, enquanto a componente sazonal apresenta movimentos que tendem a ser imprevisíveis ou irregulares (MORETTIN; TOLOI, 2004).

Geralmente, uma série temporal é considerada como a soma de três componentes distintas,

$$Z_t = T_t + S_t + a_t \tag{2.5}$$

Com t =1,2,3, ... , N. Neste caso T_t representa a tendência, S_t representa a sazonalidade, e a_t é a componente aleatória, caracterizada por uma média zero e uma variância constante σ_a^2. No modelo mencionado, o foco principal é a estimativa de S_t e a construção de uma série livre de sazonalidade, ou seja, ajustada para a sazonalidade. Portanto, com o objetivo de estimar a tendência, podemos utilizar, $\hat{S}$ como estimativa de S_t através da série sazonalmente ajustada abaixo (MORETTIN; TOLOI, 2004).

$$Z_t^{SA} = Z_t - \hat{S} \tag{2.6}$$

De acordo com Morettin;Toloi (2004), ao estimar a componente sazonal estamos cometendo erro de ajuste sazonal, expresso por:

$$\delta_t = S_t - \hat{S} \tag{2.7}$$

O ajuste sazonal é um procedimento crucial, especialmente se puder reduzir o erro de ajuste. Na estimativa da sazonalidade, quando a série temporal (ST) exibe sazonalidade estocástica, ou seja, varia ao longo do tempo, o método clássico de médias móveis é frequentemente empregado.

2.4.4 Função de Autocorrelação

A função de autocorrelação (FAC) é a auto covariância padronizada e desempenha um papel significativo ao caracterizar uma série temporal em termos de sua interdependência temporal. Em outras palavras, é útil quando se deseja medir a interdependência entre observações em uma série temporal. A função de autocorrelação tem como objetivo avaliar a correlação entre observações defasadas por períodos em uma série temporal com n observações. Portanto, o coeficiente de autocorrelação, ou a correlação serial de defasagem $k(r_k)$, é definido pela equação 2.8 (MACHADO, 2009).

$$r_k = \frac{\sum_{t=1}^{n-k}(x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^{n}(x_t - \bar{x})^2} \tag{2.8}$$

com k = 0,1,2,...

A equação define a covariância da série na defasagem k dividida pela variância da série, onde $\bar{x}$ é o valor médio das observações e n representa o comprimento da série, determinadas pela variação temporal k.

Os valores de r_k são adimensionais, e variam de -1 a 1. Assim, para interpretação dos valores r_k devemos considerar as seguintes situações (MACHADO, 2009):

a) $0 < r_k \leq 1$, existe autocorrelação positiva na série;

b) -1 $< r_k \leq 0$, existe autocorrelação negativa na série;

c) $r_k = 0$, não existe autocorrelação na série. Para estas correlações calcula-se as variações de k = 1,2,...j , onde j não deve exceder o valor $n/4$ de acordo Box et al. (2008), sendo possível representar a relação r_k contra k graficamente através de um correlograma.

A FAC também é utilizada para identificar a memória da série, ou seja, identificar se a ST

possui memória longa ou curta. Entretanto, ela é adequada para detecção de memória, no caso de termos uma série estacionária (MACHADO, 2009).

2.5 Modelos para Análise de Memória de Longo Alcance em Séries Não estacionárias

Existem várias metodologias para evidenciar a existência de correlação em séries temporais (TAQQU, 1995).

2.5.1 Estatística de Hurst (Modelo R/S)

A análise R/S, proposta por Harold E. Hurst (1880 -1978), conforme documentado por Hurst (1951), surgiu no contexto do trabalho desse hidrólogo notável. Hurst dedicou parte significativa de sua vida ao projeto de construção de uma represa para o Rio Nilo, chegando à região por volta de 1907 e permanecendo lá por quase seis décadas. Seu principal objetivo era otimizar os fluxos de água do Rio Nilo, buscando evitar tanto transbordamentos quanto níveis excessivamente baixos na represa.

Para desenvolver seu modelo, Hurst partiu do pressuposto de que o fluxo de águas pluviais seguia um processo estocástico, influenciado pela ecologia da região do Rio Nilo, caracterizada por um sistema com muitos graus de liberdade. Ele testou a hipótese de que o padrão de chuvas no Rio Nilo era governado por um processo aleatório, originando assim uma nova abordagem de análise de flutuações. Nesse contexto, o foco estava na medida do chamado "expoente de Hurst", denotado como H, que servia para distinguir entre uma série de dados aleatória e uma série não aleatória.

O método R/S de Hurst consiste em mensurar os volumes máximos e mínimos do reservatório (amplitude) e através do cálculo do desvio-padrão dos influxos de água em um determinado período de tempo τ. Assim, R/S é a razão entre a amplitude (R_τ) e o desvio padrão (S_τ) das vazões de água, como na Fig. 2.4.

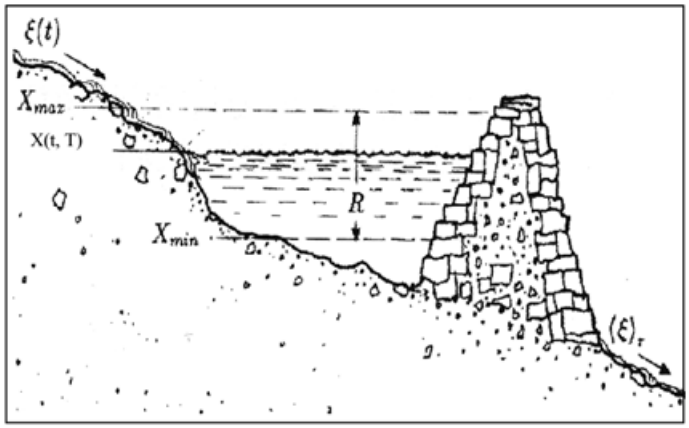

Figura 2.4: Modelo do reservatório de Hurst para o cálculo do R/S. Fonte:Fractals (FEDER, 1988)

A modelagem R/S consiste nos seguintes passos:

Primeiramente, determina-se a média aritmética do influxo de água no período τ dada pela próxima equação.

$$\langle \xi \rangle_\tau = \frac{1}{\tau} \sum_{t=1}^{\tau} \xi(\tau) \tag{2.9}$$

Onde, $\langle \xi \rangle_\tau$ apresenta o influxo de água no reservatório no instante de tempo t. Em seguida, determinamos a variação da média para v, de modo que a soma da variação acumulada da média, para os períodos de 1 à τ seja dada pela Equação 2.10.

$$X(t,\tau) = \sum_{v=1}^{t} [\xi(v) - \langle \xi \rangle \tau] \tag{2.10}$$

Em que $(\xi)\tau$ representa a média de todos os pontos da série no período τ e t representa um tempo entre o primeiro período, (t = 1), e o último, $(t = \tau)$.

Calculou-se a diferença entre o valor máximo e o mínimo de *X(t)*. Modelo do reservatório de Hurst na Figura 2.5, no período dada pela Equação 2.11, para $1 \leq t \leq \tau$:

$$R(\tau) = Max[X(t,\tau)] - Min[X(t,\tau)] \tag{2.11}$$

E, por último, dividimos R(τ) pelo seu desvio padrão S(τ), ou seja:

$$S(\tau) = \sqrt{\frac{1}{\tau}\left(\sum_{t=1}^{\tau}\left[\xi(t) - \langle\xi\rangle_{\tau}\right]^2\right)} \tag{2.12}$$

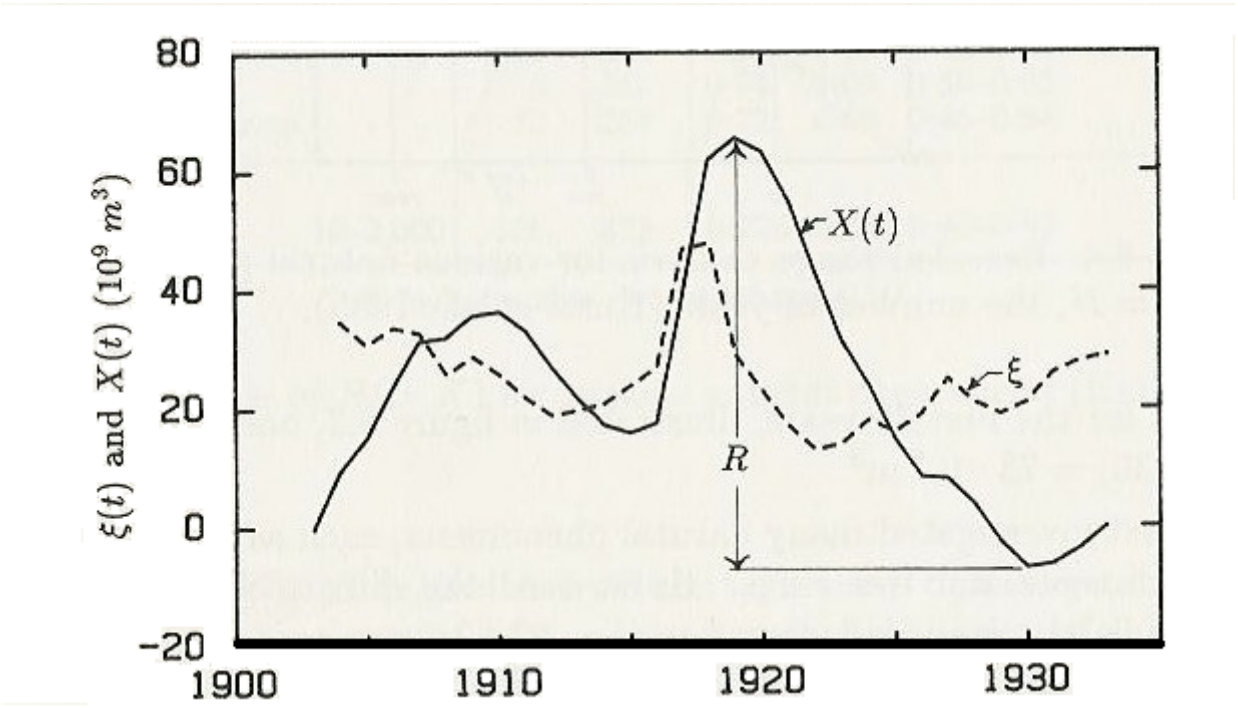

Figura 2.5: Modelo do Reservatório de Hurst (1951). Fonte: Fractals (FEDER, 1988).

Assim, para tamanhos de tempo distintos, a relação R/S poderá, ou não, seguir uma lei de potência em τ, onde H é o chamado expoente de Hurst.

$$\frac{R}{S} \sim \tau^H \tag{2.13}$$

O Expoente de Hurst tem uma variação entre 0 e 1, conforme a Tabela 2.1 :

Tabela 2.1: Propriedade do expoente de Hurst

Valor	Característica da série temporal
H < 0,5	comportamento anti-persistente
H = 0,5	descorrelacionada ou aleatória
H > 0,5	comportamento persistente

Outra característica importante do expoente H é a de informar a persistência, ou não, do processo, bem como informações sobre a correlação, a qual é calculada por (BRESLIN; BELWARD, 1999).

Se a série se comportasse como um movimento Browniano, H seria igual a 0,50.

Em outras palavras, a série dos desvios acumulados aumentaria com a raiz quadrada do tempo N. Ele testou outros rios e H foi usualmente maior que 0,50. Testou também fenômenos naturais diferentes e em todos os casos, encontrou H maior que 0,50. Isto significa que quando H difere de 0,50, as observações não são independentes. Cada observação carrega uma memória de todos os eventos que a precederam. Esta memória não é de curta duração, mas sim de longa duração;, teoricamente ela dura para sempre. Eventos recentes têm maior impacto que os eventos mais distantes, mas lá estará a influência residual. Um sistema que exibe a estatística de Hurst é o resultado de uma longa corrente de eventos interconectados. O que acontece hoje influenciará o futuro. O que temos agora é resultado do que temos tido no passado. Isto significa que uma sucessão de valores de X, não são independentes, um do outro, isto é, X(t) tem incorporado algum efeito persistente em X(t+1). Portanto, os valores estimados de H podem ser:

1) H = 0,50: Os desvios dos níveis das inundações, em relação ao seu valor médio, são independentes ou randômicos e os valores X(t) constituem um sistema similar ao movimento Browniano. O sistema é descorrelacionado, pois, C = 0.

2) 0,50<H<1 Os desvios dos níveis das inundações, são persistentes – níveis altos tendem a serem seguidos por níveis altos e níveis baixos, seguidos de níveis baixos; X(t+1) tende a desviar da média do mesmo modo que X(t); a probabilidade de X(t+1) desviar da média na mesma direção de X(t), aumenta quando H se aproxima de 1 e a correlação é positiva (C≠0).

3) 0<H<0,50: Os níveis das inundações são anti-persistente – Os X são reversos; níveis altos têm tendência de serem seguidos de níveis baixos e vice-versa; a probabilidade de X(t+1) desviar da média na direção oposta de X(t), aumenta quando H se aproxima de zero e a correlação é negativa (C≠0) (GRABBE, 1999).

Os valores de H, nos casos 2 e 3 indicam que o sistema se refere a um processo de memória longa com componentes randômicos, onde eventos passados têm efeitos sobre os eventos futuros. Processos onde a dinâmica desses sistemas é denominada de movimento Browniano fracionário (fBm).

O expoente H traz informações sobre a geometria de um determinado perfil, e também sobre a persistência ou não do processo. Um exemplo dessa relação de persistência é o movimento Browniano fracionário, que podemos relacionar, a título de ilustração, ao movimento de um bêbado ao longo de uma linha. Se os passos do bêbado são persistentes, um passo para frente será seguido, provavelmente, por outro no mesmo sentido, e este movimento o levará sempre a distâncias cada vez maiores da origem. Para passos anti-

persistente um passo para frente, provavelmente, será seguido de um para trás e isso manterá sempre próximo a origem (FEDER, 1988; CHIERICE, 2003).

2.5.2 *Método DFA (Detrended Fluctuation Analysis)*

O método DFA – Detrended Fluctuation Analysis (em inglês), análise das Flutuações sem tendências, proposto por Peng et al. (1994), tem como objetivo identificar e mensurar a autocorrelação de longo alcance em séries temporais não-estacionárias. O método DFA é uma evolução da análise estatística clássica R/S, (HURST, 1951), possuindo mais de 2000 citações em diversas áreas científicas, para análise de autocorrelações de séries temporais.

De acordo Brito (2021), o algoritmo para o cálculo da função de flutuação para o método DFA consiste nos seguintes passos, listados logo abaixo:

⟨https://scholar.google.com.br/scholar?hl=pt-BR&as_sdt=0%2C5&q=detrended+fluctuation+analysis&oq=detrende⟩

Considere uma série temporal x_i, com i variando de 1 a N (número total de pontos). Integra-se x_i para obter X_K:

$$X_k = \sum_{i=1}^{K} [xi - < x >] \tag{2.14}$$

sendo $< x >$ o valor médio de x_i e $K = 1, 2, ... \ N$.

Divide-se a série integrada X_K em (N - n) caixas de igual comprimento n (escala temporal) sobrepostas. Cada caixa contém $n + 1$ valores, que começam em i e terminam em $i + n$.

Para cada caixa, foi ajustado em X_K um polinômio de grau ≥ 1, denotado por $\tilde{X}_{K,i}$, com $i \leq K \leq (i + n)$, ver Fig. 2.6.

Foi subtraído a série integrada X_k da série ajustada , em cada caixa sobreposta de tamanho n, e após a subtração, calculou-se então a função $f^2_{DFA}(n, \ i)$, pela equação 2.15.

$$f^2_{DFA}(n, i) \equiv 1 \div (n + 1) \sum_{K=i}^{i+n} (X_K - \tilde{X}_{K,i})^2 \tag{2.15}$$

Depois para uma dada escala temporal de comprimento n a função de flutuação, F_{DFA} (n), é calculada por:

$$F_{DFA}(n) = \sqrt{\frac{1}{N-n}\sum_{K=1}^{N-n} f_{DFA}^2(n,i)} \tag{2.16}$$

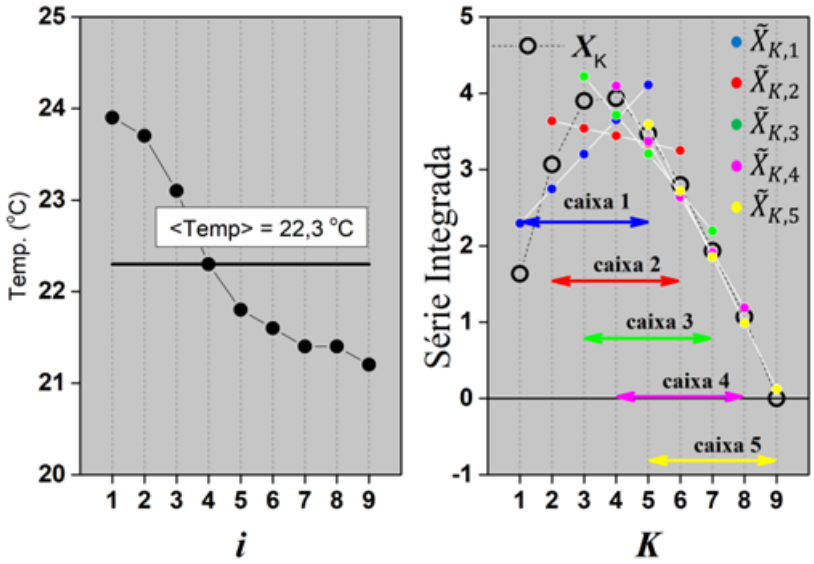

Figura 2.6: Algorítmo para o cálculo da Função de Flutuação DFA. Fonte: Fractals (ZEBENDE, 2011).

Os passos acima são repetidos para diferentes caixas de tamanho n, com $4 \leq n \leq N$ 4 (valores mínimo e máximo de n). Por fim, verificou-se a relação entre n e F_{DFA}.

Se a relação $F_{DFA} \times n$ seguir uma lei de potência, ou seja, $F_{DFA}(n) \sim n^{\alpha DFA}$, então neste caso αDFA será o expoente de autocorrelação de longo alcance. O expoente αDFA quantifica a força empírica do sinal das autocorrelações de longo alcance (lei de potência), um parâmetro de auto afinidade, ver Zebende et al. (2017). Na Tabela 2.2 apresentamos as características para o expoente αDFA, segundo Kantelhardt (2008).

Tabela 2.2: Expoente de autocorrelação α_{DFA} e suas característica.

Expoente	Tipo de sinal
$\alpha_{DFA} < 0,5$	Anti-persistente
$\alpha_{DFA} \sim 0,5$	Ruído branco não correlacionado
$\alpha_{DFA} > 0,5$	Persistente correlacionado de longo alcance
$\alpha_{DFA} \sim 1,0$	Ruído $\frac{1}{f}$
$\alpha_{DFA} > 1,0$	Não estacionário
$\alpha_{DFA} \sim 3/2$	Ruído browniano

A vantagem do método DFA, em relação a outros métodos, consiste em permitir a detecção

de autocorrelações de longo alcance embutidas em séries temporais aparentemente não estacionárias e também evitar a detecção espúria de autocorrelações aparentes de longo alcance, que são um artefato de estacionariedade.

Segundo Filho (2014), através do expoente αDFA, obtido por meio do método DFA é possível avaliar em que medida a tendência observada na série temporal passada implica em manutenção do comportamento no futuro, indicando um efeito de memória de longa duração na série.

2.5.3 Método DCCA (Detrended Cross-Correlation Analysis)

Desenvolvido por Podobnik;Stanley (2008) com o propósito de estimar o expoente que caracteriza a correlação de longo alcance entre duas séries temporais não estacionárias, ambas com o mesmo número de observações, conforme explicado por Machado (2014). Esse método representa uma generalização do método DFA. Conforme destacado por Zebende (2011), essa abordagem possibilita a identificação de componentes de sazonalidade ou periodicidade nas séries temporais sujeitas à análise.

A análise da correlação cruzada de duas séries temporais, (x_i) e (y_i), pelo método DCCA é feita seguindo o algoritmo para o cálculo da função de flutuação para o método DFA. O algoritmo consiste nos seguintes passos, listados logo abaixo:

Considere duas séries temporais (x_i) e (y_i), com i variando de 1 a N (número total de pontos). Integra-se x_i e y_i para se obter X_K e Y_K respectivamente, equação 2.17:

$$X_k = \sum_{i=1}^{K} [x_i - \langle x \rangle] \quad \text{e} \quad Y_k = \sum_{i=1}^{K} [y_i - \langle y \rangle] \tag{2.17}$$

sendo $< x >$ e $< y >$ os valores médios de x_i e y_i, com $K = 1, 2, ...N$.

Divide-se as séries integradas X_K e Y_K em $(N - n)$ caixas de igual comprimento n (escala temporal) sobrepostas. Cada caixa contém $n + 1$ valores, que começam em i e terminam em $i + n$.

Para cada caixa, ajusta-se em X_K e Y_K polinômios de grau ≥ 1, denotado por $\tilde{X}_{K,i}$ e $\tilde{X}_{K,i}$ com $i \leq K \leq (i + n)$.

Subtraiu X_K e Y_K das séries ajustadas$\tilde{X}_{K,i}$ e $\tilde{X}_{K,i}$, em cada caixa sobreposta de tamanho

n, e então calculamos a função $f^2_{DCCA}(n,\ i)$ pela Equação 2.18.

$$f^2_{DCCA}(n,i) \equiv \frac{1}{(n+1)} \sum_{K=i}^{i+n} \left(X_K - \tilde{X}_{K,i}\right)\left(Y_K - \tilde{Y}_{K,i}\right) \tag{2.18}$$

Depois para uma dada escala temporal de comprimento n a função de flutuação, $F^2_{DCCA}(n)$ é calculada por:

$$F^2_{DCCA}(n) = \frac{1}{(N-n)} \sum_{K=1}^{N-n} f^2_{DCCA}(n,i) \tag{2.19}$$

Os passos acima são repetidos para diferentes caixas de tamanho n, com $4 \leq n \leq \frac{N}{4}$ (valores mínimo e máximo de n). Quando repetido o procedimento anteriormente descrito para tamanhos diferentes, verifica-se a existência ou não da lei de potência, através da expressão 2.20.

$$F^2_{DCCA}(n) \sim n^{2\lambda} \tag{2.20}$$

em que λ descreve o expoente de correlação cruzada de longo alcance.

Uma das peculiaridades deste modelo centra-se, segundo Zebende (2011) e Machado (2014), na retirada das tendências polinomiais que poderiam mascarar as correlações cruzadas.

2.5.4 Coeficiente De Correlação Cruzada ρ_{DCCA}

Desenvolvido por Zebende (2011), o coeficiente de correlação cruzada ρ_{DCCA}, tem como objetivo quantificar o nível de correlação cruzada entre duas séries temporais não estacionárias, definido pela razão entre a função de covariância sem tendência, F^2_{DCCA} e a função de variância sem tendência, F_{DFA}, dada pela Equação abaixo:

$$\rho_{DCCA}(n) = \frac{F^2_{DCCA}(n)}{F_{DFA_x}(n) F_{DFA_y}(n)} \tag{2.21}$$

Este coeficiente de correlação cruzada é adimensional e com variação no intervalo $-1 \leq$

$\rho_{DCCA} \leq 1$. Na Tabela 2.3 apresentamos suas características, segundo Zebende (2011).

Tabela 2.3: ρ_{DCCA}, coeficiente de correlação cruzada de Zebende, e suas propriedades.

Características	ρ_{DCCA}
1	correlação cruzada perfeita
0	sem correlação cruzada
-1	anti correlação cruzada perfeita

Podemos também definir o coeficiente de correlação cruzada ρ_{DCCA} em níveis de correlação cruzada, sendo eles por exemplo, três positivos e três negativos, como mostra a Tabela 2.4, segundo Fernandes et al. (2016).

Tabela 2.4: Possíveis intervalos para o Coeficiente de Correlação Cruzada ρ_{DCCA}

Condição	ρ_{DCCA}
Forte	$\pm$ 0, 666 $\longrightarrow \pm$ 0,999
Médio	$\pm$ 0, 333 $\longrightarrow \pm$ 0,666
Fraco	$\pm$ 0, 000 $\longrightarrow \pm$ 0,333

2.5.5 Coeficiente De Correlação Cruzada Múltiplo - DMC_x^2

Proposto por Zebende; Filho (2018), o coeficiente de correlação cruzada múltiplo, DMC_x^2 é a generalização da análise do coeficiente ρ_{DCCA}, tem como objetivo mensurar as correlações cruzadas de duas ou mais séries temporais não estacionárias e é definido pela Equação 2.22.

$$DMC_x^2(n) = \rho_{y,xi}(n)^T \rho^{-1}(n)\ \rho_{y,xi}(n) \tag{2.22}$$

Em que:

$$\rho_{y,xi}(n)^T = [\ \rho_{y,x1}(n),\ \rho_{y,x2}(n), ...,\ \ \rho_{y,xi}(n)] \tag{2.23}$$

é o vetor transposto do vetor coluna das correlações cruzadas entre a variável dependente e as variáveis independentes, e $\rho^{-1}(n)$ é matriz quadrada inversa das correlações cruzadas entre as variáveis independentes, definida como:

$$\rho^{-1}(n) = \begin{pmatrix} 1 & \rho_{X_1,X_2}(n) & \rho_{X_1,X_3}(n) & \dots & \rho_{X_1,X_k}(n) \\ \rho_{X_2,X_1}(n) & 1 & \rho_{X_2,X_3}(n) & \dots & \rho_{X_2,X_k}(n) \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \rho_{X_k,X_1}(n) & \rho_{X_k,X_2}(n) & \rho_{X_k,X_3}(n) & \dots & 1 \end{pmatrix}^{-1} \tag{2.24}$$

com as seguintes propriedades:

$$\rho_{xi,xj}(n) = \rho_{xj,xi}(n) \; e \; \rho_{xi,x'i}(n) = 1 \tag{2.25}$$

Tendo como exemplo duas variáveis independentes, x1 e x2, e uma variável dependente, y, o DMC_x^2 assume a seguinte expressão abaixo:

$$DMC_x^2 = \frac{\rho_{y,x1}^2(n) + \rho_{y,x2}^2(n) - 2\rho_{y,xi}^2(n)\,\rho_{y,x2}^2(n)\,\rho_{x1,x2}^2(n)}{1 - \rho_{x1,x2}^2(n)} \tag{2.26}$$

De forma análoga, podemos estender a Equação 2.26 para três ou mais variáveis independentes, em todos os casos $0 \leq DMC_x^2 \leq 1$.

O valor do coeficiente de correlação cruzada múltiplo, DMC_x^2 , significa que, quanto mais próximo de 1, maior é a correlação cruzada múltipla entre a variável dependente e as variáveis independentes e quanto mais próximo de 0, menor é a correlação cruzada múltipla entre as mesmas. Então Zebende; Filho (2018), dividiram o intervalo do coeficiente de correlação cruzada múltiplo, DMC_x^2 e propuseram 05 (cinco) níveis de intervalos com as seguintes características, (ver Tabela 2.5):

Tabela 2.5: DMC_x^2 , coeficiente de correlação cruzada múltiplo e possíveis níveis de correlação cruzada.

Características	DMC_x^2
Muito Forte	0, 8 à 1, 0
Forte	0, 6 à 0, 8
Médio	0, 4 à 0, 6
Fraco	0, 2 à 0, 4
Muito Fraco	0, 0 à 0, 2

No entanto, para o caso particular de quatro variáveis, ou seja, uma Y (variável dependente) e três X1, X2, X3 (variáveis independentes), este estudo propõe o cálculo do DMC_x^2 com 3 variáveis independentes sendo representado por esta equação abaixo:

$$
\begin{aligned}
DMC_x^2 \quad = \quad & \Big(\rho_{X_2,X_3}^2 \times \rho_{Y,X_1}^2 - \rho_{Y,X_1}^2 + \rho_{X_1,X_3}^2 \times \rho_{Y,X_2}^2 - \rho_{Y,X_2}^2 \\
& + 2 \times \rho_{X_1,X_2} \times \rho_{Y,X_1} \times \rho_{Y,X_2} - 2 \times \rho_{X_1,X_3} \times \rho_{X_2,X_3} \times \rho_{Y,X_1} \\
& + \rho_{X_1,X_2}^2 \times \rho_{Y,X_3}^2 - \rho_{Y,X_3}^2 + 2 \times \rho_{X_1,X_3} \times \rho_{Y,X_1} \times \rho_{Y,X_3} \\
& - 2 \times \rho_{X_1,X_2} \times \rho_{X_2,X_3} \times \rho_{Y,X_1} \times \rho_{Y,X_3} \\
& - 2 \times \rho_{X_1,X_2} \times \rho_{X_1,X_3} \times \rho_{Y,X_2} \times \rho_{Y,X_3} \\
& + 2 \times \rho_{X_2,X_3} \times \rho_{Y,X_2} \times \rho_{Y,X_3}\Big) \quad \Big/ \\
& \Big(\rho_{X_1,X_2}^2 + \rho_{X_1,X_3}^2 + \rho_{X_2,X_3}^2 - 2 \times \rho_{X_1,X_2} \times \rho_{X_1,X_3} \times \rho_{X_2,X_3}^{-1}\Big)
\end{aligned} \tag{2.27}
$$

2.5.6 *Método do Diagrama de Caixas (Box Plot)*

Conceitualmente o Box Plot ou Diagrama de Caixas, segundo Montgomery (2004), trata-se de um gráfico que aponta vários aspectos importantes dos dados simultaneamente, tais como tendência central ou posição, dispersão ou variabilidade, afastamento da simetria e identificação de observações muito afastadas da maior parte dos dados (essas observações são muitas vezes chamadas valores discrepantes ou outliers).

As características de uma distribuição são em geral descritas informando os valores da média e do desvio padrão e, algumas vezes do coeficiente de assimetria. Porém a média e o desvio padrão são fortemente influenciados pela presença de valores discrepantes. Para contornar esta dificuldade, Tukey (1977) propôs descrever as características de uma distribuição através das estatísticas de ordem que são a mediana, os quartis ou juntas e os extremos, apresentados no esquema a seguir.

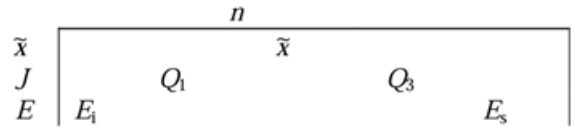

Figura 2.7: Estatísticas Utilizadas no Box Plot. Fonte: (BUSSAB; MORETIN, 2002).

Onde n é o número de observações, $\tilde{X}$ é a mediana, J as juntas (1° quartil e 3° quartil) e E os extremos (o menor valor observado, E_i e o maior valor observado, E_s).

As características da distribuição podem ser analisadas a partir do diagrama de Tukey (box plot), devido a sua configuração. A figura a seguir representa o esquema do diagrama de Tukey (box plot).

A diferença DI = Q3 - Q1 é denominada desvio interquartílico e pode ser empregada como

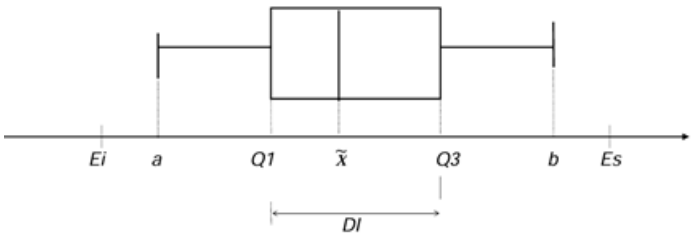

Figura 2.8: Esquema do diagrama de Tukey. Fonte: (BUSSAB; MORETIN, 2002).

medida de dispersão.

Este diagrama indica as seguintes características:

- Tendência central: é dada pela posição da mediana na escala de medida da variável;

- Dispersão: medida pelo valor de DI;

- Assimetria: indicada a partir da comparação das diferenças $\tilde{X}$ - Q1 e Q3 - $\tilde{X}$.

Todos os valores observados inferiores a Q1 - $\frac{3}{2}$ DI e superiores a Q3 + $\frac{3}{2}$ DI são discrepantes. Os valores a *e* b são o menor valor obervado não discrepante e o maior observado não discrepante, respectivamente.

Capítulo Três

METODOLOGIA

3.1 Área de Estudo

O Brasil é o quinto maior país em área de superfície do mundo, abrangendo condições climáticas contrastantes como resultado de grandes gradientes de altitude, latitude, sazonalidade, entre outros. Num país com tais características, o estudo da variabilidade espacial dos parâmetros climáticos é essencial para o conhecimento, planejamento e atuação nos mais diversos aspectos (DAS et al., 2003).

Tratando-se de uma pesquisa com enfoque em compreensão de um problema com efeitos não apenas urbanos a escolha da área para o estudo foi movida pela característica de fusão dos usos e ocupação do solo (zonas urbanas, semiurbanas e rurais), pelo nível de urbanização das regiões e pela disponibilidade de dados das variáveis fornecidas pelo INMET.

Sobre o INMET, é esperado que ofereça dados confiáveis, garantindo a segurança e a boa execução do estudo. No entanto, espera-se que a realização da pesquisa nessas regiões proporcione resultados concisos e representativos da situação climática atual. Estas informações são fundamentais na tomada de decisões de órgãos governamentais ou empresas, nacionais e estrangeiras, podem ser utilizadas pelas famílias ou pelas gerações futuras, pelos cientistas como insumos em modelos para melhor explicar ou prever eventos naturais ou induzidos pelo homem, ou podem indicar o tipo de cultivo adequado para uma região, determinando o sucesso no desenvolvimento da economia agrícola de um país (DAS et al., 2003).

3.1.1 Descrição Geral da Área em Estudo

A seguir, são apresentadas as características gerais das regiões onde são localizadas as estações meteorológicas. Fonte:(EMBRAPA, 2024).

1. Centro-Oeste: A segunda maior em extensão territorial no país, destaca-se por sua baixa densidade populacional. Seu relevo divide-se em planalto central, planalto meridional e planície do Pantanal. O clima preponderante é o tropical semiúmido. As temperaturas variam significativamente, alcançando cerca de 40 °C nos meses mais quentes e 15 °C nos mais frios. Destaca-se na Região Centro-Oeste o Pantanal, a maior planície alagada do mundo, e a predominância da vegetação de Cerrado, marcado também pela presença da Floresta Amazônica. A região é ricamente abastecida por recursos hídricos,

sendo drenada por três grandes bacias hidrográficas: Amazônica, Tocantins-Araguaia e Platina.

2. Nordeste: É reconhecida como o berço do Brasil, sendo a primeira a ser ocupada pelos colonizadores. Caracteriza-se por uma notável diversidade social, rica cultura, clima quente e deslumbrantes praias, mas também é marcada por significativos contrastes sociais. Em razão das diversas características físicas, sociais e econômicas que permeiam seu território, o Nordeste se subdivide em quatro sub-regiões: Meio-Norte, Sertão, Agreste e Zona da Mata. Cada uma dessas sub-regiões apresenta singularidades que contribuem para a riqueza e complexidade da região como um todo. Possui diversos biomas, a saber: A Caatinga, o Cerrado, a Mata Atlântica e a Floresta Amazônia.

3. Norte: Se destaca como a maior em extensão territorial, caracterizando-se também pela menor concentração populacional. Essa região é lar da vasta Floresta Amazônica. Além disso, a região é detentora da maior bacia hidrográfica das Américas e do maior rio do mundo, o Rio Amazonas. Uma característica marcante da população local é a concentração nas margens dos rios, onde muitas pessoas subsistem por meio da pesca. Existe a diversidade de grupos étnicos e modos de vida contribui para a riqueza cultural e social da região Norte.

4. Sudeste: Destaca-se como a mais populosa e densamente povoada do território brasileiro. Além disso, é a região mais economicamente desenvolvida, abrigando a única megalópole do Brasil, São Paulo. O relevo na região Sudeste é notavelmente diversificado, com a presença de elevações como as serras da Mantiqueira, da Canastra e do Mar, ao lado de planícies costeiras extensas que formam amplas baixadas litorâneas. O clima tropical prevalece no litoral, com temperaturas elevadas e estações bem definidas: um verão chuvoso e um inverno seco. Nos planaltos, observa-se o clima tropical de altitude, caracterizado por amplas variações de temperatura. A vegetação na região Sudeste varia de acordo com o clima, sendo a Mata Atlântica predominante, embora esteja significativamente comprometida devido à urbanização e expansão agrícola. Em Minas Gerais, predomina a vegetação de Cerrado e Caatinga. Rios importantes, como o Tietê, Paraíba do Sul, Paraná, Doce e a nascente do São Francisco na Serra da Canastra (MG), desempenham papel fundamental na produção de energia elétrica.

5. Sul: A segunda região mais populosa do país. Sua economia é influente e diversificada, abrangendo setores como agropecuária, indústria, extrativismo e turismo. O relevo predominante na região Sul é caracterizado, em grande parte, por planaltos, como o Planalto Atlântico e o Planalto Meridional, localizados ao norte. Nessa área, é possível encontrar a Mata das Araucárias. Ao Sul, a região apresenta áreas mais planas, conhecidas como a planície dos Pampas, cujo nome também se refere à vegetação rasteira de gramíneas. O clima predominante na região Sul é subtropical, caracterizado por estações do ano

bem definidas e amplas variações de temperatura. É a região mais fria do Brasil, experimentando geadas e, em alguns locais, até mesmo neve durante o inverno. Em termos de recursos hídricos, a região Sul desempenha um papel crucial na produção de energia elétrica para o Brasil. Possui duas importantes bacias hidrográficas: a do Rio Paraná, onde está localizada a Usina Hidroelétrica de Itaipu, uma das maiores do mundo, e a do Rio Uruguai.

A Fig. 3.1 e a Tabela 3.1 mostram as coordenadas das estações meteorológicas que serão estudadas.

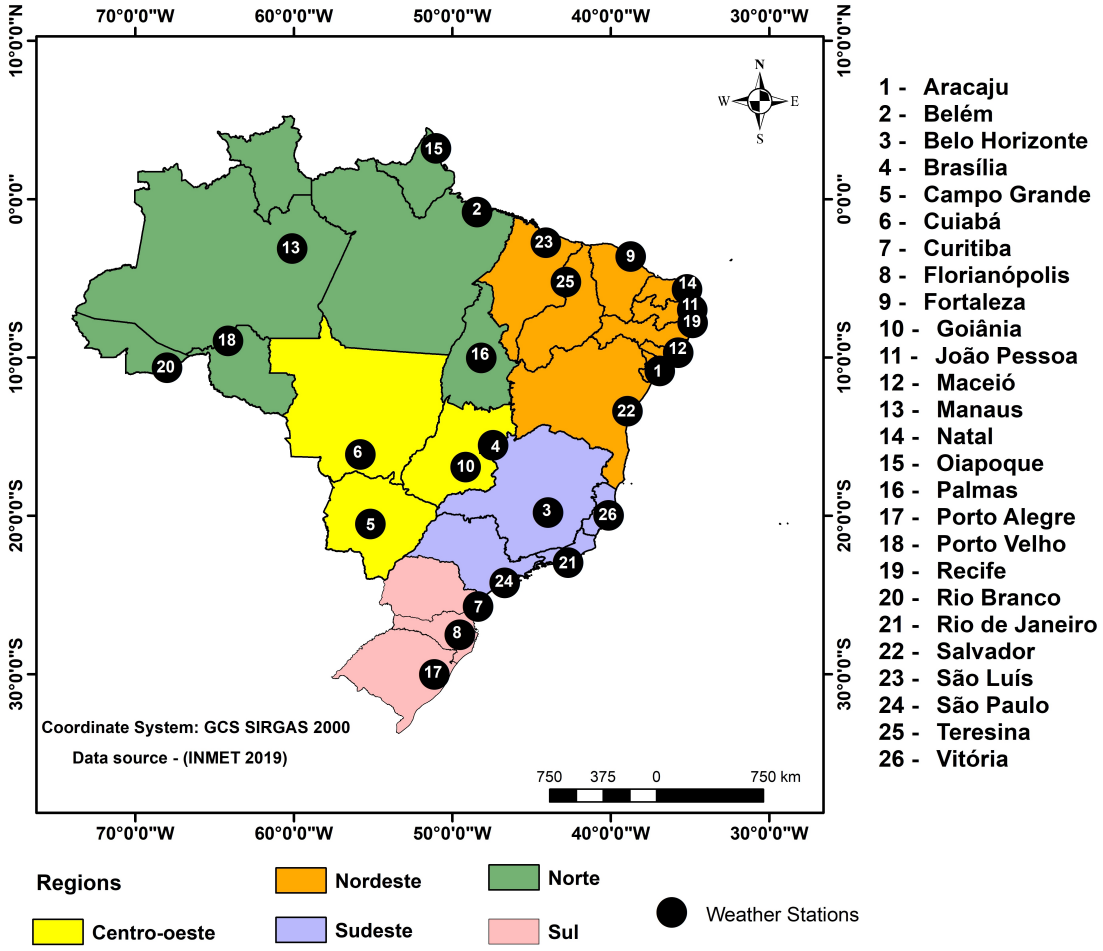

Figura 3.1: Classificação das regiões brasileiras e localização das estações meteorológicas do INMET.

Tabela 3.1: Coordenadas geográficas das estações meteorológicas do INMET.

ID	CÓDIGO	ESTAÇÕES	LATITUDE(Sul)	LONGITUDE(W)	ALTITUDE(m)
1	A409	Aracaju	10° 57' 9"	37° 3' 16"	3,72
2	A201	Belém	1° 24' 40"	48° 26' 22"	21,17
3	A521	Belo Horizonte	19° 55' 21"	43° 55' 20"	854,02
4	A001	Brasília	15° 47' 22"	47° 55' 33"	1160,96
5	A702	Campo Grande	20° 26' 50"	54° 43' 21"	528,47
6	A901	Cuiabá	15° 33' 33"	56° 3' 47"	241,56
7	A807	Curitiba	25° 26' 55"	49° 13' 50"	922,91
8	A806	Florianópolis	27° 36' 9"	48° 37' 12"	4,87
9	A305	Fortaleza	3° 48' 57"	38° 32' 16"	29,55
10	A002	Goiânia	16° 38' 34"	49° 13' 33"	727,3
11	A320	João Pessoa	7° 9' 55"	34° 48' 56"	33,5
12	A303	Maceió	9° 33' 4"	35° 46' 13"	84,12
13	A101	Manaus	3° 6' 12"	60° 0' 59"	61,25
14	A304	Natal	5° 50' 14"	35° 12' 29"	47,46
15	A242	Oiapoque	3° 48' 49"(Norte)	51° 51' 45"	15,14
16	A009	Palmas	10° 8' 52"	48° 18' 52"	267
17	A408	Porto Alegre	30° 3' 10"	51° 10' 49"	41,18
18	A925	Porto Velho	8° 47' 37"	63° 50' 45"	86,7
19	A307	Recife	8° 3' 38"	34° 52' 54"	10,36
20	A101	Rio Branco	9° 40' 47"	67° 48' 33"	163
21	A601	Rio de Janeiro	22° 59' 18"	43° 12' 27"	25,59
22	A403	Salvador	12° 58' 16"	38° 30' 30"	52,88
23	A771	São Luís	2° 35' 18"	44° 12' 52"	58
24	A701	São Paulo	23° 43' 21"	46° 37' 48"	792,36
25	A312	Teresina	5° 2' 19"	42° 48' 37"	72,42
26	A612	Vitória	20° 16' 54"	40° 18' 21"	9

3.2 Base de Dados

As variáveis meteorológicas são coletadas em estações meteorológicas automáticas, disponibilizadas no portal do INMET em formato de planilhas eletrônicas, com isso, o primeiro cuidado para a seleção das estações foi a observância daquelas que ainda estavam ativas, sendo selecionadas 26 estações, uma em cada estado brasileiro. O banco de dados foi adquirido para o período de aproximadamente 10 anos, de 2009 à 2019.

O horário também foi levado em consideração, foram coletados 13 horas de medições, medições essas que estão de acordo com os horários em que os sensores medem os dados de radiação solar das 9:00 UTC às 21:00 UTC, que para o horário de Brasília são representados como 6:00 horas da manhã às 18:00 horas da noite. As diferenças entre os fusos horários individuais sempre se referem ao Tempo Universal Coordenado (UTC), ou seja, o tempo que se aplica ao meridiano zero (longitude zero). Brasília, por exemplo, está no 48° de longitude oeste e, portanto, no fuso horário UTC-3. No entanto, regiões do norte do Brasil, como Acre e parte do Amazonas, seguem fusos diferentes. O Acre e parte do Amazonas estão no fuso UTC-5, enquanto a maior parte do Amazonas e Roraima seguem

o UTC-4, resultando em horários locais variando entre 4:00 e 16:00 ou 5:00 e 17:00 para os mesmos

Foram baixadas as planilhas para cada estação, nelas contendo informações de data e hora e das variáveis radiação solar, temperatura do ar, umidade relativa e velocidade do vento. Posteriormente, realizou-se a organização das planilhas no EXCEL, como é mostrado na Fig. 3.2.

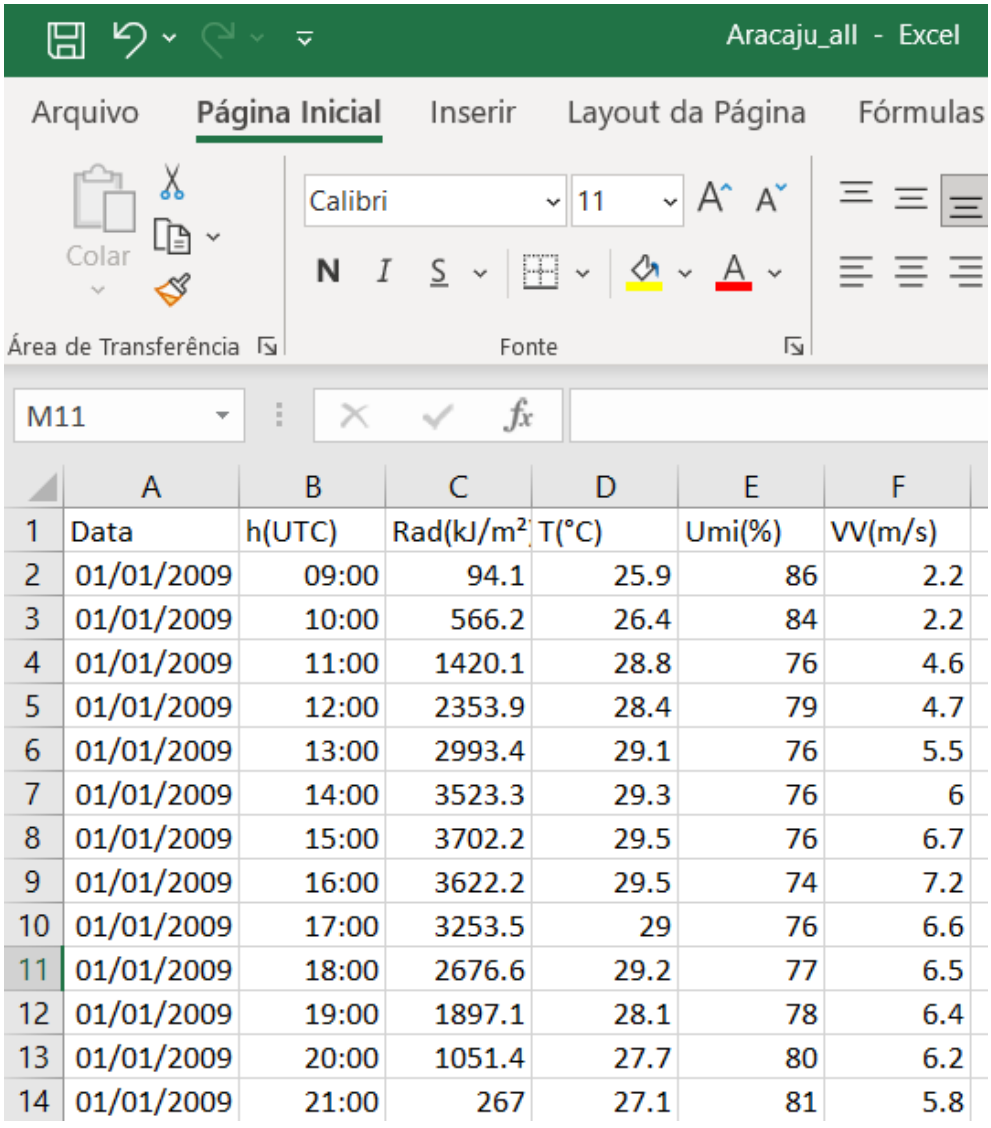

	A	B	C	D	E	F
1	Data	h(UTC)	Rad(kJ/m²	T(°C)	Umi(%)	VV(m/s)
2	01/01/2009	09:00	94.1	25.9	86	2.2
3	01/01/2009	10:00	566.2	26.4	84	2.2
4	01/01/2009	11:00	1420.1	28.8	76	4.6
5	01/01/2009	12:00	2353.9	28.4	79	4.7
6	01/01/2009	13:00	2993.4	29.1	76	5.5
7	01/01/2009	14:00	3523.3	29.3	76	6
8	01/01/2009	15:00	3702.2	29.5	76	6.7
9	01/01/2009	16:00	3622.2	29.5	74	7.2
10	01/01/2009	17:00	3253.5	29	76	6.6
11	01/01/2009	18:00	2676.6	29.2	77	6.5
12	01/01/2009	19:00	1897.1	28.1	78	6.4
13	01/01/2009	20:00	1051.4	27.7	80	6.2
14	01/01/2009	21:00	267	27.1	81	5.8

Figura 3.2: Imagem ilustrativa da base de dados das variáveis meteorológicas em planilhas eletrônicas.

Dentre as variáveis meteorológicas, a radiação solar foi escolhida como variável dependente neste estudo, por representar um aspecto de interesse a ser analisado. Em termos simples, uma variável dependente é aquela cujo comportamento será observado em função das variáveis independentes. Neste caso, temperatura do ar, umidade relativa e velocidade do vento foram selecionadas como variáveis independentes, a fim de explorar possíveis relações entre elas e a radiação solar. As variáveis independentes representam os fatores

monitorados e analisados pelo pesquisador para investigar padrões e associações, sem pressupor necessariamente uma relação de causa e efeito.

A Fig. 3.3 mostra um exemplo para o que está sendo escrito logo acima, ou seja, com uma semana de dados para a estação Salvador, entre 25/12/2019 e 01/01/2020 (dados medidos hora a hora). Assim, uma análise estatística mais precisa pode ser valiosa neste ponto, o que faremos logo mais, após introduzir a metodologia do estudo logo abaixo.

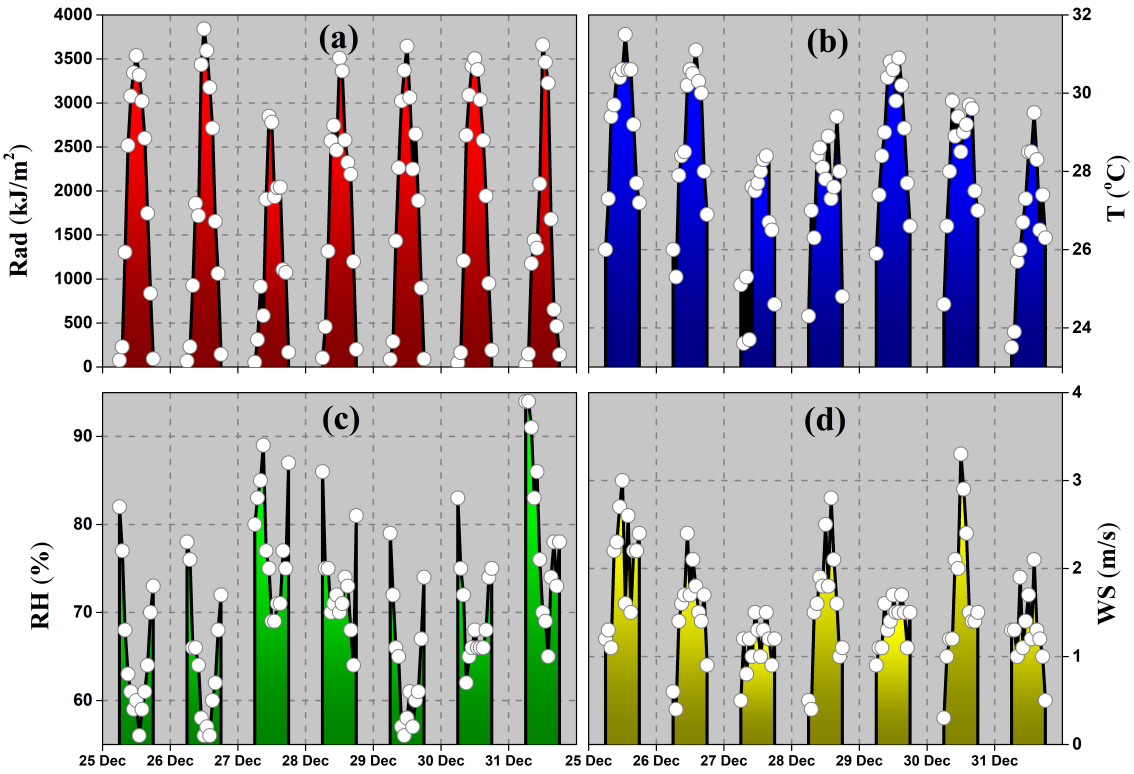

Figura 3.3: (a) Radiação Solar, (b) Temperatura do ar, (c) Humidade relativa do ar e velocidade do vento em função do tempo (horas).

3.3 Tratamento de Dados

Dados faltantes podem comprometer a precisão e a validade dos resultados, introduzindo vieses e reduzindo a representatividade da amostra. A exclusão ou imputação inadequada pode distorcer tendências e afetar relações entre variáveis. O impacto depende do padrão e do volume de ausência de dados. Estratégias adequadas são essenciais para minimizar esses efeitos e garantir análises confiáveis. Em seu artigo Zebende et al. (2020) mostra a análise o efeito da remoção de peças em séries temporais com memória de longo alcance pelo método DFA e coeficiente de correlação cruzada destendenciado e é a partir desse estudo que os dados deste trabalho foram analisados.

Para que fossem executadas as análises foi necessário o tratamento dos dados fornecidos

pelo INMET por dois principais fatores. O primeiro fator é que o método de análise de correlações cruzadas (ρ_{DCCA}) e correlações cruzadas múltipla (DMC_x^2), a quantidade de pontos em uma série (x) fosse igual ou superior a 1000. O outro fator é que a quantidade de pontos em ambas as séries a serem correlacionadas (x,y) fosse a mesma (COSTA, 2021). Lembrando que essa análise foi feita em cada estação, pois o tamanho das séries varia de estação para estação.

3.4 Processamento de Dados

Foram aplicados os métodos estatísticos propostos por (ZEBENDE, 2011) e (ZEBENDE; FILHO, 2018), com auxílio do aplicativo RHO-DCCA-MATRIX, Fig.A.14. Para o processamento de correlações cruzadas (ρ_{DCCA}), as variáveis independentes foram correlacionadas separadamente com a variável dependente. Já para o processamento de correlações cruzadas múltipla (DMC_x^2), as variáveis independentes foram correlacionadas em conjunto com a variável dependente (Fig. 3.4). Esses processamentos foram feitos para cada uma das 26 estações meteorológicas

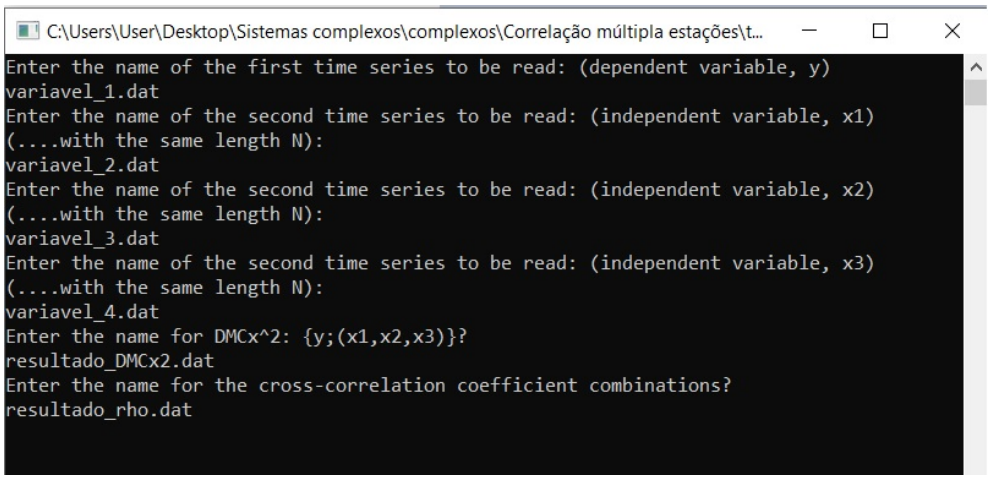

Figura 3.4: Imagem ilustrativa do processamento no RHO-DCCA-MATRIX das correlações (ρ_{DCCA}) e (DMC_x^2). O termo dependent variable y representa a radiação solar, independent variable x1 a temperatura do ar, independent variable x2 a umidade relativa e a independent variable x3 a velocidade do vento.

3.5 Análise de Dados

Após o tratamento dos dados provenientes das planilhas, foi realizada uma análise estatística descritiva para explorar as principais características dos dados. Essa análise incluiu o cálculo de valores máximos e mínimos, mediana, desvio padrão, quartis e percentis no período de estudo para cada estação. Para visualizar essas configurações de forma clara e intuitiva, foi utilizado o método do diagrama de caixas, que permite identificar a dispersão e a distribuição dos dados (TUKEY, 1977).

Além da análise descritiva, foram realizadas análises das correlações cruzadas e múltiplas

correlações cruzadas. Os resultados dessas análises foram apresentados em gráficos, que ilustram as associações entre as variáveis, e em tabelas, que detalham os coeficientes para facilitar a interpretação quantitativa. Essa combinação de ferramentas visuais e numéricas oferece uma visão abrangente e precisa das relações entre os dados.

Capítulo Quatro

RESULTADOS

4.1 Análise Estatística

Os dados das planilhas foram analisados através de uma filtragem para a obtenção dos valores máximos e mínimos de cada variável, no período de 2009 à 2019 nas respectivas estações, onde, obteve também a média global, como mostrado na tabela 4.1.

Tabela 4.1: Valores máximos e mínimos para todas as estações com: Radiação Solar (Rad), Temperatura do Ar (T), Umidade Relativa do Ar (RH) e Velocidade do Vento (WS).

Cidade	Rad (kJ/m^2)		T (°C)		RH (%)		WS (m/s)	
	Mínimo	Máx.	Mínimo	Máximo	Mínimo	Máximo	Mínimo	Máximo
Aracaju	0,0	3960,7	19,6	35,4	10	100	0,0	8,7
Belém	0,0	5230,0	23,9	34,1	35	100	0,0	8,7
Belo Horizonte	0,0	5246,5	21,7	37,0	32	100	0,0	10,1
Brasília	0,0	5063,0	19,6	37,8	16	88	0,0	9,2
Campo Grande	0,0	4984,8	20,8	38,5	10	99	0,0	8,5
Cuiabá	0,0	4819,4	23,7	39,7	11	97	0,0	8,7
Curitiba	0,0	4198,7	12,0	31,5	38	100	0,0	11,4
Florianópolis	0,0	4814,4	16,8	36,0	41	97	0,0	8,5
Fortaleza	0,0	4105,5	22,0	33,5	44	100	0,0	9,2
Goiânia	0,0	5141,9	18,0	37,5	11	100	0,0	8,0
João Pessoa	0,0	4181,0	22,2	33,6	53	100	0,0	8,5
Maceió	0,0	4049,4	20,6	34,5	46	100	0,0	9,2
Manaus	0,0	4307,1	22,7	33,8	59	100	0,0	9,4
Natal	0,0	4172,2	21,5	34,7	51	100	0,0	9,2
Palmas	0,0	4999,0	21,1	38,2	11	99	0,0	9,2
Porto Alegre	0,0	4606,9	12,8	36,5	27	100	0,0	9,4
Recife	0,0	4218,0	21,5	33,7	53	100	0,0	9,2
Rio Branco	0,0	4911,9	22,0	37,8	27	99	0,0	7,9
Rio de Janeiro	0,0	5160,2	19,4	40,5	30	100	0,0	8,5
Salvador	0,0	4304,4	22,0	34,2	52	100	0,0	9,2
São Luís	0,0	4095,0	22,6	34,8	46	100	0,0	9,4
São Paulo	0,0	5051,7	13,5	37,0	30	100	0,0	10,1
Teresina	0,0	4031,5	23,7	37,2	11	97	0,0	8,7
Vitória	0,0	4999,3	19,0	38,7	39	100	0,0	9,4
Média global	**0,0**	**4267,5**	**16,3**	**37,0**	**18,0**	**100,0**	**0,0**	**9,2**

De acordo a média global, os valores de Radiação solar variam de 0 a 4267,5 KJ/m^2 média mínima da Temperatura do ar foi de 16,3 °C e a máxima de 37 °C. A Umidade relativa deu-se um mínimo de 18 % e máximo de 100%. Já a Velocidade do vento variou de 0 a 9,2 m/s.

Ao observar a tabela, percebe-se que existem grandes variações de forma individual diante de cada cidade. Isso se dá, pois, as variáveis meteorológicas podem variar significativa-

mente em diferentes regiões do Brasil devido às características geográficas, climáticas e topográficas do país. O Brasil é um país extenso, com uma diversidade geográfica notável, o que resulta em diferentes padrões climáticos em suas diversas regiões.

Inúmeros estudos já produzidos (AZEVEDO; TARIFA, 2001; JARDIM, 2007; ASSIS, 2010) sugerem que modificações no uso da terra também podem alterar características do clima de um dado espaço, modificando o balanço de radiação e interferindo na variação dos elementos climáticos em diferentes escalas. A substituição da cobertura vegetal pelos materiais característicos das áreas urbanas e a retirada da vegetação para uso agrícola e pastoril resultam nas mudanças de escoamento superficial, na quantidade de calor armazenado, direção e velocidade dos ventos e nos valores de temperatura e umidade relativa do ar.

Para uma investigação mais acurada, o método do diagrama de caixas de Tukey (1977), trouxe a análise visível dessas variáveis. Nas Fig. 4.1, 4.2, 4.3 e 4.4 o eixo y retrata cada variável e o eixo x identifica cada estação, a mediana é dada pela linha dentro de cada caixa, a média é representado pelo símbolo do asterisco. Os limites superiores e inferiores das caixas representam os quartis. A variação de altura justifica pela distribuição dos dados, especificamente a faixa interquartil que é a diferença entre o terceiro quartil (Q3) e o primeiro quartil (Q1). O Q3 marca o ponto abaixo do qual 75% dos dados estão localizados, enquanto o Q1 marca o ponto abaixo do qual 25% dos dados estão localizados. Assim, a altura da caixa mostra a dispersão dos 50% centrais dos dados. As linhas que se estendem dos limites da caixa, chamam-se bigodes, mostram a menor e a maior variável dentro de um intervalo que não é considerado um outlier. Os bigodes geralmente se estendem até 1,5 vezes o DI (intervalo interquartil) a partir do Q1 e Q3. Valores das variáveis que se afastam significativamente do restante dos dados são marcados como pontos fora dos bigodes, representados pelo símbolo da estrela, são os outlier. Eles indicam variáveis anômalas ou extremas.

Para a radiação solar (Fig. 4.1), os maiores valores observado não discrepante se deu na estação de Natal e João Pessoa ao longo dos anos de estudo, já os menores se deram na maior parte das outras estações, onde, a menor medição da radiação solar está associada em 0,0 Kj/m^2.

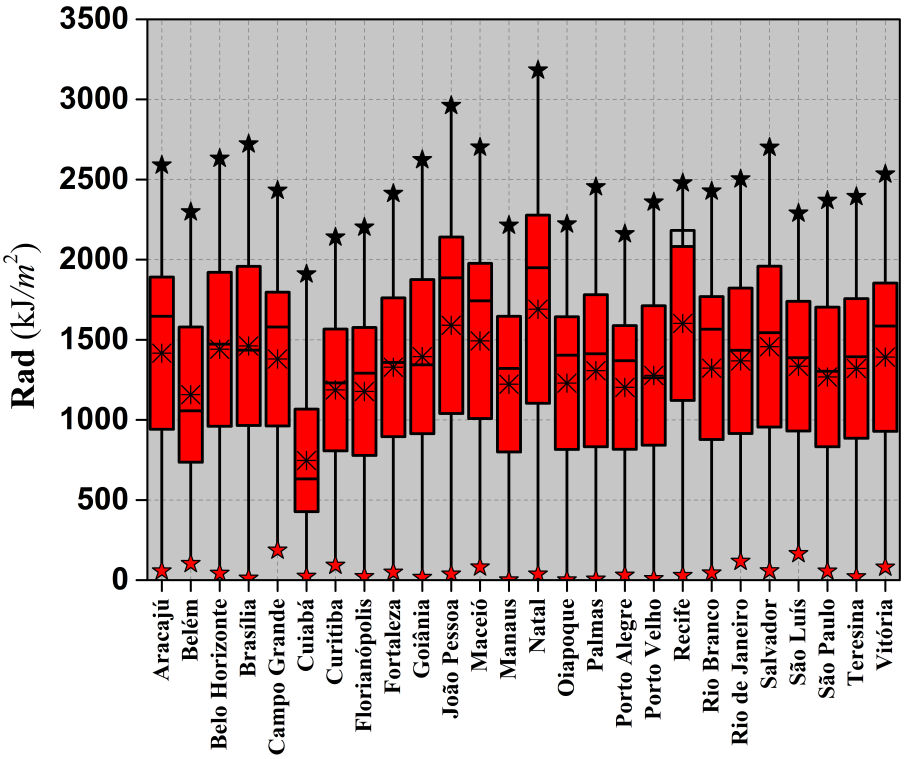

Figura 4.1: Diagrama de caixas para a variável radiação solar.

De acordo com (MONTEIRO, 1999), a radiação solar produz efeitos no balanço térmico e consequentemente na geração dos climas do globo, dessa forma, para qualquer abordagem da atmosfera, é necessário partir da compreensão dos mecanismos das trocas de energia entre o Sol e a Terra (mecanismos de transmissão de energia, além da forma, constituição e movimentos da terra).

Para a variável temperatura do ar (Fig. 4.2), os maiores valores observados se deram no intervalo de 30 à 35°C, já os menores se aproximam-se de 15 ° C. Além dos modos de variabilidade existe uma tendência de aumento da temperatura global nas últimas décadas devido aos impactos ambientais das atividades antrópicas, especialmente de emissões de gases do efeito estufa (LI; ZHAO, 2017; ZHAI; ZHOU, 2018). Um fator que influencia na temperatura local é a maritimidade (cidades litorâneas), causando menor amplitude térmica, pois a água possui maior calor especifico do que a terra continental (OLIVEIRA; FERREIRA, 2017).

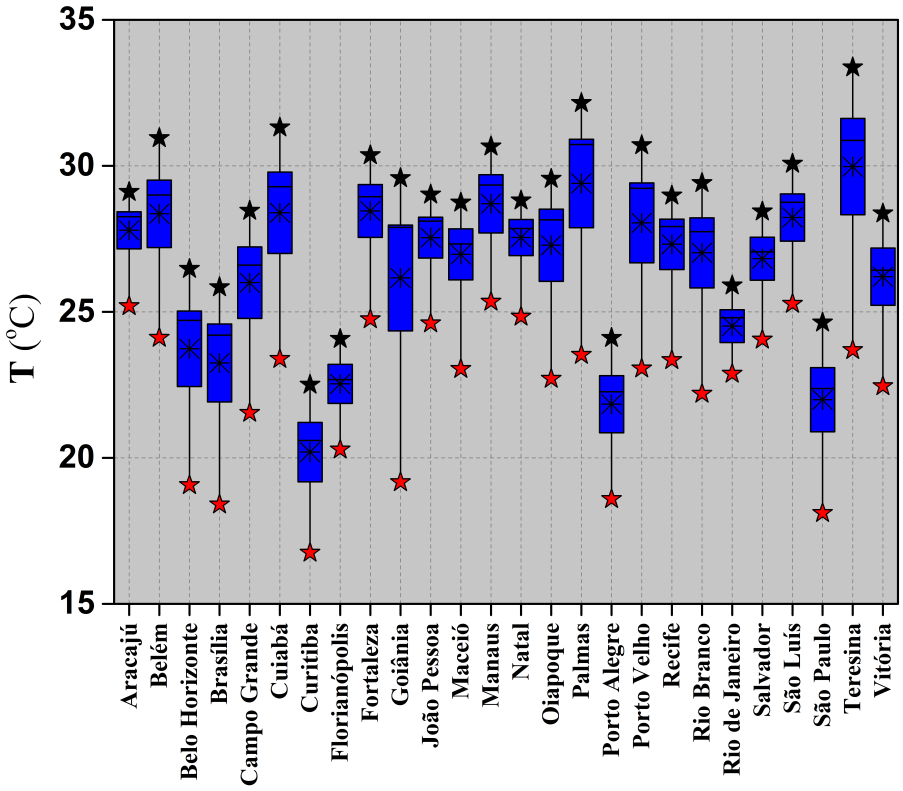

Figura 4.2: Diagrama de caixas para a variável temperatura do ar.

A umidade relativa (Fig. 4.3) do ar é analisada no eixo y em porcentagem (%), variando de 40% a 100%. As caixas verdes mostram a faixa interquartil (do primeiro ao terceiro quartil), as linhas são a faixa de variação total dos dados, incluindo os valores mínimos e máximos dentro de 1,5 vezes o intervalo interquartil. Os símbolos representados pelas estrelas pretas são outliers superiores (valores significativamente acima do máximo usual), enquanto as estrelas vermelhas são os outliers inferiores (valores significativamente abaixo do mínimo usual).

Por exemplo, as cidades como Belém e Manaus, que estão na região amazônica, mostram altas médias de umidade, enquanto cidades como Brasília apresentam variações menores e menores valores de umidade relativa. As variações na umidade relativa, tanto nas estruturas residenciais como no ar, ocorrem basicamente pela mudança da cobertura da superfície urbana. Com efeito, a rugosidade, a impermeabilidade do solo, as características dos materiais utilizados nas construções, o asfaltamento e outros elementos, respondem por tais alterações (CAPUTO; AMORIM, 2021; CARDOSO; AMORIM, 2015; MONTEIRO; SILVEIRA, 2012).

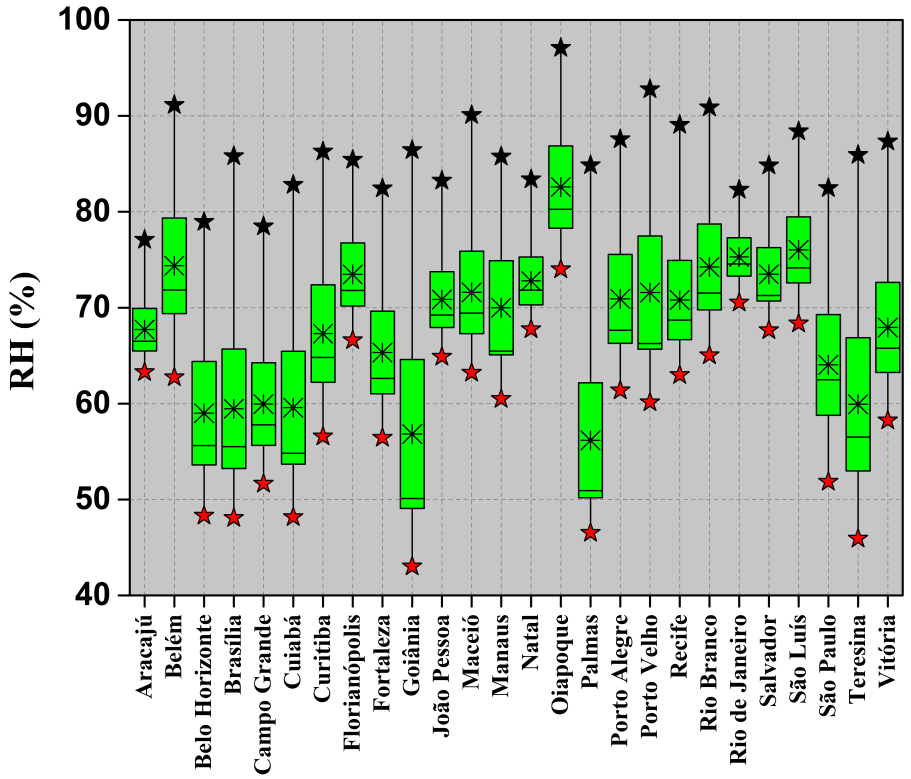

Figura 4.3: Diagrama de caixas para a variável umidade relativa do ar.

Outro ponto importante é que a variação umidade relativa do ar, precipitação e os poluentes atmosféricos, de acordo com a literatura, são as principais razões ambientais para o aumento do risco de internações e das mortes causadas por doenças respiratórias no mundo (BRAGA et al., 2001).

A Fig. 4.4 mostra a variação da velocidade do vento (m/s), as estações com maior dispersão têm caixas mais altas, indicando maior variabilidade na velocidade do vento, isso ocorre em estações como Cuiabá, Goiânia e Natal. As caixas mais baixas sugerem que os dados da velocidade do vento são mais consistentes ou menos variáveis dentro do intervalo interquartil, como em cidades como Brasília e Vitória. O conhecimento acerca da caracterização dos ventos é de extrema importância para a alocação e o dimensionamento de quebra-ventos, torres eólicas, entre outras construções, e engloba não apenas o estudo quanto à sua intensidade, mas também quanto à sua direção, sendo ambas características que variam de acordo com a época do ano e a região (MARTINS, 1993).

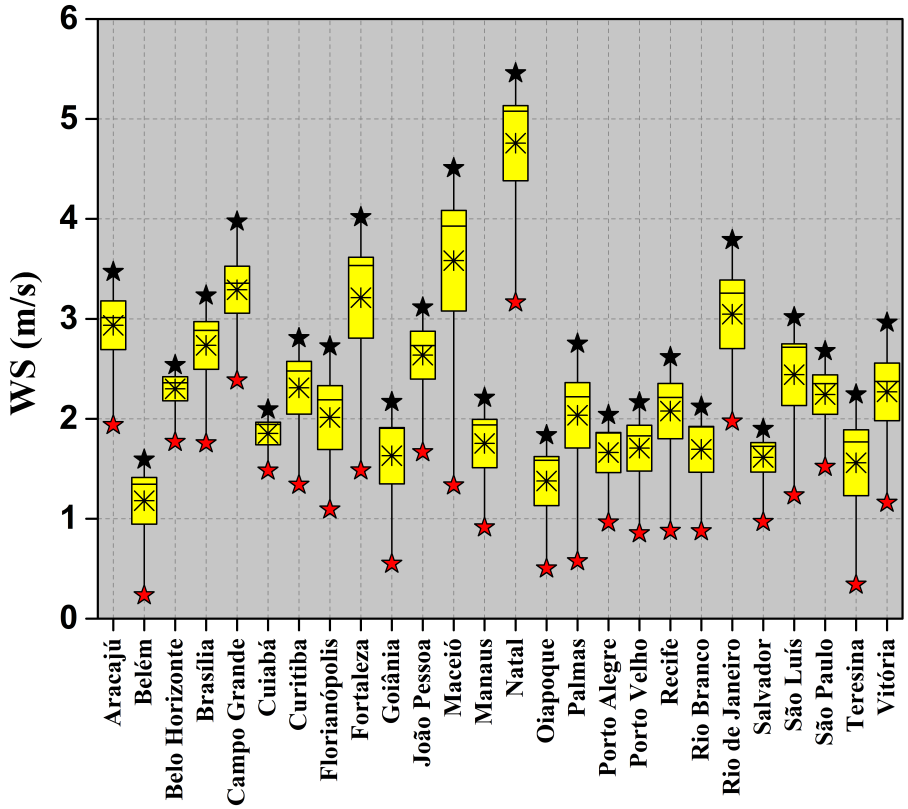

Figura 4.4: Diagrama de caixas para a variável umidade relativa do ar.

Os critérios de observação e mensuração de dados em climatologia ou em qualquer outra área do conhecimento humano são definidos a fim de corrigir e/ou evitar a contaminação por fatores alheios ao objeto de estudo. E tão importante quanto os critérios de levantamento de dados, são os critérios de análise dos dados, ou seja, a forma de organizá-los de maneira que possibilite extrair o máximo de informações acerca do objeto de estudo.

Silva; Moura (2017) em sua análise diz que, a técnica estatística do Box Plot é interessante sob vários aspectos, incluindo outros tipos de variáveis, uma vez que permite identificar padrões de anos secos e chuvosos e aqueles próximos à média (incluindo os extremos) a partir de critérios relacionados ao estabelecimento das medianas (evitando a contaminação pelos valores extremos) e não pela definição de patamares puramente arbitrários. No entanto, essa técnica pode ser potencializada quando utilizada em conjunto com outras ferramentas e/ou informações, caso dos gráficos representativos dos desvios, tendências e correlações, climogramas etc.

A autora ainda relata que a limitação dessa ferramenta se refere à relativa dificuldade na decodificação do produto (gráfico) gerado. Isso resulta da grande quantidade e complexidade da informação encerrada nesse tipo de representação que, por sua vez, exige do usuário conhecimentos significativos da área de climatologia, assim como treinamento na leitura dessa forma de representação. No entanto os dados gerados a partir da técnica do

Box Plot podem auxiliar no planejamento das atividades humanas que dependem direta ou indiretamente das chuvas, como a agricultura e a produção de energia, podendo se constituir em importante ferramenta no estudo da variabilidade das chuvas (SILVA;MOURA, 2017).

4.2 Análise por meio do coeficiente ρ_{DCCA}

Ao processar os dados no software OriginLab foram gerados os gráficos para análise, gráficos esses que as variáveis foram correlacionadas com as seguintes combinações: Radiação Solar x Temperatura do Ar, Radiação Solar x Umidade Relativa e Radiação Solar x Velocidade do Vento.

Nas Fig. A.1, A.2, A.3, A.4, A.5 e A.6, são detalhados os gráficos em que a interpretação é feita individualmente para cada estação. Já a Fig. 4.5, mostra de forma conjunta as correlações. A figura é interpretada da seguinte forma: O eixo Y tem a representação das características do ρ_{DCCA} variando de -1 a 1 e o eixo X é representado pelas horas, onde tem a intersecção da linha traçada na vertical que representa o período de 13 horas de estudos. As estações são representadas pelas formas geométricas como mostra a legenda da figura e a linha preta mostra a média dessas correlações.

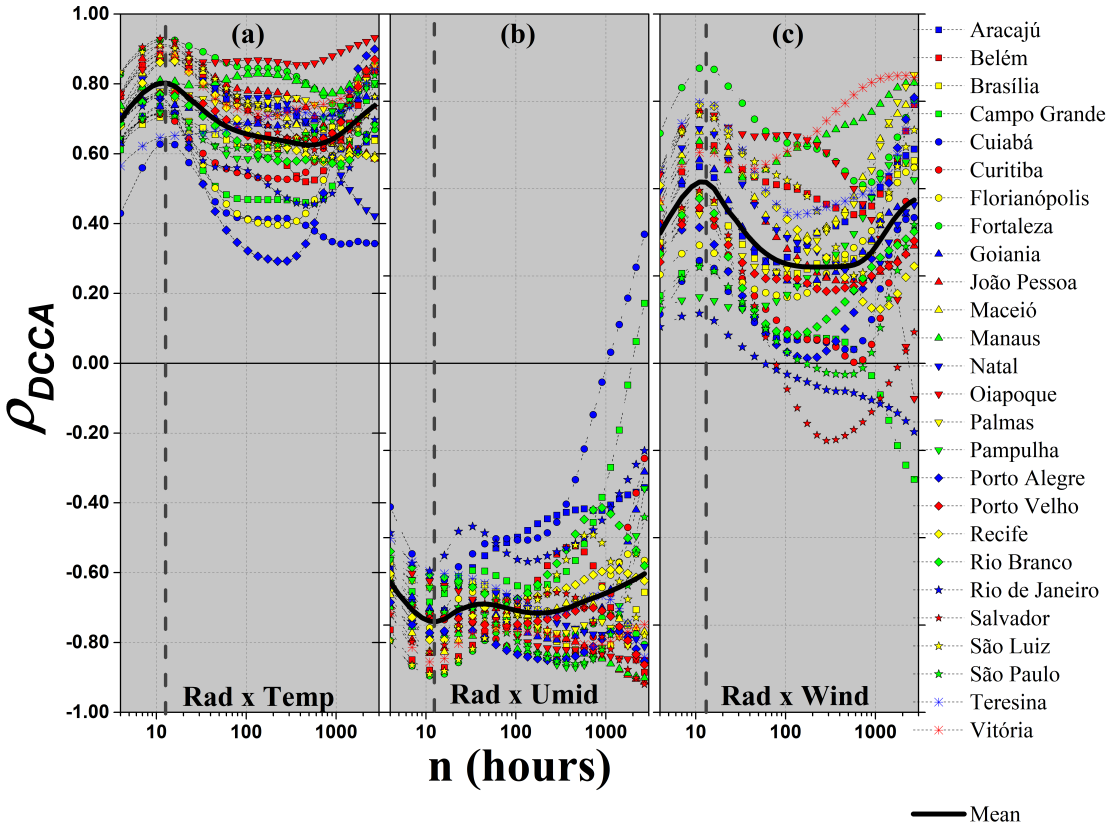

Figura 4.5: Análise do ρ_{DCCA} para as estações meteorológicas.

Com a interpretação do gráfico, os valores correspondidos foram dispostos em tabelas para melhor compreensão.

A tabela 4.2 mostra a condição do ρ_{DCCA} para a variável radiação solar correlacionada com a variável temperatura. Onde, a condição forte é a que ganha destaque na maior parte das estações.

Tabela 4.2: Condição do ρ_{DCCA} para a radiação solar x temperatura do ar.

Região	**Estações**	ρ_{DCCA} (13 h)	**Condição**
Sul	Curitiba	0,71	Forte
	Florianópolis	0,80	Forte
	Porto Alegre	0,74	Forte
Sudeste	São Paulo	0,71	Forte
	Rio de Janeiro	0,76	Forte
	Vitória	0,90	Forte
	Belo Horizonte	0,71	Forte
Centro-Oeste	Campo Grande	0,69	Forte
	Cuiabá	0,64	Médio
	Brasília	0,71	Forte
	Goiânia	0,74	Forte
Norte	Rio Branco	0,86	Forte
	Porto Velho	0,80	Forte
	Manaus	0,81	Forte
	Oiapoque	0,87	Forte
	Palmas	0,78	Forte
	Belém	0,88	Forte
Nordeste	Teresina	0,64	Médio
	São Luís	0,91	Forte
	Salvador	0,92	Forte
	Recife	0,87	Forte
	Natal	0,86	Forte
	João Pessoa	0,91	Forte
	Maceió	0,88	Forte
	Fortaleza	0,93	Forte
	Aracaju	0,88	Forte

Em sua totalidade a maior parte das estações, independentes de região mostraram uma correlação forte para a radiação solar x temperatura do ar, apenas as estações de Cuiabá e Teresina tiveram uma condição média. Essas condições fortes, se aproximando do intervalo 1, demonstram que as variáveis tem uma correlação cruzada perfeita. Podendo até mesmo ser justificado por causa da natureza da energia térmica.

Algumas premissas devem ser levadas em consideração, como as variações temporais na taxa de radiação solar. Uma das primeiras pesquisas em que se abordou este tema foi desenvolvida por Ohmura; Lang (1989) que observaram que as taxas de radiação solar incidente à superfície terrestre estariam declinando de maneira acentuada, desde 1950. Tal diminuição pode ser devido a vários fatores, como: Dispersão de Rayleigh por moléculas

de ar; Absorção por ozônio; Absorção por vapor de água; Absorção por gases como CO_2 (dióxido de carbono), entre outros. Nos últimos anos, alguns autores argumentam que essa diminuição é devido ao aumento de partículas aerossol na atmosfera (LIEPERT;TEGEN, 2002). Outra provável causa da diminuição seria a variabilidade na frequência de nebulosidade (QIAN et al., 2006).

Entre os atributos climáticos, a temperatura do ar é uma das variáveis mais influenciada pela altitude (PEREIRA et al., 2002; GALVANI; LIMA, 2006; PAIVA et al., 2012; BARRY; CHORLEY, 2003; FRITZSONS et al., 2015). Em vista disso, (FRITZSONS et al., 2008) ressaltam que a temperatura do ar de um local tem o seu gradiente térmico influenciado pela variação altimétrica. Além disso, outras particularidades do uso do solo são apontadas por (GALVANI; LIMA, 2006) como responsáveis pela variação do perfil vertical da temperatura do ar, sendo eles: cobertura vegetal, cor, declividade e orientação das vertentes. A topografia, declividade e orientação da vertente também foram apontados por (PEPIN, 2015) como fatores que influenciam na variabilidade da temperatura do ar. Diante disso, esses fatores também podem influenciar significativamente o perfil vertical de temperatura do ar.

A tabela 4.3 mostra os resultados do ρ_{DCCA} para a variável radiação solar correlacionada com a variável velocidade do vento. Onde, as condições média e fraca são as que ganham destaque na maior parte das estações.

Tabela 4.3: Condição do ρ_{DCCA} para a radiação solar x velocidade do vento.

Região	**Estações**	ρ_{DCCA} (13 h)	**Condição**
Sul	Curitiba	0,42	Médio
	Florianópolis	0,32	Fraca
	Porto Alegre	0,37	Médio
Sudeste	São Paulo	0,27	Fraco
	Rio de Janeiro	0,14	Fraco
	Vitória	0,60	Médio
	Belo Horizonte	0,19	Fraca
Centro-Oeste	Campo Grande	0,14	Fraca
	Cuiabá	0,25	Fraca
	Brasília	0,47	Médio
	Goiânia	0,58	Médio
Norte	Rio Branco	0,39	Médio
	Porto Velho	0,42	Médio
	Manaus	0,63	Médio
	Oiapoque	0,71	Forte
	Palmas	0,41	Médio
	Belém	0,063	Médio
Nordeste	Teresina	0,75	Forte
	São Luís	0,71	Forte
	Salvador	0,49	Médio
	Recife	0,74	Forte
	Natal	0,67	Forte
	João Pessoa	0,72	Forte
	Maceió	0,67	Forte
	Aracaju	0,57	Médio
	Fortaleza	0,86	Forte

Poucas foram as estações que tiveram correlação forte sob as variáveis, na região norte por exemplo, só a estação de Oiapoque, e na região nordeste as estações de Teresina, São Luís, Recife, Natal, João Pessoa, Maceió e Fortaleza. Essa condição forte para a maior parte das estações da região nordeste pode se dá pelo fato de serem regiões litorâneas. Apesar de que a radiação solar e a velocidade do vento não têm uma correlação direta forte porque representam processos físicos diferentes e geralmente não estão diretamente interligados.

Dessa forma, o vento também pode contribuir positivamente e negativamente às condições atmosféricas. Entre os pontos positivos destaca-se a dispersão dos poluentes (DEMIRICI; CUHADAROGLY, 2000), o transporte de pólen (FRIEDMAN; BARRET, 2009) e de sementes (JONGEJANS; TELENIUS, 2004) e, também a geração de energia quando convertida em outras formas de energia, como a elétrica (PIMENTA et al., 2008). Os efeitos negativos correspondem aos danos à vegetação e a propagação de doenças, em particular as bacterianas (PAZ; BROZA, 2007) e pode provocar grande destruição quando associado a eventos como furacões e tornados .

Já a tabela 4.4 mostra a condição do ρ_{DCCA} para a variável radiação correlacionada com a variável umidade relativa. Onde, as condições forte e média são as que ganham destaque na maior parte das estações.

Tabela 4.4: Condição do ρ_{DCCA} para a radiação solar x umidade relativa.

Região	**Estações**	ρ_{DCCA} (13 h)	**Condição**
Sul	Curitiba	-0,73	Médio
	Florianópolis	-0,76	Forte
	Porto Alegre	-0,76	Forte
Sudeste	São Paulo	-0,71	Forte
	Rio de Janeiro	-0,60	Médio
	Vitória	-0,85	Forte
	Belo Horizonte	-0,64	Médio
Centro-Oeste	Campo Grande	-0,64	Médio
	Cuiabá	-0,65	Médio
	Brasília	-0,64	Médio
	Goiânia	-0,71	Forte
Norte	Rio Branco	-0,76	Forte
	Porto Velho	-0,77	Forte
	Manaus	-0,65	Médio
	Oiapoque	-0,62	Forte
	Palmas	-0,72	Forte
	Belém	-0,89	Forte
Nordeste	Teresina	-0,60	Médio
	São Luís	-0,89	Forte
	Salvador	-0,79	Forte
	Recife	-0,74	Forte
	Natal	-0,70	Forte
	João Pessoa	-0,79	Forte
	Maceió	-0,83	Forte
	Aracaju	-0,83	Forte
	Fortaleza	-0,90	Forte

As estações nas regiões norte e nordeste mais uma vez mostram correlações cruzadas fortes, na região sudoeste destacam mais estações com correlações médias, nas demais regiões se intercalam de médio a forte. A radiação e a umidade relativa estão relacionadas indiretamente devido ao papel que a água desempenha na absorção e na dispersão da radiação. Os valores nas tabelas que se aproximam de 1 corresponde a características de a uma correlação cruzada perfeita, ao se aproximar de 0 mostra ser sem correlação cruzada e ao se aproximar de -1 se destaca como uma anti correlação cruzada perfeita. No fator dessas correlações, a vegetação também serve para atenuar a intensidade e modifica a concentração da umidade na atmosfera e na superfície adjacente. São várias as escalas pelas quais a vegetação pode atuar, desde uma escala micro até uma escala macro (PAZ; BROZA, 2012).

Nesse sentido, o uso do coeficiente ρ_{DCCA} como uma ferramenta de análise aplicável a diferentes cenários bem como sua aplicação relacionada às variáveis ambientais se torna

importante diante de um cenário tão complexo. Assim, compreender a dinâmica complexa da dispersão dessas variáveis pode contribuir para o controle e estruturação de diversas camadas ambientais. O coeficiente ρ_{DCCA} demonstra potencial para explorar correlações em diferentes contextos e já tem sido utilizado em outras áreas, tais como: estudo do mercado de carbono (ZHANG et al., 2020), fenômenos climáticos (Brito et al., 2019), na área da saúde (CHEN et al., 2018) e outros.

Por meio da análise de estudos que abordam esses aspectos, busca-se aprimorar a compreensão do uso desse método nesse contexto específico e identificar possíveis padrões que possam contribuir para o desenvolvimento de estratégias eficazes no campo das ciências ambientais e planejamento urbano, social, ambiental e econômico. Há que citar que apesar da eficácia do método e dos procedimentos aplicados na pesquisa, limitações como o tempo de coleta de dados e o número de variáveis estudadas impedem que se firme relação robusta entre seus resultados ao fenômeno do aquecimento global, assim como outros fatores, por exemplo, a urbanização e crescimento das cidades, o desmatamento, a queima de combustíveis, onde possuem grande influência sob as variáveis meteorológicas.

4.3 Análise por meio do coeficiente DMC_x^2

A análise de correlação cruzada múltipla foi realizada e está demonstrada na Fig. 4.6, as Fig. A.7, A.8, A.9, A.10, A.11 e A.12 mostram detalhadamente para cada estação individualmente. Como o próprio nome do coeficiente já diz, foi feito de forma múltipla a relação das variáveis temperatura do ar, umidade relativa e velocidade do vento com a radiação solar.

A figura é interpretado da seguinte forma:

O eixo X tem a representação das estações, o eixo Y mostra a escala do tempo em horas, como citado no capítulo a linha traçada na horizontal representa as 13 horas de medições com base na radiação. A correlação múltipla cruzada é caracterizada por sua condição, na legenda essa condição é retratada por intervalos que variam de 0,0 à 1,0. Os intervalos vêm mostrar que quando variam de 0,0 à 0,20 é uma condição muito fraca, de 0,20 à 0,40 a condição é fraca, de 0,40 à 0,60 mostra ser de condição média, de 0,60 à 0,80 destaca como forte e de 0,80 à 1,0 a condição é muito forte.

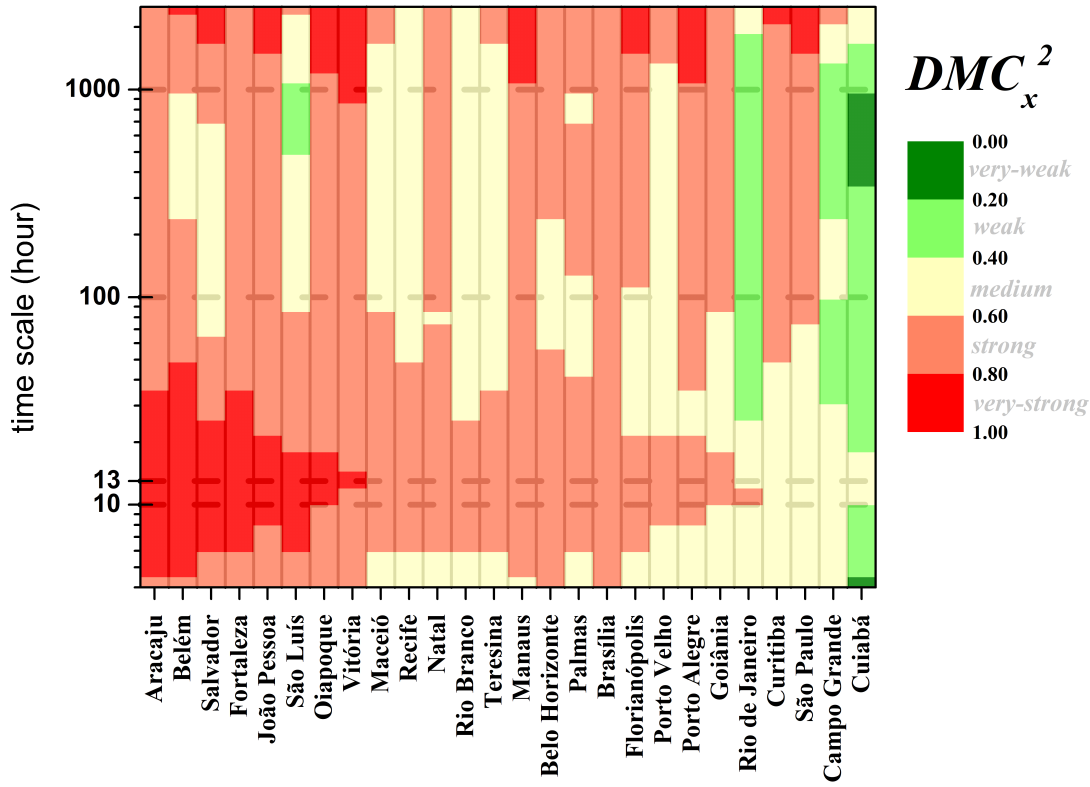

Figura 4.6: Análise do DMC_x^2 para as estações meteorológicas.

Para melhor entendimento dos resultados, a tabela 4.5 mostra os valores dessa correlação múltipla para cada estação.

As estações da região nordeste mais uma vez se destacam com correlações variando de muito forte a forte. Estudos nessa região são de extrema importância, pois, apesar de chover tanto quanto em muitas outras regiões do mundo, em particular na parte semiárida, é periodicamente afetada pela ocorrência de secas com perdas parciais ou totais na agropecuária, além de comprometer o abastecimento de água devido principalmente à irregularidade da estação chuvosa na região, com predominância de chuvas intensas e de curta duração (SILVA et al., 1998). Estudos indicam que esta região vem sofrendo com fortes variabilidades climáticas (PIMENTA et al., 1998; SILVA, 2004; SOUSA, 2006). Assim, grande parte do semiárido brasileiro, onde a agricultura não-irrigada por exemplo, já é uma atividade marginal, se torna ainda mais inadequada para a prática da agricultura de subsistência.

Cabe destacar ainda a validade do estudo de correlações na região nordeste por se tratar de uma região promissora ao desenvolvimento de energia renovável. Um exemplo disso é a geração de energia eólica. A região Nordeste concentra mais de 35% da potência eólica brasileira (GWEC, 2010). O Estado do Ceará, em particular, possui um grande potencial

Tabela 4.5: Condição do DMC_{xz}^2

Região	**Estações**	DMC_{xz}^2	**Condição**
Sul	Curitiba	0,55	Médio
	Florianópolis	0,67	Forte
	Porto Alegre	0,62	Forte
Sudeste	São Paulo	0,52	Médio
	Rio de Janeiro	0,60	Forte
	Vitória	0,80	Muito Forte
	Belo Horizonte	0,55	Médio
Centro-Oeste	Campo Grande	0,53	Médio
	Cuiabá	0,43	Médio
	Brasília	0,62	Forte
	Goiânia	0,60	Forte
Norte	Rio Branco	0,76	Forte
	Porto Velho	0,66	Forte
	Manaus	0,72	Forte
	Oiapoque	0,81	Muito Forte
	Palmas	0,70	Forte
	Belém	0,79	Forte
Nordeste	Teresina	0,72	Forte
	São Luís	0,83	Muito Forte
	Salvador	0,88	Muito Forte
	Recife	0,76	Forte
	Natal	0,75	Forte
	João Pessoa	0,84	Muito Forte
	Maceió	0,78	Forte
	Aracaju	0,73	Forte
	Fortaleza	0,87	Forte

de geração off–shore, pois possui uma plataforma continental rasa, com média de 8m de profundidade em cerca de 35% de sua faixa litorânea (ADECE, 2010). Os benefícios da inserção da energia eólica para a segurança da matriz elétrica brasileira são importantes devido à sua complementaridade com o regime hídrico e manutenção do caráter limpo e renovável da matriz energética brasileira(RAMPINELLI; ROSA, 2012).

Outro fator promissor aos estudos com a radiação solar é a produção da própria energia solar. Em uma época onde cresce a preocupação com o meio ambiente, a energia solar ganha notoriedade, haja vista que, reconhecidamente faz parte das energias limpas e renováveis. A energia é um dos principais vetores influentes na questão ambiental e está no centro das discussões globais que originaram o conceito de desenvolvimento sustentável, cuja implementação tem sido talvez, o maior desafio atual da humanidade (REIS, 2006). Dentre essas alternativas, a Energia Solar é uma das que vem apresentando significativa atenção.

Este tipo de energia reduz as linhas de transmissão de redes elétricas tradicionais, não emite gases tóxicos na atmosfera, não esgota os recursos naturais, aumenta a inde-

pendência energética nacional/regional, além de diversificar e assegurar o abastecimento energético. Portanto, a energia solar tem se mostrado ambientalmente vantajosa em relação a qualquer outra fonte de energia, tornando- se, assim, a peça fundamental de qualquer programa de desenvolvimento sustentável (TSOUTOS et al., 2005). De acordo com Dyson (2001), a energia solar é uma das fontes de energia mais limpas e não faz comprometer ou adicionar o aquecimento global. O sol é a fonte de energia renovável, e o aproveitamento dessa energia, tanto como fonte de calor quanto de luz, é uma das alternativas energéticas mais promissoras para enfrentar os desafios do novo milênio. O Brasil, sobretudo a região Nordeste, apresenta os maiores valores de irradiação solar global, logo, reconhecendo as suas vantagens, mas também os seus desafios, cabe ao Estado, em sua função de planejador, encontrar os meios de incentivar a tecnologia solar para que esta possa contribuir para o objetivo nacional de desenvolvimento econômico e de sustentabilidade da matriz energética.

A região norte a estação de Oiapoque mostrou uma correlação muito forte em comparação com as demais estações. A região norte é marcada pelas suas peculiaridades, entre as quais se incluem a acentuada desigualdade socioeconômica e também o isolamento geográfico em relação às regiões mais desenvolvidas do país. Curitiba na região Sul também teve uma condição média, Florianópolis e Porto Alegre uma condição forte. A região Sul situa-se em uma região latitudinal favorável à atuação de diversos fenômenos meteorológicos que afetam o tempo e o clima do estado como, por exemplo, as frentes frias e o fenômeno El Niño. Considerando os fenômenos de escala sinótica, têm-se as frentes frias que passam regularmente pelo estado favorecendo a boa distribuição espacial e temporal das chuvas, conforme mostrado em (CERA; FERRAZ, 2007).

No Centro-Oeste Cuiabá teve uma condição média, assim como Campo Grande já Brasília e Goiânia uma forte, pesquisas nessa região se mostram grandiosas pelo fato de que a região Centro-Oeste se tornou estratégica, tanto pela sua posição geográfica quanto pelas suas características físico-ambientais, que propiciavam a expansão da produção agrícola nos padrões da nova agricultura moderna.

Contudo, Belo Horizonte e São Paulo na região Sudeste tiveram uma condição média. O Sudeste é uma região que acontecem diversos extremos climáticos, estudos nessa localidade podem mitigar impactos gerados nas cidades. Chuvas intensas especialmente no verão os quais estão associadas a inundações e deslizamentos de terra em vários municípios do Estado de São Paulo (SP), levando a muitos problemas ambientais. No estado de Minas Gerais (MG), (CARPENEDO, 2018) e (DALAGNOL et al., 2021), destacam que as maiores causas de impactos socioeconômicos estão relacionadas aos extremos hidrológicos acentuados nos meses de chuva, em especial no verão, que incluem inundações, alagamentos e deslizamentos de terra. O estado do Rio de Janeiro (RJ) também possui características de chuvas extremas. Por fim, o estado do Espírito Santo (ES), ao se tratar

de Vitória, cujos meses mais chuvosos vão de dezembro a março, os impactos de proporção ambiental e social são agravados como deslizamentos de terras ou inundações, que acabam afetando as populações de baixa renda do estado .

Diante do exposto, as regiões que essas estações estão localizadas também se situam em biomas, a figura A.13 mostra as estações nos respectivos biomas. A influência dos biomas brasileiros na correlação cruzada entre radiação, temperatura, umidade relativa e velocidade do vento varia conforme as características ecológicas de cada região. Na Amazônia e Mata Atlântica, a densa vegetação modera a temperatura, mantém alta umidade e reduz a velocidade dos ventos, criando um microclima estável. No Cerrado e na Caatinga, a alta radiação e a vegetação esparsa resultam em maiores variações de temperatura e menor umidade, com ventos mais intensos. Já no Pantanal, o ciclo hidrológico sazonal altera significativamente as variáveis climáticas, enquanto no Pampa, o relevo plano favorece ventos mais fortes e maior evaporação. Essas diferenças influenciam como essas variáveis interagem entre si em cada bioma.

A aplicação do DMC_x^2 se mostrou eficiente, o objetivo deste trabalho foi aplicar um esse novo método para análise de múltiplas correlações cruzadas entre variáveis meteorológicas de forma inovadora. Como a expressão para correlação múltipla é bastante geral, outras variáveis podem ser empregadas, como pressão atmosférica, precipitação pluviométrica, evaporação, insolação entre outras, adicionando ainda mais informações ao cálculo de DMC_x^2.

Capítulo Cinco

CONSIDERAÇÕES FINAIS

O atual cenário no Brasil, no que tange as mudanças climáticas, crise energética, agricultura, planejamento ambiental entre outros aspectos, aponta a necessidade de novas pesquisas científicas. Através de métodos da física estatística, aplicados em séries temporais de radiação solar, temperatura do ar, umidade relativa e velocidade dos ventos, tornou-se possível analisar outras vertentes como a detecção da existência de correlações, que podem ser útil para estudos já existentes envolvendo até mesmo as fontes de energias apontadas nessa pesquisa. Visto que, o Brasil é um país promissor na utilização de energias renováveis, isso se deve a sua abundância de recursos naturais, como sol, vento e água, favorecendo a geração sustentável de energia. O país tem potencial para liderar a transição energética global. Para análise de correlações aplicou-se o coeficiente ρ_{DCCA} e DMC_x^2 sobre os dados de variáveis meteorológicas registradas em cada estado brasileiro pelo INMET, no período de 2009 a 2019.

Através das análises concluiu-se que, ambos os métodos, apresentaram correlações a partir das variáveis, mostraram ser métodos robustos, entretanto, a correlação cruzada através do ρ_{DCCA} entre radiação solar e temperatura do ar demonstrou uma relação forte em várias estações, indicando que, a intensidade da radiação solar está diretamente relacionada ao aumento da temperatura. No entanto, em Cuiabá e Teresina, essa relação não se manteve, possivelmente devido a fatores locais como urbanização e características climáticas específicas. A análise ρ_{DCCA} revelou correlações significativas entre radiação solar e umidade relativa, principalmente em biomas do Norte e Nordeste, como a Amazônia e a Mata Atlântica, onde a umidade é influenciada por padrões de evapotranspiração. O coeficiente DMC_x^2 permitiu entender melhor as interações entre essas variáveis, essencial para o manejo sustentável e a adaptação as mudanças climáticas, considerando as particularidades de cada bioma e suas influências nas condições climáticas regionais.

Os resultados encontrados, nessa pesquisa, devem ser úteis ao desenvolvimento e validação de modelos teóricos e computacionais, que auxiliem as estimativas para a radiação solar, temperatura do ar, umidade relativa e velocidade do vento, cuja necessidade em encontrar soluções para mitigar impactos ambientais. Como trabalhos futuros, pode-se verificar outros tipos de variáveis meteorológicas e estudar a influência de suas correlações e testar o DMC_x^2 para mais de quatro variáveis meteorológicas.

Apêndice A

Anexo I

A seguir são apresentadas as figuras onde é possível ver as correlações cruzadas (ρ_{DCCA}) para cada uma das estações meteorológicas de acordo cada região.

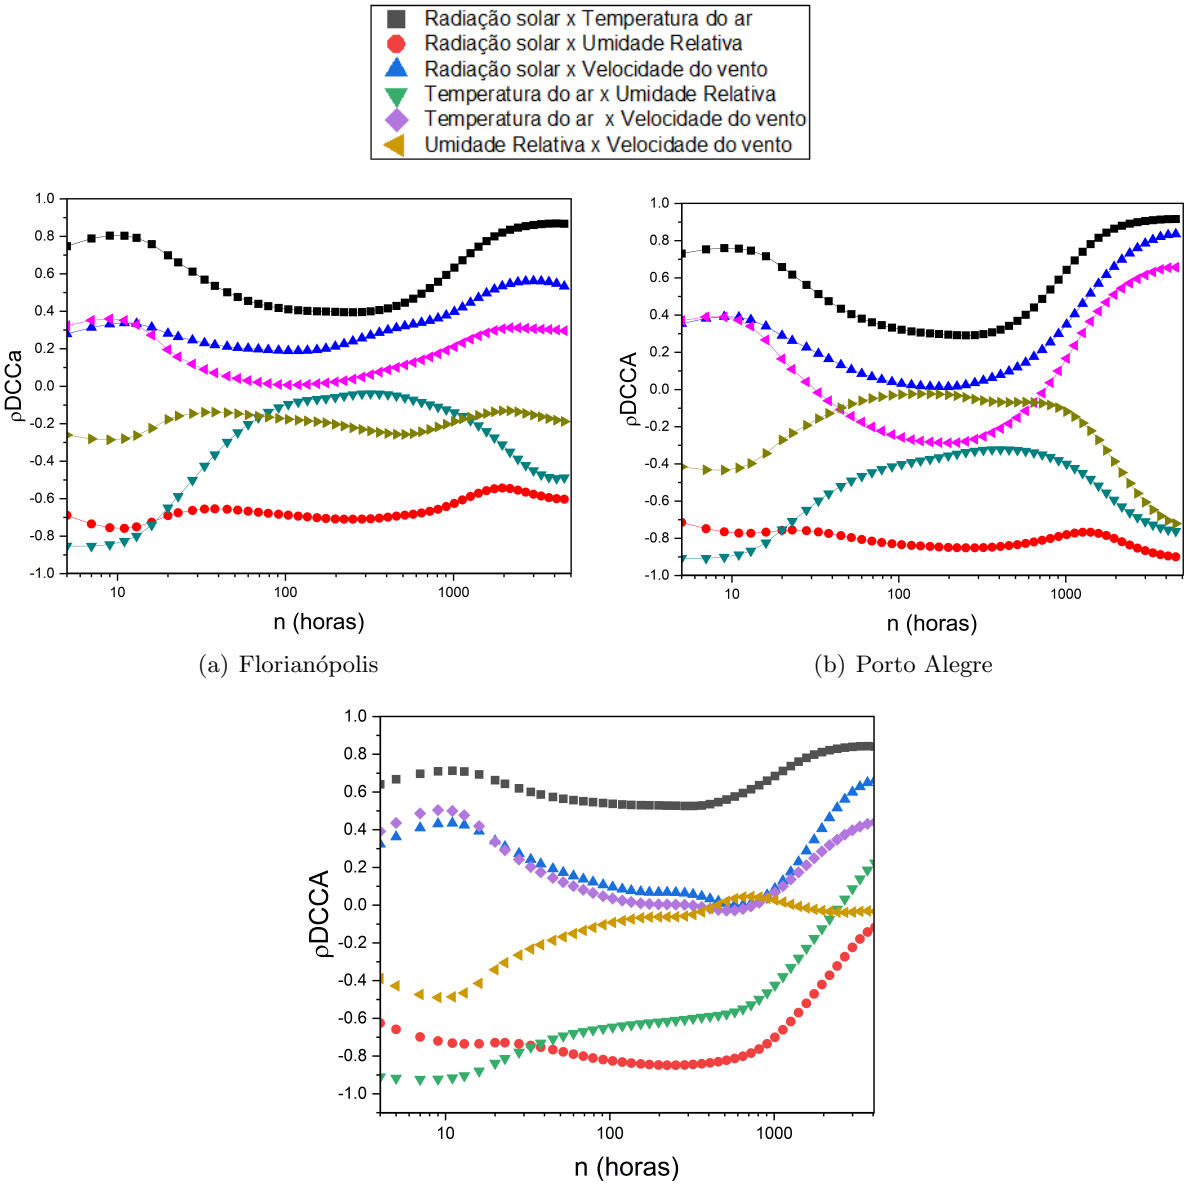

(a) Florianópolis

(b) Porto Alegre

(c) Curitiba

Figura A.1: Correlações cruzadas para a região Sul.

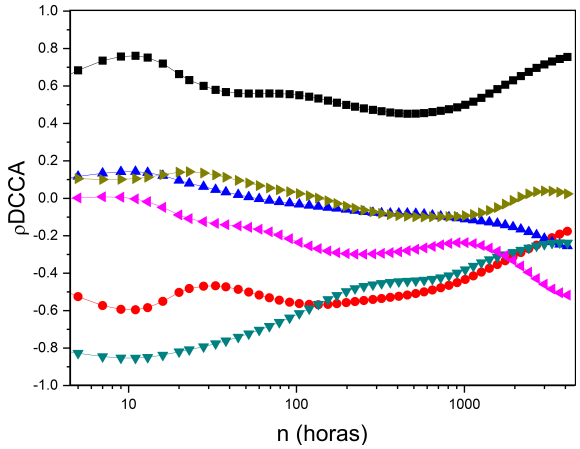

(a) Rio de Janeiro

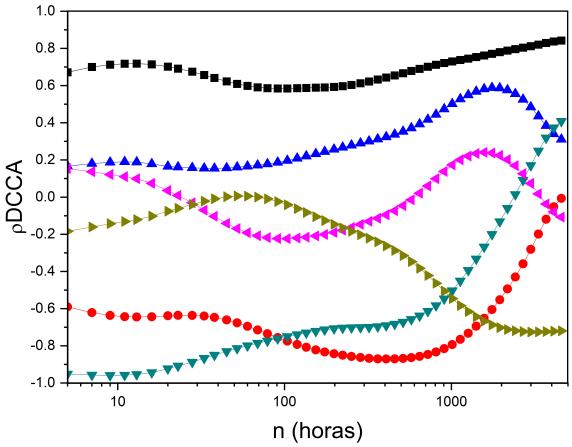

(b) Belo Horizonte

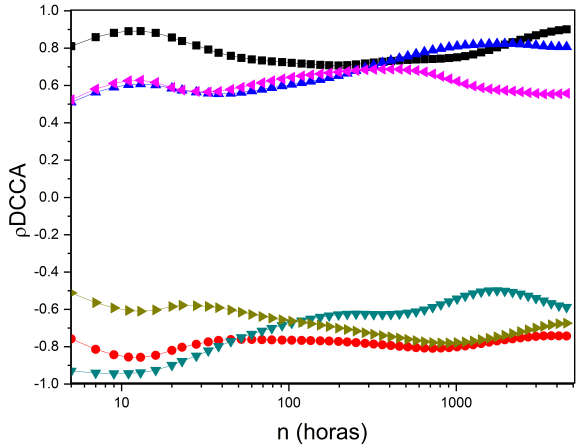

(c) Vitória

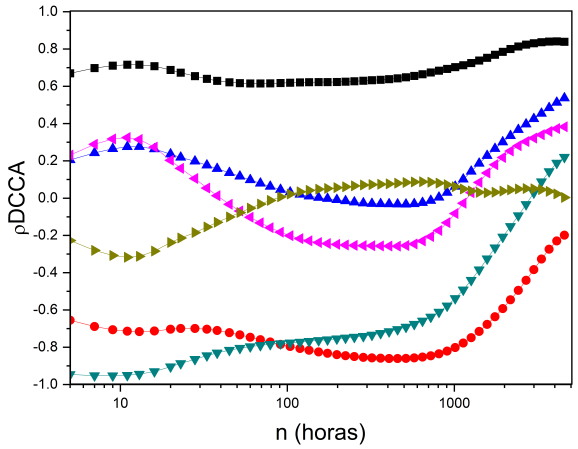

(d) São Paulo

Figura A.2: Correlações cruzadas para a região Sudeste.

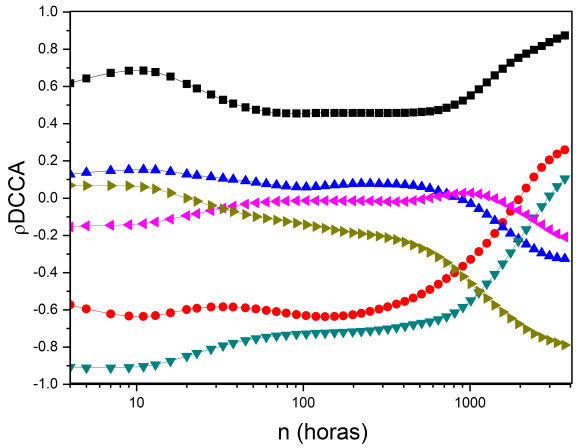

(a) Campo Grande

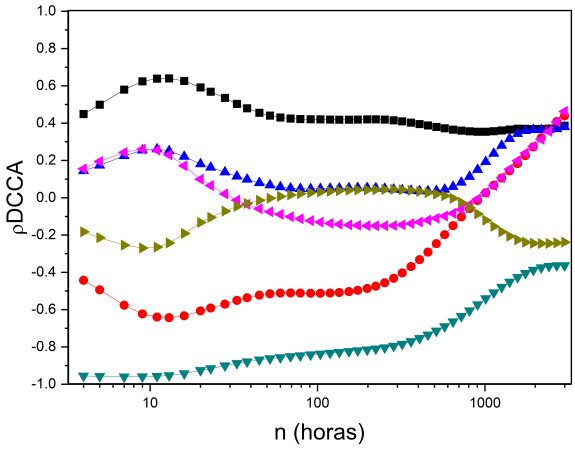

(b) Cuiabá

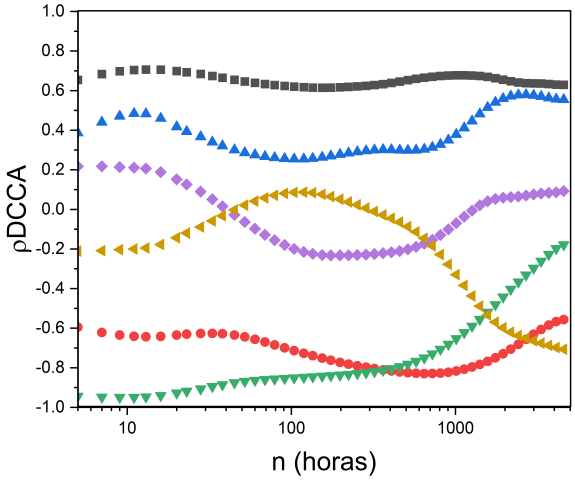

(c) Brasília

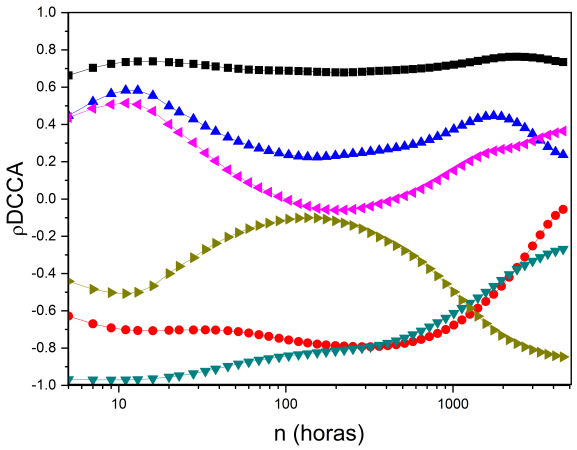

(d) Goiânia

Figura A.3: Correlações cruzadas para a região Centro-Oeste.

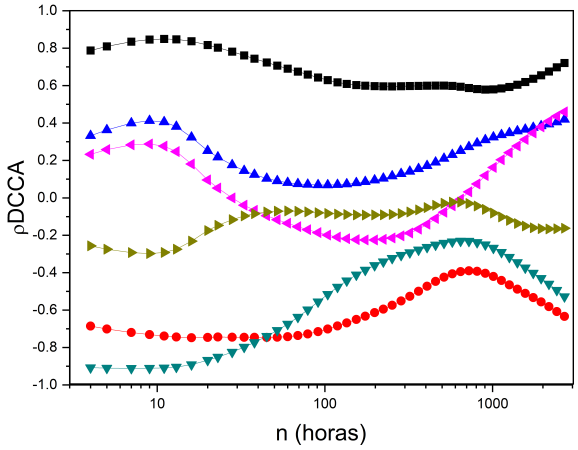

(a) Rio Branco

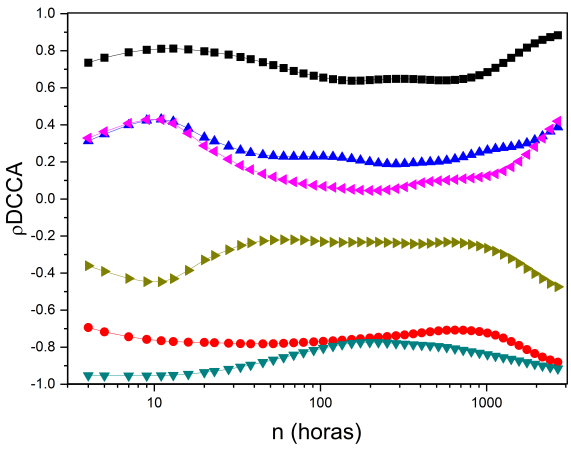

(b) Porto Velho

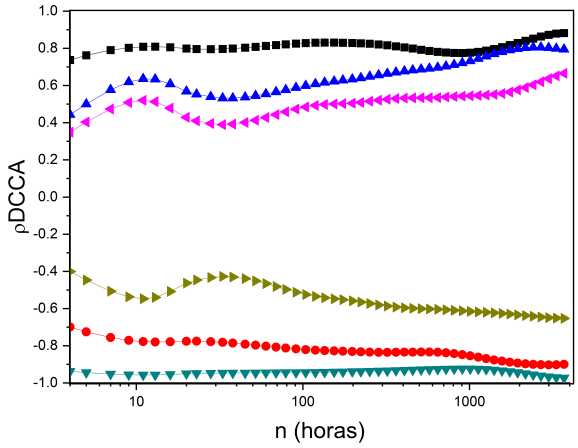

(c) Manaus

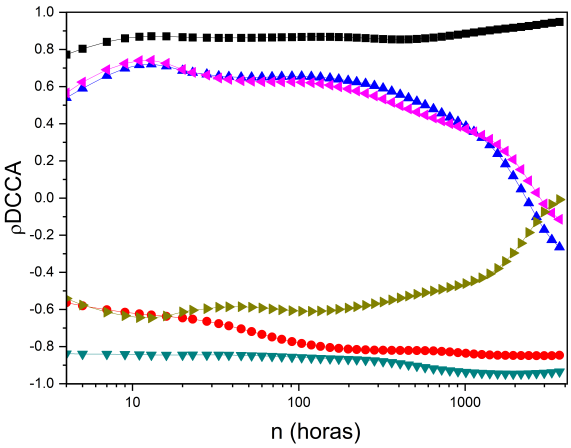

(d) Oiapoque

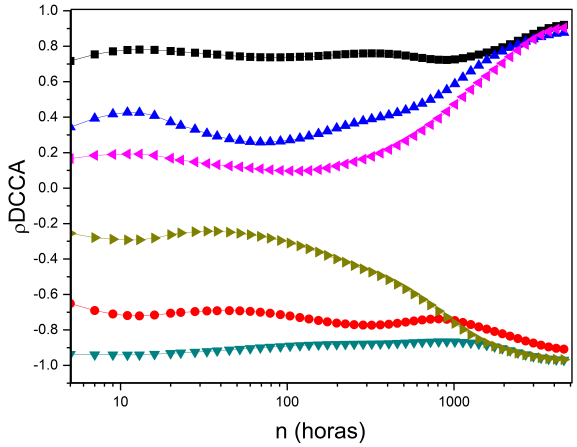

(e) Palmas

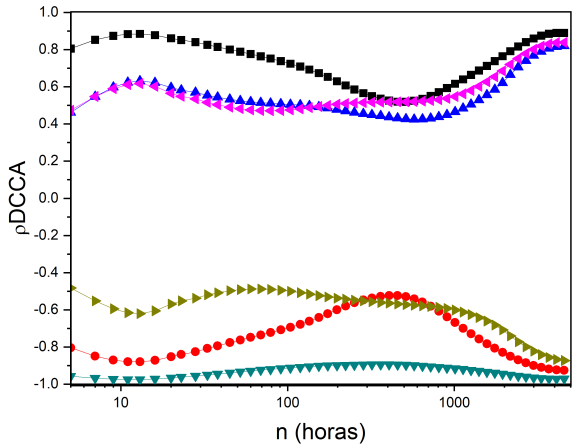

(f) Belém

Figura A.4: Correlações cruzadas para a região Norte.

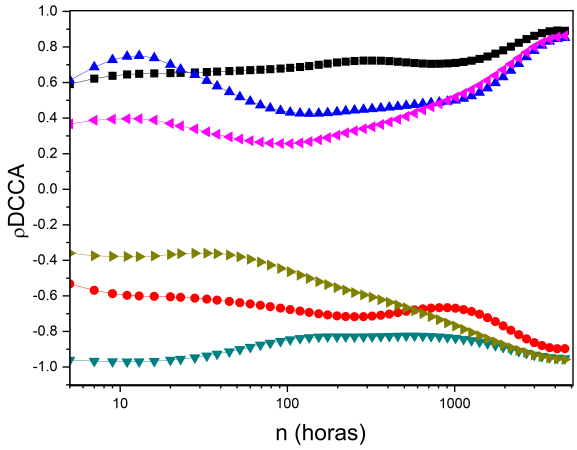

(a) Teresina

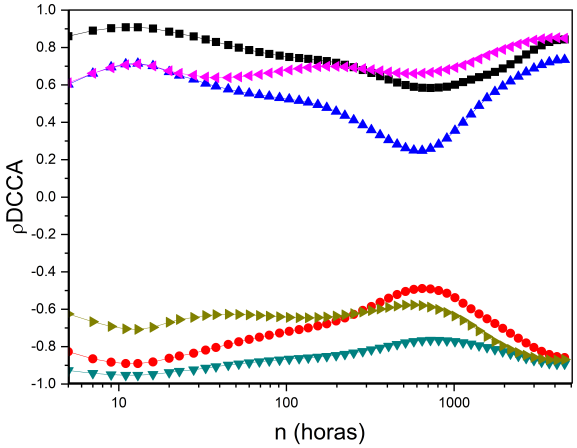

(b) São Luis

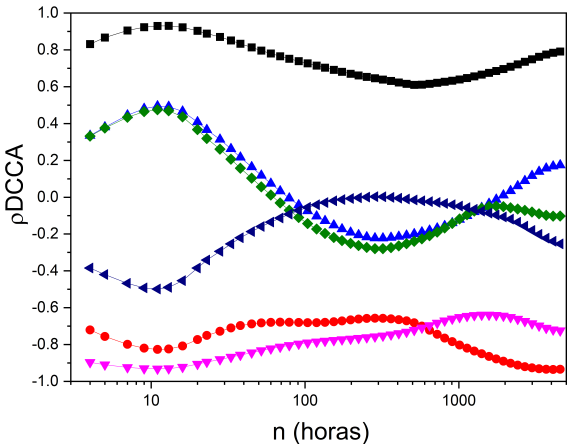

(c) Salvador

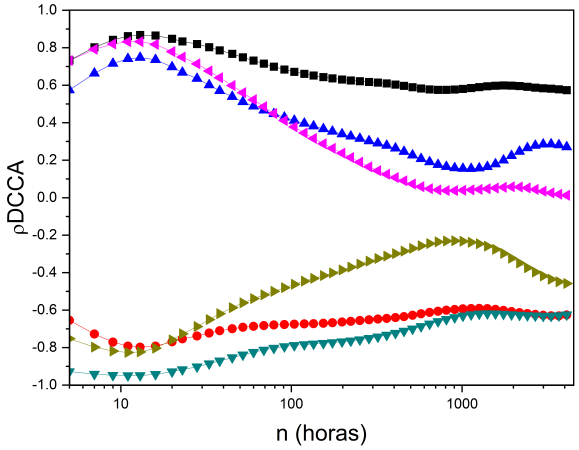

(d) Recife

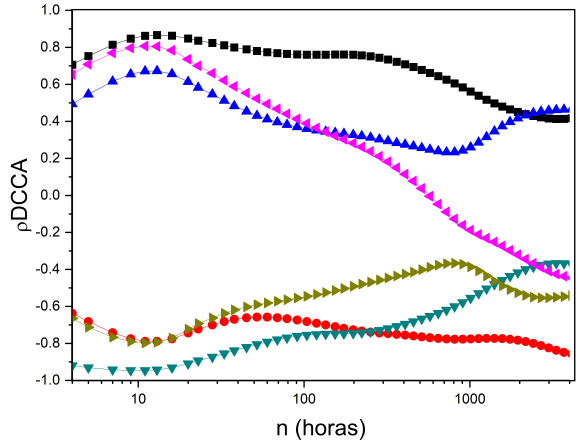

(e) Natal

Figura A.5: Correlações cruzadas para a região Nordeste.

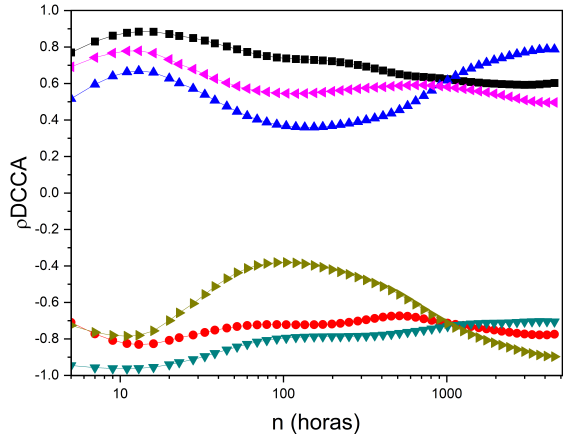

(a) Maceió

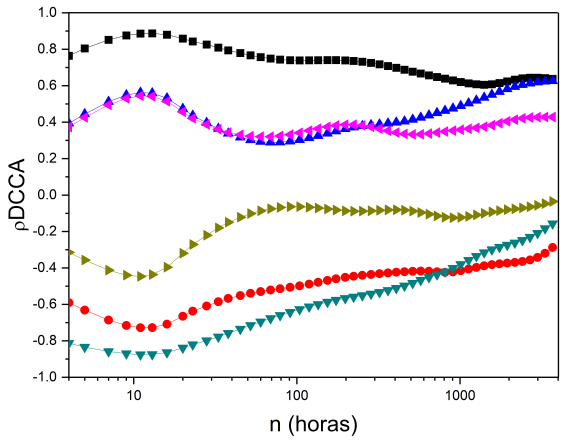

(b) Aracajú

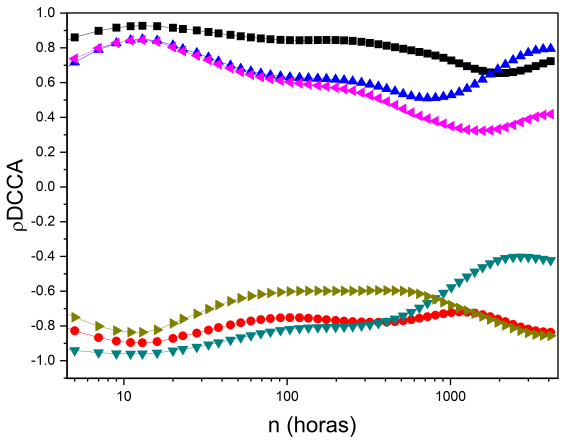

(c) Fortaleza

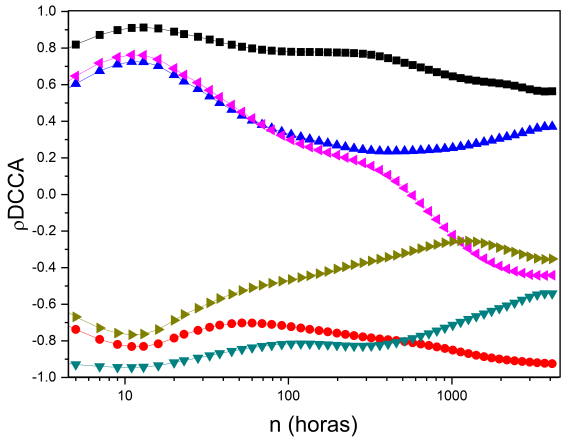

(d) João Pessoa

Figura A.6: Correlações cruzadas para a região Nordeste.

A seguir são apresentadas as correlações cruzadas múltiplas (DMC_x^2) para cada estação meteorológica

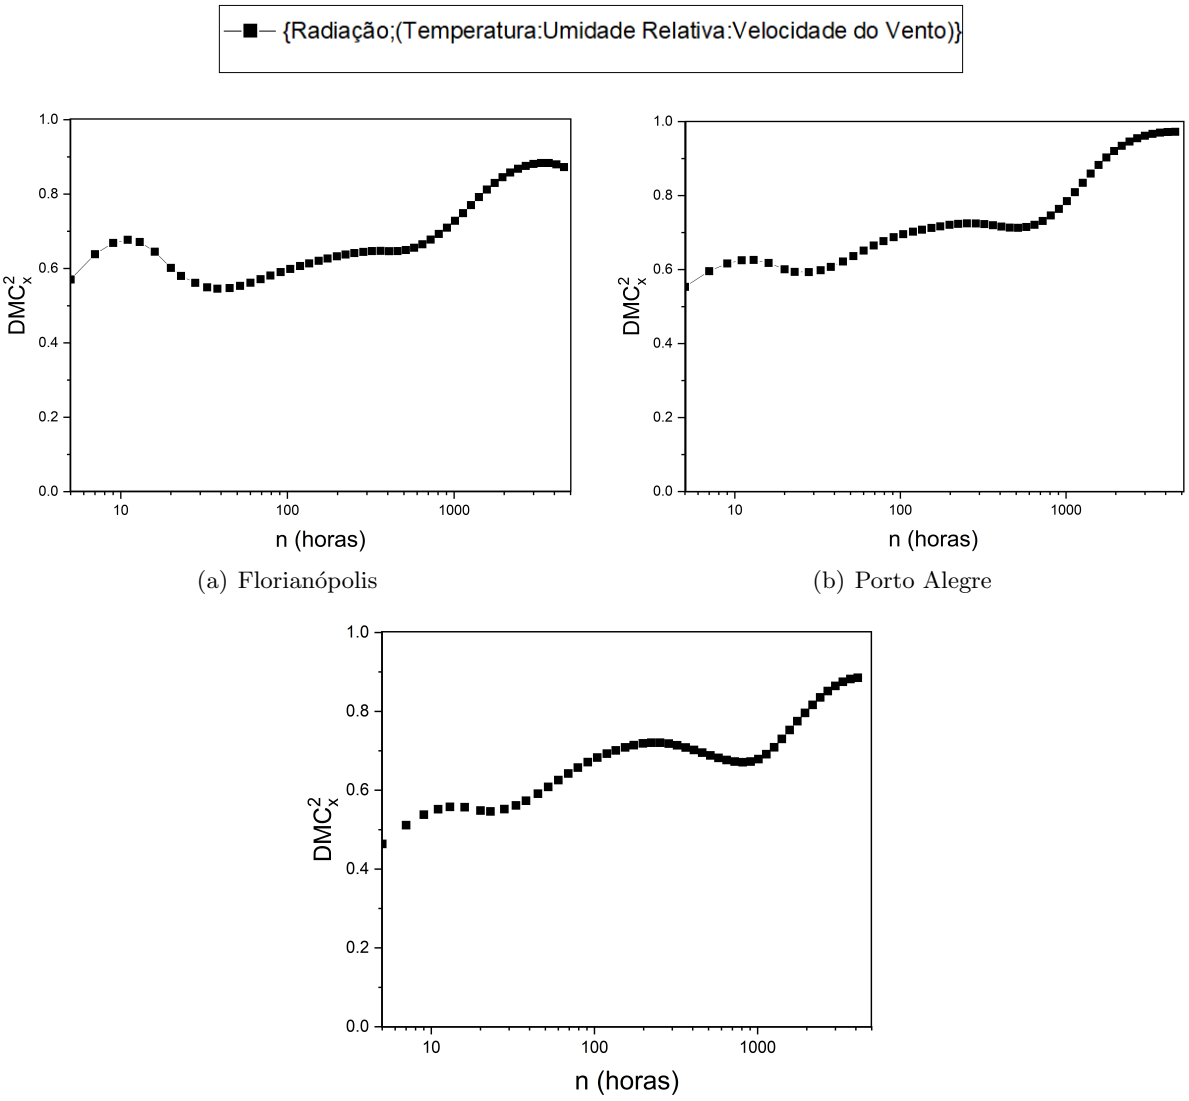

(a) Florianópolis

(b) Porto Alegre

(c) Curitiba

Figura A.7: Correlações cruzadas para a região Sul.

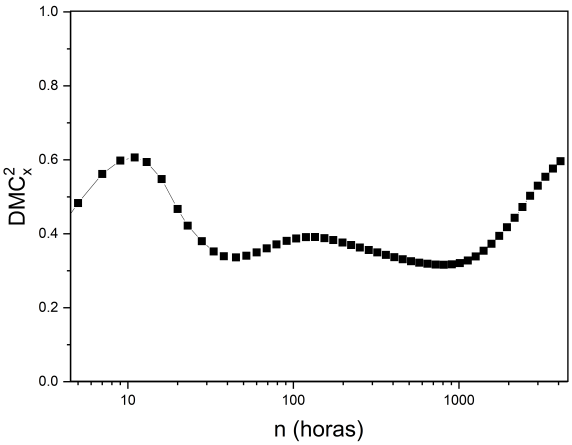

(a) Rio de Janeiro

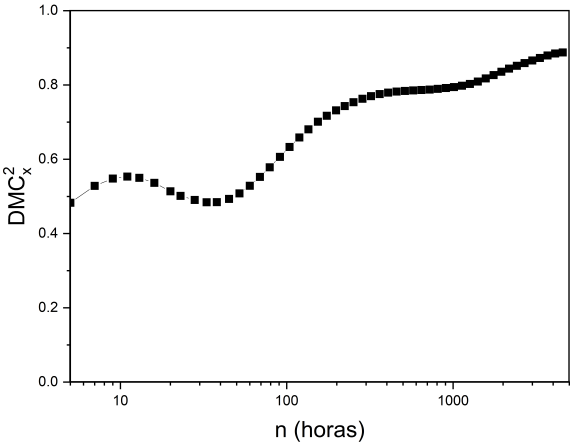

(b) Belo Horizonte

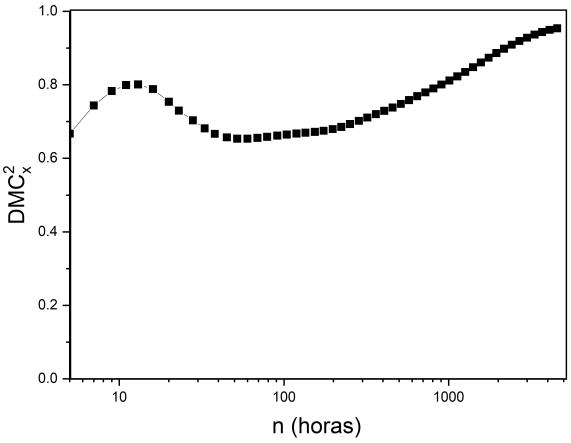

(c) Vitória

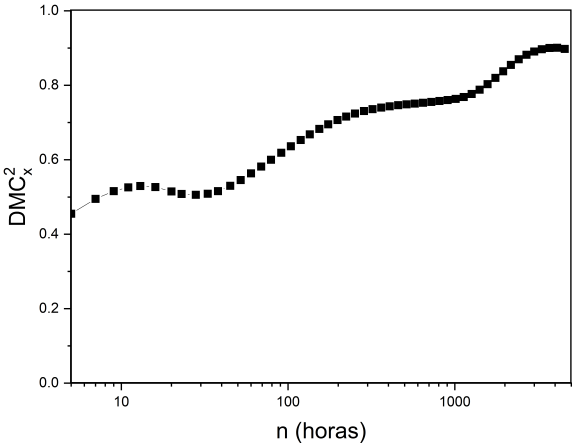

(d) São Paulo

Figura A.8: Correlações cruzadas para a região Sudeste.

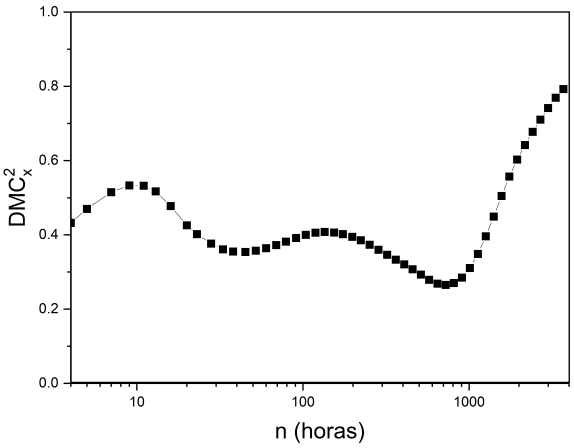

(a) Campo Grande

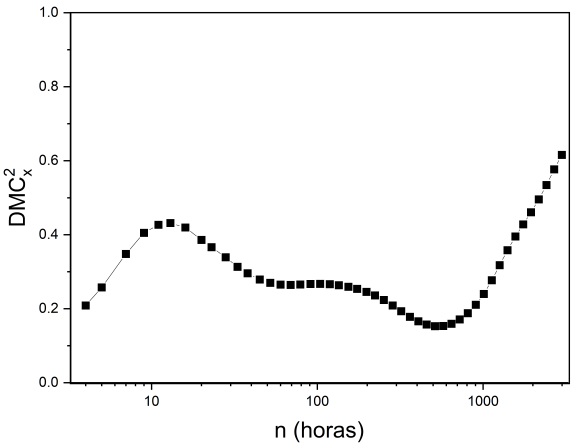

(b) Cuiabá

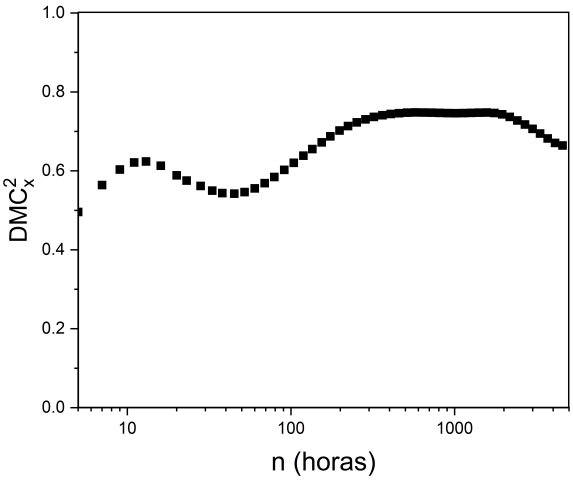

(c) Brasília

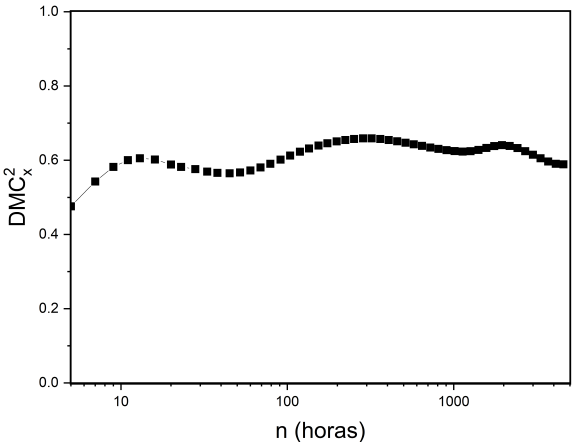

(d) Goiânia

Figura A.9: Correlações cruzadas para a região Centro-Oeste.

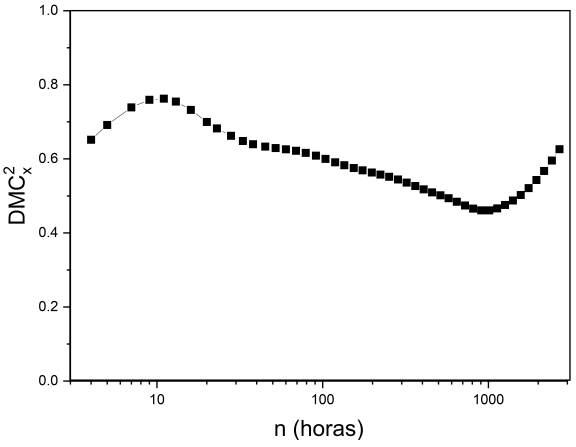

(a) Rio Branco

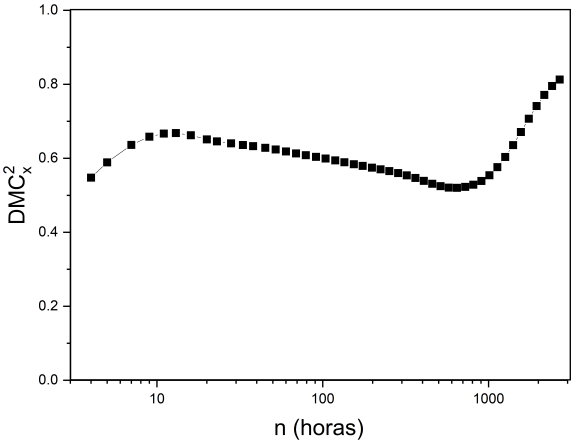

(b) Porto Velho

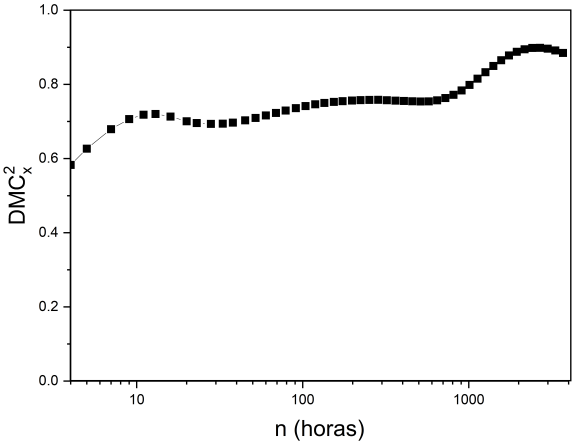

(c) Manaus

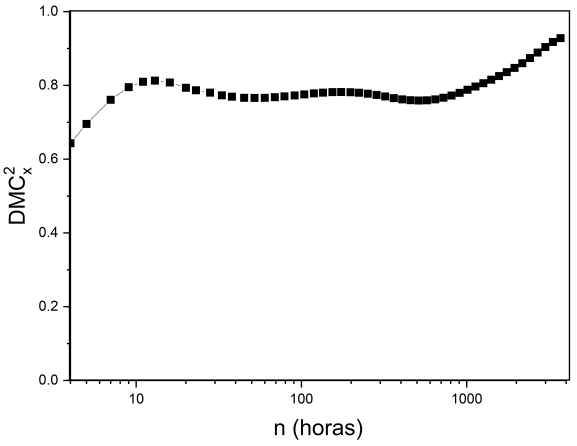

(d) Oiapoque

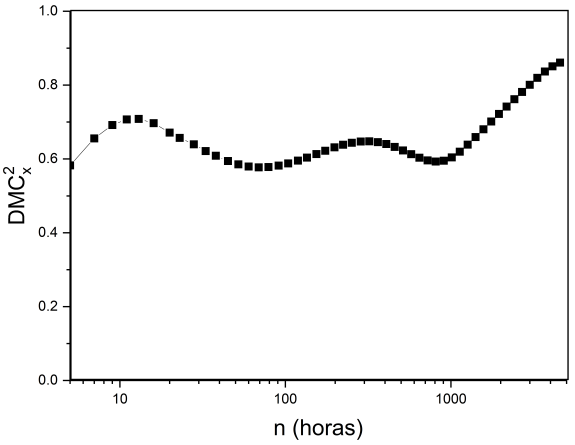

(e) Palmas

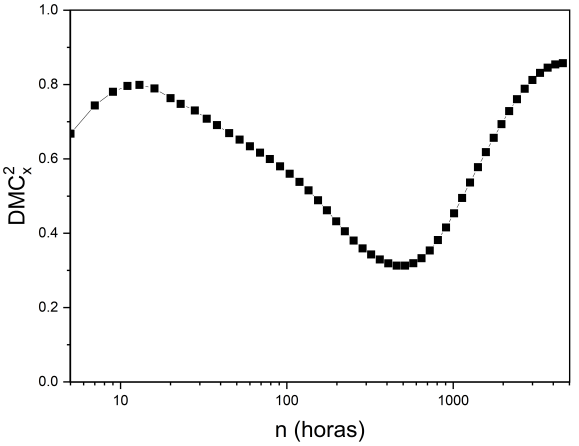

(f) Belém

Figura A.10: Correlações cruzadas para a região Norte.

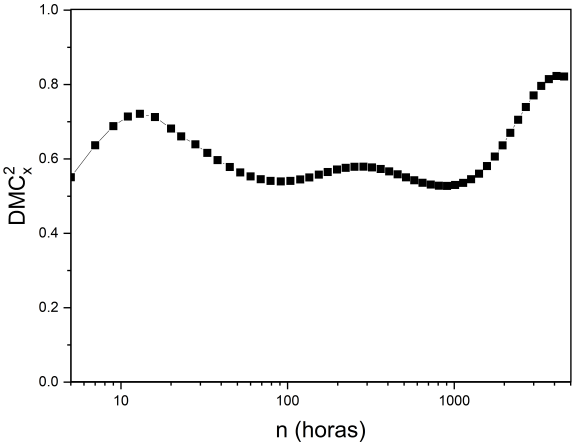

(a) Teresina

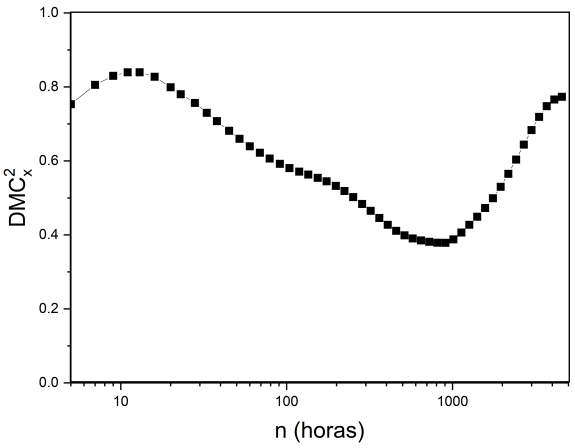

(b) São Luis

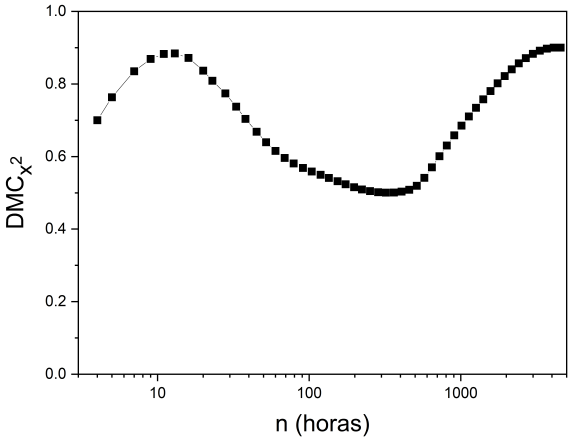

(c) Salvador

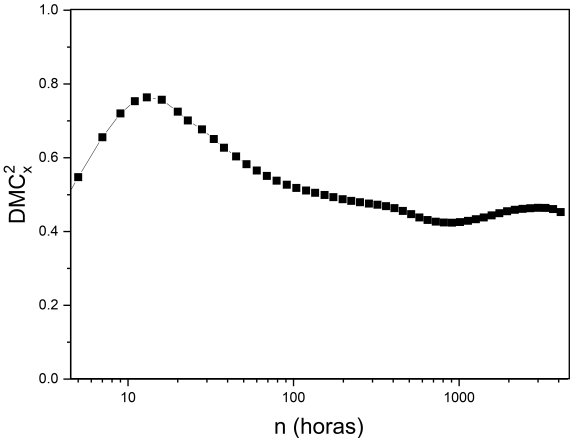

(d) Recife

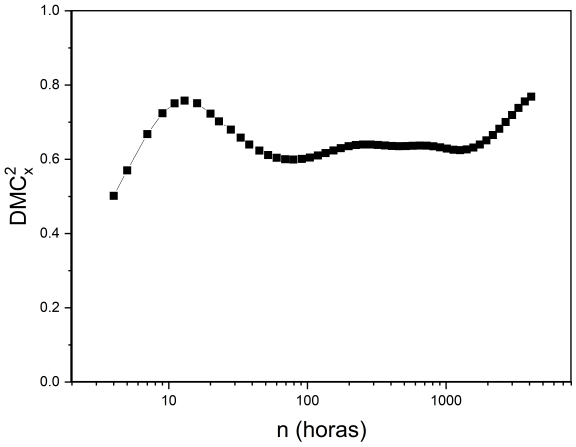

(e) Natal

Figura A.11: Correlações cruzadas para a região Nordeste.

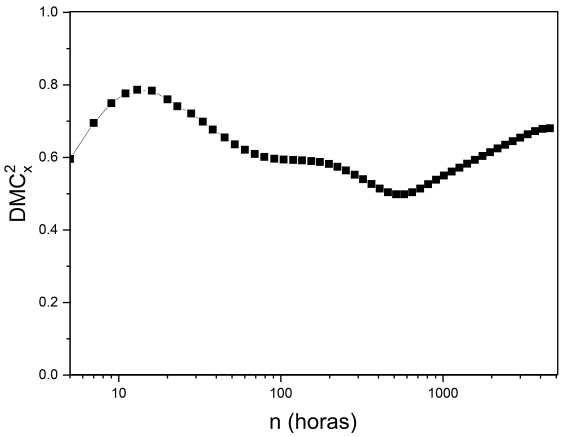

(a) Maceió

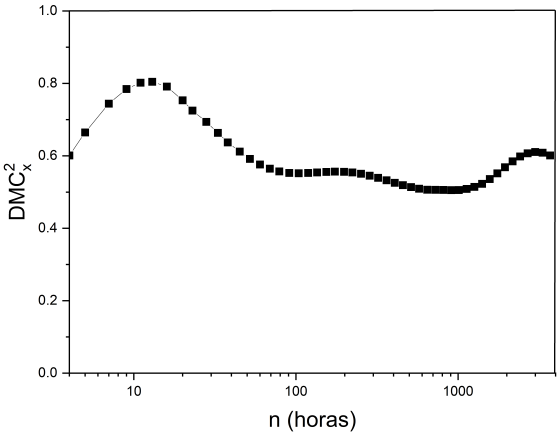

(b) Aracajú

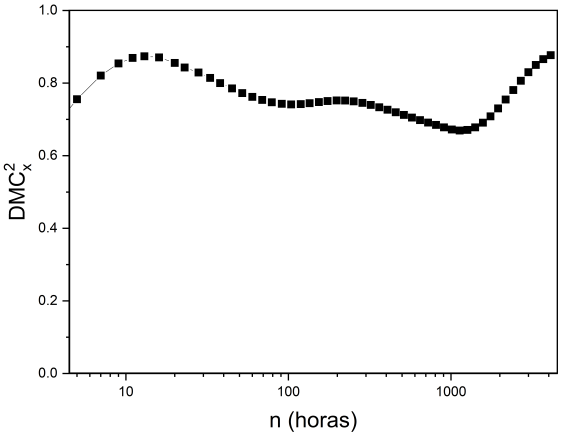

(c) Fortaleza

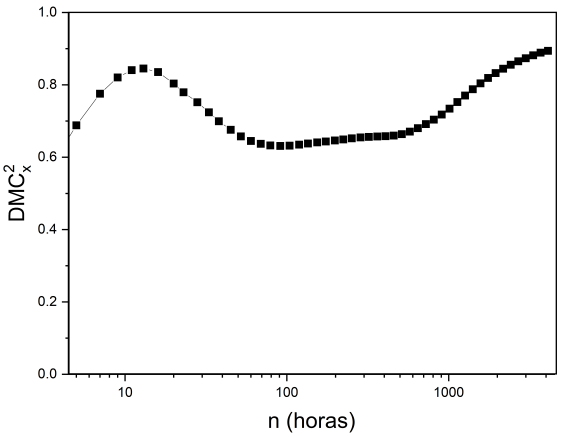

(d) João Pessoa

Figura A.12: Correlações cruzadas para a região Nordeste.

A seguir é apresentado o mapa representativo dos biomas brasileiros:

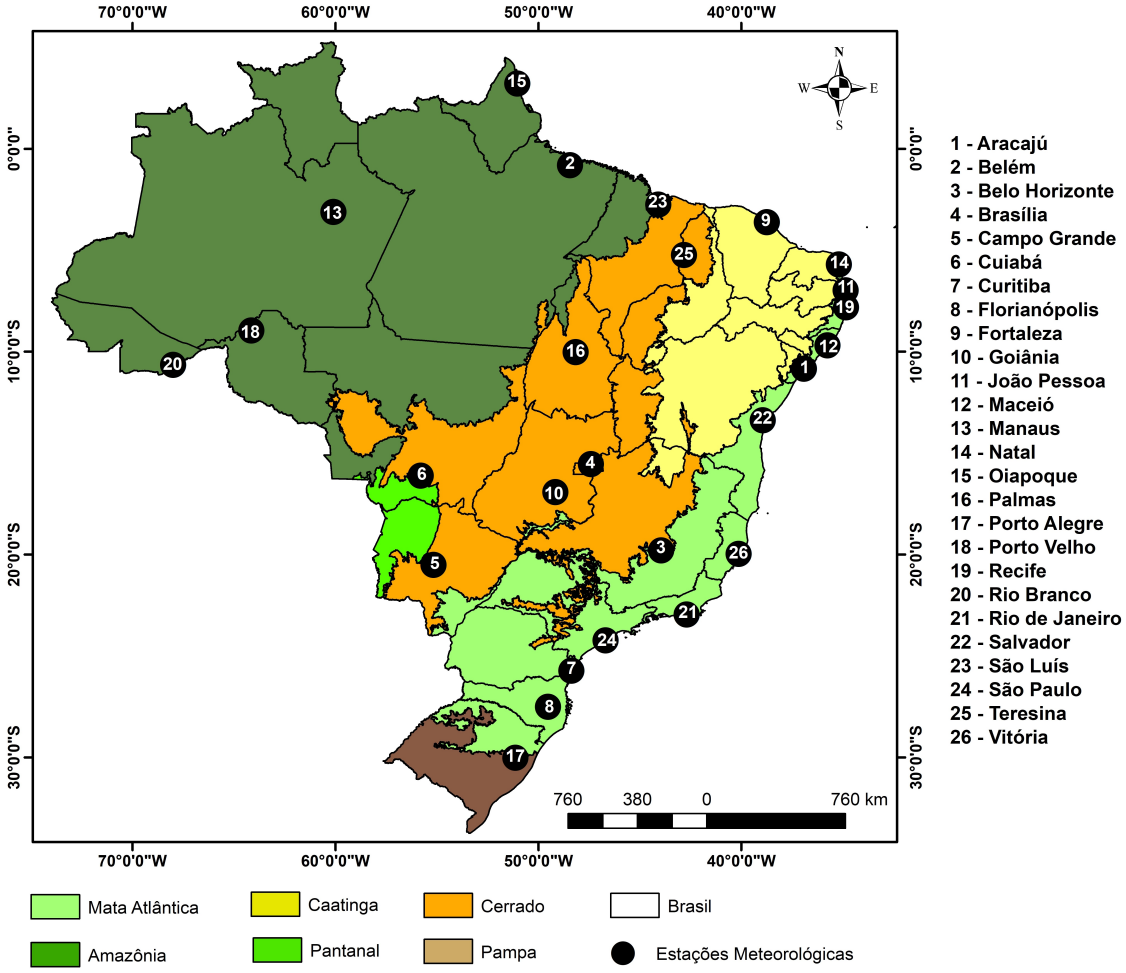

Figura A.13: Estações meteorológicas distribuídas nos biomas brasileiros.

Registro de Software

REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA E COMÉRCIO EXTERIOR
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL
DIRETORIA DE CONTRATOS, INDICAÇÕES GEOGRÁFICAS E REGISTROS

CERTIFICADO DE REGISTRO
DE PROGRAMA DE COMPUTADOR

Processo: BR 51 2016 000375-8

O INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL expede o presente Certificado de Registro de Programa de Computador, **válido por 50 anos** a partir de 1º de janeiro subsequente à data de criação indicada, em conformidade com o art. 3º da Lei Nº 9.609, de 19 de Fevereiro de 1998, e arts. 1º e 2º do Decreto 2.556 de 20 de Abril de 1998.

Título: **RHO_DCCA_MATRIX**

Criação: 15 de junho de 2015

Titular(es): SERVIÇO NACIONAL DE APRENDIZAGEM INDUSTRIAL-SENAI/DR-BAHIA (03.795.071/0001-16)

Autor(es): ANDREA DE ALMEIDA BRITO (876.091.425-49)
ARLEYS PEREIRA NUNES DE CASTRO (595.821.465-91)
GILNEY FIQUEIRA ZEBENDE (022.396.277-51)

Linguagem: C, C++

Aplicação: MT-01, MT-06

Tipo Prog.: AP-01, IT-04, SM-01

DOCUMENTAÇÃO TÉCNICA EM DEPÓSITO SOB SIGILO ATÉ 30/03/2026.

Os Direitos Patrimoniais relativos ao programa de computador objeto do presente registro foram cedidos dos Criadores para o Titular, na data de 29 de março de 2016, conforme documentação

A exclusividade de comercialização deste programa de computador não tem a abrangência relativa à exclusividade de fornecimento estatuída pelo art.25, I, da Lei nº 8.666, de 21 de Junho de 1993, para fins de inexigibilidade de licitação para compras pelo poder público.

Expedido em 02 de agosto de 2016

Assinado digitalmente por:
Breno Bello de Almeida Neves
Diretor de Contratos, Indicações Geográficas e Registros

Figura A.14: RHO-DCCA-MATRIX, sob número BR 51 2016 000375 - 8, que calcula em diferentes escalas de tamanhos os expoentes de autocorrelação, α_{DFA}, o expoente de correlação cruzada, λ_{DFA} e o coeficiente de correlação cruzada, ρ_{DCCA}.

Referências Bibliográficas

ALBUQUERQUE, R. C. *Modelagem em séries temporais aplicados a dados climatológicos no sertão paraibano.* Dissertação (Mestrado) — Universidade Estadual da Paraíba, 2015. 2.2

ADECE - AGÊNCIA DE DESENVOLVIMENTO DO ESTADO DO CEARÁ. Atração de Investimentos no Estado do Ceará: mapa territorial de parques eólicos. *Ceará*, 2010. 4.3

AMINI, M.A.; TORKAN, G.; ESLAMIAN, S.; ZAREIAN, M.J.; ADAMOWSKI, J.F. Analysis of deterministic and geostatistical interpolation techniques for mapping meteorological variables at large watershed scales. Acta Geophysica, v. 67, n. 1, p. 191–203, 2019. 2.3

ANGELOCCI, L. R.; PEREIRA, A. R.; SENTELHAS, P. C. Agrometeorologia – Fundamentos e Aplicações Práticas. 2002. 2.3

ASSIS, W. L. *O Sistema Clima Urbano do município de Belo Horizonte na perspectiva têmporo-espacial.* Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte., 2010. 4.1

ALVES, E. D. L; BIUDES, M. S. Air temperature and relative humidity standards: case study in the Cuiabá Campus of the Mato Grosso Federal University. *In Boletim de Geografia. Maringá*, p. 5-16, v. 30, n. 3, 2012. 4.2

AYOADE, J. O. Introdução a climatologia para os trópicos. São Paulo: DIFEL, 1986. 2.3

AYOADE, J. O. Introdução a climatologia para os trópicos. Rio de Janeiro: Bertrand Brasil, p. 332, 2004. 1

AZEVEDO, T. R; TARIFA, J. R. O ritmo semanal das atividades humanas e o clima na região metropolitana de são paulo. *Textos do Laboratório de Climatologia e Biogeografia - Departamento de Geografia / FFLCH / USP - Série TA - Texto 008*, p. 1–17, 2001. 4.1

BARBOZA, C. H. Nice weather, meteors at the end of the day. *In: Emeis, Stefan, Ludecke, Cornelia (eds.) Algorismus*, v. 52, p. 157–168, 2005. 2.2

BARROS, J. R.; ZAVATINI, J. A. Bases conceituais em climatologia geográfica. *Revista de Geografia da UFC*, v. 16, 2009. 2.1

BARRY, R. G; CHORLEY, R. J. Atmosphere, weather, and climate. 8. ed, Routledge, 2003. 4.2

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. Times Series Analysis: Forecasting and Control. *Englewood Clis: Prentice Hall*, 2008. 2.4.1, 2.4.4

BRAGA, A.L; SALDIVA, P.H; PEREIRA, L.A; MENEZES, J.J; CONCEIÇÃO, G.M; LIN, C.A. Health effects of air pollution exposure on children and adolescents in São Paulo, Brazil. *Pediatr Pumonol*, v. 31, p. 106-13, 2001. 4.1

BRANDO, P. M; BALCH, J. K; NEPSTAD, D. C; MORTON, D. C; PUTZ, F. E; COE, M. T; ALENCAR, A. Abrupt increases in amazonian tree mortality due to drought-fire interactions. Proceedings of the National Academy of Sciences, v. 111, p. 6347-6352, 2014. 1

BRESLIN, M. C.; BELWARD, J. A. Fractal dimensions for rainfall time series. Mathematics and Computers in Simulation, Amsterdam, v. 48, p. 437-446, 1999. 2.5.1

BRITO, A. A. *Temperatura ambiente e Umidade relativa do ar na Bahia: uma visão hora a hora via Coefciente de Correlação Cruzada ρ_{DCCA}.* Dissertação (Mestrado) SENAI-CIMATEC, 2016. 1, 2.3

BRITO, A. A.; ARAUJO, H. A.; ZEBENDE, G. F. Detrended Multiple Cross-Correlation Coefficient applied to solar radiation, air temperature and relative humidity. *Scientific Reports*, v. 9, n. 1, p. 19764, 2019. 4.2

BRITO, A. A. *Modelagem Computacional de Auto-correlações e Correlações Cruzadas Aplicada em Variáveis Meteorológicas e Simuladas.* Tese (Doutorado) SENAI-CIMATEC, 2021. 1, 2.4.1, 2.5.2

BUSSAB, W; MORETIN, P. Estatística básica. 5 ed. São Paulo: Saraiva, 2002. (document), 2.7, 2.8

CAPUTO, C. R.; AMORIM, M. C. C. T. A formação de ilhas de calor em cidade pequena: o estudo de osvaldo cruz/sp/brasil. *Revista Brasileira de Climatologia, Dourados, MS*, v. 29, 2021. 4.1

CARDOSO, R. S; AMORIM, M. C. C. T. CaracteíÃsticas do clima urbano em presidente prudente/sp a partir de dados de temperatura e umidade relativa do ar e técnicas de sensoriamento remoto. *Revista Do Departamento De Geografia*, v. 28, p. 39-64, 2015. 4.1

CARPENEDO, C. B. Atividade convectiva associada as anomalias de temperaturada superfície do mar no Atlântico Tropical e impactos climáticos no estado de Minas Gerais. *Revista Brasileira de Climatologia*, v.1, 2018. Disponível em: ¡https://revistas.ufpr.br/revistaabclima/article/view/60355¿. Acesso em: 16 ago.2024. 4.3

CERA, J. C.; FERRAZ, S. E. T. Caracterização da Precipitação no Estado do Rio Grande do Sul. *In: Anais do II Encontro Sul Brasileiro de Meteorologia, Florianópolis-SC*, 2007. 4.3

CHEN, Y. et al. DCCA cross-correlation coefficients reveals the change of both synchronization and oscillation in EEG of Alzheimer disease patients. *Physica A: Statistical Mechanics and its Applications*, v. 490, p. 171-184, 2018. 4.2

CHIERICE, R. A. F. *O uso de wavelets na determinação do expoente de Hurst de uma série temporal diária de chuvas do município de Araras-SP de 1955-2000.* Dissertação (Mestrado) - Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2003. 2.5.1

COSTA, M. D. N; BRITO, A. A; CASTRO, A. P. N; DIAS, R. M. T. S; ZEBENDE, G. F. Trends in the Air Temperature: A Practical Approach for Auto- and Cross-Correlation Analysis. *Advances in Meteorology*, p. 3098248, n. 1, 2024. 1

COSTA, M. D. N. *Análise de correlação cruzada da variável climática Temperatura do Ar entre estações meteorológicas no Estado da Bahia, BR.* Dissertação (mathesis) - Universidade Estadual de Feira de Santana, 2021. 3.3

DALAGNOL, R. et al. Extreme rainfall and its impacts in the Brazilian Minas Gerais state in January 2020:Can we blame climate change? *Climate Resilience and Sustainability*, n. 1, v.1, p. 15, 2021. 4.3

Chierice Agrometeorology related to extreme events. *World Meteorological Organization*, v. 943, p. 137, 2003. ISSN 9789263109439. 3.1

DAVIDSON, E. A; ARAUJO, A. C; ARTAXO, P; BALCH, J. K; BROWN, I. F; BUSTAMANTE, M. M; MUNGER, J. W. The amazon basin in transition. Nature, v. 481, p. 321-328, 2012. 1

DEMIRICI, E; CUHADAROGLY, B. Statistical analysis of wind correlation and air pollution in urban Trabzon. *Energy and Buildings*, p.49-53, v. 31, 2000. 4.2

DIAS, M. A. *Entrevista realizada em 13 de junho de 2013*. 2013. 2.1.1

DOUGHTY, C. E; METCALFE, D. B; GIRARDIN, C. A. J; AMEZQUITA, F. F; CABRERA, D. G; HUASCO, W. H.; ... E FELDPAUSCH, T. R. Drought impact on forest carbon dynamics and fluxes in amazonia. Nature, v. 519, p. 78-82, 2015. 1

DYSON, F. O Sol, o genoma e a internet. *Companhia as letras, SP.*, 2001. 4.3

EDWARDS, N. P. A vast machine: Computer models, climate data, and the politics of global warming. Massachusetts : MIT Press, 2010. 2.1.1

EMBRAPA. *Empresa Brasileira de Pesquisa Agropecuária*. Disponível em: ⟨https://www.embrapa.br/contando-ciencia/regiao-nordeste⟩. Acesso em: 15 abr. 2024. 3.1.1

FAPESP. *Relatório de Atividades 2008*. Disponível em: ⟨https://fapesp.br/⟩. Acesso em: 20 abr. 2024 2.1.1

FARIAS, A.; MENDONCA, F. Modelagem e mapeamento de áreas de perigo de inundação urbana na cidade de francisco beltrão (brasil). *Revista Ibero-Afro-Americana de Geografia Física e Ambiente.*, v. 1, p. 73-91, 2019. 2.2

FEDER, J. Fractals. Boston, 1988. (document), 2.4, 2.5, 2.5.1

FERNANDES, M. ; PEREIRA, E. ; MACHADO, A. ; CASTRO, A.; MIRANDA, J. G ; ZEBENDE, G. Quantifying the contagion effect of the 2008 financial crisis between the G7 countries (by GDP nominal). *Physica A: Statistical Mechanics and its Applications*, v. 453, 02 2016. 2.5.4

FILHO, A. M. S. *Autocorrelação e Correlação Cruzada: Teoria e Aplicações.* Tese (Doutorado) SENAI-CIMATEC, 2014. 1, 2.5.2

FLEMING, J.; JANKOVIC, V. C. D. Intimate universality: Local and global themes in the history of weather and climate. Sagamore Beach, Science History Publications, 2006. 2.1.1

FLEMING, J. R. Meteorology in america, 1800-1870. Baltimore, London: The Johns Hopkins University Press., 1990. 2.2

FRIEDMAN, J.; BARRET, S.C.H. Wind of change: new insights on the ecology and evolution of pollination and mating in wind pollinated plants. *Annals of Botany*, p.1515-1527, v. 103, 2009. 4.2

FRITZSONS, E; MANTOVANI, L. E; AGUIAR, A. V. Relação entre altitude e temperatura: uma contribuição ao zoneamento climático no Estado do Paraná. *Revista de Estudos Ambientais*, v. 10, n. 1, p.49-64, 2008. 4.2

FRITZSONS, E; WREGE, M. S; MANTOVANI, L. E. Altitude e temperatura: estudo do gradiente térmico no Rio Grande do Sul. *Revista Brasileira de Climatologia*, v. 16, p.108-119, 2015. 4.2

FROHLICH, C. Space science reviews. 2006. 2.3

GALVANI, E.; LIMA, N. G.B. A ocorrência de inversão térmica no perfil topoclimático do Pico das Agulhas Negras - RJ. *In: VII Simpósio Brasileiro de Climatologia Geográfica, 2006. Rondonópolis. Anais.* , 2006. 4.2

GIVONI, B. Man, climate and architecture. 1976. 2.3

GRABBE, J. O. Chaos and fractals in financial markets. 1999. 2.5.1

GUTIERREZ, J. L. C. *Monitoramento da Instrução da Barragem de Corumbá-I por Redes Neurais e Modelos de Box e Jenkins.* Dissertação (mathesis) PUC-RIO, 2003. 2.4.2

GWEC-GLOBAL WIND ENERGY COUNCIL. *Instituto Nacional de Meteorologia Global Wind Energy Outlook 2010.*. 2010. Disponível em: ⟨http://www.gwec.net/fileadmin/documents/Publications/GWEO%202010%20final.pdf⟩. Acesso em: 20 ago. 2024 4.3

HERSBACH, H.; BELL, B.; BERRISFORD, P.; HIRAHARA, S.; HORANYI, A.; MUNOZ-SABATER, J.; SIMMONS, A. The era 5 global reanalysis. Quarterly Journal of the Royal Meteorological Society, v. 146, p. 1999-2049, 2020. 2.3

HEYMANN, M. The evolution of climate ideas and knowledge. *Climate Change*, v. 1, p. 581-597, 4 2010. 2.1.1

HURST, E. Long term storage capacity of reservoirs. *Transactions of the American Society of Civil Engenieers*, v. 116, p. 770-799, 1951. 2.5.1, 2.5.2

INMET. *Instituto Nacional de Meteorologia*. 2024. Disponível em: ⟨https://mapas.inmet.gov.br/⟩. Acesso em: 07 ago.2024 (document), 2.1, 2.2

JARDIM, C. H. *Proposta de sÍntese climática a partir do comportamento térmico e higrométrico do ar em áreas urbanas.* Dissertação (Mestrado) - Universidade Estadual de Campinas, 2007. 4.1

JONGEJANS, E.; TELENIUS, A. Field experiments on seed dispersal by wind in tem umbelliterous species (Apiaceae). *Plant Ecology*, p.67-78, v. 152, 2004. 4.2

KANTELHARDT, J. W. Fractal and multifractal time series. Germany, 2008. 2.5.2

KEVIN, E. T. The definition of el niño. *Bulletin of the American Meteorological Society*, p. 2771-2778, 1997. 2.2

KRISTOUFEK, L. Measuring correlated between non-stationary series with dcca coe cient. Physica A: Statistical Mechanics and its Applications, v. 402, p. 291-298, 2014. 1

LEMES, M. Relatório preliminar sobre a implantação de previsão numérica do tempo no brasil. São José dos Campos: INPE, 1973. 2.1.1

LIEPERT, B. G.; TEGEN, I. Multi-decadal solar radiation trends in the United States and Germany and direct tropospheric aerosol forcing. *Journal of Geophysical Research.* v. 107, n. D12, 2002. 4.2

LI, C; ZHAO, T. Y. K. Quantifying the contributions of anthropogenic and natural forcings to climate changes over arid-semiarid areas during 1946-2005. *Climatic Change.*, n. 144, p. 505-517, 2017. 4.1

LIMA, K.C; SATYAMURTY, P. F. J. Large-scale atmospheric conditions associated with heavy rainfall episodes in southeast brazil. Theoretical and Applied Climatology, v. 101, n. 1-2, p. 121-135, 2010. 1

LYNCH, P. The origens of computer weather prediction and climate modeling. *Journal of Computacional Physics*, v. 227, p. 3431-3444, 7 2008. 2.1.1

MACEDO, L. R.; HENKES, A. F. Y. Y. Modelo wrf na previsão de um evento severo no rio grande do sul. IV Encontro Sul-Brasileiro de Meteorologia, Pelotas., 2011. 2.1.1

MACHADO, A. Autocorrelação e correlação cruzada: Teorias e aplicações. 2014. 2.5.3, 2.5.3

MACHADO, F. A. *Correlação de longo alcance em Indicadores de Criminalidade de Salvador-BA: DFA e DCCA.* Dissertação (Mestrado) SENAI-CIMATEC, 2009. 2.4.4, 2.4.4

MARENGO, J. A; BORMA, L. S; RODRIGUEZ, D. A; PINHO, P; SOARES, W. R; ALVES, L. M. Recent extremes of drought and flooding in amazonia: vulnerabilities adaptation. American Journal of Climate Change, v. 2, p. 87-96, 2013. 1

MARIA, P. H. S.; COSTA, A. A.; SOMBRA, S. S. Modelagem numérica em alta resolução para previsão de geração de energia eólica no ceará. *Rev. bras. meteorol*, 2008. Disponível em: ⟨https://www.scielo.br/j/rbmet/a/pZRXrycQ98FPrmLgVNcDS5t/#⟩. 2.2

MARTINS, D. O comportamento dos ventos na região de botucatu, sp. *CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA*, v. 22, p. 1413, 1993. 4.1

MIGUEL, J.C. H.; ESCADA, P. M. M. Políticas da meteorologia no brasil: Trajetórias e disputas na criação do cptec. *Revista Brasileira de História da Ciência*, Rio de Janeiro, v. 9, n. 1, p. 36–50, 2016. 2.1.1

MOLLMANN, J. R. A.; SILVA, J. R. S.; GOMES, H. B.; MOURA, M. A. L. Estudo da dispersão de monóxido de carbono (co) emitido através da queima de cana-de-açúcar, no estado de alagoas. *Revista Brasileira de Geografia Física*, p. 488-499, 2013. 2.1.1

MONTEIRO, C. A. F. O estudo geográfico do clima. *Cadernos Geográficos, Florianópolis*, n. 1, p. 7–32, 1999. 4.1

MONTEIRO F. F.; SILVEIRA, A. L. R. C. D. Uso de dados de sensoriamento remoto para identificação de ilhas de calor em teresina-pi. *5 Seminário Internacional de Planejamento e Gestão Ambiental - URBENVIRON, Brasília*, 2012. 4.1

MONTGOMERY, D. C. Introduction to statistical quality control. 4th Edition, New York: John Wiley, 2004. 2.5.6

MORETTIN, P. A.; TOLOI, C. M. C. Análise de Séries Temporais, ABE - Projeto Fisher. São Paulo, 2004. 2.4.1, 2.4.1, 2.4.2, 2.4.2, 2.4.3, 2.4.3, 2.4.3

MORIZE, H. Tempestade dos dias 11 e 12 de julho. *Revista do Observatório*, n. 8, p. 119–122, 1887. 2.2

MOURA, A.D; LEMES, M. Previsão numérica do tempo e sua perspectiva no brasil. São José dos Campos: INPE, 1980. 2.1.1

MUNHOZ, F.C.; GARCIA, A. Caracterização da velocidade e direção predominante dos ventos para a localidade de ituverava sp. *Revista Brasileira de Meteorologia*, v. 23, p. 30–34, 2008. 2.3

NEBEKER, F. Calculating the weather; meteorology in the 20th century. San Diego, London: Academic Press, 1995. 2.2

NEWMAN, A.J.; CLARK, M.P.; CRAIG, J.; NIJSSEN, B.; WOOD, A.; GUTMANN, E.; MIZUKAMI, N.; BREKKE, L.; ARNOLD, J.R. Gridded ensemble precipitation and temperature estimates for the contiguous united states. J. Hydrometeorol, v. 16, p. 2481–2500, 2015. 2.3

NOAA. *National oceanic and atmospheric*. Disponível em: ⟨https://www.climate.gov//.⟩ Acesso em: 08 ago.2024. 2.2

OHMURA, A.; LANG, H. Secular variação da radiação global na Europa. *Em Lenoble, J. e Geleyn, J.-F. (Eds.): IRS'88: problemas atuais de radiação atmosférica , A. Deepak Publ, Hampton, VA.* p. 298-301, 1989. 4.2

OLIVEIRA, D; FERREIRA, C. Aspectos climáticos da bacia hidrográfica do rio preto-mg/rj, brasil, influência dos fatores geográficos na formação desse clima regional. *Revista de Geografia e Ordenamento do Território.*, n. 11, p. 283–307, 2017. 4.1

OLIVEIRA, E. L.A; ROBAINA, L. E. S. R. B. Metodologia utilizada para o mapeamento de áreas de risco geomorfológico: bacia do arroio cadena, santa maria-rs. *Simpósio Brasieliro De Desastres Naturais*, Florianópolis: GEDN-UFSC, p. 248–261, 2004. 2.1.1

PAIVA, R. G; SILVEIRA, H; BALDO, M. C.Variação espacial da temperatura média na escala topoclimática nos municípios de São Carlos do Ivaí e Floraí-PR. Boletim de Geografia. Universidade Estadual de Maringa. DOI: http://dx.doi.org/10.4025/bolgeogr.v29i1.8482, n. 1, p. 147-161, 2012. 4.2

PARADA, N.; MEIRA, F. G.; MOURA, A. D.; KOUSKY, V.E. Workshop sobre previsão de secas para o nordeste do brasil. São José dos Campos: INPE, 1980. 2.1.1

PAZ, S.; BROZA, M. Wind direction and its linkage with vibrio cholerae dissemination. *Environmental Health Perspectives*, p. 195-200, v. 115, 2007. 4.2

PBMC2013. *Painel Brasileiro de Mudanças Climáticas*. 2013. Disponível em: ⟨https://repositorio.mcti.gov.br/handle/mctic/4306⟩. 2.3

PENG, C. ; BULDYREV, S. ; HAVLIN, S.; SIMONS, M.; STANLEY, H.; GOLDBERGER, A. Mosaic organization of DNA nucleotides. *Physical review. E, Statistical physics, plasmas, fluids, and related interdisciplinary topics*, v. 49, p. 1685–9, 03 1994. 2.5.2

PEPIN, Nicholas et al. Elevation-dependent warming in mountain regions of the world. *Nature Climate Change 5(5). DOI: ttps://doi.org/10.1038/nclimate2563*, p.424-430, 2009. 4.2

PEREIRA, A. ROBERTO; A, LUIZ. R; SENTELHAS, P. C.Agrometeorologia: Fundamentos e aplicações práticas. *Guaíba: Agropecuária* , 2002. 1, 2.3, 4.2

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. Agrometeorologia: Fundamentos e aplicações práticas. Guaíba: Agropecuária, p. 478, 2002. 1, 2.3, 4.2

PEREIRA, B. Métodos automáticos de previsão para séries temporais multivariadas. *Revista brasileira de estatística*, v. 58, n. 07, 1997. (document), 2.4.1, 2.3, 2.4.1

PIMENTA, F; KEMPTON, W; GARVINE, R. Combining meteorological stations and satellite data to evaluate the ofshore wind power resource of Southeastern Brazil. *Renewable Energy*, p.2375-2387, v. 33, 2008. 4.2

PIMENTA, M. T.; SANTOS, M. J.; RODRIGUES, R. A. Susceptibilidade a desertificação. *Revista Florestal*, v. 11, n. 1, p. 27-33, 1998. 4.3

PODOBNIK, B.; STANLEY, H. Detrended Cross-Correlation Analysis: A New Method for Analyzing Two Nonstationary Time Series. *Physical review letters*, v. 100, p. 084102, 03 2008. 2.5.3

PSCHEIDT, I.; GRIMM, A. Frequency of extreme rainfall events in southern brazil modulated by interannual and interdecadal variability. International Journal of Climatology, v. 29, n. 13, p. 1988–2011, 2009. 1

QIAN, Y.; KAISER, D. P.; LEUNG, L. R.; XU, M. More frequent cloudfree sky and less surface solar radiation in China from 1955 to 2000. *Geophysical Research Letters.* v. 1, n. 33, 2006. 4.2

RAMOS, D.N. S.; LYRA, R. F. F.; SILVA, J. R. S. Previsão do vento utilizando o modelo atmosférico wrf para o estado. *Revista Brasileira de Meteorologia*, p. 163–172, 2013. 2.1.1

RAMPINELLI, G. A.; ROSA, J., C. G. Análise da geração eólica na matriz brasileira de energia elétrica. *Revista Ciências Exatas e Naturais*, v. 14, n. 2, p. 273-302, 2012. 4.3

REIS, L. B. Energia elétrica e sustentabilidade: aspectos tecnológicos, socioambientais e legais. *Barueri, SP: Manole - Coleção Ambiental*, 2006. 4.3

SAMPAIO, G.; SILVA, D. P. Evolução dos modelos climáticos e de previsão de tempo e clima. Revista USP, n. 103, p. 41-54, 2014. 1

SILVA, J. R. S.; CARDOSO, B. C. T.; MONTEIRO, H.C.F.; SILVA, E.H. L. Estudo avaliativo da previsão numérica do tempo de curto prazo para o município de maceió/al, utilizando o modelo wrf. *Revista Brasileira de Geografia Física*, v. 12, n. 6, p. 2121-2140, 2019. 2.2

SILVA, M.R; MOURA, F. P; JARDIM, C. H. O diagrama de caixa (box plot) aplicado a análise da distribuição temporal das chuvas em janúária, belo horizonte e sete lagoas, minas gerais-brasil. *Revista Brasileira de Geografia Física.*, v. 10, p. 23–40, 2017. 4.1

SILVA, M. A. V. Meteorologia e Climatologia. 2006. 2.3

SILVA, V. DE P. R. On climate variability in Northeast of Brazil. *Journal of Arid Environments*, v. 58, n. 4, p. 575-596, 2004. 4.3

SILVA, V. DE P. R.; CORREIA, A. A.; COELHO, M. S. Análise de tendência das series de precipitação pluvial do Nordeste do Brasil. Revista Brasileira de Engenharia Agrícola e Ambiental, v. 2, n. 1, p. 111-114, 1998. 4.3

PAIVA, R. G; SILVEIRA, H; BALDO, M. C. Variação espacial da temperatura média na escala topoclimática nos municípios de São Carlos do Ivaí e Floraí-PR. *Boletim de Geografia. Universidade Estadual de Maringa. DOI: http://dx.doi.org/10.4025/bolgeogr.v29i1.8482*, n. 1, v. 147-161, 2012.

BRITO, A. A. *A influência da urbanização no clima da cidade de Campina Grande, PB.* Dissertação (Mestrado) - Campina Grande: DCA, p. 96, 2006. 4.3

Taqqu, M. S. et al. Estimators for long-range dependence: an empirical study. *Fractals*, v. 3, n. 4, p. 785–798, 1995. 2.5

TSOUTOS, T; FRANTZESKAKI, N. GEKAS, V. Environmental impacts from the solar energy Technologies. *Energy Policy* , 2005. 4.3

TAREK, M.; BRISSETTE, F. A. R. Evaluation of the era 5 reanalysis as a potential reference dataset for hydrological modelling over north america. Hydrology and Earth System Sciences, v. 24, n. 5, p. 2527–2544, 2020. 2.3

TEIXEIRA, M.S.; SATYAMURTY, P. Dynamical and synoptic characteristics of heavy rainfall episodes in southern brazil. Monthly Weather Review, v. 135, n. 2, p. 598–617, 2007. 1

TUKEY, J. W. Exploratory data analysis. 1977. 2.5.6, 3.5, 4.1

VASSOLER, R. T. *Coeficiente DCCA de Correlação Cruzada Aplicado a Séries de Temperatura do Ar e Umidade Relativa do Ar.* Dissertação (Mestrado) Programa de Pós Graduação em Modelagem Computacional e Tecnologia Industrial, 2012. 2.3

VIANELLO, R. L.; ALVES, A. R. Meteorologia básica e aplicações. Viçosa: UFV, p. 449, 2000. 2.3

VIEIRA, L.E. ; SOLANKI, S. Space science reviews. 2012. 2.3

ZHAI, P; ZHOU, B. C. Y. A review of climate change attribution studies. *Journal of Meteorological Research.*, n. 32, p. 671–692, 2018. 4.1

ZHANG, S. et al. Do the performance and efficiency of China carbon emission trading market change over time? *Environmental Science and Pollution Research*, v. 27, n. 26, p. 3314-33160, 2020. 4.2

ZEBENDE, G.; FILHO, A. Detrended Multiple Cross-Correlation Coefficient. *Physica A*, v. 510, p. 91 – 97, 2018. ISSN 0378-4371. 2.5.5, 2.5.5, 3.4

ZEBENDE, G. F. Dcca cross-correlation coefficient: Quantifying level of cross-correlation. *Physica A*, v. 390, p. 614–618, 2011. (document), 2.6, 2.5.3, 2.5.3, 2.5.4, 2.5.4, 3.4

ZEBENDE, G. F.; FERNANDEZ, B. F.; PEREIRA, M. G. Analysis of the variability in the sdb star kic10670103: Dfa approach. *Monthly Notices of the Royal Astronomical Society*, v. 464, p. 2638–2642, 2017. 2.5.2

Zebende, G.F.; BRITO, A.A. ; CASTRO, A. P. DCCA cross-correlation analysis in time-series with removed parts. *PHYSICA A-STATISTICAL MECHANICS AND ITS APPLICATIONS*, v. 545, p. 123472, 2020. 3.3

MODELAGEM DE VARIÁVEIS METEOROLÓGICAS: UM ESTUDO DE CASO DO BRASIL

Joice de Jesus Santos

Feira de Santana, Fevereiro 2025.