

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS**

PROGRAMA DE PÓS-GRADUAÇÃO EM

METEOROLOGIA



TESE DE DOUTORADO

Iwldson Guilherme da Silva Santos

**Estatísticas de cinco variáveis meteorológicas no
município de Craíbas no Estado de Alagoas**

Campina Grande, Março de 2024



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM METEOROLOGIA**

IWLDSOON GUILHERME DA SILVA SANTOS

**ESTATÍSTICAS DE CINCO VARIÁVEIS METEOROLÓGICAS NO
MUNICÍPIO DE CRAÍBAS NO ESTADO DE ALAGOAS**

**Campina Grande
2024**

IWLDSOON GUILHERME DA SILVA SANTOS

ESTATÍSTICAS DE CINCO VARIÁVEIS METEOROLÓGICAS NO MUNICÍPIO
DE CRAÍBAS NO ESTADO DE ALAGOAS

Tese de doutorado apresentada ao colegiado do Programa de Pós-Graduação em Meteorologia da Unidade Acadêmica de Ciências Atmosféricas da Universidade Federal de Campina Grande, como requisito final à obtenção do título de Doutor em Meteorologia.

Área de concentração: Meteorologia Agrícola e Micrometeorologia
Orientador: Prof. Dr. Francisco de Assis Salviano de Sousa

Campina Grande
2024

S237e

Santos, Iwldson Guilherme da Silva.

Estatísticas de cinco variáveis meteorológicas no município de Craíbas no Estado de Alagoas / Iwldson Guilherme da Silva Santos. – Campina Grande, 2024.

120 f. : il. color.

Tese (Doutorado em Meteorologia) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, 2024.

"Orientação: Prof. Dr. Francisco de Assis Salviano de Sousa".

Referências.

1. Meteorologia Agrícola. 2. Micrometeorologia. 3. Variáveis Meteorológicas. 4. Análise Wavelet. 5. Rede Neural Artificial. 6. Perfil Vertical do Vento. 7. Lei da Potência e Logarítmica. 8. Energia Eólica.
I. Sousa, Francisco de Assis Salviano de. II. Título.

CDU 551.5:631(043)

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECÁRIA SEVERINA SUELI DA SILVA OLIVEIRA CRB-15/225

IWLDSOON GUILHERME DA SILVA SANTOS

ESTATÍSTICAS DE CINCO VARIÁVEIS METEOROLÓGICAS NO MUNICÍPIO
DE CRAÍBAS NO ESTADO DE ALAGOAS

TESE APROVADA EM 14/03/2024

BANCA EXAMINADORA

Documento assinado digitalmente
 FRANCISCO DE ASSIS SALVIANO DE SOUSA
Data: 21/02/2024 14:45:29-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Francisco de Assis Salviano de Sousa
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande

Documento assinado digitalmente
 JOSEIVALDO BARBOSA DE BRITO
Data: 16/03/2024 14:09:07-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. JoséIVALDO Barbosa de Brito
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande

Documento assinado digitalmente
 BERNARDO BARBOSA DA SILVA
Data: 20/03/2024 19:33:43-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Bernardo Barbosa da Silva
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande

Documento assinado digitalmente
 ROBERTO FERNANDO DA FONSECA LYRA
Data: 03/04/2024 12:56:14-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Roberto Fernando da Fonseca Lyra
Instituto de Ciências Atmosféricas
Universidade Federal de Alagoas

Documento assinado digitalmente
 ISNALDO ISAAC BARBOSA
Data: 05/04/2024 10:34:04-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Isnaldo Isaac Barbosa
Instituto de Matemática
Universidade Federal de Alagoas

AGRADECIMENTOS

Agradeço...

Primeiramente a **Deus** por ter me dado forças, coragem e disposição para conseguir chegar até o fim de mais uma etapa acadêmica.

Em especial a minha mãe **Maria do O da Silva** pelo apoio, incentivo e segurança durante toda a minha vida, te amo minha mãe, obrigado por tudo.

Ao meu pai **Cícero Guilherme dos Santos** pela educação dada, as minhas irmãs **Isabel Cristina** e **Inaura Patrícia** que sempre acreditaram no meu potencial e sempre me estimularam a estudar mais.

Aos meus filhos **Ítalo Guilherme** e **Arthur Guilherme** dois motivos e razões que me fazem continuar a estudar, trabalhar e produzir conhecimento.

A minha namorada **Ana Lucia** pela parceria e incentivo em continuar estudando.

Aos professores **Francisco de Assis, José Ivaldo, Bernardo Barbosa, Roberto Lyra e Isnaldo Isaac** pela orientação, acompanhamento e incentivo para a elaboração e construção deste trabalho escrito.

Aos professores, coordenadores e secretários da **UFCG, DCA, UFAL, ICAT, IM e LAMMA**.

A **CNPq** pela ajuda financeira na concessão da bolsa de doutorado.

Ao professor **José Francisco** pela amizade, ajuda e orientação nas produções de artigos científicos.

A todos da Meteorologia começando pelos amigos do doutorado, colegas do mestrado e da graduação, passando pela área burocrática, técnica e limpeza.

A todos os meus amigos e colaboradores do coletivo UFAL que acreditaram e me incentivaram a concluir este doutorado.

Família, amigos e a todos que me incentivaram, apoiaram e vibraram com minhas conquistas e que de alguma forma contribuíram de maneira direta ou indireta na realização deste trabalho deixo escrito os meus sinceros agradecimentos.

Muito Obrigado!

DEDICATÓRIA

Em memória de amigos e tio,
Archidy Britto,
Douglas Villela e
Manoel Francisco.

RESUMO

Uma análise estatística de variáveis meteorológicas (VM) no Nordeste do Brasil (NEB) é de suma importância para o desenvolvimento industrial sustentável brasileiro, sobretudo aos relacionados à energia limpa e renovável. Diante disso, essa pesquisa objetiva investigar cinco VM: velocidade e direção do vento (VV - $m.s^{-1}$ e DV - °), temperatura do ar (TA - °C), umidade relativa do ar (UR - %) e pressão atmosférica (PA - mm Hg). O local de estudo foi no município de Craíbas (coordenadas geográficas: 09°37'03.4"S, 36°47'40.2"O), região semiárida (Agreste), parte central de Alagoas. Foram utilizados dois bancos de dados mensurados a cada 10 minutos: **i)** Na altura de referência de 100m as VM foram avaliadas no período total de 14 meses (março/2014 a abril/2015) e períodos sazonais (chuvoso – PC, seco – PS, transição – PT); **ii)** Para o estudo do perfil vertical do vento (PVV), com período de 38 dias, um conjunto de medições em oito níveis de altura (4, 10, 14, 19, 30, 50, 70 e 100 m) também foi utilizado. Os resultados mostraram que as VM no PS e PT foram: VV mais intensa, DV predominante SE, as maiores (menores) TA (UR) com a maior tendência de aumento (diminuição) e as menores PA. No PC as variáveis apresentaram valores opostos com DV predominante ESE. A análise Wavelet das VM apresentaram periodicidade de 12 horas, diária e mensal, a potência espectral no PC é menor que nos PS e PT. As VM que se relacionaram foram: TA e UR foi negativa e quase perfeita (muito alta) nos períodos Total, PT e PS (PC); TA e PA foi negativa e alta em todos os períodos; UR e PA foi positiva e moderada em ambos os períodos. Essa relação inversa entre TA e UR é mais intensa no PS e menor no PC, entre TA e PA é ao contrário mais forte no PC e menor no PS. A Wavelet de coerência (WC) entre as VM mostrou que a relação TA e UR apresentou o mais alto grau de coerência entre as duplas de variáveis com periodicidade variando de horas a dias, mensal e anual. A DV é a variável que mais apresentou coerências irregulares e períodos de mudanças de fase. A simulação das VM foi realizada via rede neural artificial (RNA): **i)** *Nonlinear Autoregressive* (NAR); **ii)** *Nonlinear Autoregressive with exogenous inputs* (NARX); **iii)** *Long and Short Term Memory* (LSTM). Para averiguar o desempenho das RNAs foi utilizado o Diagrama de Taylor e as métricas estatísticas: erro médio, raiz do erro quadrático médio, erro percentual absoluto médio e correlação de Pearson. A melhor simulação foi realizada pela NAR, seguido pela NARX e LSTM. As variáveis PA, UR e TA foram simuladas com mais precisão do que as simulações da DV e VV. Na evolução temporal da VV em diferentes níveis, ocorre um espelhamento da VV, se intensificando gradualmente com o aumento da altura, a VV cresce (decresce) com baixa (alta) variabilidade durante o dia (noite). Os níveis inferiores são mais turbulentos e mais susceptíveis a ocorrência de rajadas de ventos do que os níveis superiores. A lei de potência coincidiu mais com a média total do PVV do que a lei logarítmica, mas ambas estão dentro do intervalo de variabilidade do PVV e portanto perfeitamente aplicáveis. Por fim, esses resultados podem ser utilizados para energia eólica e conseqüentemente, mitigar os efeitos do aquecimento global, mudanças climáticas, entre outros fatores.

Palavras-chave: Variáveis Meteorológicas, Análise Wavelet, Rede Neural Artificial, Perfil Vertical do Vento, Lei da Potência e Logarítmica, Energia Eólica

ABSTRACT

A statistical analysis of meteorological variables (MV) in northeastern Brazil (NEB) is of paramount importance for Brazilian sustainable industrial development, especially those related to clean and renewable energy. Therefore, this research aims to investigate five MV: Wind speed and direction (WS – $\text{m}\cdot\text{s}^{-1}$ and WD - °), air temperature (AT - °C), air relative humidity (RH - %) and atmospheric pressure (AP – mm Hg). The study location was in the municipality of Craibas (geographic coordinates: 09°37'03,4"S, 36°47'40,2"W), semi-arid region (Agreste) in the central part of Alagoas. Two databases were used with a measurement interval of 10 minutes: **i)** At the reference height of 100m, the MV were evaluated in the total period of 14 months (March/2014 to April/2015) and seasonal periods (transition – PT, rainy – PR, dry - PD); **ii)** To study the vertical wind profile (VWP) a set of measurements at eight height levels (4, 10, 14, 19, 30, 50, 70 and 100m) was also used. The results showed that the MV in the PD and PT were more intense WS, predominant WD is SE, the highest (smallest) AT (RH) with the greatest tendency to increase (decrease) and the lowest AP. In PR, the variables presented opposite values with predominant WD is ESE. The Wavelet analysis of the MV showed a periodicity of 12 hours, daily and monthly, the spectral power in the PR is lower than in the PD and PT. The MV that were related were: AT and RH were negative and almost perfect (very high) in the total, PT and PD (PR) periods; AT and AP were negative and high in all periods; RH and AP were positive and moderate in both periods. This inverse relationship between AT and RH is stronger in PD and smaller in PR, between AT and AP it is, on the contrary, stronger in PR and smaller in PD. The coherence wavelet (CW) between the MV showed that the AT and RH relationship presented the highest degree of coherence between the pairs of variables with periodicity varying from hours to days, monthly and annual. The WD is the variable that showed the most irregular coherences and periods of phase change. The MV simulation was performed via artificial neural network (ANN): **i)** Nonlinear Autoregressive (NAR); **ii)** Nonlinear Autoregressive with eXogenous inputs (NARX); **iii)** Long and Short Term Memory (LSTM). To investigate the performance of the ANNs, a Taylor diagram and statistical metrics were used: mean error, root mean square error, mean absolute percentage error and Pearson correlation. The best simulation was performed by NAR, followed by NARX and LSTM. The AP, RH and AT variables were simulated more accurately than the WD and WS simulations. In the temporal evolution of WS at different levels, there is a mirroring of WS, gradually intensifying with increasing height, WS increases (decreases) with low (high) variability during the day (night). The lower levels are more turbulent and more susceptible to gusts than the upper levels. The power law coincided more with the mean total of the VWP than the logarithmic law, but both are within the VWP variability range and therefore perfectly applicable. Finally, these results can be used for wind energy and consequently, mitigate the effects of global warming, climate change, among other factors.

Keywords: Meteorological Variables, Wavelet Analysis, Artificial Neural Network, Vertical Wind Profile, Power and Logarithmic Law, Wind Energy

LISTA DE FIGURAS

Figura 1 - Mapa da região de estudo.....	31
Figura 2. Mapa do potencial eólico do estado de Alagoas.....	32
Figura 3 - Função da Wavelet de Morlet no plano cartesiano x e $f(x)$	34
Figura 4. Diagrama da relação do ângulo de fase entre duas séries temporais.....	35
Figura 5 - Diagrama de TWD com o número de níveis (m) de decomposição.....	36
Figura 6 - Função da Wavelet de Symlets no plano cartesiano x e $f(x)$	37
Figura 7 - Funções de ativação Sigmoide, Tangente Hiperbólica e Linear no plano cartesiano x e $f(x)$	38
Figura 8 - Regiões onde são mensuradas os índices El Niño-Oscilação Sul, Tropical Southern Atlantic, Tropical Northern Atlantic e Southern Atlantic Ocean Dipole.....	42
Figura 9 - Evolução temporal da velocidade do vento (a) Total, (b) período de transição, (c) período chuvoso e (d) período seco.....	50
Figura 10 - Evolução temporal da direção do vento (a) Total, (b) período de transição, (c) período chuvoso e (d) período seco.....	51
Figura 11 - Evolução temporal da temperatura do ar (a) Total, (b) transição, (c) chuvoso e (d) seco.....	52
Figura 12 - Evolução temporal da umidade relativa do ar (a) Total, (b) transição, (c) chuvoso e (d) seco.....	52
Figura 13 - Evolução temporal da pressão atmosférica (a) Total, (b) transição, (c) chuvoso e (d) seco.....	53
Figura 14 - Boxplot das variáveis meteorológicas estudadas com período total e sazonal (a) velocidade do vento, (b) direção do vento, (c) temperatura do ar, (d) umidade relativa, (e) pressão atmosférica.....	56
Figura 15 - Ciclo diário médio das variáveis meteorológicas estudadas com período total e sazonal (a) velocidade do vento, (b) direção do vento, (c) temperatura do ar, (d) umidade relativa, (e) pressão atmosférica.....	58
Figura 16 - Escalograma e espectro Wavelet global das variáveis meteorológicas estudadas (a) velocidade do vento, (b) direção do vento, (c) temperatura do ar, (d) umidade relativa, (e) pressão atmosférica no período estudado (março/2014 a abril/2015).....	59
Figura 17 - Dendrograma dos grupos homogêneos mensais (G1, G2 e G3) das variáveis meteorológicas estudadas (a) velocidade do vento, (b) direção do vento, (c) temperatura do ar, (d) umidade relativa, (e) pressão atmosférica no período estudado (março/2014 a abril/2015).....	63
Figura 18 - Função densidade de probabilidade da distribuição de Weibull com seus respectivos parâmetros considerando os períodos (a) Total, (b) Transição, (c) Chuvoso, (d) Seco. Considerando os horários do dia (e) Total, (f) Transição, (g) Chuvoso, (h)	

Seco. Considerando os horários da Noite (i) Total, (j) Transição, (k) Chuvoso e (l) Seco.....	66
Figura 19 - Rosa dos ventos para identificação da direção predominante do vento considerando o período (a) Total, (b) Transição, (c) Chuvoso, (d) Seco. Considerando os períodos do dia (e) Total, (f) Transição, (g) Chuvoso, (h) Seco. Considerando os períodos da Noite (i) Total, (j) Transição, (k) Chuvoso e (l) Seco.....	68
Figura 20 - Matriz de gráfico de dispersão e histograma das variáveis meteorológicas considerando os períodos (a) Total, (b) Transição, (c) Chuvoso, (d) Seco.....	72
Figura 21 - Mapa de calor das correlações de Pearson entre as variáveis meteorológicas considerando os períodos (a) Total, (b) Transição, (c) Chuvoso, (d) Seco.....	74
Figura 22 - Wavelet de coerência entre as variáveis meteorológicas considerando o período Total (março/2014 a abril/2015): (a) VV vs. DV, (b) VV vs. TA, (c) VV vs. UR, (d) VV vs. PA, (e) DV vs. TA, (f) DV vs. UR, (g) DV vs. PA, (h) TA vs. UR, (i) TA vs. PA, (j) UR vs. PA.....	77
Figura 23 - Gráfico misto entre as variáveis meteorológicas mensais (Linha) com a presença de (a) Precipitação Acumulada Mensal (PAM), (b) <i>El Niño-Oscilação Sul</i> na região 3.4 (ENOS34), (c) <i>Tropical Southern Atlantic Index</i> (TSA), (d) <i>Tropical Northern Atlantic Index</i> (TNA), (e) <i>Southern Atlantic Ocean Dipole Index</i> (SAODI) – (Barras). Considerando o período Total (março/2014 a abril/2015).....	82
Figura 24 - Diagrama de Taylor aplicado nas variáveis meteorológicas observadas, processadas e simuladas. Considerando os períodos TOTAL, Transição, Chuvoso e Seco. Os pontos são definidos em: A (OBS), B (NAR), C (NARX), D (VMW), E (LSTM).....	87
Figura 25 - Evolução temporal da velocidade do vento nos oito níveis de medição.....	91
Figura 26 - Ciclo diário médio da velocidade do vento nos oito níveis de medição.....	92
Figura 27 - Diferentes tipos de gráficos do ciclo diário médio da velocidade do vento nos oito níveis de medição: (a) Gráfico de superfície 3D; (b) Gráfico de contorno; (c) Boxplot; (d) Gráfico de evolução temporal da média com barras de desvio padrão.....	93
Figura 28 - Gráficos Ridgeline de função densidade de probabilidade Weibull de dois parâmetros aplicado na velocidade do vento em oito níveis de medição considerando os períodos Total (a), Dia (b) e Noite (c).....	96
Figura 29 - Perfil vertical da velocidade do vento média horária distribuídos nos oito níveis de altura entre os dias 06/12/2014 e 12/01/2015.....	98
Figura 30 - Perfil vertical da velocidade do vento da média diária e média total distribuídos nos oito níveis de altura.....	99
Figura 31 - Perfil vertical da velocidade do vento média diária, barras de erro horizontal, lei logarítmica e lei da potência distribuídos nos oito níveis de altura.....	100

LISTA DE TABELAS

Tabela 1 - Dados observados distribuídos em oito níveis de medição, com local da torre anemométrica (LTA), altura das medições (AM), variáveis meteorológicas (VM), coordenadas geográficas (Latitude, Longitude e Altitude), intervalo de medições (IM) e número de medições (N).....	33
Tabela 2 - Parâmetros utilizados na fase de treinamento das RNAs.....	38
Tabela 3 - Intervalos de correlação e sua respectiva classificação.....	42
Tabela 4 - Nível de significância, t-Student tabelado e coeficiente de correlação crítico calculado para $N - 2 = 12$ graus de liberdade.....	43
Tabela 5 - Faixa intervalar com seu respectivo ponto médio para determinação da direção do vento predominante.....	45
Tabela 6 - Estatística descritiva da VV – velocidade do vento, DV – direção do vento, TA – temperatura do ar, UR – umidade relativa e PA – pressão atmosférica durante o período de estudo (março/2014 até abril/2015) com quatro intervalos de medição Total, PT - período de transição, PC – período chuvoso e PS – período seco. Métricas estatísticas: M - média, DP – desvio padrão, CV – coeficiente de variação, Min - mínimo, Q1 – primeiro quartil, MD - mediana, Q3 - Terceiro Quartil, AT – Amplitude Total, CA – coeficiente de assimetria, CC – coeficiente de curtose.....	52
Tabela 7 - Estatística descritiva da VV - velocidade do vento e DV - direção do vento durante o período de estudo (março/2014 até abril/2015) com quatro intervalos de medição Total, PT - período de transição, PC - período chuvoso e PS - período seco, considerando o período do dia e noite separados. Métricas estatísticas: M - média, DP - desvio padrão, CV - coeficiente de variação, Min - mínimo, Q1 - primeiro quartil, MD - mediana, Q3 - Terceiro Quartil, AT - Amplitude Total, CA - coeficiente de assimetria, CC - coeficiente de curtose.....	67
Tabela 8 - Estatística bivariada (erros e correlação) entre as variáveis meteorológicas observadas, processadas e simuladas, considerando os períodos TOTAL, Transição, Chuvoso e Seco.....	83
Tabela 9 - Estatística descritiva da velocidade do vento em oito níveis de altura durante o período de estudo (06/12/2014 até 12/01/2015) com três intervalos de medição Total e período do dia e noite separados. Métricas estatísticas: M - média, DP – desvio padrão, CV – coeficiente de variação, Min - mínimo, Q1 – primeiro quartil, MD - mediana, Q3 - terceiro quartil, AT – amplitude total, CA – coeficiente de assimetria, CC – coeficiente de curtose, IT – índice de turbulência, FR – fator de rajada.....	92

LISTA DE ABREVIATURAS, SÍMBOLOS E SIGLAS

*	Complexo Conjugado
°C	Graus Célsius
$\psi(t)$	Função Wavelet Mãe
$x(t)$ e $y(t)$	Sinais de Entrada ou Variáveis Meteorológicas
$y(t + 1)$	Valor Previsto
π	Número Pi
i	Unidade Imaginária
ω	Frequência de Modulação Adimensional
$S(\cdot)$	Operador de Suavização
$\theta_{xy}(a, b)$	Ângulo de Fase
$f(\cdot)$	Função de Ativação
W_j	Pesos
T_h	Bias
Km^2	Quilômetros Quadrados
m	metros
min	minutos
mm.ano^{-1}	Milímetros por ano
mm.mês^{-1}	Milímetros por mês
mm Hg	Milímetros de Mercúrio
m.s^{-1}	Metros por Segundos
a, j	Parâmetro de Escala
b, k	Parâmetro de Translação
A	Componente de Aproximação ou Vetor de Entrada
AB	Alta da Bolívia
ABEEólica	Associação Brasileira de Energia Eólica
AEA	Atlas Eólico de Alagoas
Alt	Altitude
AM	Altura das Medições
ASAN	Anticiclones do Atlântico Norte
ASAS	Anticiclone Subtropical do Atlântico Sul
ADT-AL	Projeto Atlas Eólico e Disseminação da Tecnologia Eólica em Alagoas

BM	Brisa Marítima
BR	<i>Bayesian Regularization</i>
BT	Brisa Terreste
Cb	Nuvens Cumulonimbus
CCM	Complexos Convectivos de Mesoescala
CDM	Ciclo Diário Médio
CLA	Centro de Lançamento de Alcântara
CLS	Camada Limite Superficial
CO	Monóxido de Carbono
Ci	Nuvens Cirrus
CP	Correlação de Pearson
D	Componente de Detalhe
DOL	Distúrbios de Onda de Leste
DT	Diagrama de Taylor
DV	Direção do Vento
E	Leste
EB	Estatística Bivariada
EE	Estatística de Erros
EM	Estatística Multivariada ou Erro Médio
EMQ	Erro Médio Quadrático
ENE	Leste-Nordeste
ENEB	Costa Leste do NEB
ENOS	El Niño-Oscilação Sul
ENOS34	El Niño-Oscilação Sul na região 3.4
EPAM	Erro Percentual Absoluto Médio
ESE	Leste-Sudeste
EX	Estatística Exploratória
FF	Frentes Frias
FI	Frequência Instantânea
GHM	Grupo Homogêneo Mensal
GW	Giga Watt
GWEC	<i>Global Wind Energy Council</i>
IEA	<i>International Energy Agency</i>

IEC	<i>International Electrotechnical Commission</i>
IM	Intervalo de Medições
IPA	Índice de Poluição do Ar
Lat	Latitude
LI	Linhas de Instabilidade
LL	Lei Logarítmica
LM	<i>Levenberg-Marquardt</i>
Lon	Longitude
LP	Lei da Potência
LSTM	<i>Long and Short Term Memory</i>
LT	Linha de Tendência
LTA	Local da Torre Anemométrica
MSC	Morte Súbita Cardiovascular
MW	Mega Watt
N	Norte ou Número de medições
NAR	Não-linear Autorregressiva
NARX	Não-linear Autorregressiva com entrada eXterna
NE	Nordeste
NEB	Nordeste do Brasil
NMM	Nível Médio do Mar
NNE	Norte-Nordeste
NNW	Norte-Noroeste
NO	Monóxido de Nitrogênio
NO _x	Óxidos de Nitrogênio
NO ₂	Dióxido de Nitrogênio
NW	Noroeste
O ₃	Ozônio
OAN	Oceano Atlântico Norte
OAS	Oceano Atlântico Sul
OBS	Dados Observados
PA	Pressão Atmosférica
PMC	<i>Perceptron</i> de Múltiplas Camadas
PM10	Material Particulado 10

POA	Perturbações Ondulatórias dos Alísios
PP	Precipitação Pluviométrica
PVPN	Projeto Previsão de Ventos para Parques Eólicos do Nordeste do Brasil
PVV	Perfil Vertical do Vento
REQM	Raiz do Erro Quadrático Médio
RNA	Rede Neural Artificial
RSG	Radiação Solar Global
S	Sul
SAODI	<i>Southern Atlantic Ocean Dipole Index</i>
SE	Sudeste
SSE	Sul-Sudeste
SSW	Sul-Sudoeste
SW	Sudoeste
TA	Temperatura do Ar
TNA	<i>Tropical Northern Atlantic Index</i>
TSA	<i>Tropical Southern Atlantic Index</i>
TSM	Temperatura da Superfície do Mar
TW	Transformada de Wavelet
TWC	Transformada de Wavelet Contínua
TWD	Transformada de Wavelet Discreta
TWH	Tera Watt Hora
UR	Umidade Relativa
VCAN	Vórtices Ciclônicos em Altos Níveis
VM	Variáveis Meteorológicas
VV	Velocidade do Vento
W	Oeste
WC	Wavelet de Coerência
WNW	Oeste-Noroeste
WRNA	Wavelet junto com Rede Neural Artificial
WSW	Oeste-Sudoeste
ZCAS	Zona de Convergência do Atlântico Sul
ZCIT	Zona de Convergência Intertropical
ZCNB	Zona de Convergência sobre o NEB

SUMÁRIO

RESUMO	i
ABSTRACT	ii
LISTA DE FIGURAS	iii
LISTA DE TABELAS	v
LISTA DE ABREVIATURAS, SÍMBOLOS E SIGLAS	vi
1 INTRODUÇÃO	19
1.1 Justificativa	20
1.2 Objetivos	20
1.2.1 Geral	20
1.2.2 Específicos	20
2 REVISÃO BIBLIOGRÁFICA	21
2.1 Variáveis meteorológicas	21
2.2 Energia eólica	22
2.3 Sistemas meteorológicos atuantes em Alagoas	23
2.4 Wavelet	26
2.5 Rede neural artificial	27
2.6 Estatística aplicada	28
2.7 Perfil vertical do vento	29
3 MATERIAL E MÉTODOS	31
3.1 Área de estudo	31
3.2 Dados observados	32
3.3 Análise Wavelet	33
3.4 Redes neurais artificiais (NAR, NARX e LSTM)	37
3.5 Análise estatística	40
3.5.1 Estatística descritiva	40
3.5.2 Linha de tendência	40
3.5.3 Estatística exploratória	41
3.5.4 Ciclo diário médio	42
3.5.5 Análise de agrupamento	43
3.5.6 Estatística de erro	43
3.5.7 Correlação	44
3.5.8 Teste t-Student	44
3.5.9 Diagrama de Taylor	45

3.5.10	Função densidade de probabilidade	46
3.5.11	Direção do vento	46
3.6	Lei da Potência e Lei Logarítmica	47
4	RESULTADOS E DISCUSSÃO	49
4.1	Características individuais das variáveis meteorológicas.....	49
4.2	Relação entre as variáveis meteorológicas	71
4.3	Prognóstico das variáveis meteorológicas.....	83
4.4	Análise do perfil vertical do vento	90
5	CONCLUSÕES	101
5.1	Sugestões para trabalhos futuros	103
	REFERÊNCIAS	104
	APÊNDICE A	117
	APÊNDICE B	118
	APÊNDICE C	119

1 INTRODUÇÃO

Estudos sobre as variáveis meteorológicas (VM) são necessários para o desenvolvimento industrial sustentável brasileiro, principalmente relacionados à energia hídrica, solar e eólica (SANTOS et al., 2023). Além disso, para o aproveitamento eficiente de energia limpa e renovável é imprescindível conhecer as características estatísticas, distribuição espaço-temporal que representem a variabilidade das VM e a identificação de um padrão de relação entre as variáveis (CHANG et al., 2017).

O desenvolvimento de metodologias que busquem identificar os parâmetros verticais do vento é relevante para a construção civil, agricultura, aeroportos, e principalmente para a implantação de parques eólicos (SATHE e BIERBOOMS, 2007; SANTOS e LYRA, 2020). Segundo MANWELL et al. (2009), o perfil vertical do vento (PVV) é influenciado por várias condições meteorológicas incluindo: **i)** forma do terreno; **ii)** mudanças nas condições da superfície; **iii)** rugosidade da superfície; **iv)** estabilidade atmosférica.

O Brasil é um país continental e, portanto, os sistemas meteorológicos em multiescala e os fatores fisiográficos (proximidade ao oceano, relevo, vegetação, dentre outras) influenciam diretamente as escalas interanual e intrazonal das variáveis climáticas (CORREIA FILHO et al., 2021; 2022). As condições atmosféricas afetam a geração de energia elétrica que é realizada, por exemplo, a partir de recursos hídricos. A alta dependência das hidrelétricas pode ser um problema significativo para as próximas gerações, considerando a variabilidade natural e a vulnerabilidade às condições climáticas. Segundo PEREIRA et al. (2013), a produção de energia eólica no Nordeste do Brasil (NEB) pode ser afetada de forma positiva pelas mudanças climáticas.

Para garantir segurança do setor energético e desenvolvimento do país é necessário diversificar a matriz energética brasileira. Para isso, estudos sobre fontes renováveis é fundamental (OLIVEIRA e SOUZA, 2017; SANTOS et al., 2020). O NEB possui uma particular complementariedade entre hidro e eólica. Durante o período de seca, o volume dos reservatórios fica comprometido pela falta de chuvas. É justamente neste período que ocorre “Safra dos Ventos”, que por sua vez favorece o aumento de geração de energia eólica e solar (ALENCAR et al., 2018; ROCHA et al., 2018).

A Associação Brasileira de Energia Eólica (ABEEólica) emite um boletim anual sobre a geração de energia, no qual destaca que atualmente o Brasil atingiu uma potência de 31 GW de energia eólica acumulada, distribuídos em 1.039 parques eólicos instalados, sendo mais de 11.000 aerogeradores em operação, distribuídos em 12 estados, sendo oito deles na região do NEB (ABEEólica, 2024). O NEB é a região que mais gera e consome EE, devido aos seguintes fatores: **i)** maior fator de capacidade; **ii)** maior capacidade eólica instalada acumulada; **iii)** e o maior número de parques eólicos instalados (PEREIRA et al., 2013).

Vale ressaltar que Alagoas, assim como todos os demais estados do NEB, tem potencial para produção de energia eólica. Diversos estudos recentes indicam que Alagoas e, principalmente a região semiárida do Estado, é uma ótima opção para a construção de parques eólicos (CRUZ, 2017; RAMOS et al., 2018; SANTOS e LYRA, 2020; SANTOS et al., 2020; SILVA et al., 2023; SANTOS et al., 2023).

1.1 Justificativa

Este estudo parte da premissa de que existe uma necessidade de informações úteis e necessárias para quantificar o regime e a persistência de variáveis meteorológicas na região semiárida de Alagoas que ajudem a dimensionar o potencial de geração de energia eólica.

1.2 Objetivos

1.2.1 Geral

- Investigar cinco variáveis meteorológicas, velocidade e direção do vento (VV e DV), temperatura do ar (TA), umidade relativa do ar (UR) e pressão atmosférica (PA) para fins de produção de energia eólica no município de Craíbas, Agreste de Alagoas, NEB.

1.2.2 Específicos

- Examinar as características individuais dos parâmetros atmosféricos.
- Identificar um padrão de relação entre essas variáveis.
- Avaliar técnicas de simulação de elementos climáticos via inteligência artificial.
- Analisar o perfil vertical do vento.

2 REVISÃO BIBLIOGRÁFICA

2.1 Variáveis meteorológicas

A investigação da variabilidade das VM é de suma importância para a identificação das condições atmosféricas de um determinado lugar, detecção da dispersão de poluentes de grandes cidades, ocorrência de eventos extremos, entre outros (CHANG et al., 2017; SEIFI et al., 2021). As VM podem ser usadas para estimar o consumo mensal e anual de eletricidade, ou para período mais curtos, por exemplo, dias da semana e dias em diferentes estações (JOVIC et al., 2021). Várias pesquisas atentam-se para a relação entre eventos climáticos e os efeitos na saúde humana (TORO et al., 2010; AVDAKOVIC et al., 2016).

TORO et al. (2010) avaliaram variáveis meteorológicas na morte súbita cardiovascular (MSC) de pacientes hospitalares na capital Budapeste, Hungria. Os fatores meteorológicos estudados foram radiação global, VV, UR, PA, TA (Média, Mínima e Máxima) relacionados com o número diário de casos de morte. Foram utilizados dois bancos de dados meteorológicos, dados com intervalo de seis horas e uma hora, o período de estudo foram 10 anos (janeiro de 1995 a dezembro de 2004). Os resultados mostraram uma correlação negativa significativa entre temperatura média diária e mortalidade cardiovascular, o clima frio e seco indicou ser um fator importante de risco para o aparecimento de MSC na capital.

MOREIRA et al. (2015) objetivaram analisar o ciclo diário médio (CDM) de VM em diferentes biomas no estado do Mato Grosso. Calcularam frequências de ocorrência de precipitação pluviométrica (PP), TA, UR, VV e rajadas de vento distribuídas nos biomas Amazônia, Pantanal e região de transição Cerrado-Amazônia. Os resultados mostraram que a TA apresentou CDM clássico, com média mais baixa antes do nascer do Sol e mais alta próxima às 14 horas, já a UR apresentou comportamento inverso ao da TA, a VV e as rajadas de ventos apresentaram evolução diária correlacionadas positivamente com a TA e a PP apresentou valores distintos para os três biomas.

JOVIC et al. (2021) utilizaram cinco VM (TA, UR, PA, VV e DV) para estimar os parâmetros do modelo de carga estática exponencial na cidade Leskovac, República da Sérvia, diferente de outros estudos (TANG et al., 2018; KORUNOVIC et al., 2020) que utilizaram apenas variáveis elétricas (mudança de tensão, potência ativa e reativa) para estimar os parâmetros do modelo exponencial. Os resultados mostraram que a estimativa dos parâmetros do modelo é mais precisa quando todas as cinco VM são consideradas no relacionamento linear entre os parâmetros e as variáveis. E no relacionamento linear simples entre os parâmetros do modelo e uma variável meteorológica a TA obteve a estimativa mais precisa.

Portanto, a investigação de VM possui inúmeras aplicabilidades em várias áreas de conhecimento. Para esse estudo as variáveis VV, DV, TA, UR e PA foram analisadas individualmente e de caráter relacional, com destaque para VV e DV, para fins de produção de energia eólica.

2.2 Energia eólica

A energia eólica é a transformação da energia cinética dos ventos em energia elétrica. Dentre as energias convencionais, a eólica é a mais atraente e próspera, devido à sua sustentabilidade, natureza ecológica, baixos custos operacionais e o impacto ambiental é menos problemático do que outras fontes de energia como a hidrelétrica (SAMET et al., 2019; SANTOS et al., 2020). MARKARD e PETERSEN (2009) afirmaram que a energia eólica, em geral, é um dos recursos renováveis mais populares e é a forma mais barata de energia sustentável. Também gera benefícios em termos de emprego, investimentos, pesquisa, atividade econômica e independência energética.

A produção de energia eólica é dependente das VM, principalmente da VV e DV. Informações importantes, por exemplo, potencial eólico, direção predominante do vento e fatores fisiográficos permitem avaliar e quantificar a produção de energia real, atual e futura (BILGILI e SAHIN, 2010; SANTOS e LYRA, 2020). OLIVEIRA e SOUZA (2017) destacaram a necessidade de um reconhecimento prévio do local onde pretende-se implantar uma usina eólica, para que se tenha um aproveitamento preciso e mais eficiente da energia eólica.

A exploração de energia eólica pode ser *onshore* e *offshore*, com aerogeradores instalados no continente e oceano, respectivamente. No Brasil a produção de energia eólica é majoritariamente *onshore*, porém para atender as demandas de eletricidade de sua população é necessário expandir as pesquisas sobre energia *offshore*, onde existem áreas com VV mais intensas e a DV possui menor variabilidade, devido à ausência de barreiras fisiográficas, por exemplo, montanhas e vegetação (MANWELL et al., (2009); FREITAS et al., 2022).

De acordo com *Global Wind Energy Council* (GWEC) cerca de 77,6 GW de nova capacidade de energia eólica foram incorporados às redes elétricas em 2022, elevando a capacidade eólica total instalada para 906 GW. Os cinco principais mercados do mundo para novas instalações em 2022 foram China, Estados Unidos da América (EUA), Brasil, Alemanha e Suécia, juntos eles representam 71% das instalações globais. Em termos de instalações cumulativas até o fim de 2022, os principais mercados de energia eólica são China e EUA, o Brasil se mantém na sexta posição (GWEC, 2023).

O Brasil possui padrão de ventos com alta intensidade, considerado um dos melhores do mundo para produção de energia eólica e o fator de capacidade médio anual é de 40%. Sendo que no período de melhores ventos no segundo semestre, registra-se fatores que passam dos 70%, enquanto a média mundial é de apenas 25% (SANTOS et al., 2020). Os cinco estados brasileiros que mais produziram energia eólica no ano de 2022 foram Bahia (24,17 TWh), Rio Grande do Norte (23,20 TWh), Piauí (10,29 TWh), Ceará (7,06 TWh) e Rio Grande do Sul (5,37 TWh) - (ABEEólica, 2024).

Em Alagoas a principal fonte de energia é a hídrica. A produção de energia doméstica do Estado é baseada em óleo diesel, gás natural e indústria de cana de açúcar (RAMOS et al., 2018). O Atlas Eólico de Alagoas (AEA) informa um potencial eólico de 173 MW, 336 MW e 649 MW em 50 m, 70 m e 100 m de altura, respectivamente,

existem áreas com $VV \geq 7 \text{ m.s}^{-1}$, e no interior do Estado em Craíbas possui locais privilegiados para a instalação de parques eólicos (ELETROBRÁS, 2008).

2.3 Sistemas meteorológicos atuantes em Alagoas

O regime de chuvas sobre o Estado de Alagoas está direta ou indiretamente associada aos seguintes sistemas climáticos: ventos alísios, Zona de Convergência Intertropical (ZCIT), Zona de Convergência do Atlântico Sul (ZCAS), Anticiclone Subtropical do Atlântico Sul (ASAS), Vórtices Ciclônicos em Altos Níveis (VCAN), Distúrbios de Onda de Leste (DOL), Perturbações Ondulatórias dos Alísios (POA), Zona de Convergência sobre o NEB (ZCNB), Complexos Convectivos de Mesoescala (CCM), Linhas de Instabilidade (LI), Frentes Frias (FF) e Brisa Marítima (BM) - (MOLION e BERNARDO, 2002; LYRA et al., 2014; TEODORO et al., 2019; MONTEIRO, 2022; LYRA, 2022; CPTEC, 2024).

Segundo TEODORO et al. (2019) a ZCIT pode ser caracterizada como uma banda latitudinal de ocorrência de movimentos ascendentes, baixa pressão em superfície, nebulosidade e precipitação na região tropical. A ZCIT forma-se em baixos níveis da atmosfera pela convergência dos ventos alísios de Nordeste, vindos do hemisfério Norte, com os ventos alísios de Sudeste, vindos do hemisfério Sul. As estações do ano modificam a posição da ZCIT, considerando a região do oceano Atlântico Equatorial, a ZCIT localiza-se mais ao Norte (próximo a 10°N) durante o inverno austral e posiciona-se mais ao Sul (próximo a 3°S) de fevereiro a abril. O tempo de permanência da ZCIT em sua posição mais austral é determinante na quantidade de precipitação no NEB. Os anos mais chuvosos no NEB ocorrem quando a ZCIT inicia sua migração para o Norte no final de abril e início de maio (LYRA et al., 2014; TEODORO et al., 2019; MONTEIRO, 2022).

A ZCAS pode ser compreendida como uma banda de nebulosidade semiestacionária com orientação Noroeste-Sudeste (NW-SE) que se estende da Amazônia, passando pelo Sudeste, até o Oceano Atlântico Sul (OAS). Dependendo de fatores meteorológicos favoráveis a ZCAS pode se deslocar em direção ao semiárido nordestino. A configuração da ZCAS deve persistir por, no mínimo quatro dias consecutivos, e existem outros sistemas meteorológicos envolvidos, tais como: **i)** Um anticiclone em altos níveis, Alta da Bolívia (AB), gerado a partir da liberação de calor latente; **ii)** Um cavado invertido entre o NEB e OAS, que pode eventualmente fechar-se e formar um VCAN; **iii)** E a presença de uma FF no OAS (MONTEIRO, 2022).

Segundo LYRA (2022) os VCAN são um dos principais sistemas meteorológicos responsáveis pela produção de precipitação na pré-estação chuvosa da região NEB, ocorre entre os meses de dezembro a março com maior frequência e intensidade no mês de janeiro. Os VCAN com periferia Oeste posicionadas próximas à costa Leste do NEB (ENEB), provocam uma alteração no padrão de convergência do transporte de umidade de grande escala, que passam a convergir sobre o NEB, causando intensa precipitação em regiões localizadas sob a periferia dos VCAN e em locais abaixo do seu centro contribui para a escassez de precipitação (LYRA et al., 2014; LYRA, 2022).

Os DOL, também chamados de Ondas de Leste, são um importante sistema sinótico que influencia a precipitação de Alagoas, originam-se sobre costa oeste da África e Atlântico tropical. São responsáveis por nebulosidade, mudanças na intensidade do vento próximo da superfície e na pressão atmosférica, bem como chuvas fortes na costa ENEB durante poucos dias e eventualmente ocasionam chuvas na porção semiárida nordestina quando encontram condições meteorológicas favoráveis, especialmente nos meses de junho, julho e agosto (RODRIGUES et al., 2010; TORRES e FERREIRA, 2010).

Considera-se os meses de abril a julho como quadra chuvosa alagoana, neste período sistemas frontais interagem com a brisa marítima nas latitudes 5°S a 18°S, resultando em faixas de nuvens Cúmulos e conseqüentemente precipitação sobre a costa ENEB e podendo abranger a região semiárida de Alagoas (SILVA et al., 2011; LYRA et al., 2014). A ZCNB é outro sistema importante para precipitação durante a quadra chuvosa sobre o ENEB e região semiárida. A ZCNB é estabelecida como uma faixa de nuvens Noroeste-Sudeste quando a umidade proveniente do OAS converge sobre o continente, sendo intensificada quando associada à temperatura da superfície do mar (TSM) (MOLION e BERNARDO, 2002).

Os CCM são definidos como um conjunto de nuvens Cumulonimbus (Cb) cobertos por uma densa camada de nuvens Cirrus (Ci), podem ser identificados em imagens de satélite como sendo sistemas aproximadamente circulares e com crescimento acentuado em um intervalo de tempo de 6 a 12 horas (MILHAHN JÚNIOR, 2016). Provocam chuvas fortes e de curta duração. Podem produzir precipitação contínua sobre regiões que excedem a 100 km de extensão. Os CCM possuem três estágios que podem ser considerados: gênese, maturidade e dissipação. A gênese geralmente ocorre no final da tarde e início da noite. A maturidade ocorre durante a madrugada, quando alcança a maior área de cobertura de nuvens convectivas. E a dissipação dos CCM ocorrem quando o fluxo de calor e umidade é reduzido por ocorrência de mecanismos físicos variados que podem contribuir para interromper ou modificar o suprimento de combustível para a manutenção do sistema meteorológico (MILHAHN JÚNIOR, 2016; MONTEIRO, 2022).

As LI são formadas por conjuntos de tempestades organizadas em linha com dimensão da ordem de 100 km e duração de 1 h. Ocasionalmente chuvas fortes normalmente no final da tarde e início da noite, quando a convecção é máxima e estas nuvens (geralmente do tipo Cb) estão em maior número. As LI ocorrem tanto nos trópicos quanto nos extratropicais, e são um dos sistemas precipitantes mais frequentes na atmosfera. As LI têm um forte relacionamento com o deslocamento sazonal da ZCIT, pois as LI tendem a ficar mais extensas entre fevereiro e junho, com máximo valor no mês de abril. Em termos de intensidade, as LI mais fortes ocorrem entre os meses de janeiro e março. As LI também interagem com as BM e quando atuam em conjunto podem contribuir para que as precipitações ocorram no ENEB e adentrem em porções mais interioranas, deslocando-se para o semiárido nordestino (RIBEIRO, 2018; MONTEIRO, 2022).

As BM estão relacionadas à interação resultante do aquecimento diferencial entre a superfície terrestre e oceânica ocorrendo em porções litorâneas, permitindo uma alteração diurna importante no regime de ventos que, por sua vez, colaboram para o

transporte de umidade do oceano para o continente. A BM ocorre durante o dia quando a área continental aquece mais rápido do que a oceânica, fazendo com que a pressão sobre a superfície terrestre seja mais baixa em comparação à superfície oceânica, tornando o continente receptor de ventos. Deste modo, os ventos se deslocam do oceano para o continente nos níveis mais baixos, criando-se uma corrente de retorno nos níveis superiores, isso caracteriza-se uma BM. Durante a noite ocorre o processo inverso, ou seja, chamado de brisa terrestre (BT) - (LYRA et al., 2014; MONTEIRO, 2022; SILVA, 2022).

As FF são bandas de nuvens organizadas que se formam na área de confluência entre uma massa de ar frio (mais densa) com uma massa de ar quente (menos densa). Quando as massas de ar se encontram a massa de ar frio faz com que o ar quente e úmido suba formando nuvens de chuva. As FF são sistemas de escala sinótica e ocorrem durante todo o ano e atuam mais fortemente no Sudeste e Sul do Brasil, mas dependendo de condições meteorológicas favoráveis podem desencadear chuvas na porção semiárida do NEB, especialmente entre os meses de novembro e janeiro. Os critérios para identificar as FF geralmente são o aumento da pressão atmosférica, diminuição de temperatura e mudança na componente meridional do vento (FEDOROVA et al., 2016; MUANZA, 2018; MONTEIRO, 2022).

O El Niño-Oscilação Sul (ENOS) é um fenômeno meteorológico de interação atmosfera-oceano que está associado às alterações dos padrões de TSM, das configurações do campo de pressão e dos ventos alísios na região do Pacífico Equatorial, com uma fase quente (El Niño) e uma fase fria (La Niña). Os eventos de El Niño (La Niña) podem suprimir (potencializar) os sistemas climáticos que produzem chuva no NEB. Em anos de La Niña, são observadas chuvas acima da média em Alagoas, porém esse Estado sofre muita influência de condições observadas no OAS (COSTA et al., 2020; SANTOS, 2023). CAVALCANTE (2018) concluiu que o período de máximo desenvolvimento e maior influência dos ENOS na precipitação ou seca no NEB é próximo do seu final.

MONTEIRO (2022) objetivou analisar a influência das teleconexões (conexão à distância) e sistemas meteorológicos na produção de precipitação no semiárido nordestino. Os resultados mostraram que o ENOS exerce um importante papel nas secas recorrentes do NEB em anos de El Niño, enquanto em anos de La Niña, as chuvas seriam mais representativas em grande parte do semiárido nordestino. As análises realizadas sob o Atlântico Intertropical a partir das anomalias de TSM e deslocamento dos Anticiclones do Atlântico Norte (ASAN) e Atlântico Sul (ASAS) exercem grande influência na precipitação sobre a região NEB. Diversos sistemas meteorológicos (VCAN, DOL, ZCAS, LI, CCM) também contribuem para alguns acumulados de chuva importantes no semiárido nordestino, os quais atuam sozinhos ou de forma conjunta, com maior ou menor expressão em determinados períodos e localidades do NEB.

O clima mais seco na região semiárida de Alagoas é devido à topografia, distância da costa ENEB, sistemas climáticos de meso e grande escala, como a AB. A distância da região semiárida ao litoral é aproximadamente 115 km, isso reduz o número de Cúmulos formados no litoral e que atingem a região semiárida. A topografia influencia o clima nessa região devido à presença da Serra da Borborema ao norte do Estado, que se torna uma barreira aos ventos alísios, às nuvens Cúmulos e às brisas

marítimas que atingem Alagoas, conseqüentemente interfere no transporte de umidade do oceano para esta região (LYRA et al., 2014; MONTEIRO, 2022).

2.4 Wavelet

A análise Wavelet é uma abordagem computacional não paramétrica robusta e poderosa para analisar os padrões de variáveis meteorológicas consideradas processos não estacionários. A Transformada Wavelet (TW) representa a convolução entre os coeficientes Wavelet e séries temporais. Após a TW, as características internas das séries temporais são espalhadas para o domínio de tempo-frequência, chamado de escalograma, pelo qual a característica local para qualquer tempo e frequência pode ser detectada (MEYERS et al., 1993; CHANG et al., 2017; ROCHA et al., 2018; SEIFI et al., 2021). As técnicas de Wavelet têm sido utilizadas em diversos campos de pesquisa, por exemplo, para analisar e sintetizar sinais, por exemplo, identificar as frequências instantâneas da série temporal e investigar o padrão de relação entre duas variáveis (WENG e LAU, 1994; TORRENCE e COMPO, 1998; VALENS, 1999; AVDAKOVIC et al., 2016).

CHANG et al. (2017) utilizaram análise Wavelet para investigar a frequência instantânea (FI) dos recursos renováveis radiação solar global (RSG), VV e TA na região de Taipei, Taiwan. Os dados foram medidos com intervalo de 10 min e o período de estudo foi de 10 anos (janeiro de 2006 a dezembro de 2015). Os resultados mostraram que o espectro de VV é mais irregular do que TA e RSG, devido aos fatores climáticos e geográficos, por exemplo, o sítio meteorológico está localizado em uma área onde as estações verão e inverno influenciam a direção do vento, no verão os ventos sopram para sudoeste (SW) com baixa velocidade e no inverno sopram para o NE. Os resultados também mostraram que a VV não apresentou intensidade suficiente para a construção de parques eólicos na área de estudo.

AVDAKOVIC et al. (2016) utilizaram a técnica de Wavelet de Coerência (WC) para analisar o impacto de variáveis meteorológicas (VV, UR, TA e PA) na redução de concentração de material particulado 10 (PM10) e o monitoramento da qualidade do ar na cidade de Sarajevo, Bósnia. Os dados eram horários e o período de estudo foi todo o ano de 2012. A WC foi utilizada para identificar o padrão de interação das VM e PM10 no domínio da frequência de tempo. A WC mostrou que a TA e a PA tiveram um impacto mais significativo na concentração de PM10 em comparação com a VV e a UR. Os resultados mostram que o aumento da TA, durante o verão, e da PA, durante o outono e inverno, coincidiram no aumento das concentrações de PM10.

ROCHA et al. (2018) investigaram a aplicação de análise Wavelet em dados climáticos (TA, UR, PA e VV) no Cerrado, bioma rico em biodiversidade do Mato Grosso, para obter informações sobre efeitos e tendências sazonais dessas variáveis. Os dados eram horários e o período de estudo foram os anos 2015, 2016 e 2017. A análise Wavelet resultou em periodicidade de 24 horas (ciclo diário) para a TA e UR. A VV não apresentou periodicidade do ciclo diário efetivamente uniforme e a periodicidade da PA foi de 4 a 64 dias. A WC entre as variáveis TA e UR apresentou um padrão de relação forte de fase oposta em todo o período estudado, a VV apresentou um padrão de

relação moderada com a TA e UR. A WC da PA apresentou relação fraca com todas as variáveis. Os resultados também mostraram que a sazonalidade da região de estudo é caracterizada pela existência de duas estações anuais, quente-úmida e quente-seca.

THANGPRASERT e SUWANARAT (2017) investigaram o padrão de relação entre as variáveis VV e TA via análise Wavelet em Bangkok, Tailândia. O estudo utilizou dados horários e diários de janeiro de 2009 a dezembro de 2011 com ênfase nas quatro estações. Os resultados obtidos mostraram que as variáveis apresentaram periodicidade forte em torno de 1 dia (dados horários) e variações entre 256-450 dias (dados diários), que corresponde ao ciclo anual. Essas duas oscilações estão conectadas com os efeitos naturais do ciclo diário e o ciclo natural anual das estações. A periodicidade diária da TA é quase uniforme durante todo o ano, diferente da VV. A WC apresentou correlação forte de fase entre as variáveis no período em torno de 10-30 dias no verão e inverno, 32-50 dias no verão de 2009 e inverno de 2010.

SANTOS (2016) identificou a correlação entre VM e incidência de casos de dengue (ICD) na cidade de Maceió, Alagoas, por meio de TWC e WC. Foram utilizados dados mensais entre o período de janeiro de 1998 a dezembro de 2015. Os resultados da WC mostraram que as variáveis nebulosidade, velocidade máxima e média do vento e insolação não apresentaram correlação com ICD, a umidade relativa mostrou correlação de fase moderada com ICD. As variáveis precipitação e temperatura máxima do ar apresentaram alto grau de correlação com ICD, padrão de fase e antifase, respectivamente. Sendo que todas as variáveis mostraram coerência na escala anual.

No presente estudo utilizou-se as técnicas de Transformada de Wavelet Contínua (TWC), para análise de tempo-frequência individual das variáveis, e WC para quantificar a força de correlação entre as variáveis. A Transformada de Wavelet Discreta (TWD) foi utilizada para processamento das variáveis, decompondo as séries temporais em componentes de detalhe D (alta frequência) e uma componente de aproximação A (baixa frequência), que servirão de entrada para a rede neural artificial.

2.5 Rede neural artificial

Inspirados pela sofisticada funcionalidade dos cérebros humanos, onde centenas de bilhões de neurônios interconectados processam inúmeras informações, a rede neural artificial (RNA) é uma técnica de aprendizagem de máquina capaz de reconhecer padrões, descrever comportamentos dinâmicos (sistemas variantes em relação ao tempo), possibilidade de armazenamento de informações, capacidade de memorizar relacionamentos, classificar objetos e resolver uma grande variedade de tarefas, além de ser um modelo amplamente utilizado na previsão de energia e velocidade do vento. As RNAs são algoritmos matemáticos geralmente compostos por camada de entrada, camada intermediária ou escondida e camada de saída (GONÇALVES, 2011; SANTOS, 2019).

Segundo VIGANÓ et al. (2017) as principais vantagens das RNAs na previsão de série temporal de VM, são: **i)** não requer conhecimento dos processos físicos causadores dos fenômenos; **ii)** pode ser aplicada em sistemas sem soluções específicas;

iii) possibilita o treinamento contínuo da rede; **iv)** não amplifica os erros de medição; **v)** permite a otimização no processo de previsão que envolva séries temporais de entrada e saída. Além disso, é uma ferramenta para previsão de séries temporais com baixo custo computacional (SANTOS et al., 2020; SANTOS et al., 2022).

SAMET et al. (2019) combinaram RNA *Perceptron* de múltiplas camadas (PMC) e TWD para previsão da velocidade do vento. Utilizaram dois conjuntos de dados experimentais em diferentes áreas geográficas. O primeiro caso inclui VV coletados em intervalos de 10 min, em fevereiro de 2008, na região de Soltaniyeh, província de Zanjan, Irã. O segundo conjunto experimental a VV é registrada a cada cinco minutos, em junho de 2017, na região costeira do Alabama, EUA. O desempenho das previsões foi avaliado por 12 algoritmos de treinamentos e os resultados mostraram que os algoritmos de treinamento *Levenberg-Marquardt* (LM) e *Bayesian Regularization* (BR) superaram significativamente o restante das metodologias.

GUO et al. (2020) utilizaram RNA sozinha e com Wavelet para identificar associações lineares e não lineares entre o índice de poluição do ar (IPA) e 19 VM nas regiões de Xi'an e Lanzhou, China. A série temporal foi diária e o estudo foi realizado entre janeiro de 2010 a dezembro de 2012. Com base nos resultados, o IPA pode ser prevista com precisão com apenas três valores registrados anteriormente. Em relação aos índices de coeficiente de correlação entre IPA alvo e VM testadas, o IPA apresentou correlações mais fortes com a pressão média de vapor d'água, temperaturas média, mínima e máxima. O algoritmo de treinamento que reproduziu com mais precisão IPA foi o *Bayesian Regularization*, durante a fase de previsão o modelo Wavelet obteve um desempenho melhor do que a RNA sozinha em ambos os locais de estudo.

NASCIMENTO et al. (2023) investigaram a aplicação de rede neural profunda baseada em transformador integrada à Wavelet para PVV e geração de EE para as próximas seis horas a frente. O estudo também utilizou múltiplas VM (TA, UR e PA) como entrada para previsão de séries temporais multivariadas. Os dados utilizados eram horários, coletados em torres anemométricas de 100, 120 e 150 m instaladas nas cidades de Esplanada, Mucugê e Mucuri, no Estado da Bahia, Brasil. O desempenho do modelo proposto foi comparado com o modelo *Long Short Term Memory* (LSTM). Os resultados mostraram que o modelo proposto melhorou a precisão da previsão da VV e geração de EE, com desempenho superior ao modelo LSTM e é comparável a estudos semelhantes realizados anteriormente a ele.

No presente estudo utilizou-se RNAs para simular as variáveis meteorológicas (VV, DV, TA, UR e PA) na região semiárida de Alagoas. As VM serão sinais de entrada e/ou alvo e a partir de seus respectivos valores as RNAs treinam, testam, validam e extrapolam valores semelhantes às VM originais.

2.6 Estatística aplicada

TOLEDO e OVALLE (1981) definiram três significados distintos para o termo estatística: **i)** é uma atividade humana especializada; **ii)** um corpo de técnicas; **iii)** uma metodologia especializada para a coleta, classificação, apresentação, análise e interpretação de dados quantitativos e a utilização desses dados auxiliam para a tomada

de decisões. BUSSAB e MORETTIN (2002) afirmaram que a estatística é a parte da metodologia da ciência que tem por objetivo a coleta, redução, análise e modelagem dos dados, obtendo resultados de uma amostra para inferência da população.

SILVESTRE (2016) avaliou a aplicabilidade de diversas técnicas de estatística na climatologia geográfica, bem como na geografia do clima. Algumas técnicas estatísticas utilizadas no estudo foram: análise exploratória dos dados; análise de tendência da série temporal; correlação entre duas séries; modelos estatísticos para relacionar uma variável dependente com duas ou mais variáveis independentes; classificação climática; entre outras. A autora concluiu que ainda há algumas aplicações incorretas das técnicas estatísticas, realizou sugestões de correções e sugeriu técnicas que poderiam ser utilizadas nesses estudos.

CABRAL JÚNIOR e LUCENA (2021) aplicaram técnicas estatísticas para analisar a variabilidade da precipitação e temperatura média do ar. Visaram uma interpretação quantitativa e representativa das condições termo pluviométricas dominantes em Campina Grande, Paraíba e Petrolina, Pernambuco, ambas regiões do semiárido brasileiro. Os dados meteorológicos foram mensais e anuais, correspondem ao período de 38 anos (1977 a 2014). Os resultados mostraram que Campina Grande é mais chuvosa e Petrolina é mais quente. A distribuição das chuvas é distinta, em Petrolina as chuvas se concentram entre dezembro e abril e Campina Grande o período chuvoso ocorre de março a julho. Por fim, a temperatura média do ar em Campina Grande apresentou tendência de aumento nas quatro estações do ano.

LEONI et al. (2017) aplicaram estatística descritiva e multivariada no estudo de qualidade do ar na cidade do Rio de Janeiro. As variáveis consideradas foram dióxido de nitrogênio (NO_2), monóxido de nitrogênio (NO), óxidos de nitrogênio (NO_x), monóxido de carbono (CO), ozônio (O_3), VV, RSG, TA e UR. A estatística multivariada empregou análise de componentes principais (ACP), agrupamentos euclidianos e critérios de Ward. Os dados foram horários e o período de estudo foi entre julho e outubro de 2011. Os resultados indicaram uma alta correlação entre os poluentes primários, por exemplo, NO_x e NO (0,95), NO_x e CO (0,71), NO e O_3 (0,66). Correlação positiva entre o O_3 , TA, RSG e VV, e a UR apresentou correlação negativa com essas quatro variáveis. A estatística descritiva mostrou que o CO é a variável mais dispersa, seguido pela RSG e NO. A análise de agrupamento apresentou três grupos: G1 (NO, NO_x , NO_2 e CO); G2 (TA, RSG, VV e O_3) e não se agrupou NA (UR).

2.7 Perfil vertical do vento

Estudos sobre o perfil vertical do vento mostram que próximo a superfície a velocidade do vento é amena e intensifica-se gradualmente com a altitude, devido a interação dessa variável com os fatores climáticos e geográficos, por exemplo, rugosidade superficial e fisiografia local (relevo, vegetação, montanhas entre outros) – (CORRÊA, 2007; SATHE e BIERBOOMS, 2007; RAMOS et al., 2018; SILVA, 2018; GONÇALVES JÚNIOR et al., 2021).

Segundo RAMOS et al. (2018), no Centro de Lançamento de Alcântara (CLA) localizado no litoral do Maranhã, NEB, o perfil vertical do vento possui maior intensidade e menor turbulência mecânica na época seca (julho-dezembro). No período chuvoso (janeiro-junho), esse comportamento do perfil vertical do vento é invertido. A combinação dos ventos alísios de NE com a intensificação da brisa marítima descreve os padrões dinâmicos na Camada Limite Superficial (CLS) no período seco. Entretanto, a soma do enfraquecimento da brisa com os efeitos de eventos sinóticos (ZCIT e VCAN) sobre a região estudada, reduzem a velocidade do vento (MAGNAGO et al., 2010).

SILVA (2018) utilizou dados observados de VV e DV para determinar os parâmetros aerodinâmicos da Lei Logarítmica (LL) e da Lei da Potência (LP). Os dados foram obtidos em duas campanhas experimentais, Projeto Atlas Eólico e Disseminação da Tecnologia Eólica no Estado de Alagoas (ADT-AL) e Projeto Previsão de Ventos para Parques Eólicos do Nordeste do Brasil (PVPN) distribuídos em cinco torres anemométricas localizadas nas mesorregiões (Sertão, Agreste e Leste) do Estado. Os dados foram armazenados em médias de 10 minutos, o período de estudo visa às estações do ano: Abril/2008 (outono), Junho/2008 (inverno), Outubro/2008 (primavera) e Janeiro/2009 (verão). Os resultados mostraram que a VV no Sertão e Agreste são maiores do que no Leste, a VV é mais intensa na estação seca do que na estação chuvosa e a DV predominante é SE. O modelo desenvolvido para estimar os parâmetros aerodinâmicos da LL não indicou resultados coerentes, diferente da LP que reduziu os erros de 1,13% para 0,01% e indicando que os parâmetros variam de um local para outro e sazonalmente.

ROBALLO e FISCH (2008) investigaram o escoamento atmosférico no CLA através de análises de perfis de vento. Os dados foram coletados por sensores de VV e DV, instalados em uma torre anemométrica com seis níveis de medições (6, 10, 16,3, 28,5, 43 e 70 m), dois períodos de estudo 1995-1999 e 2004-2005 para análises de validação. Os resultados identificaram os parâmetros verticais do vento, como velocidade de atrito e comprimento de rugosidade que compõem a LL, e o coeficiente da camada limite da LP, mostrando a sazonalidade destes parâmetros para os meses de chuva e seca. Na estação chuvosa os valores estimados foram superiores aos observados, devido à fraca condição de neutralidade. Diferente da estação seca onde esses valores foram mais próximos, com velocidade do vento forte (valor médio superior a 10 m.s^{-1}), produzindo muita mistura turbulenta na forma mecânica e implicando em uma atmosfera neutra.

3 MATERIAL E MÉTODOS

3.1 Área de estudo

A Figura 1 exibe o mapa do Brasil, com destaque para o NEB, seguido do Estado de Alagoas e o município de Craíbas com coordenadas geográficas: $09^{\circ}37'03.4''\text{S}$, $36^{\circ}47'40.2''\text{W}$. Informações adicionais como local exato da torre anemométrica e altimetria do relevo estão dispostos na Figura 1. A torre foi instalada em um terreno plano do município de Craíbas, região semiárida (Agreste) parte central de Alagoas (CRUZ et al., 2017). A chuva média anual de Craíbas é de $800 \text{ mm}\cdot\text{ano}^{-1}$ e a temperatura do ar média mensal apresenta valores entre 23°C e 27°C (LYRA et al., 2014; 2017). De acordo com a classificação climática de Köppen-Geiger, a área de estudo é do tipo As' (clima de savana, com inverno e outono chuvosos e verão seco) – (RAMOS et al., 2018; SANTOS et al., 2023).

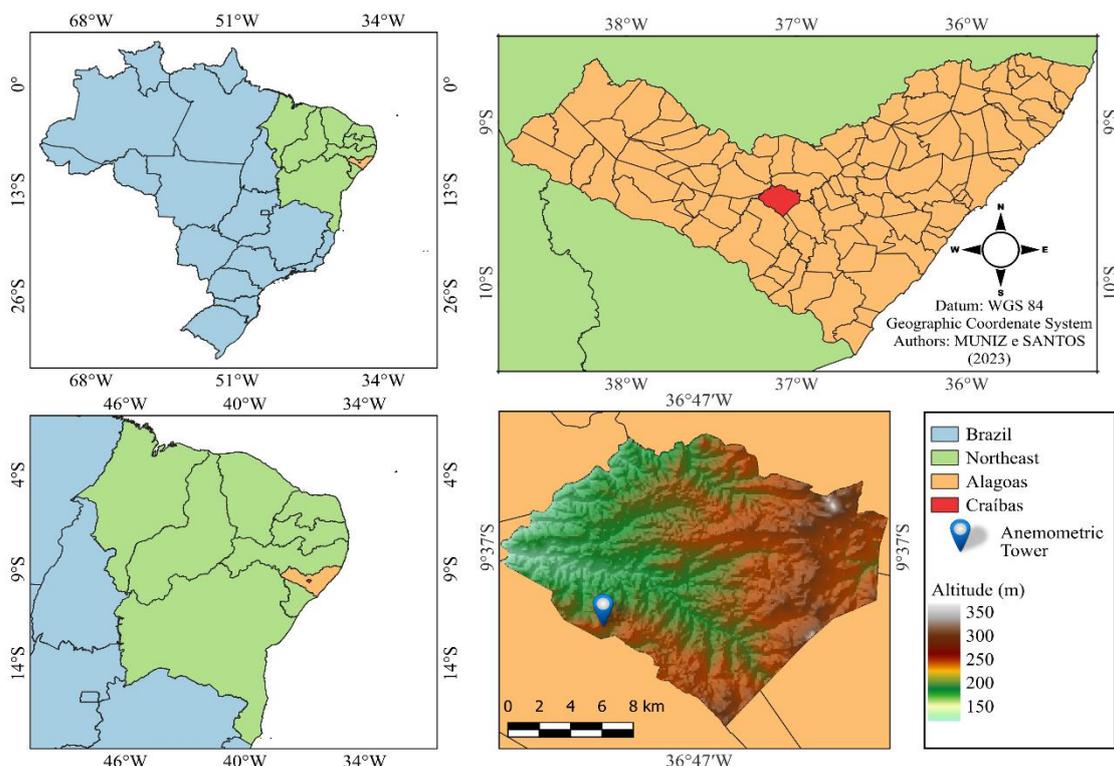


Figura 1. Mapa da região de estudo. Fonte: Autores (2023).

O Estado de Alagoas encontra-se nas latitudes $08^{\circ}48'05''\text{S}$ e $10^{\circ}30'09''\text{S}$, longitudes $35^{\circ}09'09''\text{O}$ e $38^{\circ}15'54''\text{O}$, e altitudes inferiores a 850 m acima do nível médio do mar (NMM). O estado é dividido geopoliticamente em 102 municípios, a capital é Maceió, possui uma área territorial de $27.830,66 \text{ km}^2$ e uma população estimada de 3.365.351 habitantes (IBGE, 2022). A estação chuvosa de Alagoas ocorre de abril a julho, com variabilidade na distribuição espaço-temporal, devido à sua

topografia, proximidade do ambiente costeiro e dos sistemas meteorológicos em multiescala (LYRA et al., 2014; MONTEIRO, 2022).

A Figura 2 apresenta o mapa do potencial eólico do estado de Alagoas divulgado no Atlas Eólico de 2008 elaborado pela ELETROBRÁS (2008). Esse mapa mostra áreas promissoras com ventos constantes e superiores a 7 m.s^{-1} e as maiores intensidades do vento ocorrem em áreas com altitudes elevadas (Agreste e Sertão) e área litorâneas, Sudeste e extremo Sul do Estado. Além disso, a Figura 2 exhibe rodovias, linhas de transmissões, subestações de rede elétrica, entre outras informações importantes para escoamento da produção de energia a partir da instalação de parques eólicos.

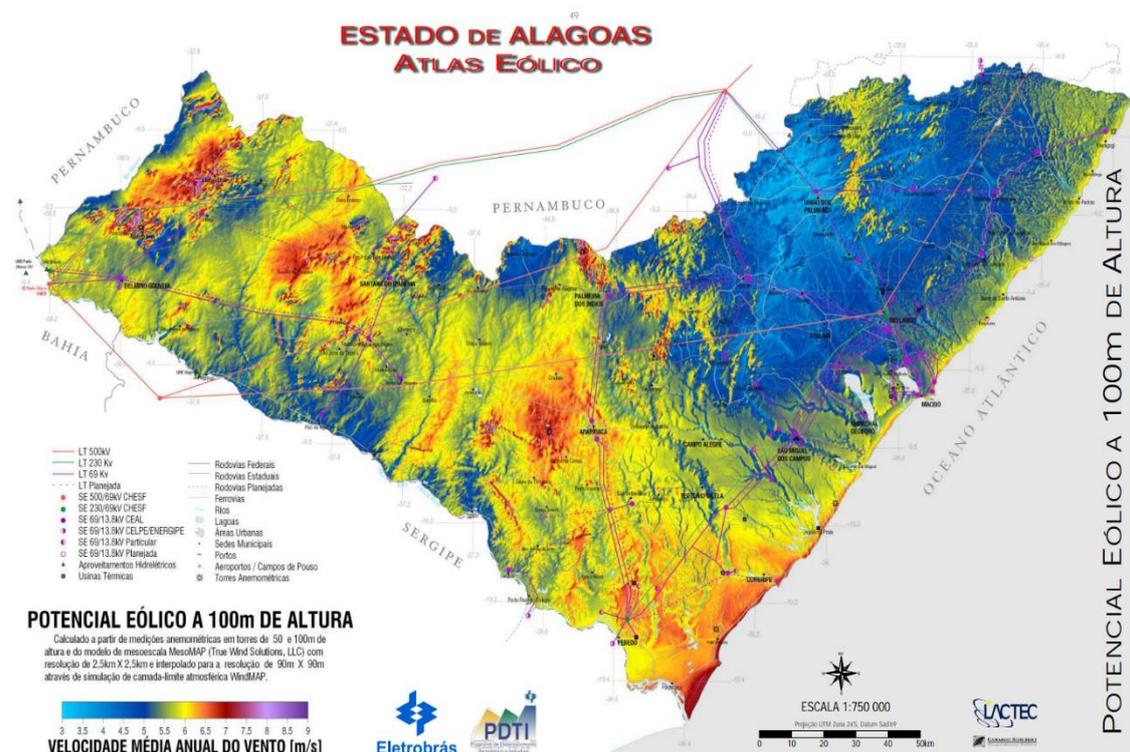


Figura 2. Mapa do potencial eólico do estado de Alagoas. Fonte: ELETROBRÁS (2008).

3.2 Dados observados

Os dados observados (OBS) foram obtidos na campanha experimental do Projeto Previsão de Ventos para Parques Eólicos do Nordeste do Brasil (PVPN). O PVPN se propôs a instalação de uma torre anemométrica de 100 m (altura de referência) e contava com um conjunto de medições em oito níveis de altura (4, 10, 14, 19, 30, 50, 70 e 100 m) – (CRUZ et al., 2017; Silva, 2018).

Os OBS foram medidos com frequência a cada 15 segundos (frequência.s^{-1}) e com as médias armazenadas a cada 10 minutos em um *datalogger* CR1000 (Campbell Scientific - EUA), com eletricidade gerada através de um painel fotovoltaico (modelo KS-20 da *Kyocera*) e sensores calibrados de acordo com as normas internacionais de

qualidade e segurança das agências reguladoras: *International Energy Agency* (IEA); *International Electrotechnical Commission* (IEC) – (Santos et al., 2020).

A VV foi medida por um anemômetro de concha (modelo A100LK) confeccionado pela empresa *Vector Instruments* (Reino Unido). A DV foi medida por um *Windvane* (modelo 024A) fabricante *Campbell Scientific* (EUA). A TA e UR foram medidas por um termo-higrômetro (modelo HMP155A) fabricado pela *Campbell Scientific*. A PA foi medida por um barômetro (modelo PTB110) fabricante *Vaisala* (Finlândia) – (Silva et al., 2023).

As informações contidas na Tabela 1 descrevem detalhadamente o sítio experimental. O estudo das cinco VM foi realizado na altura de referência de 100 m e o período estudado foi entre março de 2014 até abril de 2015. Para identificar a sazonalidade das VM foi definido quatro intervalos sazonais distintos: Total (14 meses), chuvoso (abril, maio, junho e julho), seco (setembro, outubro, novembro e dezembro) e período de transição (janeiro, fevereiro, março e agosto). Para a análise da VV, a diferença entre dia e noite também foi realizada, e para o seu perfil vertical foram utilizados os oito níveis de medição, totalizando 38 dias de análise. Por fim, os dados do projeto PVPN não apresentaram falhas durante todo o período de estudo.

Tabela 1. Dados observados distribuídos em oito níveis de medição, com local da torre anemométrica (LTA), altura das medições (AM), variáveis meteorológicas (VM), coordenadas geográficas (Latitude, Longitude e Altitude), intervalo de medições (IM) e número de medições (N). Fonte: Autores (2023).

LTA	AM (m)	VM	Lat (°)	Lon (°)	Alt (m)	Data-Hora (Início)	Data-Hora (Fim)	IM	N
Craíbas	100	VV, DV, TA, UR e PA	09°37'03"S	36°47'40"W	240	01/03/2014 00:00	30/05/2015 23:50	10	61.344
	4, 10, 14, 19, 30, 50, 70 e 100	VV	ou -9,6176	ou -36,7944		06/12/2014 00:00	12/01/2015 23:50	min	5.472

3.3 Análise Wavelet

Para a análise de tempo-frequência utilizou-se a técnica de TWC. Os filtros de Wavelet identificam as frequências maiores com períodos menores e as frequências menores com períodos maiores (Yi e SHU, 2012; CHANG et al., 2017). A TWC é dada pela Eq. (1):

$$TWC_x(a, b) = \frac{1}{\sqrt{a}} \int x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

em que $\psi(t)$ representa uma função de Wavelet mãe, com duração finita, energia finita e média zero. $\psi(t)$ pode ser dilatada e deslocada ao longo do eixo temporal através dos parâmetros de escala (a) e translação (b), respectivamente (VELASCO e MENDOZA, 2008). $x(t)$ representa o sinal que será analisado (variáveis meteorológicas) e (*) denota o conjugado complexo.

Existem muitas funções de Wavelet disponível na literatura científica. No entanto, a Wavelet de Morlet foi à escolhida, porque consiste em partes reais e

imaginárias que permitem investigar a coerência e o ângulo de fase do sinal (TORO et al., 2010). A função da Wavelet de Morlet é dado pela Eq. (2) e a Figura 3 mostra o gráfico desta função no plano cartesiano x e $f(x)$:

$$\psi(t) = \frac{1}{\sqrt[4]{\pi}} e^{\left(-\frac{t^2}{2}\right)} e^{(i\omega t)} \quad (2)$$

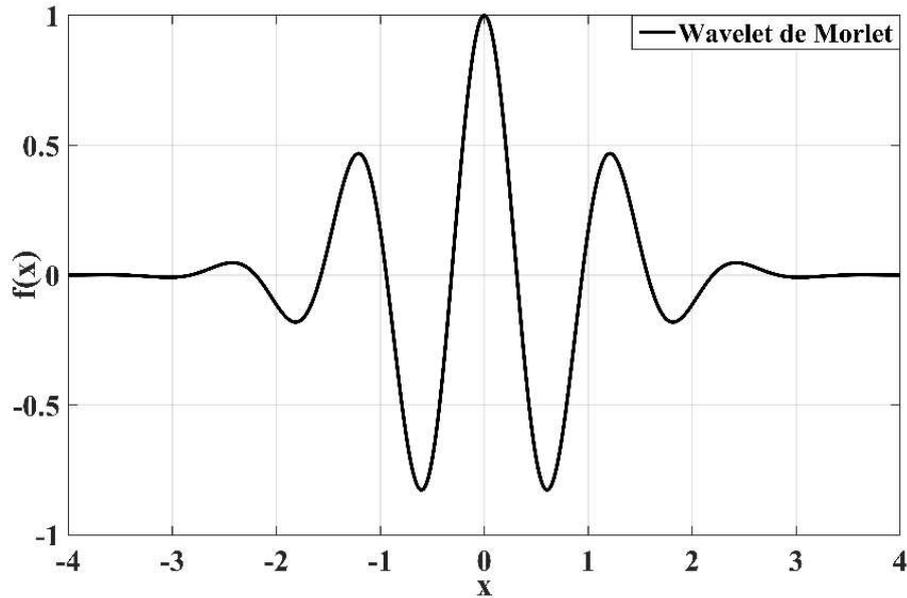


Figura 3. Função da Wavelet de Morlet no plano cartesiano x e $f(x)$. Fonte: Autor (2023).

onde $\pi^{-1/4}$ é o fator de normalização, (i) é a unidade imaginária e (ω) é a frequência de modulação adimensional definida para seis neste estudo (CHANG et al., 2017). O espectro de potência Wavelet (gráfico de escalograma) é definido como o quadrado da TWC tornando-se a Eq. (3):

$$P_x(a, b) = |TWC_x(a, b)|^2 \quad (3)$$

Note que o parâmetro de escala é relacionado a frequência ou período no espectro de potência Wavelet, enquanto o parâmetro de translação representa a localização no eixo temporal (ROCHA et al., 2018). A Wavelet de Coerência Cruzada (WC) – (Eq. (4)) para quaisquer dois sinais $x(t)$ e $y(t)$ em escala e tempo específicos pode ser representada como:

$$TWC_{xy}(a, b) = TWC_x(a, b) \cdot TWC_y(a, b)^* \quad (4)$$

Utilizando WC para quantificar a força da correlação entre duas variáveis e encontrar áreas em que elas se correlacionam. Portanto, a WC entre dois sinais é dada pela Eq. (5):

$$WC = \frac{|S(TWC_{xy}(a, b))|^2}{S(|TWC_x(a, b)|^2) \cdot S(|TWC_y(a, b)|^2)} \quad (5)$$

em que $S(\cdot)$ é um operador de suavização no tempo e escala. O valor de WC varia entre 0 e 1, onde o maior valor indica maior coerência. O ângulo de fase entre as variáveis pode ser usado como uma medida para examinar sua relação interativa (CHANG et al., 2017). Para escala e tempo específico, o ângulo de fase entre dois sinais é descrito pela seguinte Eq. (6):

$$\theta_{xy}(a, b) = \tan^{-1} \left(\frac{\text{Im}[TWC_{xy}(a, b)]}{\text{Re}[TWC_{xy}(a, b)]} \right) \quad (6)$$

Se as variáveis mostram alta coerência, as setas no gráfico de escalograma indicam o relacionamento de fase entre os sinais. Por exemplo, setas apontando para a direita (próximo de 0°) indica que ambas as séries temporais estão em fase, e setas apontando para a esquerda (próximo de 180°) indica que os dois sinais estão em fase oposta. Em ambos os casos, eles implicam em relacionamento linear (direto e inverso, respectivamente) entre as variáveis. Setas apontando para cima ou para baixo (90° e 270°) indicam uma situação fora de fase, significando que ambas as variáveis têm uma relação não linear (TORRENCE e COMPO, 1998; GRINSTED et al., 2004; VELASCO e MENDOZA, 2008).

Para uma completa interpretação da diferença de fase entre duas séries analisadas, deve-se seguir a Figura 4 que mostra a forma de orientação dos vetores entre duas séries temporais. A série temporal que é processada primeiramente segue a seguinte sequência: VV, DV, TA, UR e PA. Portanto, a relação do ângulo de fase entre duas séries temporais é dado por:

1 – as duas séries estão em fase; 5 – as duas séries estão em fases opostas; 2 – série 2 avançada 45° da série 1; 3 – série 2 avançada 90° da série 1; 4 – série 2 avançada 135° da série 1; 6 – série 1 avançada 135° da série 2; 7 – série 1 avançada 90° da série 2; 8 – série 1 avançada 45° da série 2.

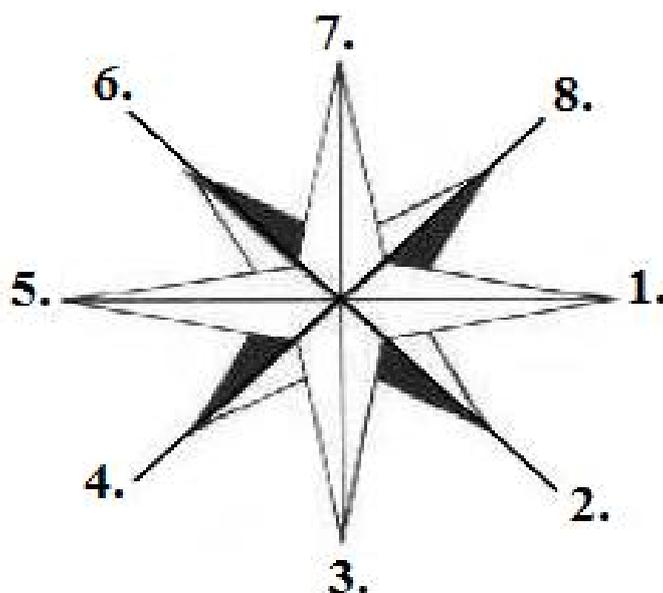


Figura 4. Diagrama da relação do ângulo de fase entre duas séries temporais. Fonte: Autor (2023).

A Transformada de Wavelet Discreta – (Eq. (7)) é encontrada substituindo $a = 2^j$ e $b = k2^j$ na TWC – (Eq. (1)), temos:

$$TWD_x(j, k) = \frac{1}{\sqrt{2^j}} \int x(t) \psi^* \left(\frac{t - k2^j}{2^j} \right) dt \quad (7)$$

em que j e k são o coeficiente de escala e coeficiente de translação, respectivamente.

De acordo com MALLAT (1989) a decomposição e reconstrução são as etapas principais da TWD na análise de dados. A série temporal original é decomposta no processo de decomposição usando o filtro passa alto e passa baixo. Em comparação com a série original, as subséries decompostas são classificadas como componente de detalhe D (alta frequência) e uma componente de aproximação A (baixa frequência). Os filtros decompõem ainda mais a componente de aproximação, enquanto a componente de detalhe permanece inalterado. O procedimento é repetido até um determinado grau de decomposição como mostrado na Figura 5:

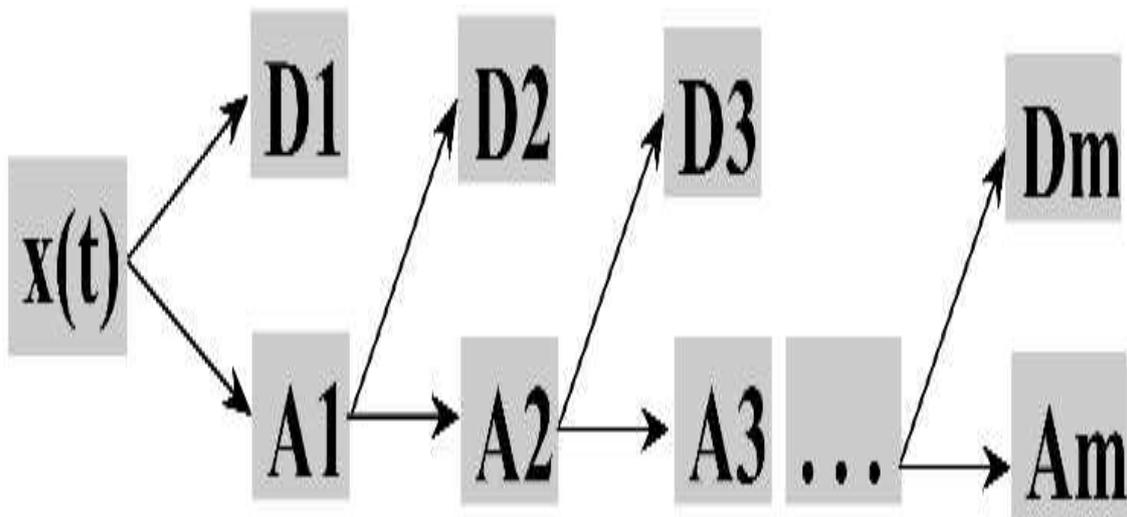


Figura 5. Diagrama de TWD com o número de níveis (m) de decomposição. Fonte: Autor (2023).

Sem perda de informação, a reconstrução da série temporal original é obtida somando os componentes decompostos anteriormente da seguinte forma (SAMET et al., 2019):

$$x(t) = A_1 + D_1 = A_2 + D_2 + D_1 = \dots = A_m + D_m + \dots + D_3 + D_2 + D_1 \quad (8)$$

Para a TWD a Wavelet mãe utilizada foi a *Symlets* (Figura 6) com quatro níveis de decomposição, resultando em uma série de dados suavizada. A escolha da *Symlets* se deu pelo fato de fornecerem excelentes resultados no processamento de sinais, pois apresentam uma melhor caracterização dos coeficientes de Wavelet (A e D) e pelo grande número de estudos que a utilizaram em suas pesquisas, tais como (KHELIL et

al., 2020; BERREZZEK *et al.*, 2019; YU *et al.*, 2017; YAO *et al.*, 2013; RAMESH BABU e ARULMOZHIVARMAN, 2013).

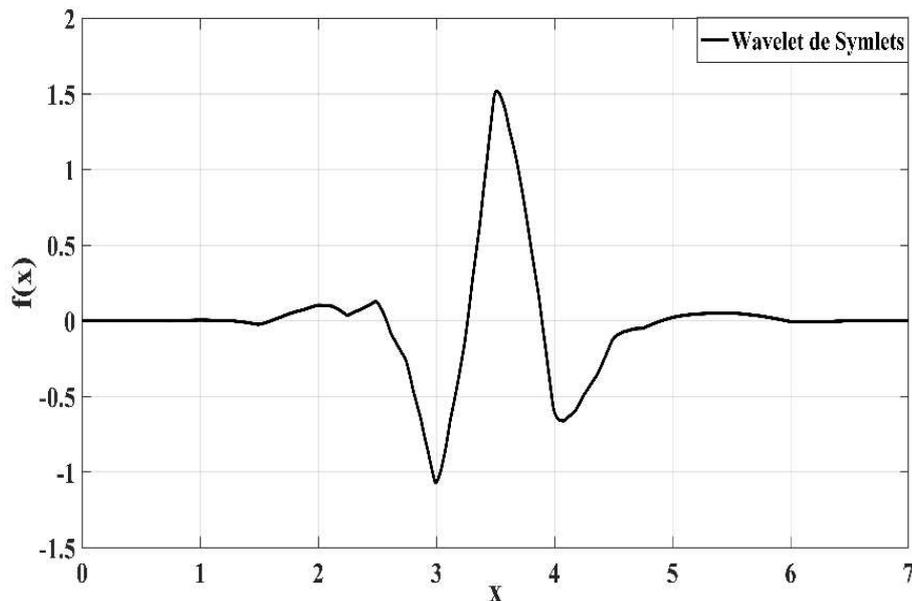


Figura 6. Função da Wavelet de *Symlets* no plano cartesiano x e $f(x)$. Fonte: Autor (2023).

Resumindo, a análise Wavelet será realizada da seguinte forma: **i)** TWC para analisarmos as frequências instantâneas ou períodos das VM; **ii)** WC para investigar o padrão e fase de coerência entre duas VM; **iii)** TWD para processar as VM, que chamaremos de variáveis meteorológicas suavizadas pela Wavelet Symlets (VMW), que servirão de dados de entrada para a RNA.

3.4 Redes neurais artificiais (NAR, NARX e LSTM)

A previsão das VM foi realizada por meio do uso de três RNAs: **i)** *Nonlinear Autorregressiva* (NAR); **ii)** *Nonlinear Autorregressiva with eXogenous inputs* (NARX); **iii)** *Long and Short Term Memory* (LSTM). Ambas as RNAs são recorrentes e pertencentes à abordagem de *Deep Learning*. Das três RNAs a LSTM é a que possui mais camadas ocultas e pode aprender dependências de longo prazo entre etapas de tempo da série temporal. NAR e NARX possuem um funcionamento praticamente idêntico, diferenciando-se na introdução dos sinais de entrada e/ou destino (SAMET *et al.*, 2019; SANTOS *et al.*, 2020).

Segundo SARAIVA *et al.* (2021) a arquitetura da RNA é caracterizada pela sua topologia, algoritmo de treinamento e nós. Os nós são elementos computacionais simples que interagem localmente, são também processadores simples inspirados por suas contrapartes biológicas (neurônios cerebrais). Os neurônios artificiais realizam cálculos baseados na informação de entrada: eles somam o produto dos vetores de

entrada A com pesos W_j , subtraem a ativação residual interna T_h representada como uma bia, e então transformam este resultado em uma forma funcional $f(*)$ (BERREZZEK et al., 2019; SANTOS et al., 2022). Com isso a Eq. (9) fica desta forma:

$$f(W_j A - T_{h_i}) = f\left(\sum_{i=1}^n (W_{ij} A_i - T_{h_i})\right) \quad (9)$$

Um parâmetro importante presente no algoritmo das RNAs utilizadas são as funções de ativação: Sigmoide (Eq. (10)), Tangente Hiperbólica (Eq. (11)) e Linear (Eq. (12)). A função de ativação tem uma característica em que x pode assumir qualquer valor, seja ele infinitamente positivo ou negativo, mas $f(x)$ sempre estará dentro do intervalo aberto entre 0 e +1 (Sigmoide) e entre -1 e +1 (Tangente Hiperbólica). É uma função continuamente diferenciável e não linear com formato de S , servem de entrada para a camada seguinte, elas reduzem o efeito de valores extremos de entrada, proporcionando um melhor funcionamento da RNA (VIGANÓ et al., 2017; SANTOS et al., 2020).

Matemáticos e cientistas da computação relatam que a função sigmoide, conforme mostrado na Figura 7, é mais favorável para previsão de VM, pois ela não propaga valores negativos (NASCIMENTO et al., 2023). Para as RNAs-NAR e -NARX utilizaremos a função de ativação Sigmoide na camada oculta. Na RNA-LSTM utiliza-se ambas as funções (Sigmoide e Tangente Hiperbólica). E a função Linear é utilizada apenas na camada de saída para ambas as RNAs.

$$f(x) = \left(\frac{1}{1 + e^{-x}}\right) \quad (10)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (11)$$

$$f(x) = x \quad (12)$$

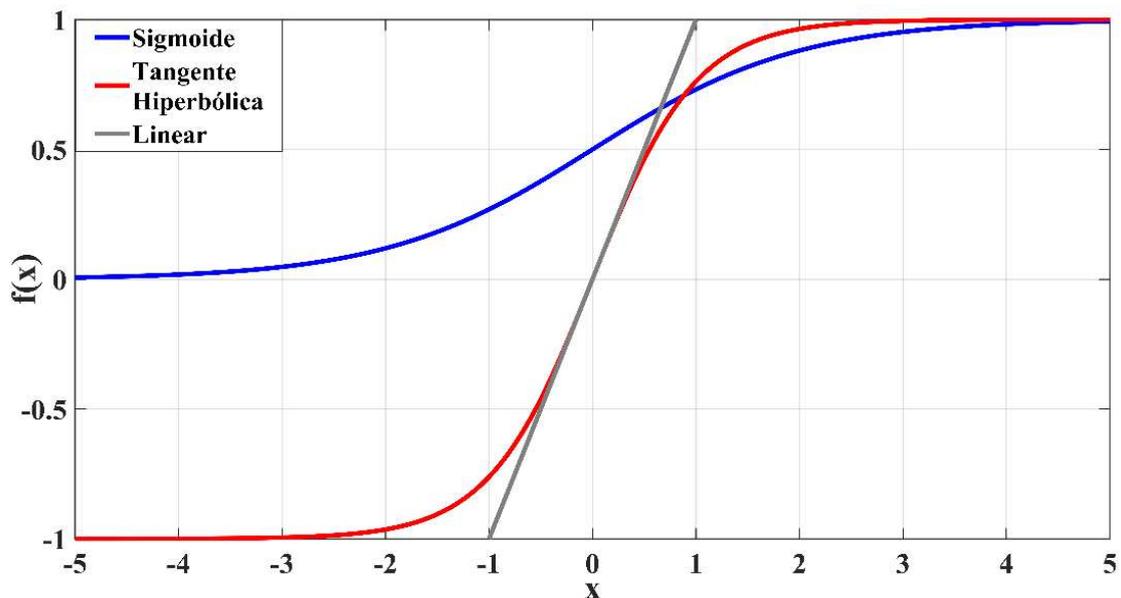


Figura 7. Funções de ativação Sigmoide, Tangente Hiperbólica e Linear no plano cartesiano x e $f(x)$. Fonte: Autor (2023).

O algoritmo de treinamento e aprendizagem das RNAs utilizadas foi o *Levenberg-Marquardt* (LM), é um processo pelo qual os parâmetros são ajustados por meio de estimulação contínua do ambiente externo, de modo que a RNA aprenda situações de causa e efeito (aprendizado supervisionado) – (VIGANÓ et al., 2017; CARMO, 2022). O parâmetro de desempenho das RNAs-NAR e -NARX é o erro médio quadrático (EMQ) – (Eq. (11)), para a RNA-LSTM é a raiz do erro quadrático médio (REQM) – (Eq. (12)). Estes parâmetros identificam o quanto as RNAs conseguem reproduzir os dados de entrada/destino ao longo do treinamento, teste e validação. O EMQ realiza a média do quadrado da diferença entre o valor de predição $y(t + 1)$ e o valor de entrada $x(t)$ e/ou destino $y(t)$, a REQM desempenha a raiz quadrada do EMQ (SILVA, 2018).

$$EMQ = \frac{1}{N} \sum_{i=1}^N (y(t + 1) - y(t))^2 \quad (11)$$

$$REQM = \sqrt{\frac{1}{N} \sum_{i=1}^N (y(t + 1) - y(t))^2} \quad (12)$$

O algoritmo das RNAs e os parâmetros utilizados tiveram como referência principal os trabalhos de GONÇALVES (2011), MOURA (2014), SILVA (2018), SANTOS (2019) e BATISTA et al. (2021). A Tabela 2 mostra a configuração final na fase de treinamento das RNAs. Chamaremos de LSTM o prognóstico realizado pela RNA-LSTM e chamaremos de NAR o prognóstico realizado pela RNA-NAR, ambas funcionando apenas com as VM sendo entrada e alvo. Por fim, chamaremos de NARX o prognóstico realizado pela RNA-NARX com o sinal VMW sendo entrada e o sinal VM sendo alvo.

Tabela 2. Parâmetros utilizados na fase de treinamento das RNAs.

Parâmetros	Dados/valores	
RNAs	NAR e NARX	LSTM
Sinais de entrada/alvo	VM e VMW	VM
Algoritmo de treinamento	<i>Levenberg-Marquardt</i> (LM)	
Algoritmo de desempenho	EMQ	REQM
Treinamento	70%	90%
Teste	15%	10%
Validação	15%	-
Camada escondida	1	5
Neurônios na camada escondida	10	100
Função de ativação	Sigmoide	Sigmoide e Tangente Hiperbólica
Camada de saída	1	1
Função de ativação	Linear	
Neurônios na camada de saída	1	1

3.5 Análise estatística

A investigação das VM foi baseada em uma análise individual das variáveis via estatística descritiva (ED), linha de tendência (LT), estatística exploratória (EX), ciclo diário médio, análise de agrupamento mensal. Foi realizada também estatísticas de erro entre as VM observadas e previstas via RNAs, correlações, teste de t-Student e Diagrama de Taylor (DT). Além disso, avaliou-se a VV e DV por meio de função densidade de probabilidade (FDP) e rosa-dos-ventos para identificação da direção resultante do vento.

3.5.1 Estatística descritiva

A ED foi realizada para avaliar as características individuais das VM. Na ED utilizou-se a média (M) – (Eq. (13)), desvio padrão (DP) – (Eq. (14)), coeficiente de variação (CV) – (Eq. (15)), mínimo (Min), primeiro quartil (Q1), mediana (MD), terceiro quartil (Q3), máximo (Max), amplitude total (AT) – (Eq. (16)), coeficiente de assimetria (CA) – (Eq. (17)) e coeficiente de curtose (CC) – (Eq. (18)) aplicada aos dados observados no período de estudo. As equações da ED estão listadas a seguir:

$$M = \bar{x}(t) = \mu = \frac{1}{N} \sum_{i=1}^N x_i(t) \quad (13)$$

$$DP = \sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i(t) - \bar{x}(t))^2} \quad (14)$$

$$CV = \frac{\sigma}{\mu} = \frac{\sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i(t) - \bar{x}(t))^2}}{\frac{1}{N} \sum_{i=1}^N x_i(t)} \quad (15)$$

$$AT = \text{Max}(x(t)) - \text{Min}(x(t)) \quad (16)$$

$$CA = \frac{E(x_i(t) - \bar{x}(t))^3}{\sigma^3} \quad (17)$$

$$CC = \frac{E(x_i(t) - \bar{x}(t))^4}{\sigma^4} \quad (18)$$

Em que, o número total de valores (N) é dado na Tabela 1 última coluna, o índice (i) varia de um a N , $x_i(t)$ são os valores observados com seus respectivos índices, $\bar{x}(t)$ valores médios e $E(*)$ representa o valor esperado da quantidade em estudo.

3.5.2 Linha de tendência

A partir dos gráficos de evolução temporal das VM estudadas foi realizado a LT. Para isso utiliza-se regressão linear simples (RLS) – (Eq. (19)), para indicar se as VM estão com tendência de diminuição, crescimento ou ficar estável durante o período estudado. Os elementos da Eq. (19) $y(t)$ e $x(t)$ representam as VM e os coeficientes angular (a) e linear (b).

$$y(t) = a \cdot x(t) + b \quad (19)$$

O coeficiente de determinação (R^2) – (Eq. (20)), variando entre 0 e 1, será utilizado para medir o ajuste da LT em explicar a variabilidade individual das VM e no gráfico de dispersão será utilizado para avaliar a qualidade do ajuste da RLS entre duas variáveis.

$$R^2 = \left(\frac{\sum_{i=1}^N (x_i(t) - \bar{x}(t))(y_i(t) - \bar{y}(t))}{\sqrt{\sum_{i=1}^N (x_i(t) - \bar{x}(t))^2} \sqrt{\sum_{i=1}^N (y_i(t) - \bar{y}(t))^2}} \right)^2 \quad (20)$$

3.5.3 Estatística exploratória

A estatística exploratória foi baseada no gráfico Boxplot para melhor visualizar algumas métricas da ED, por exemplo, Q1, MD, Q3, assimetria dos dados, amplitude interquartilica e a existência de valores atípicos (*outliers*). Matriz de gráficos de dispersão entre pares de variáveis junto com Histograma, para analisar o relacionamento linear entre as variáveis e para identificar a frequência de ocorrência percentual das classes das variáveis.

Foi realizado também gráfico misto (Linha e Barras) para verificar o comportamento das VM mensal com a presença de Precipitação Acumulada Mensal (PAM), *El Niño-Oscilação Sul* na região 3.4 (ENOS34), *Tropical Southern Atlantic Index* (TSA), *Tropical Northern Atlantic Index* (TNA) e *Southern Atlantic Ocean Dipole Index* (SAODI). Os valores da PAM são do município de Arapiraca, região mais próxima de Craíbas, distância em linha reta de aproximadamente 30 km, cálculos realizados no APÊNDICE (A). Os dados foram disponibilizados pela Secretária de Estado do Meio Ambiente e dos Recursos Hídricos (SEMARH) e contabilizados pelo Instituto Nacional de Meteorologia (INMET) – (SEMARH, 2023).

Os dados do ENOS são calculados pelo seu principal indicador o *Oceanic Niño Index* (ONI). A metodologia do ONI é disponibilizada em: https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostu-ff/ONI_v5.php. As condições de *El Niño* (fase positiva) existem quando o ONI é igual ou maior do que $0,5 \text{ } ^\circ\text{C}$ por três meses consecutivos. As condições de *La Niña* (fase negativa) existem quando o ONI é igual ou menor do que $-0,5 \text{ } ^\circ\text{C}$ também por três meses consecutivos (NOAA, 2023; SANTOS et al. 2023).

O TSA e TNA são indicadores das temperaturas da superfície no oeste do Oceano Atlântico Sul tropical (OAS) e no leste do Oceano Atlântico Norte tropical (OAN), respectivamente. São componentes importantes da variabilidade da TSM no Oceano Atlântico tropical, caracterizado por anomalias quentes ou frias da TSM

(ENFIELD et al., 1999). As metodologias de TSA e TNA estão disponibilizadas em: <https://meteorologia.unifei.edu.br/teleconexoes>.

Segundo NNAMCHI et al. (2011), SAODI é definido pela diferença da anomalia da TSM média em dois setores do Oceano Atlântico, um de aquecimento setor NE (20°W-10°E, 0°-15°S) e outro de resfriamento setor SW (40°W-10°W, 25°S-40°S), respectivamente. Para o cálculo do SAODI é utilizado a TSM do *Extended Reconstructed Sea Surface Temperature* (ERSST) versão 5 (HUANG et al., 2017; SOUZA e REBOITA, 2021). A Figura 8 mostra as regiões dos Oceanos Pacífico e Atlântico onde são mensurados os índices ENOS34, TSA, TNA e SAODI, respectivamente.

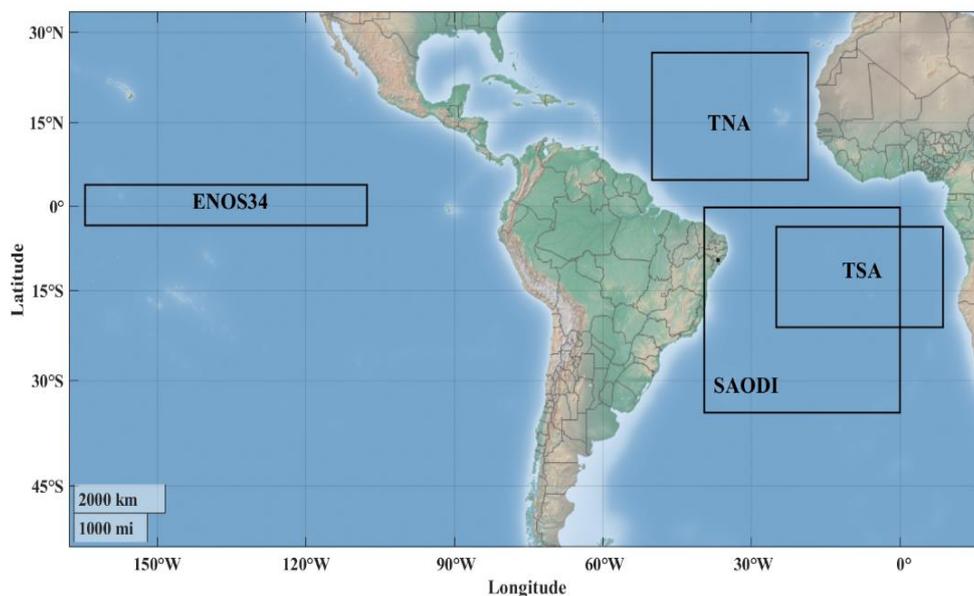


Figura 8. Regiões onde são mensuradas os índices El Niño-Oscilação Sul, Tropical Southern Atlantic, Tropical Northern Atlantic e Southern Atlantic Ocean Dipole. Fonte: Autor (2023).

3.5.4 Ciclo diário médio

Para mostrar uma distribuição temporal representativa das VM o ciclo diário médio foi realizado para transformar todo o período de estudo (14 meses) em 24 horas. Foram transformados também o período chuvoso (abril, maio, junho e julho), período seco (setembro, outubro, novembro e dezembro) e período de transição (janeiro, fevereiro, março e agosto) em 24 horas (RAMOS et al., 2018; OLIVEIRA e SOUZA, 2017).

Para realizar o CDM são utilizados todos os 00:00 minutos do período analisado e finalizado com a média. Depois todos os próximos 00:10 minutos do estudo e média. E assim por diante até utilizar todos os 23:50 minutos do estudo e finalizar com a média. Feito este procedimento o grande número de dados é simplificado, isso facilita a

visualização diária da distribuição temporal das VM (ARANHA, 2016; OLIVEIRA e SOUZA, 2017).

3.5.5 Análise de agrupamento

A análise de agrupamento (AA) foi realizada para agrupar os padrões mensais semelhantes das VM. O método proposto para o agrupamento mensal foi o agrupamento hierárquico de Ward (WARD, 1963), que considera a distância euclidiana entre os meses como uma medida de dissimilaridade (LYRA et al., 2014). A distância euclidiana (DE) é dada pela Eq. (21) a seguir:

$$DE = \left[\sum_{i=1}^N (x_{p.i} - x_{k.i})^2 \right]^{1/2} \quad (21)$$

Em que $x_{p.i}$ e $x_{k.i}$ são as variáveis quantitativas i dos elementos p e k , respectivamente. Para realizar a análise de agrupamento hierárquico nesses dados foi feito os seguintes procedimentos: **i)** utilizamos a Eq. (21) para encontrar a similaridade ou dissimilaridade entre todos os pares mensais das VM; **ii)** agrupamos os meses em um gráfico de árvore de agrupamento hierárquico; **iii)** utilizamos o valor do coeficiente de correlação cofenética (CCC) – (Eq. (22)) para validar a consistência do padrão de agrupamento hierárquico (Dendrograma). Esse procedimento teve como referência o trabalho de LYRA et al. (2014).

$$CCC = \frac{\sum_{i<j} (y_{ij} - \bar{y})(z_{ij} - \bar{z})}{\sqrt{\sum_{i<j} (y_{ij} - \bar{y})^2 \sum_{i<j} (z_{ij} - \bar{z})^2}} \quad (22)$$

Em que y_{ij} é a distância entre os elementos i e j , z_{ij} é a distância fonética entre os elementos i e j . Por fim, \bar{y} e \bar{z} são os valores médios de y_{ij} e z_{ij} , respectivamente.

3.5.6 Estatística de erro

Os indicadores estatísticos utilizados na validação das RNAs (NAR, NARX e LSTM) foram: erro médio (EM) – (Eq. (23)); raiz do erro quadrático médio (REQM) – (Eq. (24)); erro percentual absoluto médio (EPAM) – (Eq. (24)). As métricas estatísticas EM e REQM possuem a mesma unidade de medida das VM e EPAM é dado em porcentagem. As equações são mostradas a seguir:

$$EM = \frac{1}{N} \sum_{i=1}^N (y(t)_i - x(t)_i) \quad (23)$$

$$REQM = \sqrt{\frac{1}{N} \sum_{i=1}^N (y(t)_i - x(t)_i)^2} \quad (24)$$

$$EPAM = \frac{1}{N} \sum_{i=1}^N \left| \frac{y(t)_i - x(t)_i}{x(t)_i} \right| \cdot 100\% \quad (25)$$

Em que, $y(t)$ representa as VM previstas e $x(t)$ as observadas. Existem outras métricas de EE presentes na literatura, mas essas três métricas indicam a acurácia do desempenho das previsões.

3.5.7 Correlação

Foi utilizado a Correlação Pearson (CP) – (Eq. (26)) para medir o grau de correlação entre as VM e entre as VM e suas respectivas previsões:

$$CP = \frac{\sum_{i=1}^N (x_i(t) - \bar{x}(t))(y_i(t) - \bar{y}(t))}{\sqrt{\sum_{i=1}^N (x_i(t) - \bar{x}(t))^2} \sqrt{\sum_{i=1}^N (y_i(t) - \bar{y}(t))^2}} \quad (26)$$

Os elementos $x_i(t)$ e $y_i(t)$ representam as VM observadas e previstas, respectivamente. Os valores da CP foram classificados segundo a metodologia de HOPKINS (2009) – (Tabela 3).

Tabela 3. Intervalos de correlação e sua respectiva classificação. Fonte: Alterado de HOPKINS, 2009.

Classificação	Intervalos
Muito baixa	$ 0,0 \leq CP < 0,1 $
Baixa	$ 0,1 \leq CP < 0,3 $
Moderada	$ 0,3 \leq CP < 0,5 $
Alta	$ 0,5 \leq CP < 0,7 $
Muito Alta	$ 0,7 \leq CP < 0,9 $
Quase perfeita	$ 0,9 \leq CP < 1,0 $

3.5.8 Teste t-Student

Foi realizado também o teste estatístico não paramétrico de hipótese t-Student (Eq. (27)) para verificar o grau real de ligação das VM observadas e previstas (OLIVEIRA e SOUZA, 2017). O teste de t-Student relaciona correlação com grau de liberdade (número de observações utilizadas menos dois):

$$t = \frac{CP \cdot \sqrt{N - 2}}{\sqrt{1 - CP^2}} \quad (27)$$

Em que CP é o coeficiente de correlação de Pearson, N é o número de observações, t é um valor tabelado em um nível de significância APÊNDICE (B). A partir da Eq. (27)

foi extraído o coeficiente de correlação crítico (t_c) – (Eq. (28)), que é um valor para o qual se aceita ou não a hipótese estatística, t_c é dado a seguir:

$$t_c = \sqrt{\frac{t^2}{(N - 2) + t^2}} \quad (28)$$

Para a correlação de 14 meses de dados, ou seja, tem-se $N - 2 = 12$, é o grau de liberdade. Com base nessa informação e utilizando os valores de t e t_c , tabelados e calculados, respectivamente, estão dispostos na Tabela 4.

- Para 99% de significância, ou seja, com erro de 1% ($\alpha = 0,01$); $t = 2,68$; $t_c = 0,61$.
- Para 95% de significância, ou seja, com erro de 5% ($\alpha = 0,05$); $t = 1,78$; $t_c = 0,46$.
- Para 90% de significância, ou seja, com erro de 10% ($\alpha = 0,1$); $t = 1,36$; $t_c = 0,37$.

Tabela 4. Nível de significância, t-Student tabelado e coeficiente de correlação crítico calculado para $N - 2 = 12$ graus de liberdade. Fonte: Autor (2024).

Significância	t	t_c
99%	2,68	0,61
95%	1,78	0,46
90%	1,36	0,37

Isso significa que para os coeficientes de correlação obtidos com 12 graus de liberdade, a significância estatística de que realmente há correlação entre as variáveis é de 99%, 95% e 90% para CP igual ou superior aos t_c (0,61; 0,46; 0,37), respectivamente.

O resultado obtido pode sugerir a aceitação da hipótese de nulidade do coeficiente ou não. Caso os CP calculados sejam iguais ou superiores aos valores de t_c para um determinado grau de liberdade e percentual de significância, a hipótese de nulidade é rejeitada e a tendência observada é verdadeira para aquele nível de significância obtido, e portanto, existe correlação entre as VM observadas e previstas. Este procedimento teve como base os estudos de MENEZES (2010), LIMA (2011) e OLIVEIRA e SOUZA (2017).

3.5.9 Diagrama de Taylor

O Diagrama de Taylor foi realizado para representar graficamente e resumir o grau de correspondência entre as VM previstas e observadas. No DT visualiza-se o coeficiente de correlação de Pearson (Eq. (26)), REQM (Eq. 24) e o DP (Eq. 14) das variáveis. Essas estatísticas juntas são todas indicadas por pontos em um gráfico

bidimensional, quanto mais próximo o ponto (previsto) estiver do ponto (observado), melhor será o desempenho do modelo (TAYLOR, 2001; PEREIRA et al., 2014; TIAN e CHEN, 2021).

Para a construção do Diagrama de Taylor, foram considerados os dados observados $x(t)$ e estimados $y(t)$. A raiz quadrada da média do quadrado das diferenças centralizadas (E') - (Eq. (29)), similar a lei dos cossenos, que relaciona um ângulo interno de um triângulo com seus lados ($a^2 = b^2 + c^2 - 2 \cdot b \cdot c \cdot \cos \theta$). Portanto, a Eq. (29) é dada por:

$$E' = \sigma_{y(t)}^2 + \sigma_{x(t)}^2 - 2 \cdot \sigma_{y(t)} \cdot \sigma_{x(t)} \cdot CP \quad (29)$$

sendo $\sigma_{y(t)}$ e $\sigma_{x(t)}$ os desvios padrão dos dados estimados e observados, respectivamente.

Por fim, TAYLOR (2001) propôs a construção de um diagrama que contenha essas quatro estatísticas E' , $\sigma_{y(t)}$, $\sigma_{x(t)}$ e CP representadas por $\frac{1}{2}$ ou $\frac{1}{4}$ de círculo. Os eixos x e y têm as medidas do desvio padrão, sendo sobre o eixo x colocado o valor de $\sigma_{x(t)}$. A distância radial da origem à posição representando a previsão é o $\sigma_{y(t)}$. O azimute da origem a previsão é proporcional ao CP . A distância entre o ponto do dado observado no diagrama ao ponto do dado estimado é o valor de E' (PEREIRA et al., 2014; TIAN e CHEN, 2021).

3.5.10 Função densidade de probabilidade

A FDP da distribuição de Weibull (Eq. (30)) possui um melhor ajuste ao padrão típico do vento. Dentre as diversas opções disponíveis na literatura, a Weibull é a que melhor representa o comportamento padrão da VV (CRUZ et al., 2017; OLIVEIRA e SOUZA, 2017). Para fins eólicos, existe um consenso mundial para a utilização da Weibull em pesquisas que envolvem análise estatística da VV. A distribuição de Weibull e seus parâmetros de escala (a , m.s⁻¹) – (Eq. (31)) e forma (b , adimensional) – (Eq. (32)) foram otimizados no intervalo de confiança 95%. A função analítica de Weibull e seus parâmetros são mostrados a seguir:

$$f(x(t)|a, b) = \frac{b}{a} \cdot \left(\frac{x_i(t)}{a}\right)^{b-1} e^{-\left(\frac{x_i(t)}{a}\right)^b} \quad (30)$$

$$a(x(t)) = \left[\left(\frac{1}{N}\right) \sum_{i=1}^N x_i(t)^b \right]^{\frac{1}{b}} \quad (31)$$

$$b(x(t)) = \frac{N}{\left(\frac{1}{a}\right) \sum_{i=1}^N x_i(t)^b \log(x_i(t)) - \sum_{i=1}^N \log(x_i(t)^b)} \quad (32)$$

3.5.11 Direção do vento

Para a construção do gráfico da direção do vento predominante utilizamos a metodologia proposta por SILVA (2007). O cálculo da DV é realizado através de decomposição vetorial das suas componentes zonal (u) e meridional (v) – (COSTA e LYRA, 2012; CRUZ et al., 2017; RAMOS et al., 2018). Foram realizados rosa-dos-ventos a partir dos quatro intervalos sazonais Norte, Leste, Sul e Oeste, exatamente nesta sequência com sentido horário. A Tabela 5 mostra as direções divididas em 16 regiões, com faixa intervalar de $22,5^\circ$ para cada região, identificando os pontos cardeais, colaterais e subcolaterais, cuja direção resultante corresponde à sessão da rosa mais preenchida.

Tabela 5. Faixa intervalar com seu respectivo ponto médio para determinação da direção do vento predominante. Fonte: Autor (2024).

Direção	Abreviatura	Intervalo	Ponto Médio
Norte	N	$348,75^\circ - 11,25^\circ$	0°
Norte-Nordeste	NNE	$11,25^\circ - 33,75^\circ$	$22,5^\circ$
Nordeste	NE	$33,75^\circ - 56,25^\circ$	45°
Leste-Nordeste	ENE	$56,25^\circ - 78,75^\circ$	$67,5^\circ$
Leste	E	$78,75^\circ - 101,25^\circ$	90°
Leste-Sudeste	ESSE	$101,25^\circ - 123,75^\circ$	$112,5^\circ$
Sudeste	SE	$123,75^\circ - 146,25^\circ$	135°
Sul-Sudeste	SSE	$146,25^\circ - 168,75^\circ$	$157,5^\circ$
Sul	S	$168,75^\circ - 191,25^\circ$	180°
Sul-Sudoeste	SSW	$191,25^\circ - 213,75^\circ$	$202,5^\circ$
Sudoeste	SW	$213,75^\circ - 236,25^\circ$	225°
Oeste-Sudoeste	WSW	$236,25^\circ - 258,75^\circ$	$247,5^\circ$
Oeste	W	$258,75^\circ - 281,25^\circ$	270°
Oeste-Noroeste	WNW	$281,25^\circ - 303,75^\circ$	$292,5^\circ$
Noroeste	NW	$303,75^\circ - 326,25^\circ$	315°
Norte-Noroeste	NNW	$326,25^\circ - 348,75^\circ$	$337,5^\circ$

3.6 Lei da Potência e Lei Logarítmica

Para a construção do perfil vertical do vento (PVV) foram utilizados os oito níveis de medição (4, 10, 14, 19, 30, 50, 70, 100m). Foi realizado o PVV horário e diário durante todo o período de estudo (38 dias) para melhor visualizar o comportamento do vento no decorrer do dia. As Leis Logarítmicas (Eq. (33)) e de Potência (Eq. (34)) são utilizadas para comparação com o PVMD da VV. As duas leis são descritas abaixo:

$$x(z_r) = \frac{u_*}{k} \cdot \ln\left(\frac{z_r}{z_0}\right) \quad (33)$$

$$\frac{x(z_r)}{x(z_1)} = \left(\frac{z_r}{z_1}\right)^\alpha \quad (34)$$

Para construir um perfil mais condizente com a VV observada adotamos o nível $z_r = 100$ m como altura de referência e $x(z_r)$ como a velocidade de referência, u_* (Eq.

(35)) é a velocidade de fricção, $k \cong 0,4$ é a constante de *Von Kármán*, z_0 (Eq. (36)) é o comprimento da rugosidade do terreno e α (Eq. (37)) é o expoente da camada limite. A altura de referência é recomendada pela Organização Mundial de Meteorologia (OMM) – (OLIVEIRA e SOUZA, 2017).

$$u_* = \frac{k \cdot (x(z_2) - x(z_1))}{\ln\left(\frac{z_2}{z_1}\right)} \quad (35)$$

$$z_0 = \exp\left(\frac{x(z_2) \cdot \ln z_1 - x(z_1) \cdot \ln z_2}{x(z_2) - x(z_1)}\right) \quad (36)$$

$$\alpha = \frac{\ln x(z_r) - \ln x(z_1)}{\ln z_r - \ln z_1} \quad (37)$$

Em que esses parâmetros aerodinâmicos foram encontrados a partir da velocidade do vento nos oito níveis de medição utilizados. O Apêndice (C) mostra os cálculos e procedimento para determinar esses parâmetros aerodinâmicos.

O índice de turbulência (IT) - (Eq. (38)) foi calculado através da razão entre o desvio padrão (Eq. 14) e velocidade do vento média (Eq. (13)) nos oito níveis de medição (n), desta forma:

$$IT_n = \frac{\sigma_n}{\mu_n} \quad (38)$$

O fator de rajadas (FR) – (Eq. (39)) é a razão entre os valores máximos e médios da velocidade do vento. Segundo FISCH (1999) o estudo das rajadas de vento é uma das formas de se analisar a estrutura da turbulência de um determinado local, sendo que as rajadas de vento podem ser definidas como aumento/diminuição repentina da velocidade do vento em ciclos muito pequenos e contínuos (SILVA, 2007; RAMOS et al., 2018).

$$FR = \frac{VV_{Max}}{\mu_n} \quad (39)$$

Por fim, toda a análise estatística (ED, EX, EE), gráficos para visualização do comportamento individual das variáveis (boxplot, rosa-dos-ventos, CDM, histograma, FDP Weibull, TWC e PV) e gráficos que definem um padrão relacional entre as variáveis (WC, DT e misto) foram realizados no *software* computacional *MATLAB*® (versão R2021b).

4 RESULTADOS E DISCUSSÃO

Os resultados serão apresentados e discutidos por meio de análise estatística e vários tipos de gráficos que representam o comportamento individual e relacional das variáveis meteorológicas velocidade e direção do vento, temperatura do ar, umidade relativa do ar e pressão atmosférica, com quatro intervalos de medição Total, período de transição, chuvoso e seco e considerando os horários do dia e noite, juntos e separados.

4.1 Características individuais das variáveis meteorológicas

A Figura 9 exibe a distribuição temporal total e sazonal da VV, junto com a linha de tendência e seus respectivos coeficientes. Em todos os gráficos verifica-se coeficiente angular próximo de zero, isso significa que durante o período estudado a velocidade do vento tende a ficar estável, ou seja, tende a manter a variabilidade. Consequentemente, as velocidades médias do PT ($7,01 \text{ m.s}^{-1}$) e PS ($7,3 \text{ m.s}^{-1}$) apresentam velocidades consideradas viáveis para construção de usina eólica (CRUZ et al., 2017; RAMOS et al., 2018). Todos os coeficientes de determinação também foram próximos de zero, indicando que a LT explica muito pouco a variabilidade dos dados. Esses resultados são consistentes com o estudo conduzido por ANJOS (2013), que analisou a série temporal diária e LT da VV e radiação solar a 10 m, no período de 2003 a 2011, na Ilha Fernando de Noronha situada no OAS.

A partir da Figura 9a é possível notar um ciclo sazonal bem definido na intensidade da VV. No PT (Figura 9b) resultou em dois valores extremos, um em janeiro outro em fevereiro, caracterizado como *outliers*. O PC (Figura 9c) apresentou as velocidades mais baixas em comparação com os outros períodos, devido a interação da VV com os sistemas meteorológicos causadores de chuva (MOLION e BERNARDO, 2002; LYRA et al., 2014; MONTEIRO, 2022). Observa-se maior intensidade da VV no PS (Figura 9d), corroborando com a literatura (MOURA, 2014; CHAVES FILHO, 2016; RAMOS et al., 2018). A exceção foi o mês de novembro de 2014, um sistema meteorológico alterou a intensidade da velocidade do vento por aproximadamente uma semana.

Vários estudos representaram a VV num gráfico de evolução temporal apenas com o intervalo total, por exemplo: AVDAKOVIC et al. (2016) na cidade de Sarajevo, Bósnia; CHAVES FILHO (2016) na região NEB; OLIVEIRA e SOUZA (2017) no estado da Paraíba; ROCHA et al. (2018) no bioma Cerrado do Mato Grosso; KHELIL et al. (2020) nas regiões da Annaba, Sidi Bouzid e Tetouan em seus respectivos países Argélia, Tunísia e Marrocos; SAMET et al. (2019) em Soltaniyeh, província de Zanjan, localizado no Irã; SANCHES e SUSKI (2022) em Florianópolis, Santa Catarina.

Outras pesquisas consideraram também o intervalo sazonal e mensal, por exemplo: GONGALVES (2011) na região NEB; LIMA (2011) no estado da Paraíba; CARVALHO et al. (2012) localizado na parte central de Portugal; RAMOS (2012) no estado de Alagoas; MOURA (2014) e RAMOS et al. (2018) ambos realizados em Girau do Ponciano, Alagoas; CHANG et al. (2017) região de Taipei, Taiwan; XU et al. (2021) na província de Sichuan, China.

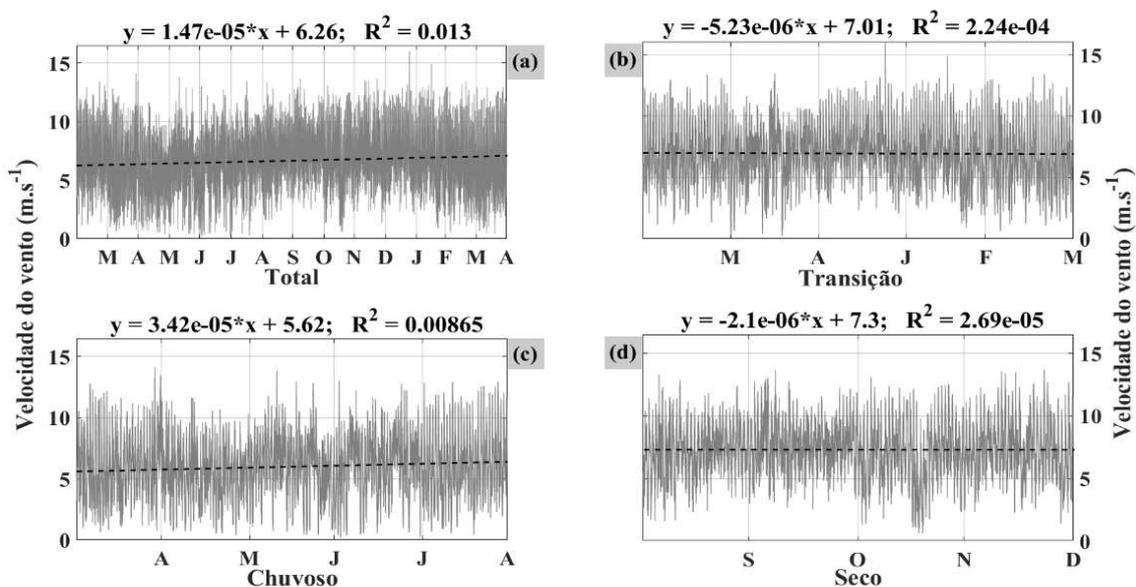


Figura 9. Evolução temporal da velocidade do vento (a) Total, (b) período de transição, (c) período chuvoso e (d) período seco. Fonte: Autor (2023).

A Figura 10 mostra a evolução temporal do período inteiro e sazonal da DV. Novamente, os dados apresentaram coeficiente angular próximos de zero, indicando que a DV tende a ficar estável no período estudado, ou seja, também tende a manter a variabilidade. Conseqüentemente, os coeficientes lineares indicam a direção predominante do vento ESE (Tabela 5). Os coeficientes de determinação da DV foram um pouco melhor do que os da VV, com exceção do R^2 do período chuvoso, isso indica que a LT da DV também explica pouco a variabilidade dos dados.

O ciclo sazonal da DV (Figura 10a) é bem definido. O PC (Figura 10c), além de diminuir a intensidade da VV, aumenta a variabilidade da DV. Por exemplo, tomando como referência as LT, claramente observa-se que o PC apresentou mais direções próximas de zero, se distanciando mais da direção predominante, do que o PT (Figura 10b) e PS (Figura 10d). Isso é devido à interação da DV com a precipitação, fatores climáticos e geográficos, por exemplo, rugosidade superficial e fisiografia.

Esses resultados concordam com o estudo de RAMOS et al. (2018) realizado na região Agreste de Alagoas, intervalo de medição 10 min, período de estudo 3,1 anos (outubro de 2007 a outubro de 2010), com três períodos para identificação dos padrões sazonais: Anual, estação seca (outubro-janeiro) e estação chuvosa (maio-agosto). Os resultados mostraram que a VV em 50 m de altura foi superior a 7 m.s^{-1} , atingindo $8,5 \text{ m.s}^{-1}$ no período seco e os ventos mais intensos ($\geq 10 \text{ m.s}^{-1}$) foram observados durante a noite. A DV varia pouco, oscilando ente NE e SE.

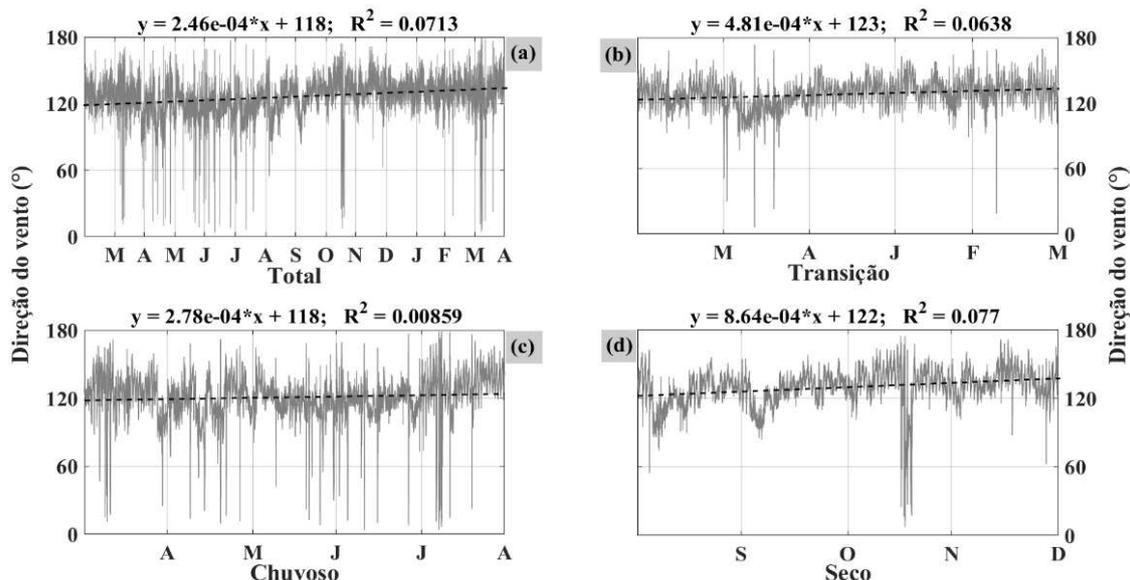


Figura 10. Evolução temporal da direção do vento (a) Total, (b) período de transição, (c) período chuvoso e (d) período seco. Fonte: Autor (2023).

CARVALHO et al. (2012) simularam a velocidade e a direção do vento via modelo WRF em um terreno complexo de Portugal. Para a validação do modelo, foram utilizados dados de três estações de medição de vento, com intervalo de 10 minutos, durante janeiro (inverno) e junho (verão) de 2008. Esse estudo também realizou a evolução temporal da velocidade e direção do vento para ambos os meses. Os resultados mostraram que a variabilidade da DV é maior em janeiro do que em junho, devido à interação dessa variável com o terreno e eventos climáticos sazonais. Uma consequência dessa maior variabilidade é a DV predominante em janeiro que variou entre W, SW e E, enquanto em junho é NNW. Os resultados também mostraram que o modelo WRF é capaz de reproduzir com precisão o regime do vento, mas em todas as simulações apresentou tendência de subestimação para a VV.

As Figuras 11 e 12 apresentam a distribuição temporal total e sazonal da temperatura e umidade relativa do ar. Utilizando os argumentos das figuras anteriores, com isso a TA e UR também tendem a manter a variabilidade no período estudado e a LT explica pouco a variabilidade dos dados.

Vale destacar, que em comparação entre os períodos sazonais, o PS das variáveis da temperatura e umidade relativa do ar apresentaram as inclinações da LT mais expressivas, indicando que a TA no PS é quem mais tende a aumentar, ao contrário da UR que mais tende a diminuir. Este comportamento é decorrente do ciclo anual. Essa proporcionalidade inversa entre TA e UR ocorrem devido à variação de radiação solar que atinge a superfície, o ar perde vapor de água (H_2O) à medida que é aquecido. Maior incidência de energia solar aumenta a TA, aumenta a capacidade de retenção de água na atmosfera e dificulta a entrada de água na atmosfera, consequentemente a UR diminui (VAREJÃO-SILVA, 2006).

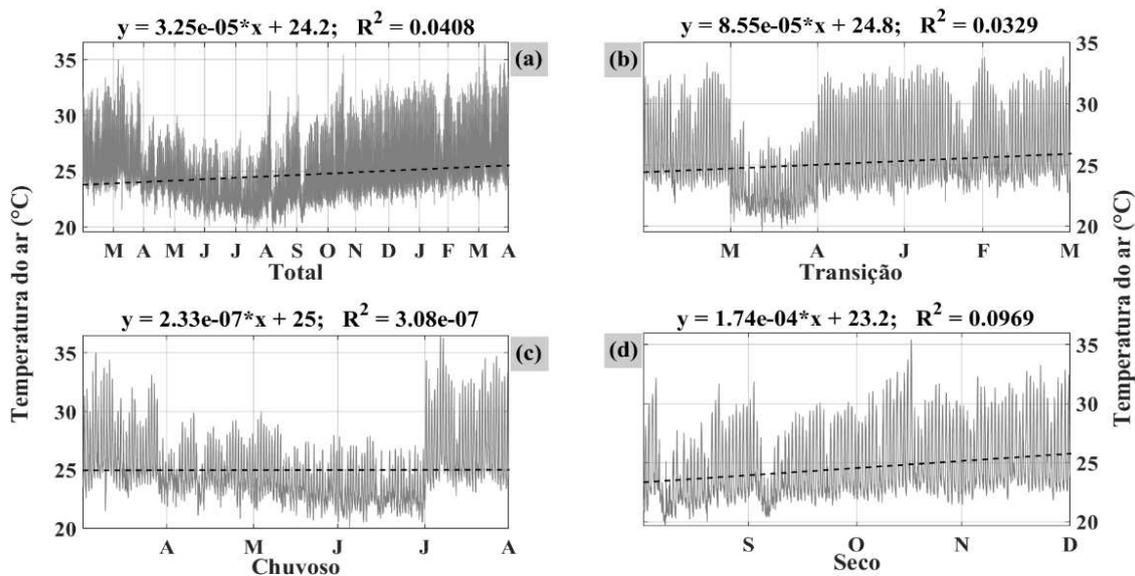


Figura 11. Evolução temporal da temperatura do ar (a) Total, (b) transição, (c) chuvoso e (d) seco. Fonte: Autor (2023).

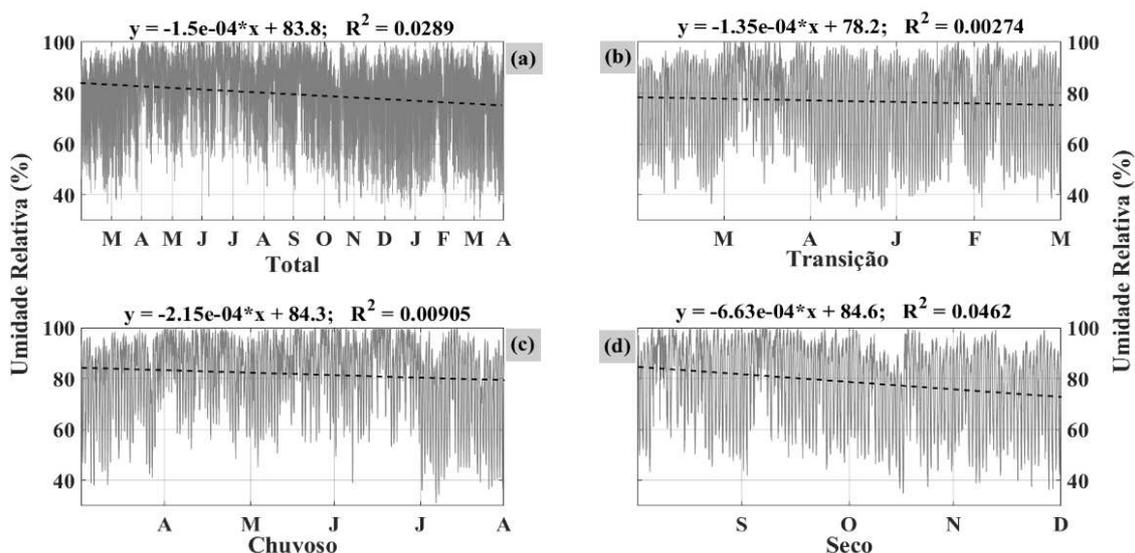


Figura 12. Evolução temporal da umidade relativa do ar (a) Total, (b) transição, (c) chuvoso e (d) seco. Fonte: Autor (2023).

LOPES e JARDIM (2012) investigaram a relação entre uso da terra e topografia nas variações de temperatura e umidade relativa do ar em área urbana e rural nos municípios de Contagem e Betim, centro-sul do estado de Minas Gerais. A medição dos dados climáticos ocorreu durante o inverno (20/06 a 21/09/2011) de forma contínua e simultânea, com intervalo horário. Os gráficos de evolução temporal da TA e UR em ambas as regiões foram inversamente proporcionais. A TA na área urbana apresentou um atraso na distribuição horária e menor amplitude quando comparados a TA na área rural. Atribui-se esses fatos à situação topográfica, características de conservação e produção de calor no meio urbano, associado ao baixo calor específico dos materiais

utilizados na construção civil, maior densidade de edificações, relativa ausência de áreas verdes e participação de fontes adicionais de calor de origem antropogênica.

A Figura 13 mostra a evolução temporal total e sazonal da PA. De forma análoga as outras variáveis, a PA também tende a manter a variabilidade no período estudado e a LT explica pouco a variabilidade dos dados. Destaque para o maior coeficiente de determinação, dentre todos encontrados, da PA no PS (Figura 13d), em que R^2 explica quase 30% da variabilidade dos dados, este comportamento é decorrente do ciclo anual.

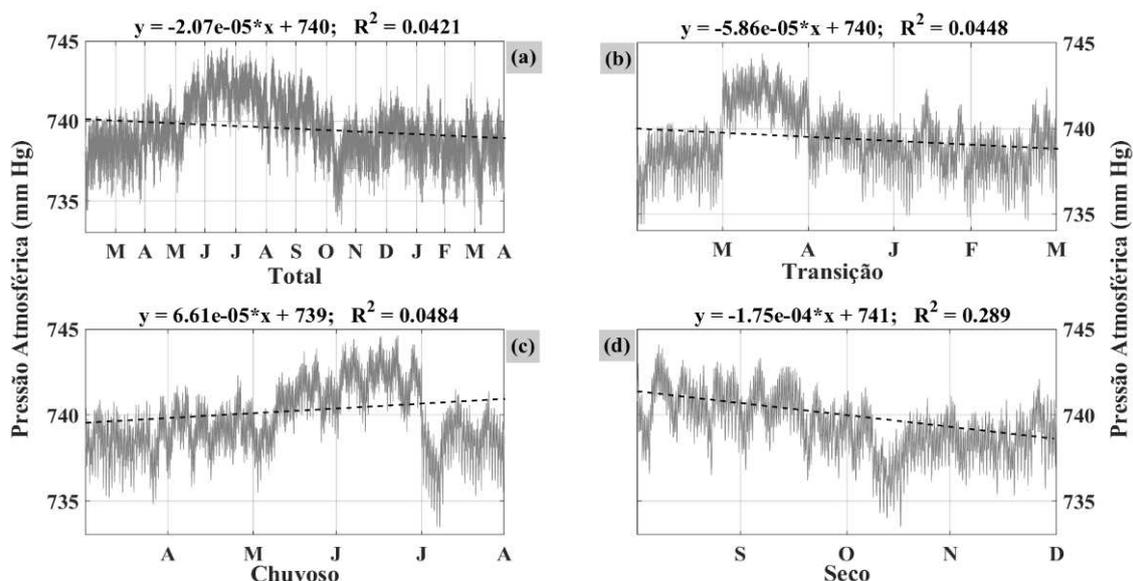


Figura 13. Evolução temporal da pressão atmosférica (a) Total, (b) transição, (c) chuvoso e (d) seco. Fonte: Autor (2023).

AVDAKOVIC et al. (2016) construíram gráficos de distribuição temporal anual de VM (VV, UR, TA e PA) e material particulado 10 (PM10) na cidade de Sarajevo, Bósnia. Os dados eram horários e o período de estudo foi todo o ano de 2012. Os gráficos de evolução temporal mostraram que as maiores concentrações de PM10 ocorrem especialmente no inverno (janeiro, fevereiro e dezembro), coincidindo com menores (maiores) médias mensais da TA (UR). Os resultados mostraram que a TA e a PA tiveram um impacto mais significativo na concentração de PM10 em comparação com a VV e a UR. Os resultados também mostram que o aumento da TA, durante o verão, e da PA, durante o outono e inverno, coincidiram no aumento das concentrações de PM10.

A Tabela 6 apresenta a estatística descritiva das VM. Os maiores valores do DP foram observados na série temporal DV e UR comparados com a PA, VV e TA, respectivamente. A interação do vento com a rugosidade superficial aumentou a faixa de variabilidade da DV. As características do clima local, tal como altas taxas de insolação, alta temperatura, baixa precipitação, entre outros fatores, contribuem para a diminuição da UR. Em termos de comparação entre as variáveis com diferentes médias,

o CV indica a homogeneidade da série temporal. Portanto, a VM mais homogênea é a PA e a VV é a mais heterogênea (VAREJÃO-SILVA, 2006).

Vale destacar a VV média do PS de $7,28 \text{ m.s}^{-1}$, que segundo SILVA (2007) esta velocidade é considerada viável para implantação de parques eólicos para o aproveitamento das energias renováveis. A DV média indica a direção predominante do vento SE (Tabela 5), devido à atuação da Alta Subtropical do Atlântico Sul (ASAS) e Alísios de Sudeste na região NEB. Uma segunda predominância de ESE, devido a interação do vento com a precipitação (LYRA et al., 2014; RAMOS et al., 2018).

Segundo CHANG et al. (2017) valores de assimetria e curtose (0 e 3) representam uma distribuição Normal. Todas as variáveis avaliadas no estudo desviaram pouco da distribuição normal, exceto para a DV, que apresentou valores discrepantes. Vale destacar que todas as variáveis apresentaram $CC > 0,263$ (distribuição Platicúrtica), que é uma distribuição mais achatada que a distribuição Normal (MANWELL et al., 2009).

Estudos realizados no Agreste de Alagoas. MOURA (2014) utilizou apenas M e Max para descrever a VV em Girau do Ponciano, com intervalo de 10 min e no ano de 2009. CRUZ et al. (2017) utilizaram M, DP, CV, Min, Max, AT e variância para descrever a VV e DV em Craíbas, com intervalo de 10 min e período de um ano (abril/2014 até março/2015). RAMOS et al. (2018) não utilizaram métricas de estatística descritiva para descrever a VV, DV e TA em Girau do Ponciano, optaram por gráficos de evolução temporal horário e mensal para discutir os valores das VM. SANTOS et al. (2020) utilizaram apenas M, Max e Min para descrever a VV em Craíbas, com intervalo de dados a cada 10 min e o período de estudo foi de apenas um mês (abril/2015). Os resultados dessas pesquisas citadas já indicam que a região do Agreste alagoano tem potencial para produção de energia eólica.

CHANG et al. (2017) utilizaram Min, Max, DP, CA e CC para descrever as variáveis meteorológicas VV, TA e radiação solar global (RSG) em Taipei, Taiwan. Os dados eram a cada 10 min e foram transformados em diários, o período de estudo foi de 10 anos (janeiro/2006 até dezembro/2015). Os resultados mostraram que a VV não apresentou intensidade suficiente para construção de parque eólicos na área de estudo.

Tabela 6. Estatística descritiva da VV – velocidade do vento (m.s^{-1}), DV – direção do vento ($^{\circ}$), TA – temperatura do ar ($^{\circ}\text{C}$), UR – umidade relativa (%) e PA – pressão atmosférica (mm Hg) durante o período de estudo (março/2014 até abril/2015) com quatro intervalos de medição Total, PT - período de transição, PC – período chuvoso e PS – período seco. Métricas estatísticas: M - média, DP – desvio padrão, CV – coeficiente de variação, Min - mínimo, Q1 – primeiro quartil, MD - mediana, Q3 – Terceiro Quartil, Max – máximo, AT – Amplitude Total, CA – coeficiente de assimetria, CC – coeficiente de curtose. Fonte: Autor (2023).

VV	Total	PT	PC	PS	DV	Total	PT	PC	PS
M	6,71	6,96	5,99	7,28	M	125,96	128,56	120,68	129,29
DP	2,28	2,21	2,32	2,05	DP	16,32	12,02	18,93	15,78

CV	0,34	0,32	0,39	0,28
Min	0,19	0,24	0,19	0,60
Q1	5,19	5,43	4,35	5,95
MD	6,73	6,86	6,07	7,24
Q3	8,25	8,46	7,62	8,69
Max	16,01	16,01	14,14	13,69
AT	15,82	15,78	13,95	13,09
CA	-0,06	0,08	-0,03	-0,06
CC	2,77	2,74	2,59	2,85

CV	0,13	0,09	0,16	0,12
Min	3,50	6,10	3,50	7,30
Q1	117,99	121,62	112,18	122,51
MD	127,41	129,02	121,62	130,76
Q3	136,05	136,42	131,34	138,76
Max	178,76	173,56	178,76	174,24
AT	175,26	167,46	175,26	166,94
CA	-1,66	-0,93	-1,57	-1,66
CC	10,89	8,59	9,80	10,19

TA	Total	PT	PC	PS
M	25,19	25,69	25,03	24,75
DP	2,85	2,98	2,65	2,83
CV	0,11	0,12	0,11	0,11
Min	19,54	19,54	20,11	19,63
Q1	23,09	23,66	23,19	22,63
MD	24,42	24,76	24,44	23,69
Q3	26,86	27,79	26,23	26,80
Max	36,38	33,87	36,38	35,41
AT	16,84	14,33	16,27	15,78
CA	0,85	0,61	1,19	0,84
CC	3,02	2,41	4,29	2,76

UR	Total	PT	PC	PS
M	79,18	76,76	81,92	78,80
DP	15,66	16,35	14,51	15,64
CV	0,20	0,21	0,18	0,20
Min	31,05	34,11	31,05	34,85
Q1	67,08	63,00	72,67	65,45
MD	84,70	82,60	86,50	84,20
Q3	91,90	90,60	93,20	91,80
Max	100,00	100,00	100,00	100,00
AT	68,95	65,89	68,95	65,15
CA	-0,72	-0,57	-0,94	-0,62
CC	2,36	2,04	3,03	2,16

PA	Total	PT	PC	PS
M	739,45	740,56	739,72	739,38
DP	1,79	1,98	1,90	1,65
CV	0,002	0,003	0,003	0,002
Min	733,50	734,40	733,50	733,50
Q1	738,20	739,00	738,40	738,20
MD	739,30	741,10	739,50	739,40
Q3	740,70	742,10	741,10	740,60
Max	744,60	744,40	744,60	744,10
AT	11,10	10,00	11,10	10,60
CA	0,16	-0,58	0,10	-0,09
CC	2,68	2,42	2,54	2,77

A Figura 14 mostra o Boxplot total e sazonal das VM. O Boxplot da velocidade do vento (Figura 14a), em todos os períodos, foi simétrico e semelhante, com destaque para o PT que apresentou mais *outliers* (superior e inferior). A exceção foi o PC que não apresentou *outliers* inferior e resultou nas menores métricas estatísticas, por exemplo, Min, Q1, MD e Q3. O Boxplot da direção do vento (Figura 14b) foi o mais compacto dentre todas as variáveis, foi assimétrico e semelhante em ambos os períodos, apresentou a menor amplitude interquartílica (AIQ) e maior ocorrência de *outliers* em comparação com todas as VM. A maior dispersão da variável DV se deve pela sua interação com a precipitação, vegetação e topografia (RAMOS et al., 2018; SILVA et al., 2021; CASTELHANO, 2022).

O Boxplot da TA (Figura 14c) destaca-se a assimetria positiva em todos os períodos e apresentou *outliers* superiores, com exceção do PT. A série UR (Figura 14d) exibiu uma elevada assimetria negativa, maior AIQ e apresentou *outliers* apenas no PC. A assimetria inversa de TA e UR é consequência do efeito da continentalidade e dos fatores climáticos locais que influenciam ambas as variáveis (CASTELHANO, 2022). Por fim, o Boxplot da PA (Figura 14e) apresentou *outliers* em ambos os períodos, mostrou assimetria positiva (Total e PC) e negativa (PT e PS).

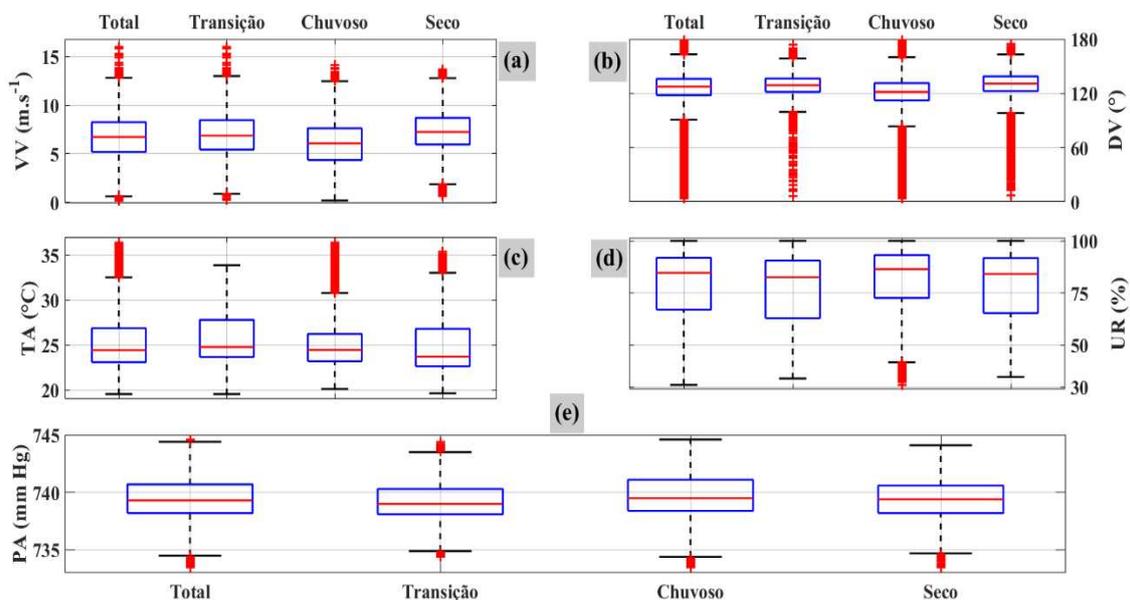


Figura 14. Boxplot das variáveis meteorológicas estudadas com período total e sazonal (a) velocidade do vento, (b) direção do vento, (c) temperatura do ar, (d) umidade relativa, (e) pressão atmosférica. Fonte: Autor (2023).

CASTELHANO (2022) analisou a dinâmica dos ventos na cidade de Aracaju, Sergipe. O período dos dados foi de 2003 a 2019 e a série temporal de VV e DV eram horários. Foram gerados Boxplot que permitiram analisar a oscilação do vento ao longo dos meses e das horas do dia. Os resultados identificaram DV predominante de E, com velocidades médias entre $3,5$ e 4 m.s^{-1} , forte influências de sistemas sinóticos regionais como equatorial atlântico e ZCIT, e de mesoescala como as frentes de brisa marítima.

SILVA et al. (2021) utilizaram Boxplot mensal para caracterizar os padrões sazonais climatológicos de diversas VM, por exemplo, VV, DV, TA, UR, acumulados médios anuais de precipitação, médias de evaporação e horas de brilho solar, na cidade de Manaus, Amazônia, no período de 1961 a 2017. Os resultados indicaram VV média anual baixa de apenas $1,7 \text{ m.s}^{-1}$, podendo atingir valores máximos de 11 m.s^{-1} nos meses menos chuvosos, DV predominante é E seguidas de NE. Os resultados também mostraram uma tendência de aumento na TA e diminuição da UR, devido aos efeitos do crescimento urbanístico em Manaus nos últimos anos, ocasionando recordes máximos na TA e mínimos na UR.

A Figura 15 exhibe o CDM da VV, DV, TA, UR e PA, respectivamente. De modo geral, todos os ciclos diários médios mostraram pequenas variabilidades ao longo do dia. O CDM da VV (Figura 15a), para ambos os períodos, mostrou mínimos próximos às 07 horas e os máximos próximos às 18 horas, com o PC apresentando as menores velocidades e PS as maiores, a exceção está no final da tarde entre às 17 e 19 horas, quando o PT atinge as velocidades máximas. O CDM do PT é quem mais assemelha-se ao CDM do Total.

O CDM da DV (Figura 15b) no PC foi quem mais se distanciou do Total entre todas as variáveis e períodos analisados. O CDM do PT e PS são semelhantes e a maior diferença da direção do vento entre todos os períodos foram entre as 07 e 08 horas. Também é possível determinar a direção predominante do vento pelo CDM da DV, no PS e PT são SE, no PC é ESE e no Total está entre SE e ESE (Tabela 5). Vale destacar a direção do vento entre 115° e 135° intervalo de variabilidade média diária de apenas 20° , muito bom para aproveitamento eólico (CRUZ et al., 2017; RAMOS et al., 2018).

O CDM da TA (Figura 15c) e UR (Figura 15d) foram similares e inversamente proporcionais em todos os períodos, entre às 03 e 06 horas a TA apresentou os valores mínimos e UR os valores máximos, próximo às 14 horas a UR mostrou valores mínimos e TA os máximos. A proporcionalidade inversa entre UR e TA ocorre devido à variação do fluxo de radiação solar, conseqüentemente altera o Balanço de Energia próximo a superfície. A TA está relacionada ao fluxo de calor sensível (Q_H) e a UR ao fluxo de calor latente (Q_{LE}). Com o aumento de raios solares o Q_H é usado pelo sistema Terra-Sol basicamente para aumentar a temperatura, o Q_{LE} é usado pelo sistema para evapotranspiração (evaporação dos corpos d'água e transpiração das plantas). O Q_{LE} não altera a temperatura, altera a quantidade de umidade disponível na atmosfera, o fluxo de radiação solar aumenta a TA, o ar perde vapor d'água à medida que é aquecido e a UR diminui (VAREJÃO-SILVA, 2006).

O CDM da PA (Figura 15e) foi diferente dos anteriores, pois apresentou dois valores extremos, um local (noite) e outro absoluto (dia). Em todos os períodos os máximos e mínimos absolutos ocorreram às 09 horas e entre às 15 e 16 horas, mínimos e máximos locais ocorreram às 03 e 22 horas, respectivamente. A PA apresenta dois extremos, devido à interação gravitacional do sistema Terra-Sol-Lua (MACHADO, 2017). O CDM da PA no PC apresentou as maiores pressões e o PT as menores, o PS é quem mais assemelha-se ao CDM do Total.

Esses resultados concordam com o estudo de ARANHA (2016) que realizou o CDM da VV e TA na região urbana de Campina Grande, Paraíba. Os valores mínimos da TA e VV foram por volta das 05 horas, os máximos foram às 13 e 15,

respectivamente. NASCIMENTO et al (2016), realizaram CDM da TA, umidade específica do ar (UE) e saldo de radiação (SR) em dois sítios experimentais de Rondônia. Os dados foram medidos com intervalo de 10 min, divididos em estações úmida (janeiro a março) e seca (julho a setembro) dos anos 2005, 2009 e 2010. O CDM da TA e UE foram similares e inversamente proporcionais em ambos os experimentos e períodos, apresentaram mínimos e máximos por volta das 07 e 16 horas, respectivamente.

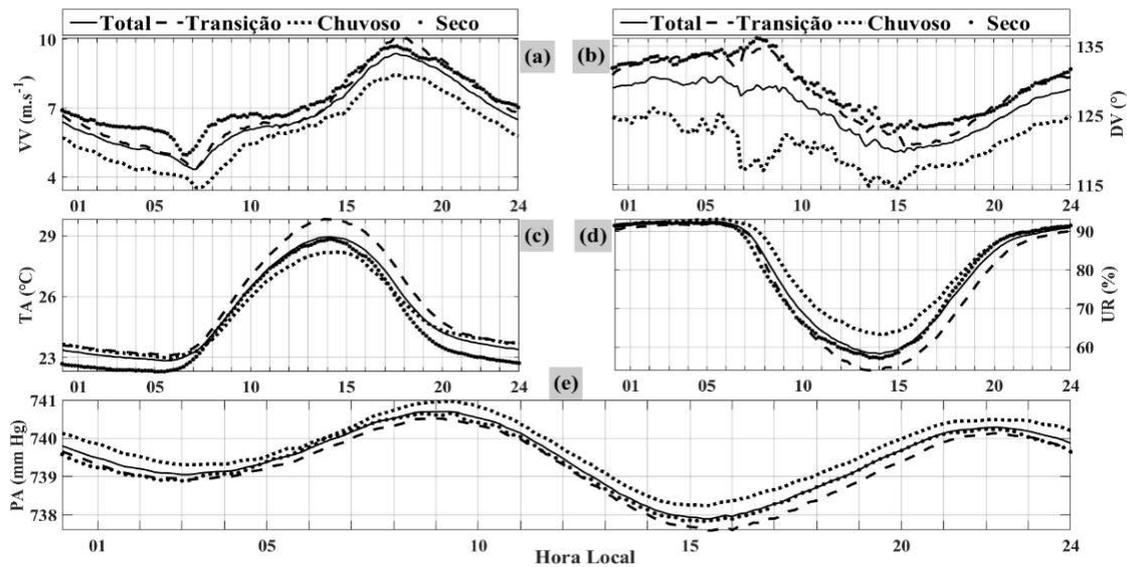


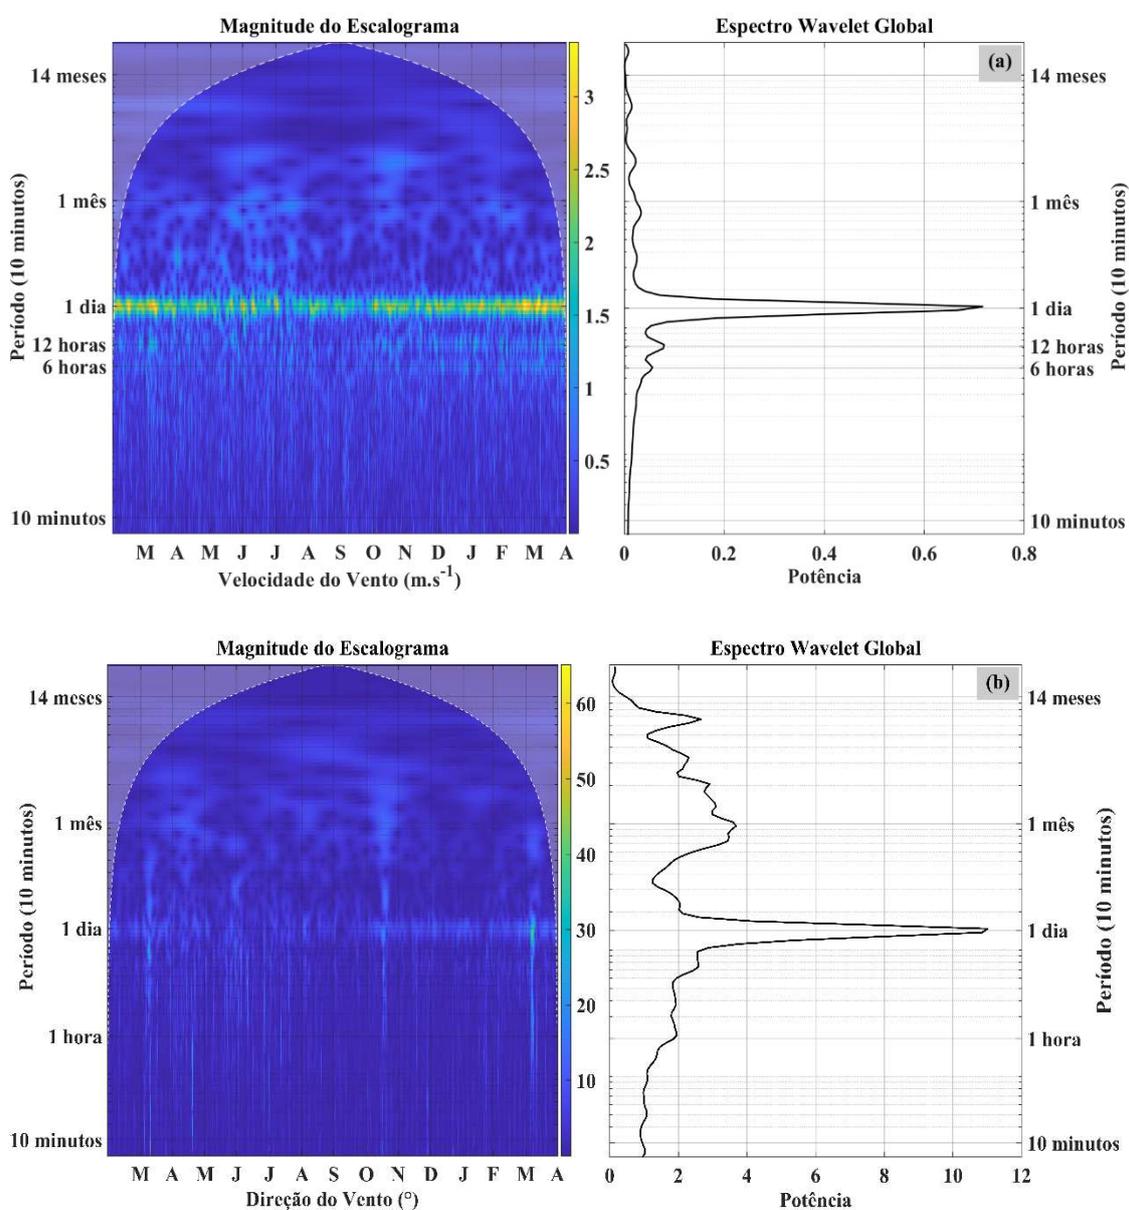
Figura 15. Ciclo diário médio das variáveis meteorológicas estudadas com período total e sazonal (a) velocidade do vento, (b) direção do vento, (c) temperatura do ar, (d) umidade relativa, (e) pressão atmosférica. Fonte: Autor (2023).

A Figura 16 mostra a magnitude do escalograma e o espectro Wavelet global (EWG) para as cinco VM. A técnica de TWC mostra as principais periodicidades das séries temporais. No escalograma as cores indicam a energia associada a cada período da série temporal, as partes em azul escuro indicam oscilação irregular ou ausente, a linha branca tracejada representa o Cone de Influência (COI) e o espectro de potência acima do COI é incerto devido aos efeitos de borda (CHANG et al., 2017). Segundo VILANI e SANCHES (2013), através do EWG é possível verificar a importância dos picos de potência espectral com base no espaço tempo-frequência.

A periodicidade de 1 dia está presente em todas as VM, sendo a principal para a VV, DV, TA e UR (Figura 16a, b, c, d). A exceção foi a PA (Figura 16e), que apresentou uma periodicidade principal de 12 horas. Essas periodicidades estão associadas ao clima local, variação horária da radiação solar durante o dia e devido à interação gravitacional do sistema Terra-Sol-Lua (VILANI e SANCHES, 2013). As variáveis DV e PA também apresentaram periodicidade mensais com menor potência quando comparadas as periodicidades dominantes. Isso indica que essas VM apresentaram um padrão de oscilação significativa durante o período estudado, e a

periodicidade de 12 horas e 1 dia evidencia uma sazonalidade bem definida dessas variáveis (PALÁCIOS et al., 2016).

As VM apresentaram magnitude e potência espectral distintas. A UR exibiu a maior potência espectral, seguido pela DV e TA, respectivamente. O espectro da PA e DV foram os mais irregulares dentre as variáveis analisadas, apresentando periodicidades de 12 horas, 1 dia e mensais. O escalograma da DV mostrou mais oscilações irregulares ou ausentes, devido a sua alta variabilidade discutida anteriormente. O escalograma das variáveis VV, TA e UR apresentaram diferença de magnitude entre os períodos, o PC foi menos intenso do que o PT e PS, indicando que a precipitação altera a periodicidade das VM estudadas. Os resultados da análise Wavelet reforçam os obtidos com as análises estatísticas (VELASCO e MENDOZA, 2008).



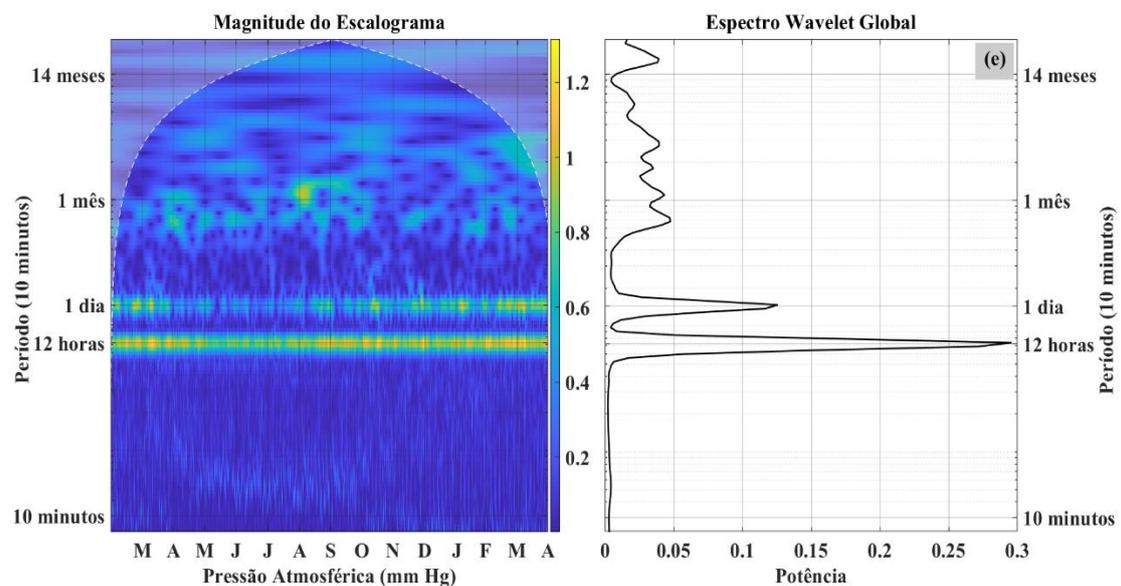
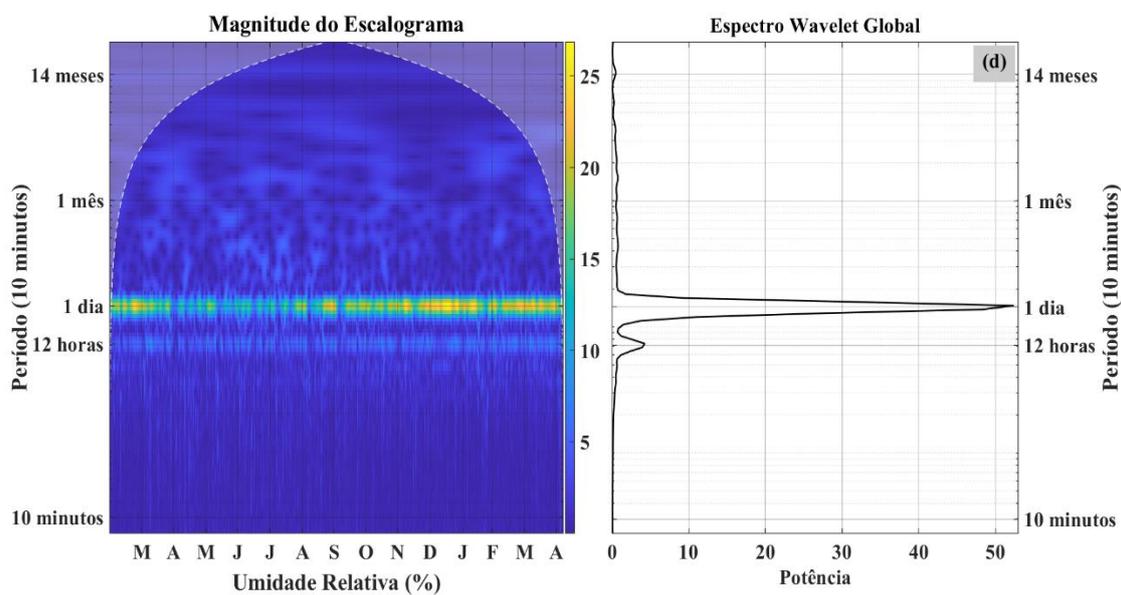
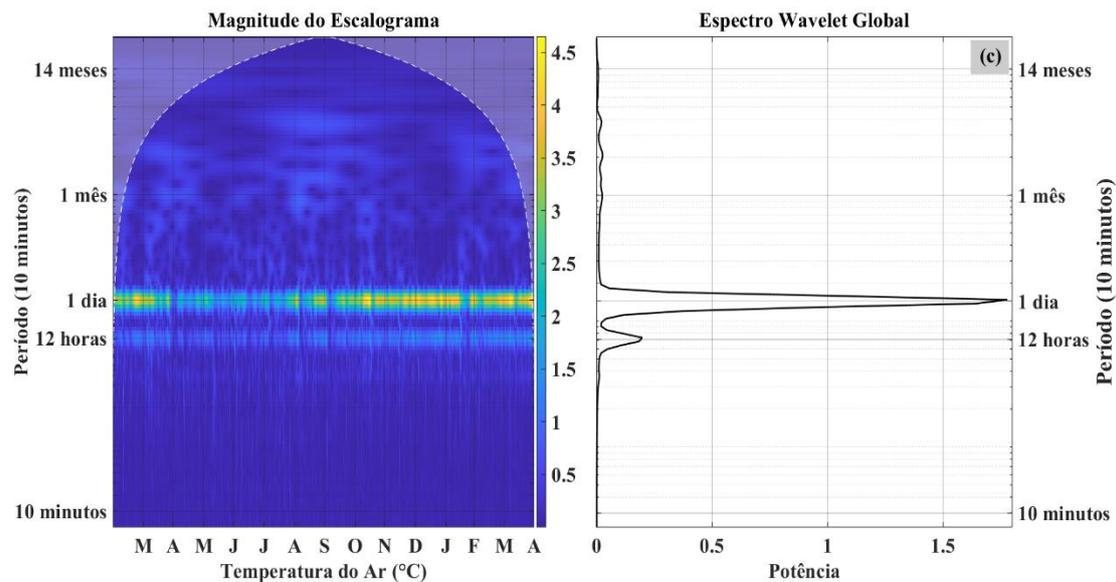


Figura 16. Escalograma e espectro Wavelet global das variáveis meteorológicas estudadas (a) velocidade do vento, (b) direção do vento, (c) temperatura do ar, (d) umidade relativa, (e) pressão atmosférica no período estudado (março/2014 a abril/2015). Fonte: Autor (2023).

Esses resultados foram similares aos estudos de ROCHA et al. (2018) que investigaram a aplicação de análise Wavelet em dados climáticos como TA, UR, PA e VV no Cerrado do Brasil. Os dados eram horários e o período de estudo foram os anos 2015, 2016 e 2017. A análise Wavelet resultou em periodicidade de 24 horas (ciclo diário) para a TA e UR. A VV não apresentou periodicidade do ciclo diário efetivamente uniforme e a periodicidade da PA foi de 4 a 64 dias. Os resultados também mostraram que a sazonalidade da região de estudo é caracterizada pela existência de duas estações anuais, quente-úmida e quente-seca.

O estudo conduzido por CHANG et al. (2017) utilizaram análise Wavelet para investigar a periodicidade de recursos renováveis como VV, TA e RSG na região de Taipei, Taiwan. Os resultados mostraram que o espectro da VV é mais irregular do que a TA e RSG devido aos fatores climáticos e geográficos. Por exemplo, o sítio meteorológico está localizado em uma área que no verão ocorre a chegada de um evento climático com direção do vento de SW com baixa velocidade, enquanto no inverno a direção predominante do vento vem de NE.

THANGSPRASERT e SUWANARAT (2017) investigaram o relacionamento entre VV e TA usando análise Wavelet no Bangkok, Tailândia. O estudo utilizou dados médios horários e diários de janeiro de 2009 a dezembro de 2011. Os resultados mostraram forte periodicidade das variáveis ao redor de um dia (dados horários) e variações entre 256-450 dias (dados diários).

VILANI e SANCHES (2013) analisaram a TA por meio de TWC em três pontos localizados no município de Cuiabá (área urbana) e um ponto na cidade de Chapada dos Guimarães, Mato Grosso (área rural). Os dados de TA foram medidos a cada 30 min no ano de 2007. Os resultados da análise Wavelet para os quatro pontos de estudo apresentou periodicidade de 1 dia, com potências temporalmente significativas de forma esparsa para todo o ano, outra periodicidade significativa ocorreu entre 2 e 32 dias, com EWG mais acentuada nas áreas urbanas. A análise Wavelet diária apresentou periodicidade de 4 a 16 dias (abril) e de 150 a 250 dias (junho a setembro) ambos pertencentes a estação seca (abril a setembro) nessas regiões estudadas.

A Figura 17 mostra o dendrograma dos grupos homogêneos mensais (GHM) das VM analisadas no período estudado. De modo a encontrar grupos mensais divididos nos períodos de transição, chuvoso e seco, determinou-se três grupos (G1, G2 e G3) por meio do método subjetivo, corte transversal no dendrograma, conforme proposto por PINTO et al., 2017. É mostrado também o valor do CCC que mede o grau de preservação das distâncias emparelhadas pelo dendrograma, ou seja, o CCC valida a consistência da análise de agrupamento com intervalo que varia de 0 a 1 (LYRA et al., 2014; SILVA et al., 2020). Segundo a literatura quando o CCC > 0,7 indica que o método de agrupamento é adequado para resumir a informação do conjunto de dados (SOKAL e ROHLF, 1962; WARD, 1963; SARAÇLI et al., 2013).

A Figura 17a exibe o dendrograma dos GHM da VV. Os grupos foram divididos em: G1 (junho e julho de 2014) meses do período chuvoso com baixa intensidade do vento; G3 (maio de 2014) não se agrupou, porque apresentou a menor média mensal da velocidade do vento; G2 é formado pelos 11 meses restantes. Nesse dendrograma destaca-se o G2 constituído por meses dos três períodos (transição, chuvoso e seco) e pelo maior número de meses agrupados dentre todas as VM analisadas. A VV mensal apresentou uma das menores medidas de dissimilaridade, mas foi a única variável que resultou em CCC menor que 0,7, indicando que esse método de agrupamento não é adequado para explicar os dados mensais da VV.

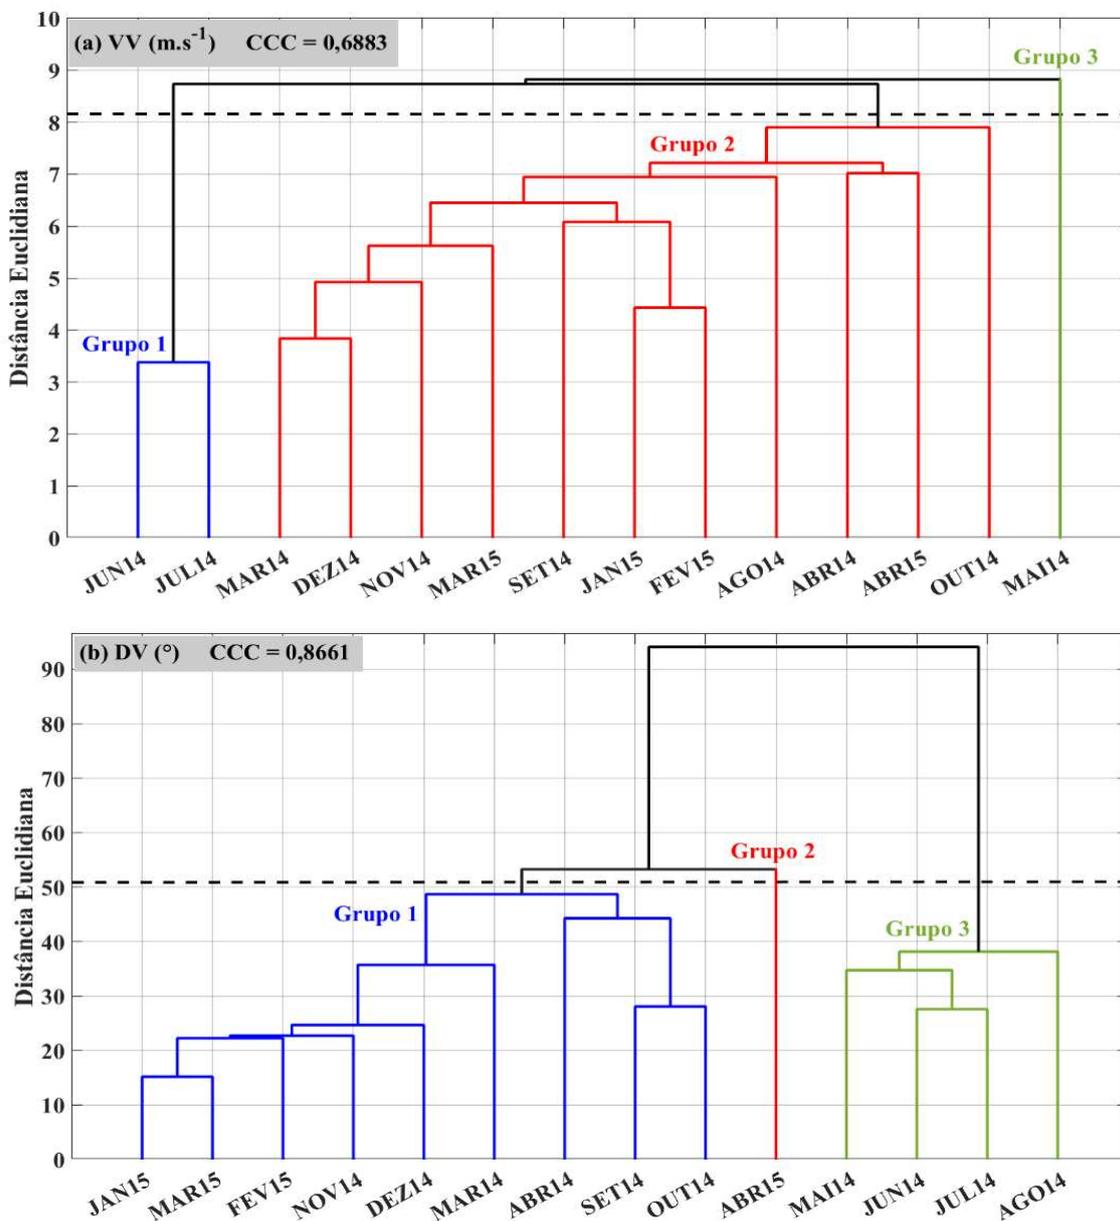
Os GHM da DV são mostrados na Figura 17b. Os grupos foram divididos em: G2 (abril de 2015) não se agrupou, porque apresentou a maior variabilidade mensal da direção do vento; G3 é formado pela sequência de meses consecutivos do período chuvoso e transição (maio, junho, julho e agosto de 2014), resultaram em médias mensais similares; G1 é constituído pelos 9 meses restantes e distribuídos em ambos os períodos. Ao contrário da VV, os GHM da DV apresentaram as maiores medidas de dissimilaridade, porém com valor de $CCC = 0,8661 > 0,7$ que valida a consistência desse agrupamento para resumir os dados mensais da DV.

A Figura 17c mostra o dendrograma dos GHM da TA. Os grupos foram distribuídos em: G3 (julho e agosto de 2014) ambos os meses apresentaram as menores temperaturas; G2 é formado por quatro meses, dois meses chuvosos (maio e junho de 2014) e dois secos (setembro e outubro de 2014), resultaram em temperaturas intermediárias semelhantes; G1 formado pelos 8 meses restantes, distribuídos em todos os períodos e apresentaram as maiores temperaturas. Nesse dendrograma destaque para o maior $CCC = 0,8736$ encontrado dentre todas as VM analisadas, confirmando a adequação desse método de agrupamento em explicar os dados mensais de TA.

A Figura 17d mostra o dendrograma dos GHM da UR. Os grupos foram divididos em: G1 (setembro, outubro e abril de 2014) resultaram em valores intermediários semelhantes; G2 é formado pela sequência de meses consecutivos do período chuvoso e transição (maio, junho, julho e agosto de 2014), conseqüentemente apresentaram as maiores porcentagens de água no ar; G3 constituído pelos 7 meses restantes, distribuídos em todos os períodos e apresentaram as menores porcentagens de umidade. Os GHM da UR apresentaram uma das maiores medidas de dissimilaridade, entretanto com valor de $CCC = 0,8091 > 0,7$ indicando que esse método de agrupamento é adequado para simplificar os dados mensais da UR.

Os GHM da PA são mostrados na Figura 17e. Os grupos foram distribuídos em: G3 (julho e agosto de 2014) apresentaram as maiores pressões atmosféricas, respectivamente; G2 é formado por meses do período chuvoso e seco (junho, setembro e outubro de 2014), porque resultaram em valores intermediários similares; G1 é constituído pelos 9 meses restantes, distribuídos em ambos os períodos e apresentaram as menores pressões atmosféricas. A ED informou que a PA apresenta baixa variabilidade e é a VM mais homogênea dentre as variáveis estudadas, corroborando com os GHM que apresentaram uma das menores medidas de dissimilaridade e com valor de $CCC = 0,8581 > 0,7$, portanto esse método de agrupamento é adequado para sumarizar os dados mensais da PA.

Resumindo, os dendrogramas dos GHM das VM estudadas não apresentaram uma distribuição temporal de acordo com a divisão dos meses para cada período. Em contrapartida, quase todos os CCC foram maiores que 0,7, garantindo que esse método de agrupamento é eficaz para explicar a homogeneidade dos dados mensais das VM. A exceção foi a VV que apresentou CCC menor que o limiar.



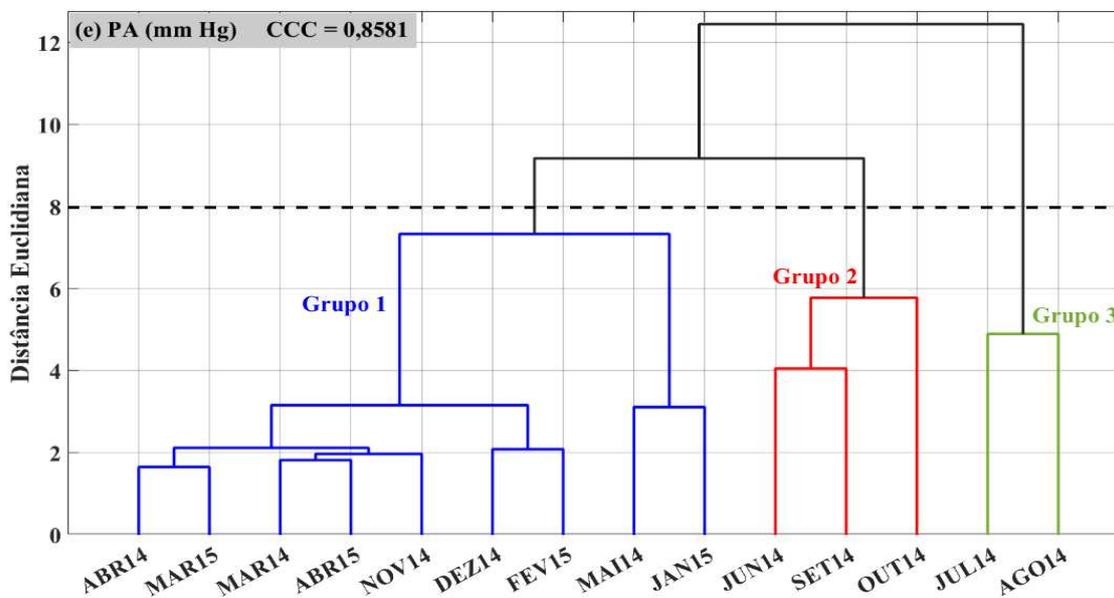
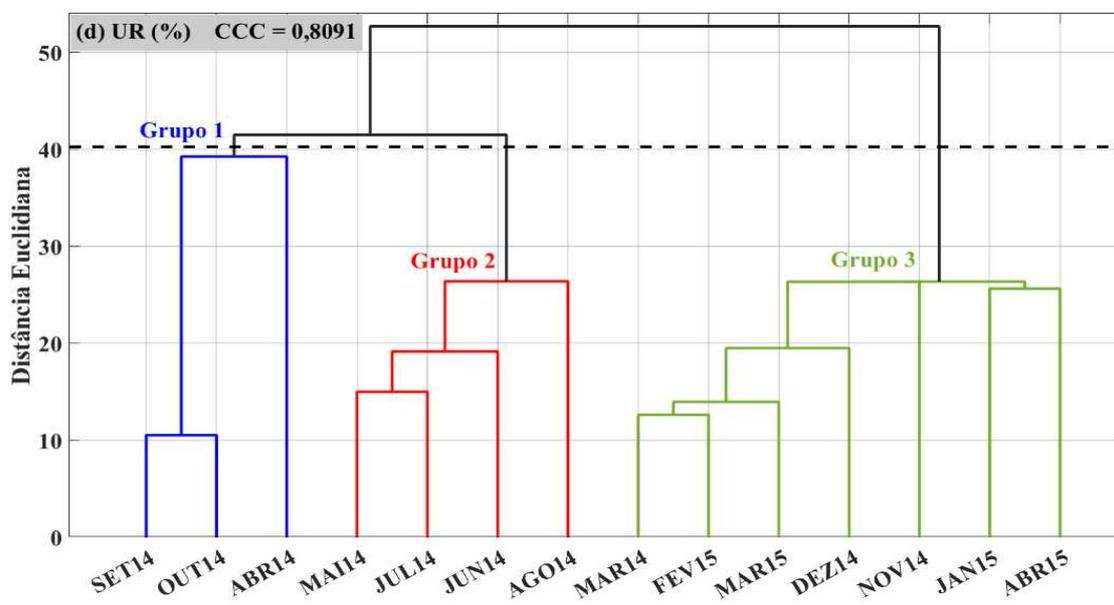
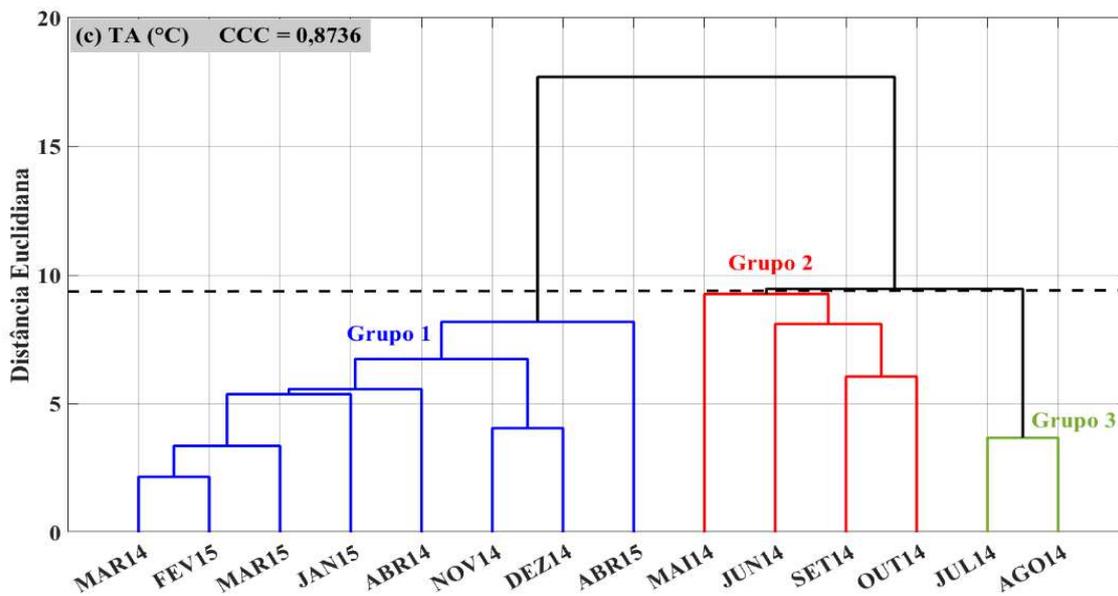


Figura 17. Dendrograma dos grupos homogêneos mensais (G1, G2 e G3) das variáveis meteorológicas estudadas (a) velocidade do vento, (b) direção do vento, (c) temperatura do ar, (d) umidade relativa, (e) pressão atmosférica no período estudado (março/2014 a abril/2015). Fonte: Autor (2023).

SILVA (2011) utilizou análise de agrupamento para identificar regiões homogêneas de vento na área costeira do NEB. Os dados eram horários referentes ao período de 2003 a 2009 para as oito capitais litorâneas. A aplicação de análise de agrupamento resultou em três grupos homogêneos com padrões sazonais distintos: G1 formado apenas por São Luís, devido aos ventos de menor variabilidade entre E-NE; G2 constituído por João Pessoa e Maceió, caracterizada por baixas velocidades; G3 formada por Fortaleza, Natal, Recife, Aracaju e Salvador apresentaram as maiores velocidades.

CARGNELUTTI FILHO (2006) analisaram a variabilidade temporal da temperatura máxima do ar média mensal de 37 municípios do Estado do Rio Grande do Sul. Os dados eram diários e foram coletados no período de 1931 a 2000, totalizando 70 anos de observações. A identificação de meses homogêneos foi verificada por meio de análise de agrupamento, método hierárquico do vizinho mais distante, utilizando-se 60% de similaridade como critério para definição dos grupos. Os grupos foram divididos em: G1 (janeiro, fevereiro, março, abril, outubro, novembro e dezembro) são os meses com menor variabilidade da temperatura máxima do ar; G2 (junho e setembro) são os meses em situação intermediária; G3 (maio, julho e agosto) apresentaram a maior variabilidade.

VAGHETTI et al. (2019) analisaram o comportamento da UR média mensal em regiões homogêneas do Estado do Rio Grande do Sul. Foram utilizados 26 estações meteorológicas no período de 1975 a 2009 (35 anos) e os dados eram médias mensais. Utilizaram análise de agrupamento e método de Ward para identificar as regiões homogêneas, o número de regiões foi realizado de forma subjetiva através do corte no dendrograma, obtendo quatro regiões homogêneas. Os resultados indicaram que todas as regiões apresentaram média alta acima de 70% de UR, a proximidade a costa marítima dita a diferença de UR entre as regiões, quanto mais afastada do oceano é a região menores são os valores da umidade relativa do ar.

A Figura 18 mostra a FDP da distribuição de Weibull aplicada na série temporal da velocidade do vento Total e Sazonal (Transição, Chuvoso e Seco), considerando os horários do dia e noite juntos e separados. Entre os períodos definidos, a FDP Weibull ajusta-se melhor a série temporal Total (Figura 18a, e, i), corroborando com o estudo de RAMOS et al. (2018) realizado em Girau do Ponciano.

Os parâmetros de Weibull (escala e forma) apresentaram um desenvolvimento sazonal distinto, onde a curva de ajuste do PT (Figura 18b, f, j) é mais semelhante ao Total em comparação com os outros períodos sazonais. Os parâmetros de Weibull para o PC (Figura 18c, g, k) foi mais concentrada nos menores valores, escala variando entre 6,48 e 6,94 m.s^{-1} e forma variando entre 2,75 e 2,94, devido a interação da VV com a presença da chuva. Destaque para os maiores valores de escala (7,87 a 8,19 m.s^{-1}) e de

forma (3,77 a 4,25) do PS (Figura 18d, h, l), concordando com a literatura científica (CRUZ et al., 2017; RAMOS et al., 2018).

As maiores porcentagens de densidade de probabilidade para ambos os períodos sazonais ocorreram entre as classes de 7 a 8 m.s^{-1} , a exceção foi o PC que apresentou as maiores porcentagens na classe de 6 m.s^{-1} . Segundo AMARANTE et al., (2001) o melhor cenário para produção de energia eólica é quando o fator de escala da velocidade do vento está concentrado em 7 m.s^{-1} . Portanto, com base nas distribuições de Weibull encontradas, o local de estudo apresentou ventos propícios para a produção de energia eólica, principalmente no PS e PT, respectivamente.

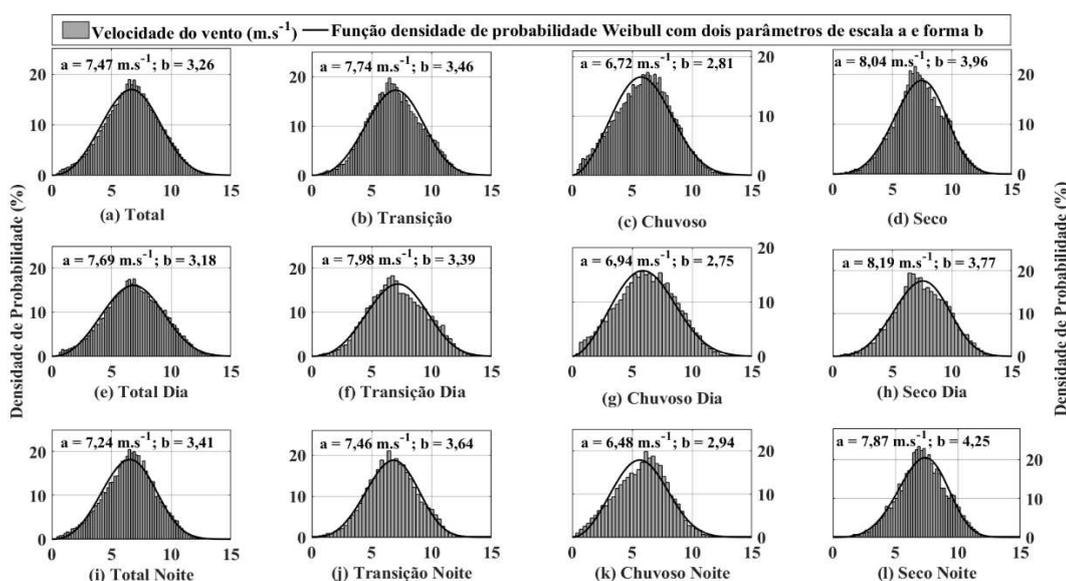


Figura 18. Função densidade de probabilidade da distribuição de Weibull com seus respectivos parâmetros considerando os períodos (a) Total, (b) Transição, (c) Chuvoso, (d) Seco. Considerando os horários do dia (e) Total, (f) Transição, (g) Chuvoso, (h) Seco. Considerando os horários da Noite (i) Total, (j) Transição, (k) Chuvoso e (l) Seco. Fonte: Autor (2023).

Os parâmetros de Weibull encontrados foram próximos aos resultados obtidos por CRUZ et al. (2017), que obtiveram parâmetro de escala de 6,2 a 8,3 m.s^{-1} e o de forma entre 2,67 e 4,25. Já RAMOS et al. (2018), obtiveram parâmetros de escala e forma com dados anuais entre 8,6 m.s^{-1} e 3,5, na estação seca de 9,4 m.s^{-1} a 3,7 e na chuvosa, valores entre 7,8 m.s^{-1} e 4,6. Ambos os estudos foram realizados com dados do Agreste de Alagoas.

Um estudo realizado por OLIVEIRA e SOUZA (2017) avaliou o desempenho dos modelos BRAMS e WRF na simulação do vento nas mesorregiões do Agreste, Borborema e Sertão da Paraíba. Os dados observados eram horários e o período estudado foi setembro de 2010. Os parâmetros de escala e forma encontrados para os dados observados foram: Agreste (10,18 m.s^{-1} e 6,84), Borborema (8,16 m.s^{-1} e 5,07) e Sertão (8,88 m.s^{-1} e 4,92).

AZAD et al. (2014) utilizaram FDP Weibull de dois parâmetros para encontrar características de conservação de energia eólica na Ilha Hatiya em Bangladesh. Os dados de velocidade do vento foram horários, com período de estudo de 10 anos (1998-2007) e foram classificados aproximadamente em período de vento forte de abril a setembro e período de vento fraco de outubro a março. Os parâmetros de escala variaram entre 2,83 e 7,25 m.s^{-1} , os parâmetros de forma variaram entre 1,99 e 3,31.

SHI et al. (2021) realizaram um estudo de caso em que compararam os ajustes da distribuição de Weibull de dois e três parâmetros em diferentes locais. Os dados foram registrados a cada três horas com dois períodos de estudo 1958-2021 e 1956-2021. Os locais de estudo foram Shengsi, ilha do mar da China Oriental, e Xianyang, cidade localizada na Bacia de Guanzhong cercada por montanhas. Em Shengsi, os parâmetros de escala variaram entre 7,19 e 7,46 m.s^{-1} , os de forma variaram entre 1,98 e 2,08 e o terceiro parâmetro local resultou em 0,31. Em Xianyang os parâmetros de escala variaram entre 2,78 e 2,83 m.s^{-1} , de forma variaram entre 1,42 e 1,49 e o terceiro parâmetro local foi de -0,12. Os autores concluíram que as duas distribuições têm basicamente o mesmo ajuste nos dados de velocidade do vento em Shengsi, mas o ajuste da distribuição de Weibull com três parâmetros foi melhor do que a com dois parâmetros em Xianyang.

SEDLIACKOVA et al. (2022) analisaram os dados de velocidade do vento via FDP Weibull no norte da Eslováquia. O período de estudo foi de 11 anos (2005-2015) medidos em três horas do dia 7:00, 14:00 e 21:00. Os resultados apresentaram parâmetros de Weibull mensais, sazonais e anual. Os parâmetros de escala mensais (anual) variaram entre 2,28 e 3,18 m.s^{-1} (2,73 m.s^{-1}), os parâmetros de forma mensais (anual) variaram entre 1,44 e 1,76 (1,55).

A Figura 19 mostra a rosa dos ventos aplicada na série temporal da direção do vento Total e Sazonal, considerando os horários do dia e noite juntos e separados. De forma geral, observa-se duas direções predominantes bem definidas ESE e SE (Figura 19a, e, i). A direção do vento no PT (Figura 19b, f, j) é quem mais assemelhasse com o Total em comparação com os períodos restantes. O PC (Figura 19c, g, k) apresenta direção predominante ESE. Por fim, o PS (Figura 19d, h) resultou em direção predominante ESE e SE, e no período da noite (Figura 19 l) foi SE (Tabela 5).

A DV apresentou uma pequena variabilidade ao longo do período estudado, o PC apresentou o maior intervalo de variabilidade e o PS apresentou o menor, ambos no período noturno. O PC de dia a variabilidade é menor que a noite, mas a direção predominante é exclusivamente ESE. O PS de dia a variabilidade é maior do que a noite e direção predominante é ESE e SE. Segundo COSTA e LYRA (2012), a variabilidade da direção do vento no Estado de Alagoas em ambos os períodos sazonais, diários e noturnos está associada aos ventos alísios.

Esses resultados concordam com o estudo da CRUZ et al. (2017) realizado em Craíbas com direção predominante SE e direção secundária ESE. O estudo constatou que durante a estação chuvosa a direção predominante foi de sentido ESE, tendo sempre como segunda direção predominante SE. Na estação seca, a variabilidade do vento foi menor que na estação chuvosa, com direção predominante SE.

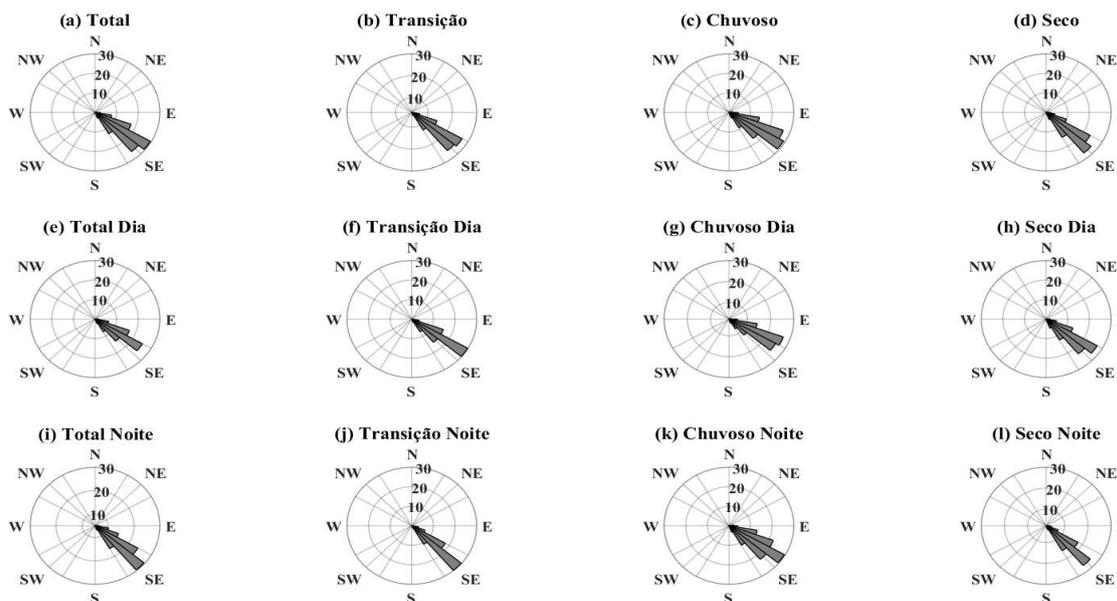


Figura 19. Rosa dos ventos para identificação da direção predominante do vento considerando o período (a) Total, (b) Transição, (c) Chuvoso, (d) Seco. Considerando os períodos do dia (e) Total, (f) Transição, (g) Chuvoso, (h) Seco. Considerando os períodos da Noite (i) Total, (j) Transição, (k) Chuvoso e (l) Seco. Fonte: Autor (2023).

MOLION e BERNARDO (2002) discutiram o padrão sazonal da DV devido a sistemas meteorológicos de diferentes escalas e estão relacionados com regimes de chuva. Em escala sinótica, o deslocamento da circulação Subtropical Atlântica tem seu centro de alta pressão deslocado para a Linha do Equador durante o verão. Os ventos próximos à superfície ao longo da costa brasileira são intensificados durante esse movimento da circulação para o norte (COSTA e LYRA, 2012; RAMOS et al., 2018)

A DV resultante nesse estudo foi diferente da direção do vento encontrada por RAMOS et al. (2018) em Girau do Ponciano. A rosa dos ventos resultou em três direções predominantes NE, E e SE. A direção do vento anual é E, variando para NE e SE durante a estação seca e chuvosa, respectivamente. SILVA (2011) afirmou que a direção predominante em Girau do Ponciano é E, com direções secundárias em ENE e ESE, respectivamente. Ambos os estudos concluíram que o escoamento do vento é forçado pelo relevo local. A região do Agreste alagoano apresenta características montanhosas, como serras e planícies elevadas, com isso a rugosidade superficial, a fisiografia local e fortes variações térmicas canalizam o vento.

CASTELHANO (2022) constatou que a direção predominante do vento na cidade de Aracaju, Sergipe, durante os meses de setembro a março e em todas as horas do dia é majoritariamente E, devido as frentes de brisa marítima que são mais intensas durante os meses de verão. Durante a estação chuvosa (abril a agosto) o vento interage com a precipitação, com isso a direção predominante E diminui e aumenta as direções secundárias no sentido ESE e SE, devido a atuação mais forte dos sistemas polares.

SILVA et al. (2002) determinaram a potência eólica média horária da direção predominante do vento no NEB no período de janeiro de 1977 a dezembro de 1981. Os resultados constataram que a direção predominante do vento no NEB é de E, com

flutuações para SE e NE. A direção predominante do vento em Alagoas, nas cidades de Palmeira dos Índios, Maceió e Coruripe são E, SE e E, respectivamente.

A Tabela 7 apresenta a ED da VV e DV considerando o período do dia e noite separados. Os valores da VV dia foram quase que exclusivamente maiores que o VV noite, indicando que a velocidade do vento no período diário é mais intensa, mais heterogênea e com maior intervalo de variabilidade do que a velocidade do vento no período noturno. Diferente dos resultados de SILVA (2011) em Girau do Ponciano, com ventos noturnos médios de $8,08 \text{ m.s}^{-1}$ maiores do que os ventos diários de $7,23 \text{ m.s}^{-1}$. O estudo também afirma que o fato do vento ser mais intenso a noite do que no dia é característico de regiões mais afastadas do litoral.

Destacam-se os maiores valores M do PS e PT diário e PS noturno ambos com valores acima de 7 m.s^{-1} , atingindo os valores viáveis para implantação de parques eólicos. Entre os períodos sazonais, o PC de dia e de noite apresentaram os menores valores M, entretanto apresentaram os maiores DP, respectivamente, indicando que a maior variabilidade da VV é diária e no PC. Esses resultados concordam com o estudo de BRITO-COSTA (2009) que realizou uma análise espacial e temporal do vento no Estado de Alagoas. O estudo concluiu que entre Litoral, Agreste e Sertão, a região do Agreste apresenta as maiores velocidade do vento médios diários e mensais no período estudado (12/2007 a 11/2008).

Observa-se na Tabela 7 que a DV Total diária e noturna apresentou direção predominante SE. Devido a interação do vento com a precipitação, relevo e vegetação local, variação da incidência solar, entre outros, isso aumenta a faixa de variabilidade da DV resultando em uma direção secundária de ESE. Os períodos sazonais PT e PS diário e noturno também apresentaram direção predominante SE e direção secundária ESE. O PC noite apresentou direção predominante ESE e secundária SE. O PC dia apresentou o maior DP, consequentemente resultou no maior intervalo de variabilidade com direção predominante ESE e direções secundárias E e SE (Tabela 5).

Resumindo, a VV diária é mais intensa e com maior variabilidade do que a VV noturna. Entre os períodos sazonais, o PT assemelha-se com o Total, o PS apresentou as maiores velocidades e o PC as menores, corroborando com a literatura científica (COSTA e LYRA, 2012; CRUZ et al., 2017; RAMOS et al., 2018). A DV Total, PT e PS de dia e noite resultou em SE como direção predominante e ESE como direção secundária. A DV no PC apresentou a maior faixa de variabilidade diária e noturna, respectivamente. A direção predominante do vento no PC dia e noite foi ESE, a direção secundária no PC noite foi SE, e devido à alta variabilidade do vento no PC dia as direções secundárias variaram entre E e SE (SILVA et al., 2002; BRITO-COSTA, 2009; RAMOS et al., 2013; MOURA, 2014).

SILVA (2011) investigou as características do vento em quatro locais do Estado de Alagoas, Maragogi e Roteiro (Litoral), Girau do Ponciano (Agreste) e Água Branca (Sertão). O intervalo de medição dos dados era a cada 10 minutos e o período de estudo foi todo o ano de 2008. Os resultados indicaram que as maiores velocidades médias foram observadas no interior (Agreste e Sertão) em comparação ao litoral do Estado. Para Girau do Ponciano os resultados em m.s^{-1} foram: média anual - MA (7,66), MA dia (7,23), MA noite (8,08), PT (7,26), PC (6,93), PS (8,78), PT dia (6,42), PT noite (8,10), PC dia (6,94), PC noite (6,93), PS dia (8,33) e PS noite (9,23). A direção predominante

anual foi E, direção secundária ENE e direção terciária ESE. No PT as direções foram ENE, E e NE, no PC (ESE, SE e E) e no PS (E, ENE e ESE).

Tabela 7. Estatística descritiva da VV - velocidade do vento ($m.s^{-1}$) e DV - direção do vento ($^{\circ}$) durante o período de estudo (março/2014 até abril/2015) com quatro intervalos de medição Total, PT - período de transição, PC - período chuvoso e PS - período seco, considerando o período do dia e noite separados. Métricas estatísticas: M - média, DP - desvio padrão, CV - coeficiente de variação, Min - mínimo, Q1 - primeiro quartil, MD - mediana, Q3 - Terceiro Quartil, AT - Amplitude Total, CA - coeficiente de assimetria, CC - coeficiente de curtose. Fonte: Autor (2023).

VV dia	Total	PT	PC	PS	VV noite	Total	PT	PC	PS
M	6,89	7,17	6,18	7,40	M	6,51	6,73	5,79	7,16
DP	2,39	2,33	2,45	2,19	DP	2,13	2,05	2,17	1,89
CV	0,35	0,33	0,40	0,30	CV	0,33	0,30	0,37	0,26
Min	0,34	0,64	0,34	0,60	Min	0,19	0,23	0,19	1,12
Q1	5,26	5,53	4,46	5,95	Q1	5,11	5,34	4,27	5,94
MD	6,88	7,03	6,21	7,35	MD	6,58	6,70	5,96	7,16
Q3	8,59	8,84	7,94	8,97	Q3	7,94	8,12	7,30	8,43
Max	16,01	16,01	14,14	13,69	Max	13,24	13,24	12,77	12,89
AT	15,67	15,37	13,80	13,09	AT	13,05	13,01	12,58	11,77
CA	-0,05	0,08	-0,01	-0,08	CA	-0,15	-0,01	-0,12	-0,09
CC	2,66	2,60	2,50	2,75	CC	2,82	2,80	2,60	2,86

DV dia	Total	PT	PC	PS	DV noite	Total	PT	PC	PS
M	124,12	126,56	118,28	128,03	M	127,87	130,67	123,06	130,65
DP	16,98	11,81	19,77	16,95	DP	15,38	11,88	17,77	14,30
CV	0,14	0,09	0,17	0,13	CV	0,12	0,09	0,14	0,11
Min	4,00	18,80	4,00	7,30	Min	3,50	6,10	3,50	27,10
Q1	116,47	119,51	110,77	120,43	Q1	120,57	125,65	113,94	125,09
MD	124,94	125,98	119,37	129,00	MD	130,19	132,27	124,08	132,91
Q3	133,10	133,06	128,19	137,65	Q3	137,48	137,70	134,28	139,47
Max	174,24	173,56	172,78	174,24	Max	178,75	169,69	178,75	169,15
AT	170,24	154,76	168,78	166,94	AT	175,26	163,59	175,26	142,05
CA	-1,75	-0,40	-1,83	-1,66	CA	-1,51	-1,57	-1,21	-1,55
CC	11,90	7,40	10,59	10,88	CC	9,21	11,36	8,21	7,70

4.2 Relação entre as variáveis meteorológicas

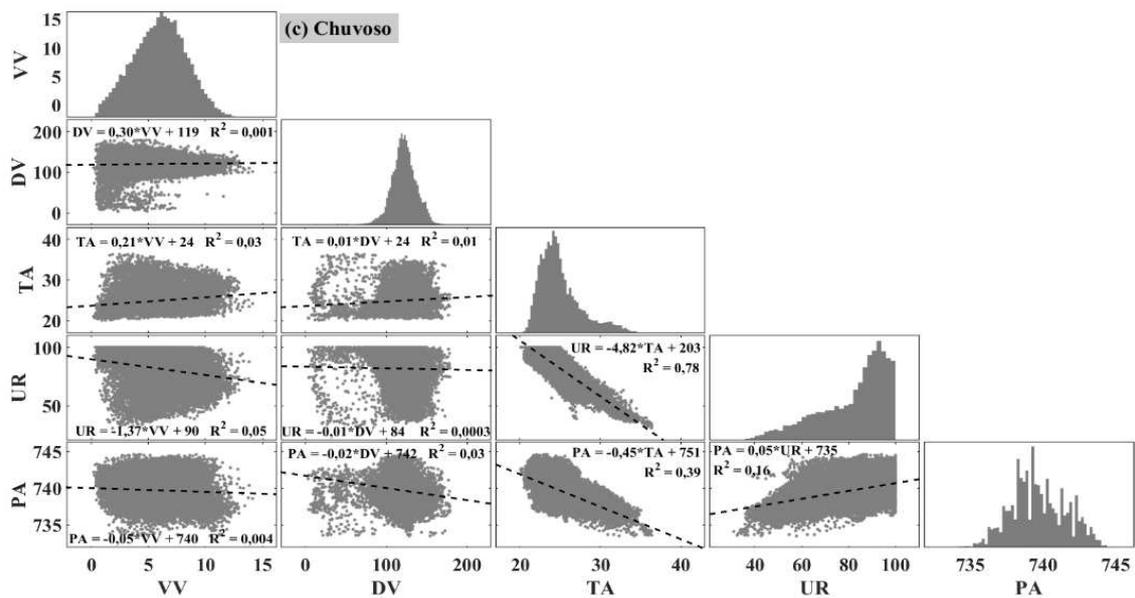
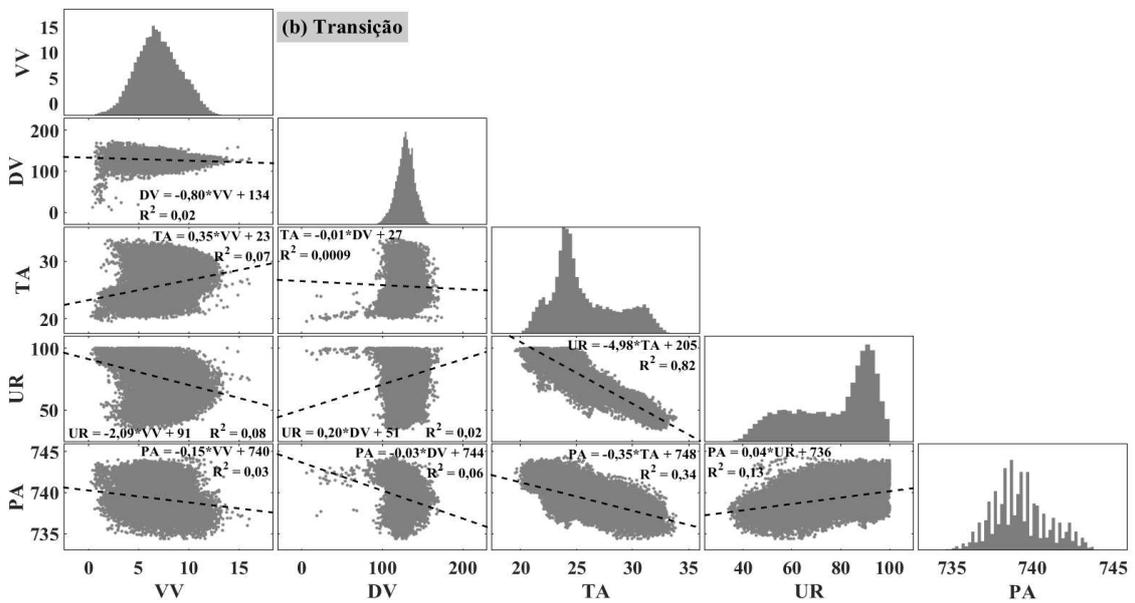
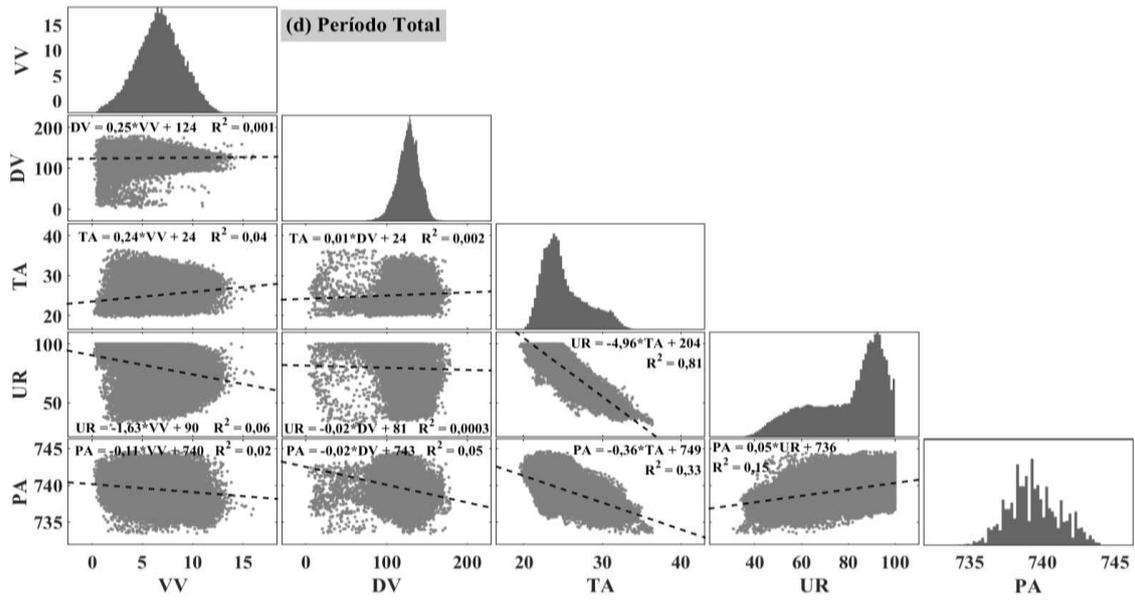
A Figura 20 mostra a matriz de gráfico de histograma (elementos da diagonal principal) e dispersão (elementos abaixo da diagonal principal), incluindo RLS e R^2 das VM estudadas considerando os períodos Total e sazonal. O histograma das VM no período Total (Figura 20a) apresentaram as maiores frequência de ocorrência (FO) devido a sua maior quantidade de dados, consequência disso, o PS (Figura 20d) mostrou as menores ocorrências. O PT (Figura 20b) e PC (Figura 20c) apresentaram quantidade de dados iguais.

Em todos os períodos, a distribuição da VV é simétrica e unimodal, as maiores FO foram próximo de 7 m.s^{-1} . Para a DV, as maiores FO ocorreram próximo à classe de 130° (Total, PT e PS), correspondendo à direção predominante SE (Tabela 5). O PC apresentou as maiores FO próximo a classe de 120° , resultando em uma segunda direção predominante ESE. As maiores FO da TA ocorreram na categoria de 24°C (Total, PT e PC) e 23°C (PS), destaque para a maior assimetria positiva em ambos os períodos. Na série UR, em todos os períodos, as maiores FO foram próximas de 90%, destaque para elevada assimetria negativa. Por fim, a PA (Total, PC e PS) apresentaram as maiores FO na classe de 739,4 mm Hg, seguido pela classe de 738,4 mm Hg. As maiores FO do PT foram na classe de 738,8 mm Hg e a classe de 738,4 mm Hg.

Os gráficos de dispersão apresentam os resultados do relacionamento linear entre as VM estudadas. Devido à diferença de valores das séries temporais individuais e no próprio tamanho dos dados (61.344) – (Tabela 1), esta abordagem não é conveniente para a avaliação das conexões entre as VM, principalmente a VV e DV (AVDAKOVIC et al., 2016). No entanto, através dos gráficos de dispersão (Figura 20a, b, c, d) é possível identificar um relacionamento linear inverso entre a TA e UR e entre a TA e PA, e o relacionamento linear direto entre UR e PA. Essa conexão inversa entre TA e UR é mais intensa no PS e menor no PC, entre TA e PA é ao contrário mais forte no PC e menor no PS e a conexão direta entre UR e PA não apresentou diferença significativa entre os períodos sazonais.

Os melhores ajustes da RLS foram entre os pares TA e UR, TA e PA, UR e PA, pois resultaram nos maiores coeficientes de determinação, respectivamente. Destaque para o R^2 entre TA e UR no PS que explicou 88% da variabilidade dos dados, entre TA e PA no PC o R^2 explica 39% da variabilidade das variáveis e entre UR e PA no PC e PS o R^2 foram iguais explicando apenas 16% da variabilidade das séries. Os coeficientes de determinação restantes foram baixos, consequentemente são insuficientes para explicar a variabilidade de relacionamento entre as VM.

O estudo recente de SANCHES e SUSKI (2022) realizou gráficos de evolução temporal e histogramas das VM (VV, DV, TA, UR e PA) no Campus Florianópolis do Instituto Federal de Santa Catarina (IFSC). As séries temporais dos dados foram obtidos a cada intervalo de um minuto durante o período de 47 dias (02/08 a 17/09/2019). Os resultados indicaram FO da VV na classe de 1 m.s^{-1} , a DV apresentou duas direções predominantes SE e N, a TA na categoria de 16°C , a UR na classe de 70% e PA próximo a 1024 hPa.



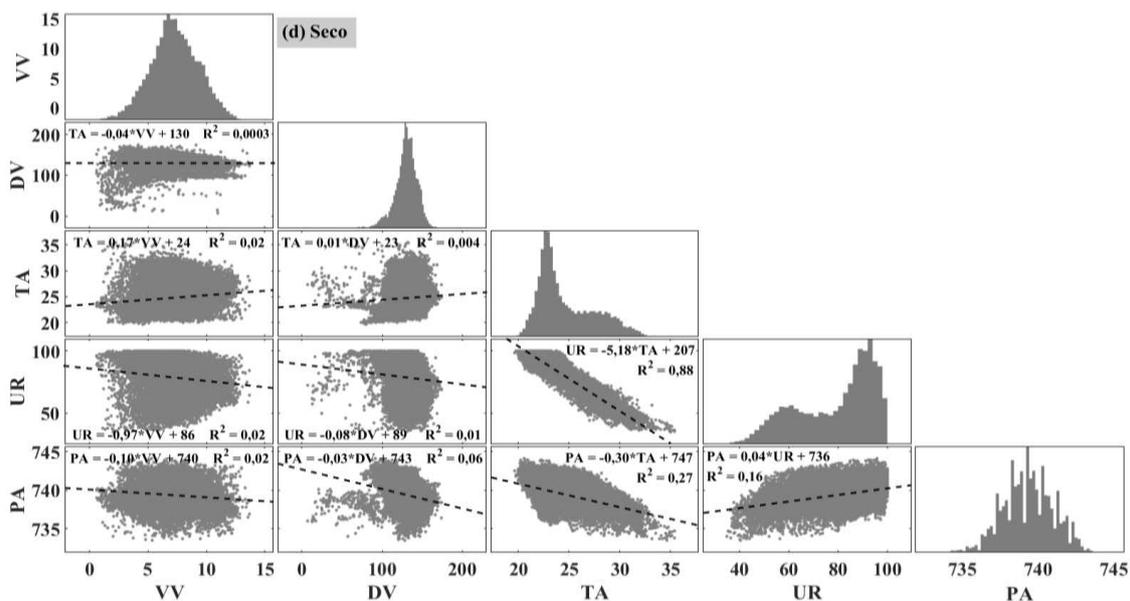


Figura 20. Matriz de gráfico de dispersão e histograma das variáveis meteorológicas considerando os períodos (a) Total, (b) Transição, (c) Chuvoso, (d) Seco. Fonte: Autor (2023).

AVDAKOVIC et al. (2016) utilizaram gráfico de dispersão para avaliar o relacionamento linear entre VM (VV, UR, TA e PA) e concentração de material particulado 10 na cidade de Sarajevo, Bósnia. Os dados eram horários e o período de estudo foi todo o ano de 2012. Os resultados mostraram que a concentração de PM10 se relacionou diretamente com a UR e PA, e inversamente com a TA e VV. O R^2 em todos os gráficos foi insuficiente para explicar a variabilidade dos dados.

PEREIRA e DAMASCENO (2020) desenvolveram um modelo de estimação da irradiação global em Fortaleza, Ceará. As VM utilizadas foram irradiação, temperatura e umidade, os dados foram medidos no intervalo de uma hora e o período de estudo foi de um ano (18/11/2018 a 19/11/2019). Os resultados mostraram um relacionamento linear direto entre a temperatura e irradiação com equação ($y = 12,934x - 24,451$), relacionamento linear inverso entre a umidade e irradiação ($y = -2,9407x + 76,684$). O modelo multivariado resultou na equação ($y = 0,107x_1 + 34,213x_2 - 10,324x_3 - 1,451$) e o coeficiente de determinação foi de 87,21%.

GUAN et al. (2007) analisaram o relacionamento de VM (irradiação solar global – ISG, temperatura de bulbo seco – TBS, UR, PA, VV, DV, entre outras) em todas as capitais da Austrália. Os dados eram horários e o período de estudo foi de 10 anos. Os resultados mostraram relações lineares diretas fortes entre IGS e TBS com R^2 variando de 27 a 66% de explicação da variabilidade dos dados, relação linear direta fraca entre TBS e VV com R^2 variando de 1 a 12%, relação linear inversa forte entre TBS e UR com R^2 variando de 53 a 72%, e relação linear inversa fraca entre PA e TBS com R^2 variando de 2 a 6%.

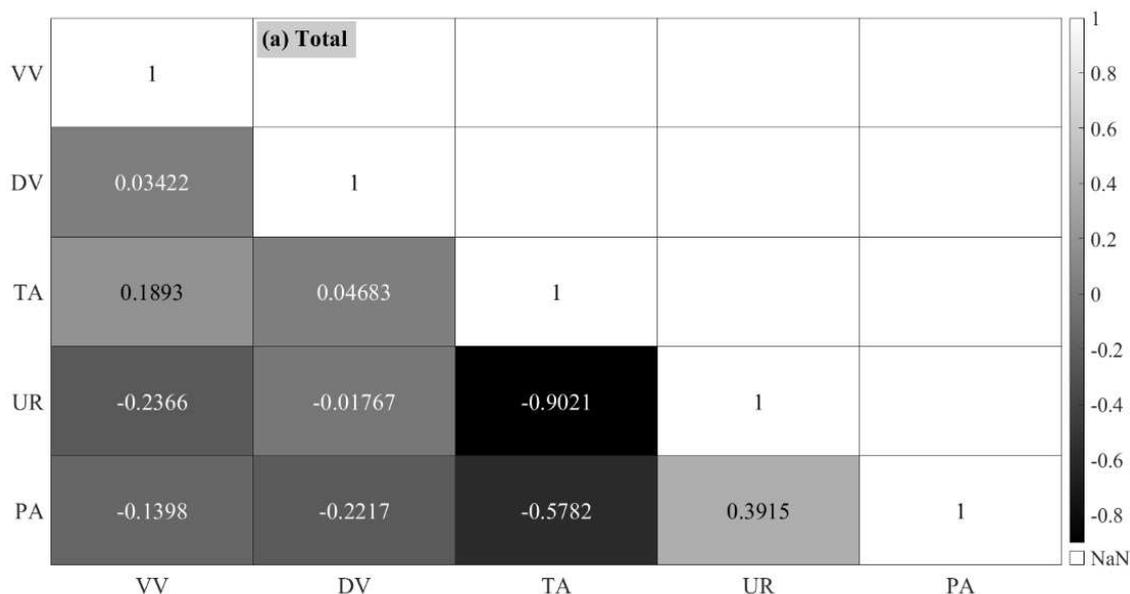
A Figura 21 mostra o mapa de calor da CP entre as VM analisadas considerando os períodos Total e sazonal. Em todas as correlações envolvendo a VV e DV foram baixas ou muito baixas indicando que essas variáveis não se correlacionam linearmente

com as variáveis restantes. Devido a um forte relacionamento linear inverso, consequentemente as maiores correlações foram negativas entre TA e UR, TA e PA, respectivamente. Seguido pela correlação positiva entre UR e PA, devido a um relacionamento linear direto entre essa dupla de variáveis.

A correlação negativa entre TA e UR foram classificadas como quase perfeitas nos períodos Seco (Figura 21d), Transição (Figura 21b) e Total (Figura 21a), respectivamente. No período Chuvoso (Figura 21c) foi classificado como muito alta, segundo a metodologia de HOPKINS (2009), mostrado na Tabela 3. Isto indica que essa correlação inversa é mais forte no período seco e diminui um pouco no período chuvoso. Ao contrário da correlação negativa entre TA e PA que fica mais intensa no período de chuva e menos intensa no período seco, em ambos os períodos a correlação foi classificada como alta. A correlação positiva entre UR e PA classificou-se como moderada. As correlações do período de seco são as que mais se assemelham com as correlações do período Total.

Fazendo uso do teste estatístico não paramétrico de hipótese t-Student com 12 graus de liberdade e para nível de significância 99%, 95% e 90% (Tabela 4), verificam-se que realmente só existe correlações entre as duplas TA e UR, TA e PA, UR e PA, visto que essas correlações são maiores ou iguais aos t_c (0,61; 0,46; 0,37), respectivamente. Comprovando que não existe correlação da VV e DV com as variáveis restantes. Portanto, a hipótese de nulidade é rejeitada apenas para as correlações entre as variáveis TA, UR e PA em ambos os períodos Total e sazonal.

GUAN et al. (2007) analisaram o relacionamento de VM (ISG, TBS, UR, PA, VV, DV e outras) em todas as capitais da Austrália. Os dados eram horários e o período de estudo foi de 10 anos. Os resultados mostraram correlação de Pearson alta e muito alta entre TBS e ISG (0,519 a 0,809), correlação muito alta entre TBS e UR (-0,849 a -0,724) e correlação baixa entre TBS e PA (-0,253 a -0,131).



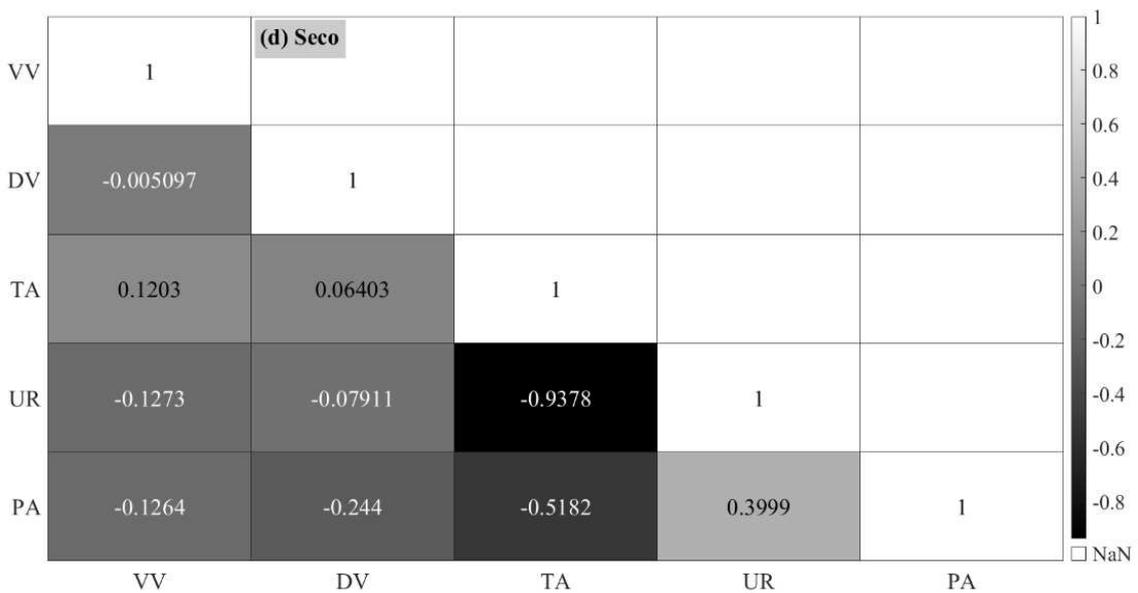
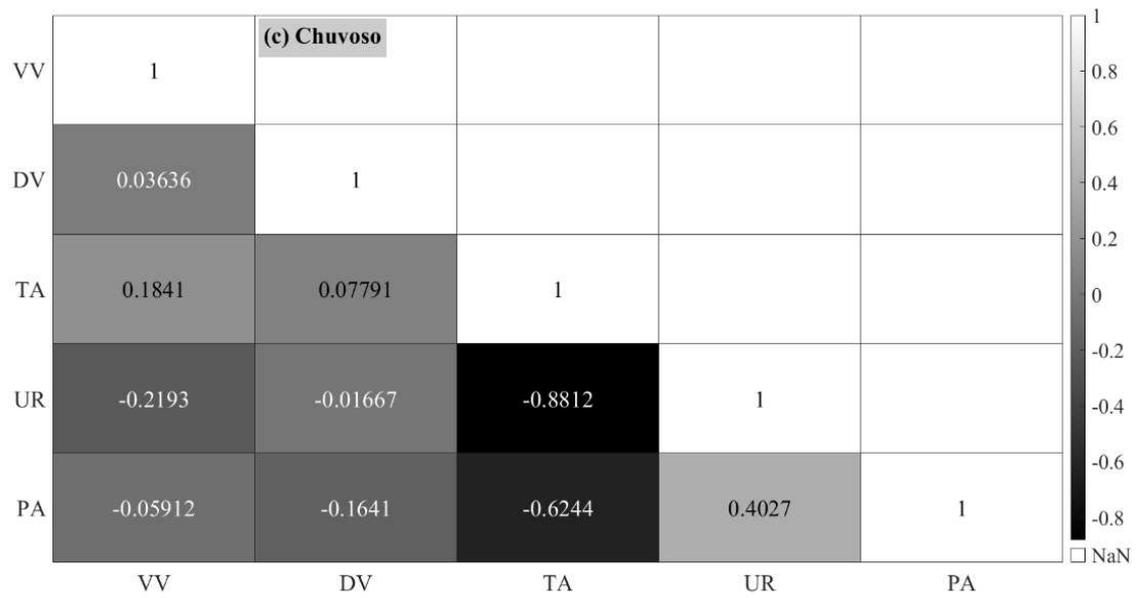
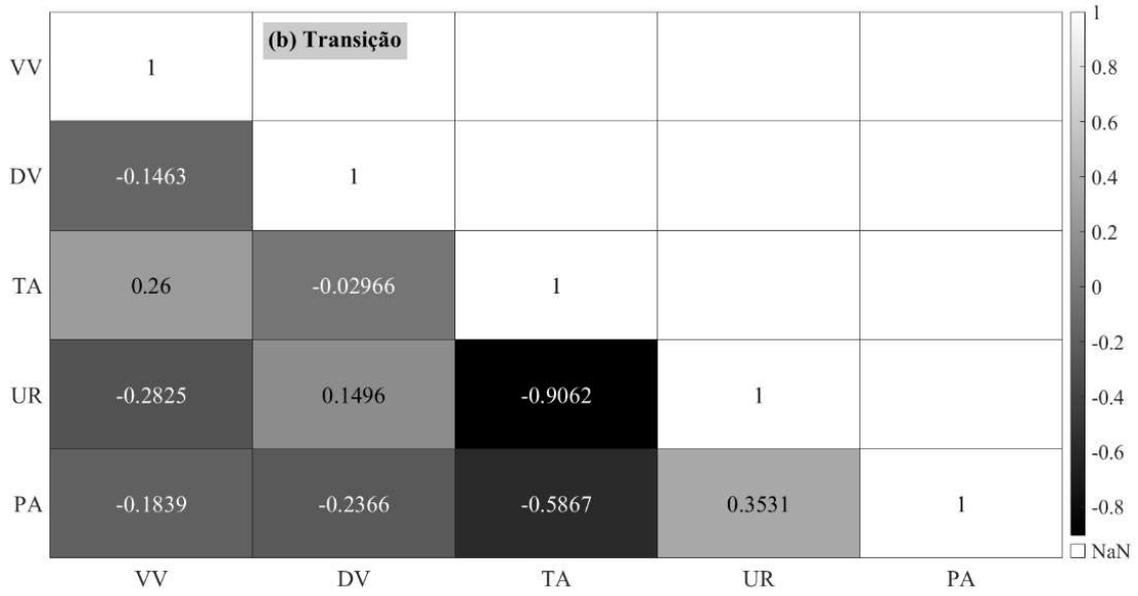


Figura 21. Mapa de calor das correlações de Pearson entre as variáveis meteorológicas considerando os períodos (a) Total, (b) Transição, (c) Chuvoso, (d) Seco. Fonte: Autor (2023).

GRIGOLETTI et al. (2016) realizaram um estudo de tratamento de dados climáticos em Santa Maria, Rio Grande do Sul, para análise de desempenho térmico de edificações. Os dados climáticos foram temperatura de ponto de orvalho – TPO, TBS, UR, PA, RSG, DV, VV, precipitação e outras. As medições foram horárias e o período de estudo compreendido entre os anos de 2002 e 2013. Os resultados mostraram correlação de Pearson muito alta entre TPO e TBS (0,878), correlação alta entre UR e RSG (-0,645) e moderada entre TBS e UR (-0,436) e TBS e RSG (0,433).

MIAO et al. (2023) analisaram a distribuição vertical de poluentes atmosféricos em uma área urbana durante episódios de poluição do ar no inverno em Shenyang, China. Os dados foram concentrações de poluentes atmosféricos (PM_{2.5}, PM₁₀, CO e O₃) e fatores microclimáticos (TA, UR, DV, VV e PA) medidos em três níveis de altura a cada um minuto durante dezembro de 2018 a março de 2019. Os resultados das correlações entre os fatores climáticos foi muito alta entre TA e UR em ambos os níveis. Os pares de fatores climáticos restantes foram baixas ou muito baixas e por vezes não apresentaram correlação.

SILOKO e UDDIN (2023) realizaram um estudo estatístico da conectividade da VV com a UR e TA em Ughelli, Estado do Delta da Nigéria. Para analisar a correlação das variáveis os autores utilizaram função de Kernel Gaussiana, os dados foram diários e o período de estudo foi de cinco anos (2018-2022). Os resultados mostraram que em termos de conectividade a VV e a UR se correlacionam negativamente em 2018 (-0,07) e 2022 (-0,09), e positivamente em 2019 (0,39), 2020 (0,33) e 2021 (0,14). Entre VV e TA a correlação foi negativa para todo o período de estudo variando de -0,47 a -0,08.

A Figura 22 mostra a WC entre todas as VM analisadas considerando o período Total. De forma geral, os resultados mostraram que as séries temporais apresentaram alta coerência em diversas frequências normalizadas (FN). Por exemplo, durante todo o período de estudo próximo a frequência normalizada de 128 (ciclos/amostra), equivalente a aproximadamente a periodicidade de 24 horas, todas as duplas de variáveis apresentaram coerência de magnitude quadrada próximo do valor máximo nessa frequência normalizada. A direção das setas pretas indica a fase de coerência entre as variáveis como mostrado no Diagrama da relação do ângulo de fase (Figura 4).

A VV mostrou correlação moderada com todas as variáveis na periodicidade diária em todo o período de estudo. A WC da VV também mostrou algumas correlações irregulares em períodos distintos: entre os meses de março a abril e novembro de 2014, entre os meses de janeiro a fevereiro de 2015, com periodicidades de dias a meses. A VV apresentou fase de coerência inversa (fase oposta) com as variáveis DV, UR e PA (Figura 22 a, c, d) e fase de coerência direta com a TA (Figura 22b).

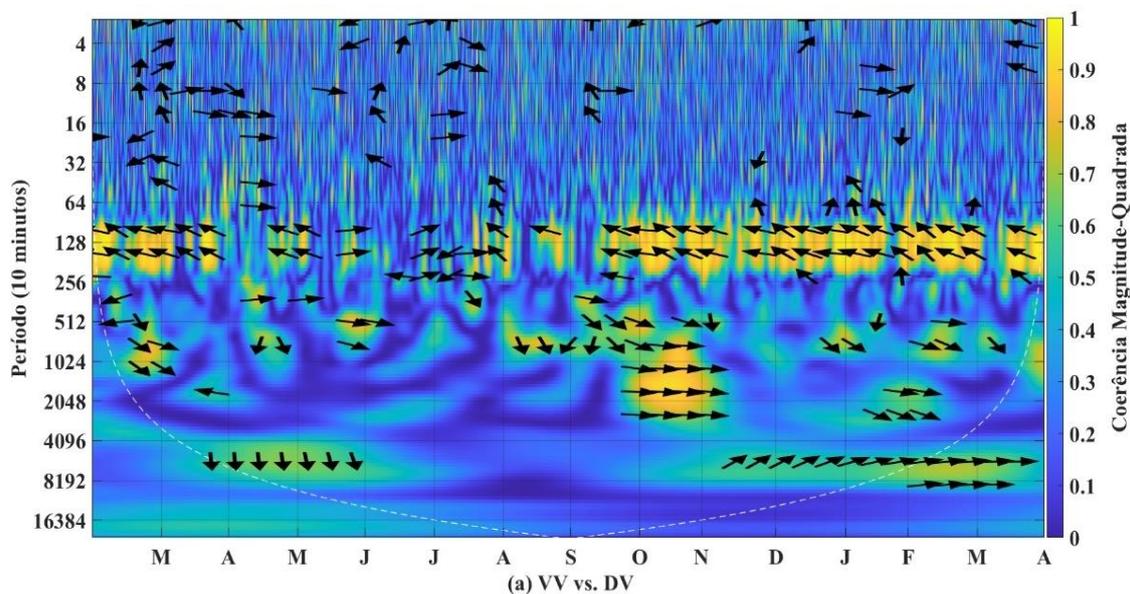
A DV apresentou fase oposta com a TA (Figura 22e) e fase com a UR (Figura 22f) e PA (Figura 22g). A DV é a variável que mais apresentou períodos de mudança de fase (fase oposta para fase e vice-versa). Por exemplo, entre VV e DV no mês de novembro de 2014 ocorreu mudança de fase oposta para fase, entre DV e TA durante os

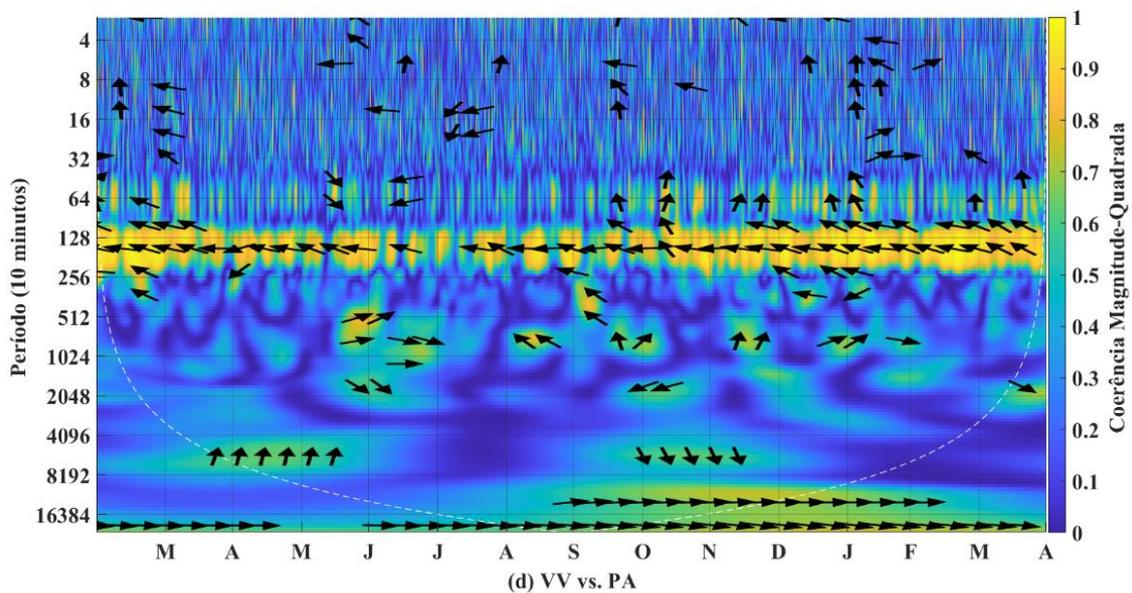
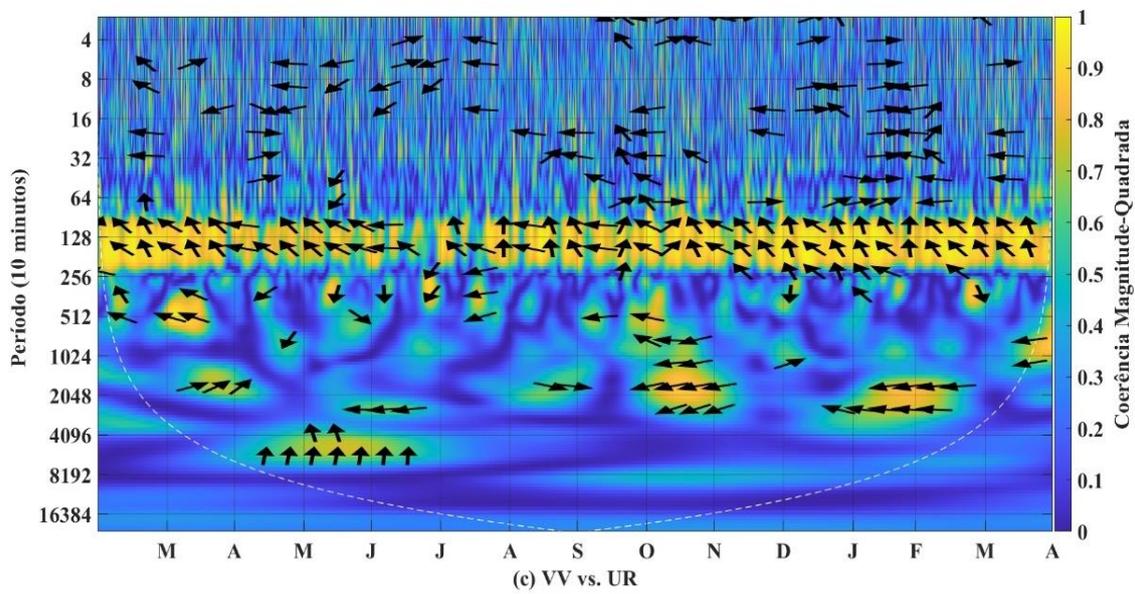
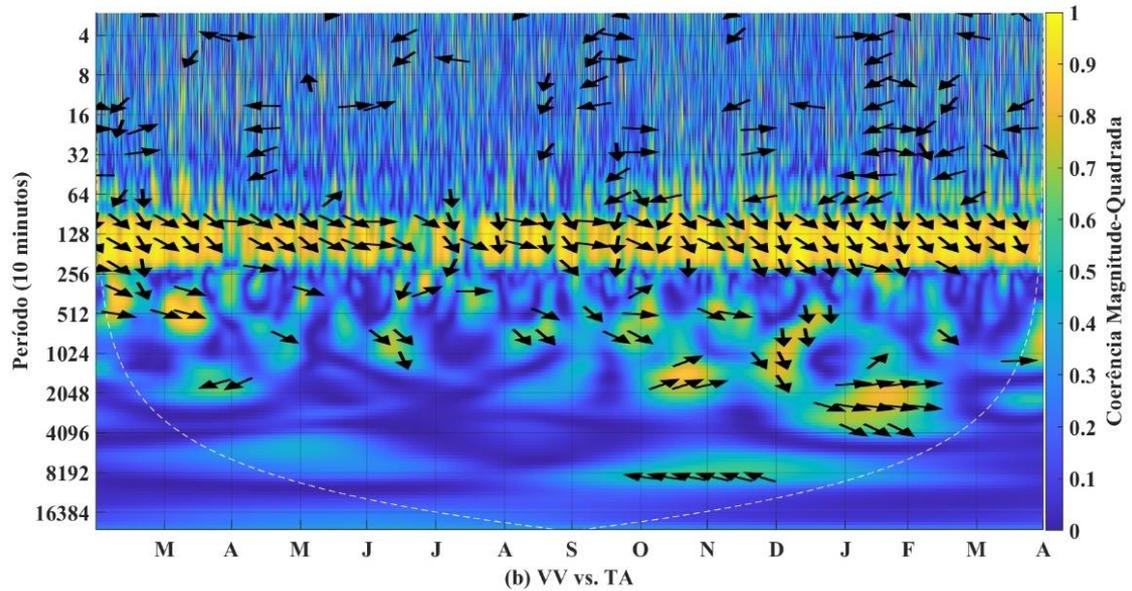
meses de abril a junho e de maio a dezembro ocorreram mudanças de fase oposta para fase, entre DV e UR durante os meses de abril a junho e de agosto a dezembro ocorreram alterações de fase para fase oposta, entre DV e PA durante os meses de maio a junho e de setembro a outubro ocorreram mudanças de fase para fase oposta. A magnitude de coerência da DV com todas as variáveis no PC foi menor do que os PT e PS, isso indica que a precipitação também altera a coerência da DV com as outras variáveis.

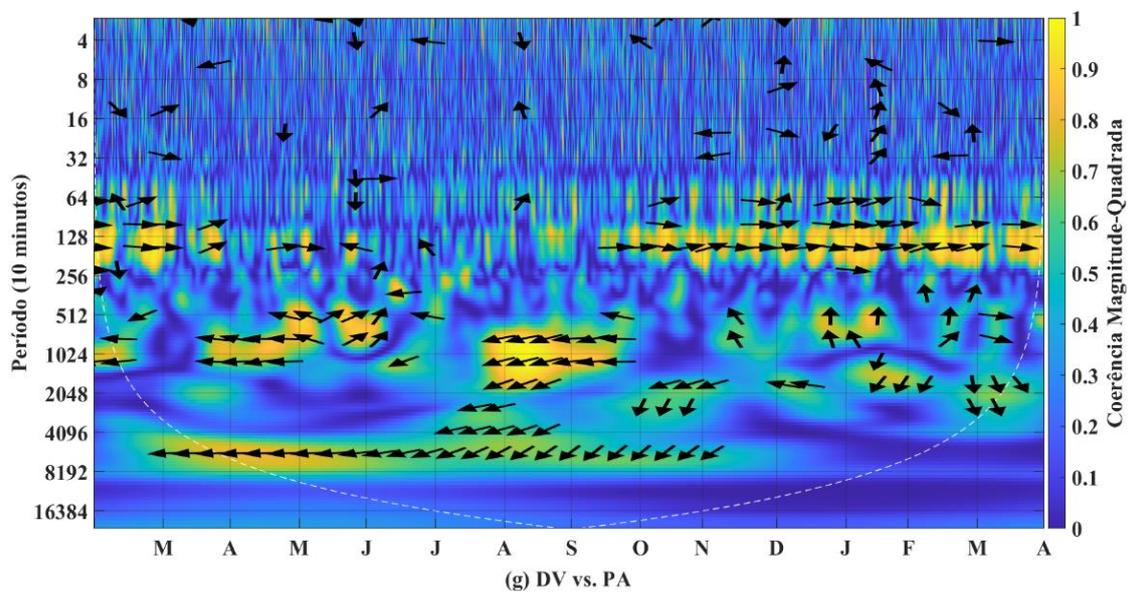
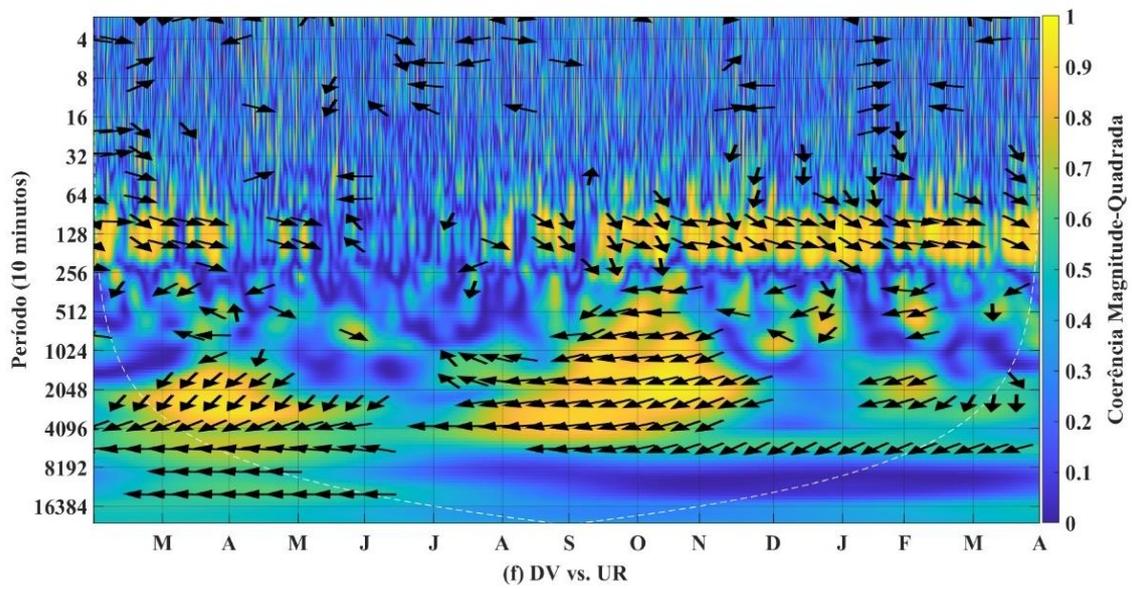
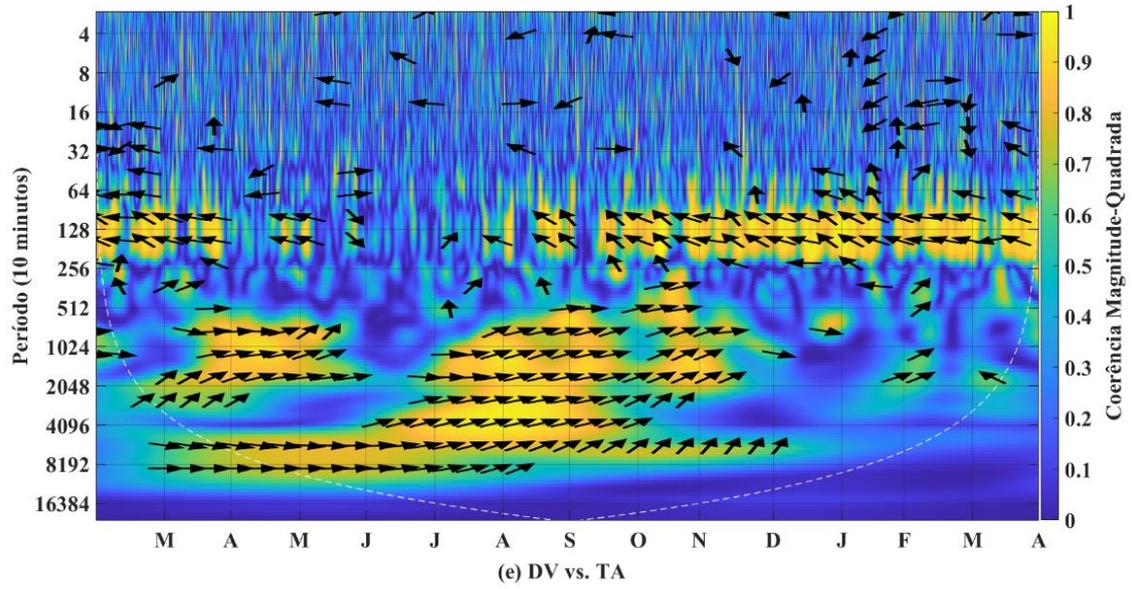
TA e UR (Figura 22h) apresentou o mais alto grau de coerência entre as duplas de variáveis sendo exclusivamente de fase oposta, o que é esperado, uma vez que quando se tem um aumento da temperatura (período da tarde) se tem uma diminuição da umidade e vice-versa. A magnitude de coerência foi máxima entre as FN de 32 a 256 (ciclos/amostra), indicando que a TA e UR possui coerência significativa com periodicidade de horas a dias. Magnitudes próximas do máximo em períodos distintos, por exemplo, durante os meses de março a maio de 2014 entre as FN de 256 a 2048 (ciclos/amostra) equivalendo à periodicidade de dias a mensal, de agosto de 2014 a abril de 2015 entre as FN de 256 a 16384 (ciclos/amostra) periodicidade de dias a anual.

A WC da PA apresentou correlação moderada de fase oposta com a TA (Figura 22i) e de fase com a UR (Figura 22j). As maiores magnitudes de coerência entre a PA e as variáveis restantes ocorreram próximos as FN de 64 e 128 (ciclos/amostra), devido a PA apresentar duas periodicidades de 12 horas e 1 dia. A WC entre PA e TA apresentou mais correlações irregulares do que entre PA e UR, em períodos distintos: no mês de maio, entre os meses de abril a outubro e de maio de 2014 a janeiro de 2015.

ROCHA et al. (2018) utilizaram WC para analisar o grau de correlação das variáveis TA, UR, PA e VV no Cerrado, Mato Grosso. Os dados eram horários e o período de estudo foram os anos 2015, 2016 e 2017. A WC entre as variáveis TA e UR apresentou um padrão de relação forte de fase oposta em todo o período estudado, a VV apresentou um padrão de fase e fase oposta moderada com a TA e UR, respectivamente. A WC da PA apresentou relação fraca com todas as variáveis.







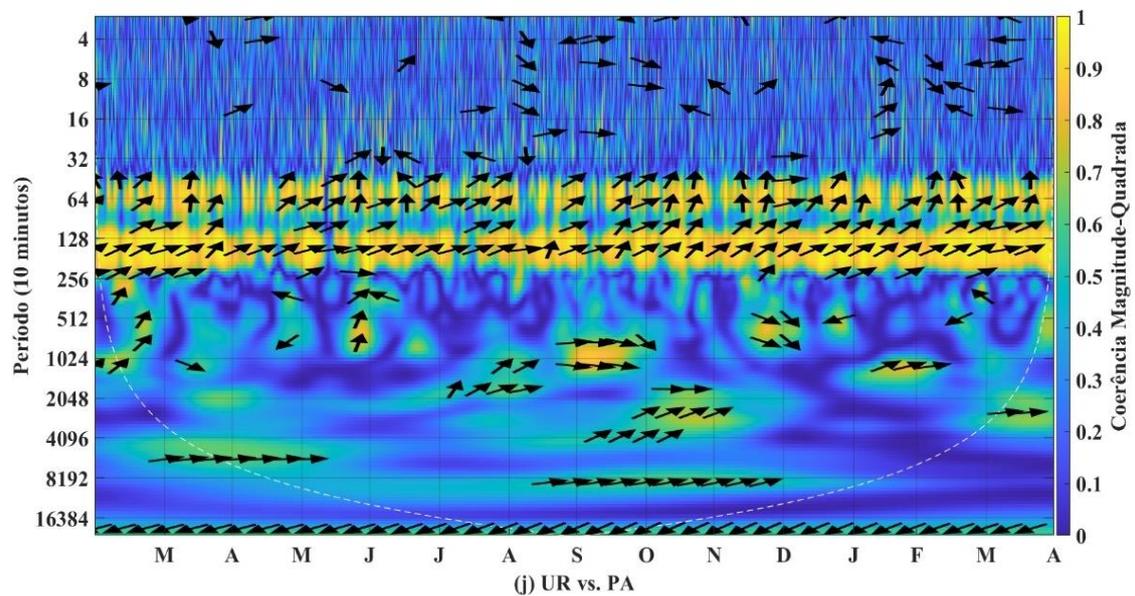
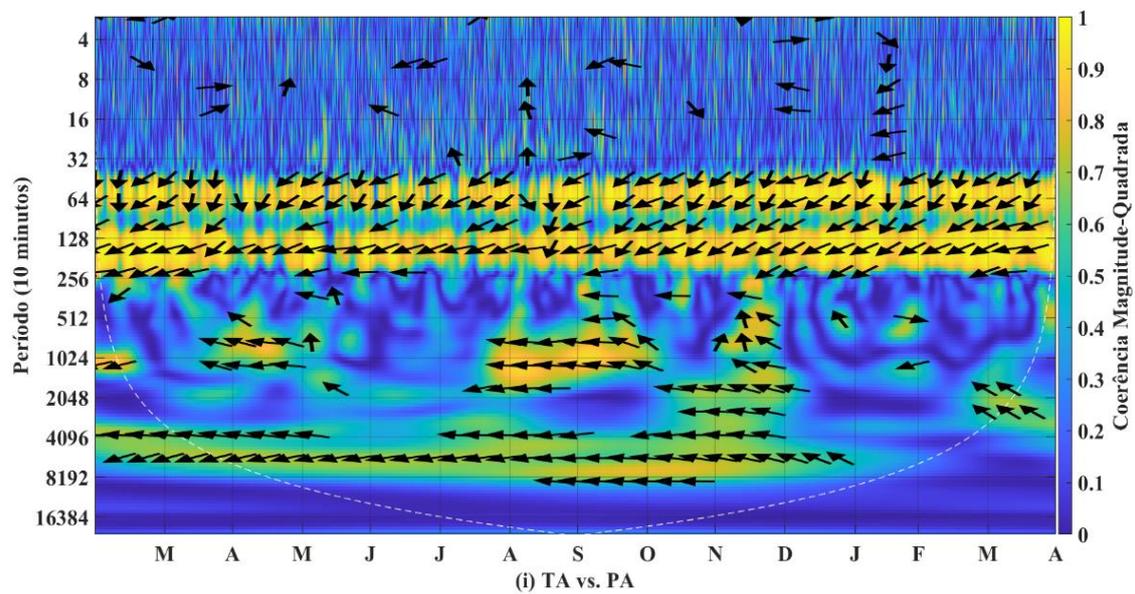
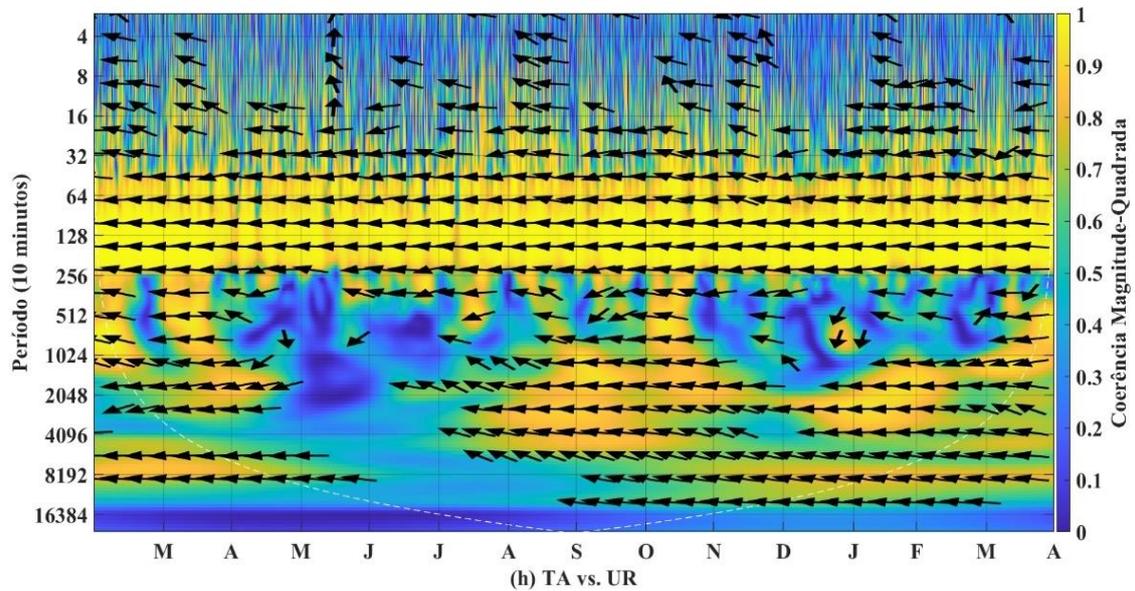


Figura 22. Wavelet de coerência entre as variáveis meteorológicas considerando o período Total (março/2014 a abril/2015): (a) VV vs. DV, (b) VV vs. TA, (c) VV vs. UR, (d) VV vs. PA, (e) DV vs. TA, (f) DV vs. UR, (g) DV vs. PA, (h) TA vs. UR, (i) TA vs. PA, (j) UR vs. PA. Fonte: Autor (2023).

CHANG et al. (2017) investigaram a correlação inerente entre as variáveis VV, TA e RSG por meio de análise Wavelet consistindo em WC e ângulo de fase entre essas variáveis. Os dados foram medidos em 10 minutos e transformados em diários num período de estudo 10 anos (2006-2015) em Taipei, Taiwan. Os resultados mostraram a seguinte coerência dos pares de variáveis: VV e TA mostraram correlação de fase oposta, RSG e TA apresentaram correlação significativa de fase, VV e RSG apresentaram correlação de fase oposta, ambos com periodicidade anual.

BARLIK (2021) utilizou WC para analisar os efeitos da TA, PA, UR e VV na concentração de PM10 na cidade de Ardahan, Turquia. Os dados eram horários e foram transformados em médias diárias, o período de estudo foi de 10 anos (2010-2020). Os resultados da WC entre as VM e a concentração de PM10 mostraram correlações fortes e moderadas na periodicidade de 256 a 512 dias (aproximadamente 1 ano). A WC de concentração de PM10 com a TA foi forte e de fase oposta, com a UR foi moderada e de fase, com a VV apresentou um intervalo maior de periodicidade entre 8 e 512 dias e de fase oposta, com a PA mostrou ausência de correlação.

A Figura 23 mostra a distribuição mensal das VM (linhas) sendo comparadas com a precipitação acumulada mensal e índices oceânicos (barras). Primeiramente analisando a Figura 23a que mostra a evolução temporal da PAM em Arapiraca. A precipitação acumulada total foi de $1087,80 \text{ mm} \cdot (14 \text{ meses})^{-1}$, o PC foi de $604,60 \text{ mm} \cdot (5 \text{ meses})^{-1}$, o PS foi de $253,20 \text{ mm} \cdot (4 \text{ meses})^{-1}$ e o PT foi de $230 \text{ mm} \cdot (5 \text{ meses})^{-1}$. O mês de maior precipitação ocorreu em julho de 2014 com $185,60 \text{ mm} \cdot \text{mês}^{-1}$, seguido por outubro do mesmo ano com $149,80 \text{ mm} \cdot \text{mês}^{-1}$ sendo um mês do PS. Os meses que menos choveram foram em janeiro de 2015 com apenas $4 \text{ mm} \cdot \text{mês}^{-1}$ e dezembro de 2014 com $6,40 \text{ mm} \cdot \text{mês}^{-1}$.

Analisando a evolução temporal mensal das VM (linhas). A VV (Figura 23a) atinge as menores intensidades no PC, principalmente no mês de maio de 2014 com apenas $5,45 \text{ m} \cdot \text{s}^{-1}$, e as maiores velocidades no PS e PT, sendo que os meses de setembro, outubro e dezembro de 2014 e janeiro de 2015 apresentaram os valores de $7,20 \text{ m} \cdot \text{s}^{-1}$, $7,70 \text{ m} \cdot \text{s}^{-1}$, $7,35 \text{ m} \cdot \text{s}^{-1}$ e $7,49 \text{ m} \cdot \text{s}^{-1}$, velocidades consideradas viáveis para a construção de parques eólicos. A DV (Figura 23b) mostra direção mensal em ESE de abril a agosto de 2014, nos meses restantes apresenta direção mensal em SE. A amplitude da direção do vento mensal foi de $18,01^\circ$ menor que uma faixa intervalar de uma pétala de rosa dos ventos ($22,5^\circ$) – (Tabela 5).

A TA (Figura 23c) é afetada diretamente pela precipitação que diminui gradativamente no PC até atingir a temperatura mínima de $22,99^\circ \text{C}$ no mês de agosto de 2014, a partir desse mês aumenta gradativamente até atingir o valor máximo mensal de $27,19^\circ \text{C}$ no último mês de estudo abril de 2015. A UR (Figura 23d), nos meses de maio a outubro de 2014, apresentou valores acima de 80% e abaixo deste limiar nos meses restantes, coincidindo com janeiro de 2015 sendo o mês que menos choveu e o de

menor UR do ar 73,48%. A PA (Figura 23e) também mostrou relacionamento direto com a precipitação, aumentando gradativamente no PC até atingir o valor máximo de 742,14 mm Hg no mês de julho de 2014 e diminuído até atingir o valor mínimo de 738,17 mm Hg no mês de novembro de 2014 que é PS.

Analisando os índices oceânicos (barras). Os dados mensais de ENOS34 (Figura 23b) mostra que entre novembro de 2014 a abril de 2015 ocorreu fases El Niño, período em que ocorreu menor precipitação e UR, maiores TA e VV, e DV é SE, corroborando com a literatura científica, em que em períodos de El Niño é Seca no N e NE do Brasil e ventos mais intensos (PEREIRA et al., 2013; SANTOS et al., 2023). Os dados de TSA (Figura 23c) mostra predominância de valores positivos indicando que a TSM estava anormalmente quente sobre a região do OAS, apenas novembro e dezembro de 2014 ocorreram valores negativos indicando anomalia fria, coincidindo com pouca precipitação e uma diminuição distinta da VV mensal no PS (SOUZA e REBOITA, 2021)

A TNA (Figura 23d) apresenta anomalia fria sobre a região do OAN entre março e junho de 2014, março e abril de 2015. Anomalia quente entre julho de 2014 e fevereiro de 2015, com valores máximos em setembro e outubro de 2014, respectivamente, coincidindo com a maior PAM fora do PC e a VV mensal máxima. Os dados de SAODI (Figura 23e) apresentaram predominância de valores negativos indicando que o setor subtropical (SW) estava anormalmente mais frio do que o aquecimento do setor tropical (NE), os valores extremos ocorreram em novembro e dezembro de 2014 e janeiro de 2015, respectivamente, coincidindo com as menores PAM, baixa UR, aumento da TA, ventos fortes e com direção predominante de SE (SOUZA e REBOITA, 2021).

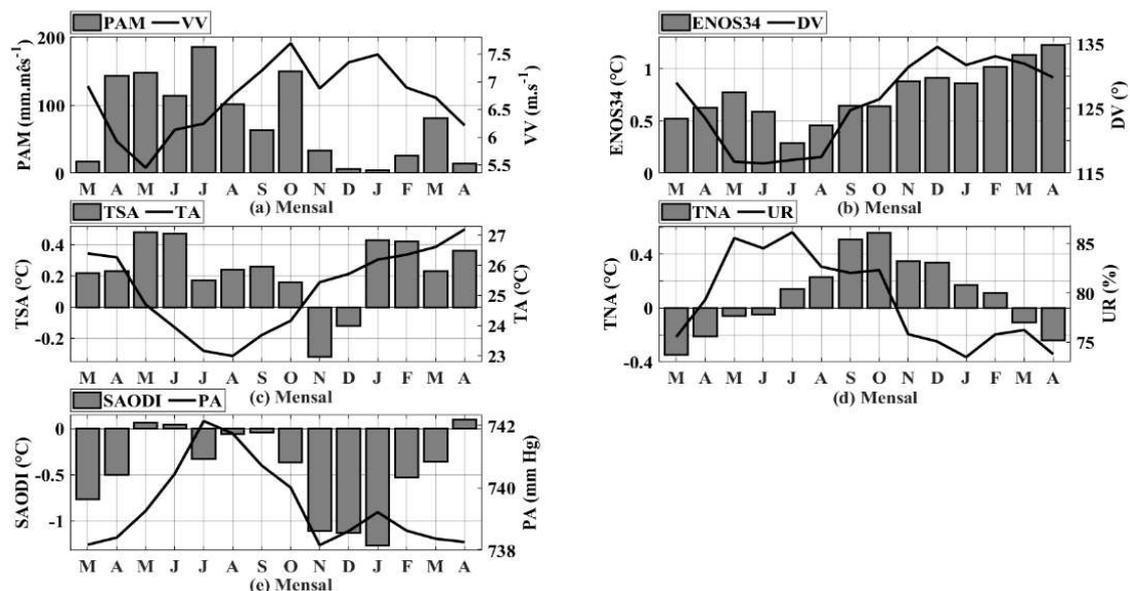


Figura 23. Gráfico misto entre as variáveis meteorológicas mensais (Linhas) com a presença de (a) Precipitação Acumulada Mensal (PAM), (b) *El Niño-Oscilação Sul* na região 3.4 (ENOS34), (c) *Tropical Southern Atlantic Index* (TSA), (d) *Tropical*

Northern Atlantic Index (TNA), (e) *Southern Atlantic Ocean Dipole Index (SAODI)* – (Barras). Considerando o período Total (março/2014 a abril/2015). Fonte: Autor (2023).

Segundo os Boletins Climanálise (CPTEC, 2023), a PAM no semiárido nordestino em 2014-2015 está associada à atuação de Cavados, VCAN, LI, DOL, posicionamento mais ao sul da ZCIT, aumento da formação de aglomerados de nuvens associadas à propagação de distúrbios e ao escoamento de E mais intenso. A PAM acima da média histórica para outubro de 2014 foi devido a uma circulação anticiclônica anômala nos médios níveis da atmosfera (700 e 500 hPa) sobre o continente e em conjunto com o avanço do primeiro sistema frontal até o litoral do NE contribuíram para expressivos acumulados de precipitação no ENEB e parte do Agreste de Alagoas.

SANTOS et al. (2023) investigaram efeitos de fases extremas do ENOS34 (El Niño forte e muito forte e La Niña forte) em chuvas extremas de Alagoas. O período de estudo foi de 1960 a 2016. Os resultados mostraram alta variabilidade interanual de precipitação devido às influências do ENOS. Em mais de 70% dos anos de ENOS extremos, as chuvas ficaram abaixo ou acima da média e coincidem com as fases El Niño e La Niña, respectivamente. A análise da distribuição espacial indica que a mesorregião climática mais próxima da costa (Leste) chove mais do que nas regiões continentais (Agreste e Sertão). A chuva anual do Agreste foi de 916,13 mm.ano⁻¹, nos anos de 2014 e 2015 o El Niño apresentou fases moderada, forte e muito forte.

SILVA (2013) analisou a relação linear entre a TSM dos oceanos Pacíficos e Atlântico com a vazão do rio Madeira, localizado na parte Sul da região Norte do Brasil. O período de estudo foi de 1968 a 2009 e os dados em escalas mensal, sazonal e anual. Os resultados mostraram que a precipitação e a vazão do rio Madeira apresentaram correlação linear significativa com áreas específicas dos oceanos Atlântico e Pacífico. Um resultado importante diz que os períodos de anomalia da TSM no TAN indicam que a ocorrência de TSM mais altas (baixas) que o normal, foram acompanhadas por ventos de leste mais fracos (fortes).

FERREIRA e KEMENES (2023) avaliaram a influência dos eventos climáticos extremos (ENOS 1+2, 3, 3.4, 4, TNA e TSA) sobre os elementos climáticos (precipitação, evapotranspiração, UR, TA e VV) da Parnaíba, na Planície Litorânea do Piauí. O período de estudo foi de 30 anos (1991-2020) e os dados em escala mensal e anual. Os resultados constataram que ocorreu uma mudança no comportamento do clima de Parnaíba nesses 30 anos, com a diminuição da precipitação e VV, aumento da TA e taxa de evapotranspiração. O estudo constatou que nos anos 2014 e 2015 ocorreu ENOS ausente e muito forte, respectivamente, nesses anos a precipitação apresentou correlação negativa baixa e alta com o ENOS34, correlação negativa alta com o TNA e correlação positiva alta e baixa com o TSA, respectivamente.

4.3 Prognóstico das variáveis meteorológicas

Nesta seção serão apresentados e discutidos os resultados relacionados a simulação das VM através da técnica de processamento de sinal TWD e RNA. As VM observadas serão chamadas de OBS, as séries de dados processadas via Wavelet Symlet serão chamadas de VMW e as variáveis simuladas via RNA serão chamadas de NAR, NARX e LSTM. Considerando quatro períodos de análise, os períodos Total, Transição, Chuvoso e Seco.

A Tabela 8 mostra as métricas estatística utilizadas para comparar as variáveis observadas com as variáveis processadas e simuladas. Os indicadores estatísticos utilizados para validar os prognósticos foram: erro médio e raiz do erro quadrático médio, ambas com a unidade de medida sendo a mesma das VM, erro percentual absoluto médio dado em porcentagem, e a correlação de Pearson que é adimensional. O melhor cenário para os prognósticos é quando EM, REQM e EPAM são zero e quando CP é um, indicando prognósticos perfeitos.

Todos os valores do EM foram próximos de zero, apresentando 48 erros negativos (subestimativa) e 32 erros positivos (superestimativa). Corroborando com SANTOS et al. (2020), informando que a maioria dos prognósticos subestimam a velocidade do vento. As relações (VMW, OBS) apresentaram os menores erros médios em ambos os períodos, devido as VMW conservarem as características das variáveis OBS. Entre os prognósticos, o melhor EM ocorreu na relação (NAR, OBS) para a variável VV no PT, seguido pela relação (NARX, OBS) para a variável UR no período Total. Os piores EM ocorreram nas relações (LSTM, OBS) para a variável DV no PC, PT e PS, respectivamente.

A REQM indica a intensidade do erro dos prognósticos. A relação (NAR, OBS) apresentou todos os valores de REQM próximo de zero, indicando bons prognósticos das variáveis, principalmente na simulação da VV e PA em ambos os períodos. As relações (NARX, OBS) e (LSTM, OBS) apresentaram REQM maiores que um, exclusivamente apenas para as variáveis DV e UR em todos os períodos. Essas variáveis (DV e UR) apresentam as maiores variabilidades e consequentemente as RNAs (NARX e LSTM) não reproduziram bem essas altas variabilidades. Os melhores valores de REQM ocorreram na relação (VMW, OBS) para a variável PA, seguido pela relação (NAR, OBS) para a variável TA, ambos no PC. Os piores valores de REQM ocorreram na relação (LSTM, OBS) para a variável DV nos períodos Total, PC, PT e PS, respectivamente.

O EPAM informa o erro dos prognósticos em termos de porcentagem. As simulações da VV apresentaram os maiores valores do EPAM, seguido da DV, isso é devido ao vento OBS apresentarem os valores mais próximos de zero, consequentemente o resultado do EPAM tende a aumentar. As simulações da PA apresentaram os melhores EPAM em ambos os períodos, devido a sua unidade de medida (mm Hg) de valores distantes de zero. As relações (NAR, OBS) apresentaram os melhores valores do EPAM de todas as variáveis e períodos, seguido pelas relações (NARX, OBS) e por último a relação (LSTM, OBS).

Todos os valores da CP foram categorizados majoritariamente como quase perfeita de acordo com a Tabela 3. Apenas a relação (LSTM, OBS) para a variável DV no período Total ocorreu CP classificada como muito alta. As relações (NAR, OBS) apresentaram os maiores valores da CP, seguido pelas relações (NARX, OBS) e as

relações (LSTM, OBS) apresentaram os menores valores da CP, em ambos os períodos. A DV é a variável que apresentou menor correlação com os prognósticos, devido a mudanças de direção do vento e valores extremos. A TA apresentou as maiores correlações com os prognósticos, seguido pela UR, PA e VV.

Portanto, os prognósticos NAR apresentaram as melhores métricas estatísticas de erro e correlação, seguido pelo prognóstico NARX e LSTM, respectivamente. Os prognósticos da DV apresentaram as piores métricas estatísticas, devido a essa variável apresentar grande variabilidade e muitas mudanças de direção. Os prognósticos da PA foi quem mais se aproximou do melhor cenário, devido ao seu menor intervalo de variabilidade e unidade de medida utilizada. Os prognósticos das variáveis TA, VV e UR também foram consistentes. Não fica claro em qual período os prognósticos foram melhores.

Tabela 8. Estatística bivariada (erros e correlação) entre as variáveis meteorológicas observadas, processadas e simuladas, considerando os períodos TOTAL, Transição, Chuvoso e Seco. Fonte: Autor (2024).

VM	RELAÇÃO	PERÍODO	EM	REQM	EPAM	CP
VV (m.s ⁻¹)	(NAR,OBS)	TOTAL	0,0021	0,0791	1,5586	0,9994
DV (°)	(NAR,OBS)	TOTAL	-0,0410	0,7530	1,0932	0,9911
TA (°C)	(NAR,OBS)	TOTAL	0,1466	0,1628	0,6792	0,9998
UR (%)	(NAR,OBS)	TOTAL	0,0066	0,2090	0,2904	0,9998
PA (mm Hg)	(NAR,OBS)	TOTAL	-0,0441	0,1055	0,0143	0,9977
VV (m.s ⁻¹)	(NARX,OBS)	TOTAL	-0,0032	0,3350	5,8734	0,9812
DV (°)	(NARX,OBS)	TOTAL	0,4186	1,6824	1,8353	0,9850
TA (°C)	(NARX,OBS)	TOTAL	0,0238	0,1575	0,6297	0,9977
UR (%)	(NARX,OBS)	TOTAL	-8,26e-04	1,0265	1,3915	0,9964
PA (mm Hg)	(NARX,OBS)	TOTAL	-0,0452	0,1268	0,0171	0,9963
VV (m.s ⁻¹)	(VMW,OBS)	TOTAL	-1,37e-04	0,2104	3,7122	0,9932
DV (°)	(VMW,OBS)	TOTAL	-4,59e-05	0,7814	0,6421	0,9982
TA (°C)	(VMW,OBS)	TOTAL	4,42e-06	0,0948	0,3800	0,9991
UR (%)	(VMW,OBS)	TOTAL	4,90e-05	0,6284	0,8444	0,9987
PA (mm Hg)	(VMW,OBS)	TOTAL	4,54e-05	0,0637	0,0086	0,9990
VV (m.s ⁻¹)	(LSTM,OBS)	TOTAL	-0,1344	0,6978	12,3783	0,9130
DV (°)	(LSTM,OBS)	TOTAL	0,4893	4,4312	4,7028	0,8805
TA (°C)	(LSTM,OBS)	TOTAL	0,1579	0,3838	1,4988	0,9854
UR (%)	(LSTM,OBS)	TOTAL	-0,1408	2,7028	3,7477	0,9767
PA (mm Hg)	(LSTM,OBS)	TOTAL	-0,0421	0,3269	0,0442	0,9797
VV (m.s ⁻¹)	(NAR,OBS)	PT	-5,44e-05	0,0916	1,6529	0,9991
DV (°)	(NAR,OBS)	PT	-0,3066	0,8006	0,7143	0,9923
TA (°C)	(NAR,OBS)	PT	-0,0988	0,1291	0,4712	0,9998
UR (%)	(NAR,OBS)	PT	-0,0065	0,2733	0,3802	0,9997
PA (mm Hg)	(NAR,OBS)	PT	-0,0062	0,1034	0,0140	0,9961
VV (m.s ⁻¹)	(NARX,OBS)	PT	0,0248	0,3282	5,3670	0,9820
DV (°)	(NARX,OBS)	PT	-0,0012	1,4595	1,2307	0,9848
TA (°C)	(NARX,OBS)	PT	-0,1193	0,1516	0,5806	0,9986
UR (%)	(NARX,OBS)	PT	0,0503	1,0146	1,4219	0,9968
PA (mm Hg)	(NARX,OBS)	PT	0,0095	0,1020	0,0138	0,9967

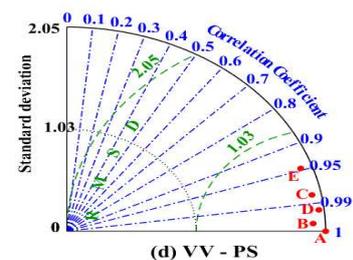
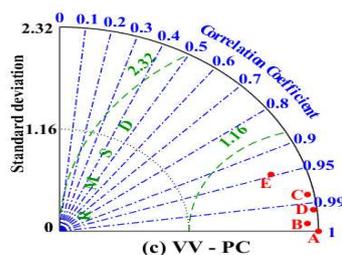
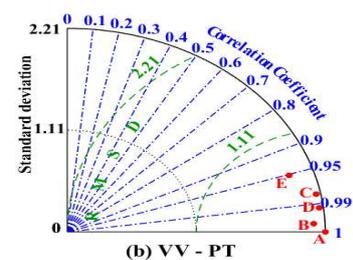
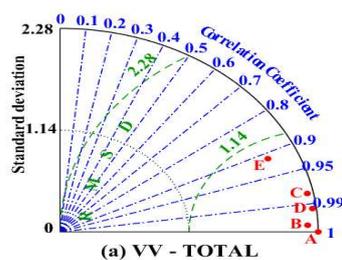
VV (m.s ⁻¹)	(VMW,OBS)	PT	-1,52e-04	0,2121	3,4727	0,9927
DV (°)	(VMW,OBS)	PT	5,62e-05	0,7384	0,5817	0,9970
TA (°C)	(VMW,OBS)	PT	-1,47e-05	0,0941	0,3696	0,9992
UR (%)	(VMW,OBS)	PT	-6,36e-05	0,6080	0,8510	0,9989
PA (mm Hg)	(VMW,OBS)	PT	2,17e-05	0,0688	0,0093	0,9988
VV (m.s ⁻¹)	(LSTM,OBS)	PT	-0,0147	0,5129	8,7028	0,9516
DV (°)	(LSTM,OBS)	PT	-0,8617	2,9717	2,5308	0,9265
TA (°C)	(LSTM,OBS)	PT	0,2585	0,3514	1,3630	0,9919
UR (%)	(LSTM,OBS)	PT	-0,6532	1,9972	2,6860	0,9896
PA (mm Hg)	(LSTM,OBS)	PT	-0,0124	0,2461	0,0333	0,9853
VV (m.s ⁻¹)	(NAR,OBS)	PC	0,0046	0,0803	1,9354	0,9992
DV (°)	(NAR,OBS)	PC	-0,0299	0,9055	1,8047	0,9912
TA (°C)	(NAR,OBS)	PC	-0,0291	0,0585	0,2307	0,9995
UR (%)	(NAR,OBS)	PC	0,0103	0,2386	0,3150	0,9997
PA (mm Hg)	(NAR,OBS)	PC	0,0366	0,0634	0,0086	0,9990
VV (m.s ⁻¹)	(NARX,OBS)	PC	-0,0041	0,3214	6,6031	0,9828
DV (°)	(NARX,OBS)	PC	-0,1680	2,0918	2,6785	0,9836
TA (°C)	(NARX,OBS)	PC	-0,0498	0,1586	0,6368	0,9973
UR (%)	(NARX,OBS)	PC	-0,0399	1,0614	1,3797	0,9956
PA (mm Hg)	(NARX,OBS)	PC	-0,0584	0,1049	0,0142	0,9982
VV (m.s ⁻¹)	(VMW,OBS)	PC	-4,39e-06	0,1969	4,1300	0,9943
DV (°)	(VMW,OBS)	PC	-3,64e-04	0,8802	0,7713	0,9982
TA (°C)	(VMW,OBS)	PC	3,10e-06	0,0974	0,3928	0,9989
UR (%)	(VMW,OBS)	PC	2,90e-05	0,6388	0,8192	0,9985
PA (mm Hg)	(VMW,OBS)	PC	2,24e-05	0,0574	0,0078	0,9992
VV (m.s ⁻¹)	(LSTM,OBS)	PC	-0,1052	0,5703	11,7391	0,9467
DV (°)	(LSTM,OBS)	PC	-0,8920	3,8080	4,8140	0,9090
TA (°C)	(LSTM,OBS)	PC	0,0526	0,2934	1,1737	0,9911
UR (%)	(LSTM,OBS)	PC	-0,3839	1,9606	2,5758	0,9829
PA (mm Hg)	(LSTM,OBS)	PC	-0,0282	0,2699	0,0365	0,9863
VV (m.s ⁻¹)	(NAR,OBS)	PS	-0,0032	0,0869	1,4429	0,9994
DV (°)	(NAR,OBS)	PS	-0,0322	0,7228	0,7784	0,9838
TA (°C)	(NAR,OBS)	PS	0,0669	0,0946	0,4024	0,9997
UR (%)	(NAR,OBS)	PS	-0,0101	0,3337	0,4637	0,9995
PA (mm Hg)	(NAR,OBS)	PS	-0,0202	0,0626	0,0085	0,9988
VV (m.s ⁻¹)	(NARX,OBS)	PS	0,0112	0,3482	5,3893	0,9767
DV (°)	(NARX,OBS)	PS	0,0443	1,4577	1,3502	0,9874
TA (°C)	(NARX,OBS)	PS	0,0107	0,1553	0,6208	0,9975
UR (%)	(NARX,OBS)	PS	-0,0198	1,0246	1,3983	0,9962
PA (mm Hg)	(NARX,OBS)	PS	-0,0736	0,1544	0,0209	0,9942
VV (m.s ⁻¹)	(VMW,OBS)	PS	-1,08e-04	0,2275	3,4672	0,9902
DV (°)	(VMW,OBS)	PS	-5,17e-04	0,7329	0,5830	0,9983
TA (°C)	(VMW,OBS)	PS	-1,30e-05	0,0923	0,3758	0,9991
UR (%)	(VMW,OBS)	PS	-6,96e-06	0,6453	0,8733	0,9986
PA (mm Hg)	(VMW,OBS)	PS	1,87e-05	0,0676	0,0091	0,9986
VV (m.s ⁻¹)	(LSTM,OBS)	PS	0,1012	0,5164	8,0813	0,9436
DV (°)	(LSTM,OBS)	PS	0,6317	2,9138	2,7641	0,9408
TA (°C)	(LSTM,OBS)	PS	0,0035	0,5201	2,0696	0,9903
UR (%)	(LSTM,OBS)	PS	-0,3262	1,5604	2,0952	0,9901
PA (mm Hg)	(LSTM,OBS)	PS	0,0829	0,4965	0,0671	0,9771

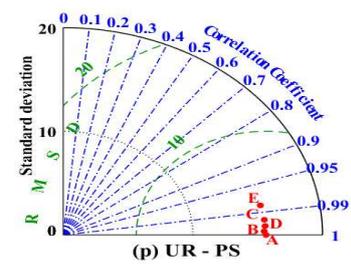
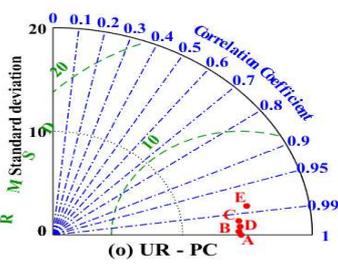
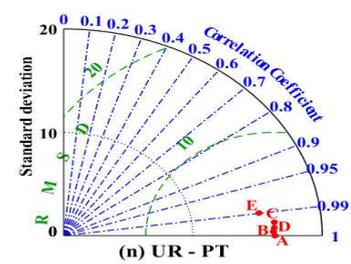
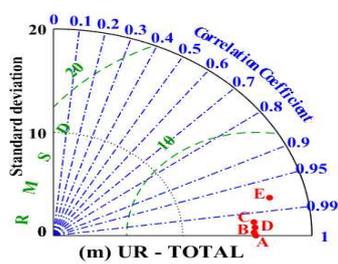
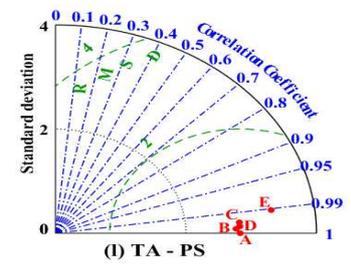
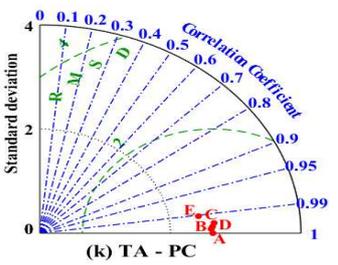
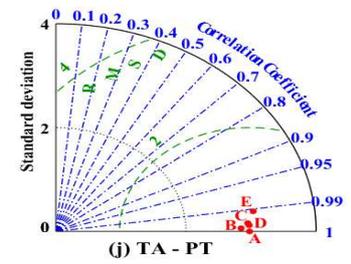
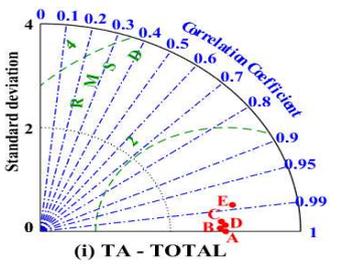
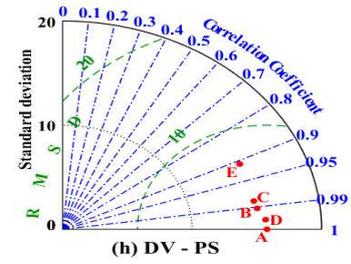
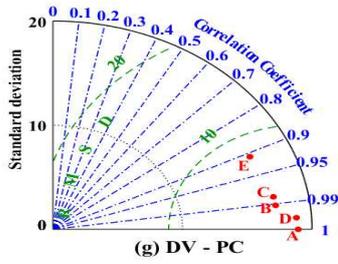
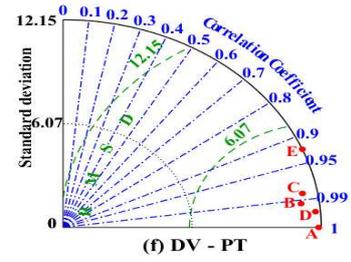
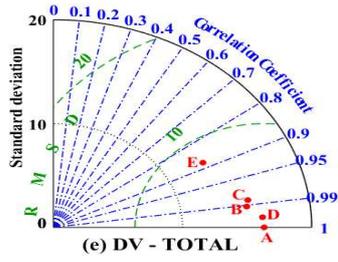
Outra forma de analisar qual foi o melhor prognóstico é através da representação gráfica do Diagrama de Taylor. O Diagrama de Taylor resume graficamente a Tabela 8 acima, mostrando pontos bidimensionais que representam as métricas estatísticas (CP, REQM e DP) entre as VM observadas e simuladas. Quanto mais próximo os pontos (processados e simulados) estiverem do ponto (observado), melhor será o desempenho dos prognósticos (TAYLOR, 2001; PEREIRA et al., 2014; TIAN e CHEN, 2021).

A Figura 24 mostra o Diagrama de Taylor entre as VM analisadas e seus respectivos prognósticos durante os períodos Total e sazonal. Os pontos significam: A as variáveis OBS; B os prognósticos via RNA-NAR; C os prognósticos via RNA-NARX; D as variáveis processadas via TWD; E os prognósticos via RNA-LSTM.

De modo geral, o ponto E (LSTM) é quem mais se afastou do ponto A (OBS), consequentemente apresentou o pior desempenho de simulação dentre todas as variáveis e em ambos os períodos. O ponto B (NAR) é quem mais se aproximou do ponto A (OBS) e portanto apresentou o melhor prognóstico. O ponto C (NARX) apresentou uma distância intermediária entre os pontos B (NAR) e E (LSTM), portanto é o segundo melhor prognóstico.

O Diagrama de Taylor da Figura 24 (i, j, k, l, m, n, o, p, q, r, s, t) mostrou que os pontos A, B, C e D estão mais próximas uns dos outros, quase coincidindo, isso indica que os prognósticos simularam bem as variáveis PA, UR e TA em ambos os períodos. Já o Diagrama de Taylor da Figura 24 (a, b, c, d, e, f, g, h) apresentou as maiores distâncias entre os pontos A, B, C, D e E, isso informa que os prognósticos têm mais dificuldades de simular as variáveis DV e VV, respectivamente. Por fim, através do uso do Diagrama de Taylor também não fica claro em qual período sazonal os prognósticos apresentaram um desempenho mais consistente, visto que não existe uma diferença de distância significativa entre os pontos A, B, C, D e E nos períodos sazonais.





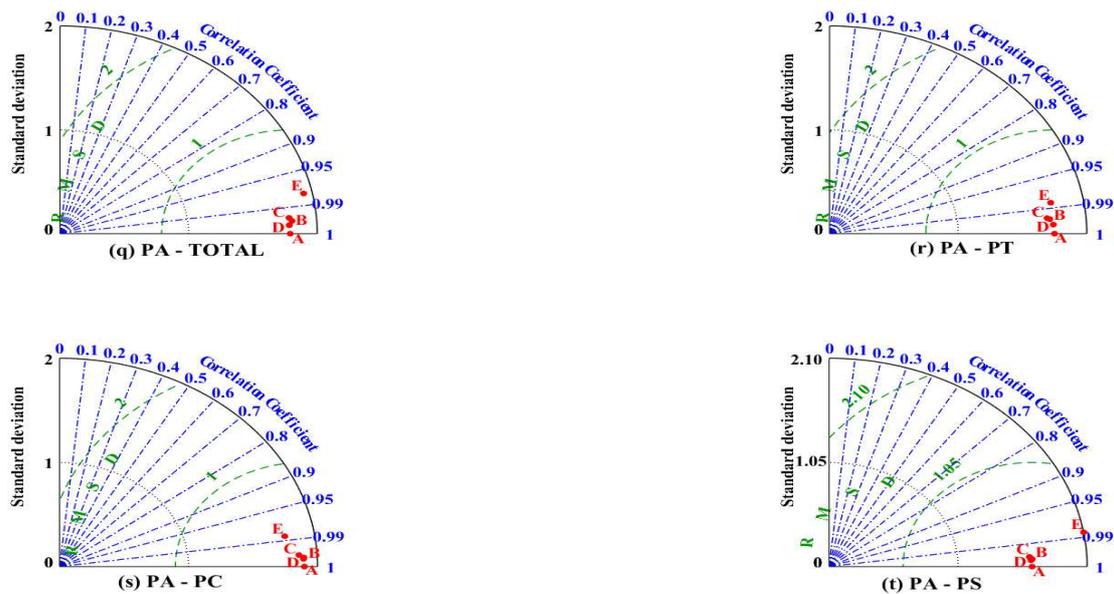


Figura 24. Diagrama de Taylor aplicado nas variáveis meteorológicas observadas, processadas e simuladas. Considerando os períodos TOTAL, Transição, Chuvoso e Seco. Os pontos são definidos em: A (OBS), B (NAR), C (NARX), D (VMW), E (LSTM). Fonte: Autor (2023).

Muitos estudos utilizaram RNA para a previsão da velocidade do vento, por exemplo, SANTOS et al. (2020) usaram RNA (NAR e NARX) e WRF para previsão da VV na região Agreste de Alagoas, as métricas estatísticas utilizadas para averiguar a acurácia das previsões foram: EM (-0,31 a 0,04 m.s^{-1}), REQM (1,14 a 1,27 m.s^{-1}), EPAM (22 a 23%) e CP (0,63 a 0,72). CAMELO et al. (2018) utilizaram um modelo híbrido (ARIMAX, RNA e ARXAN) para previsão da VV em regiões do NEB (Fortaleza, Natal e Parnaíba), a estatística de erros para cada modelo foram: ARIMAX, MAE (0,81 a 0,92 m.s^{-1}), RMSE (1,08 a 1,23 m.s^{-1}) e MAPE (17,19 a 18,84%); RNA, MAE (0,64 a 0,75 m.s^{-1}), RMSE (0,89 a 1,01 m.s^{-1}) e MAPE (12,01 a 15,30%); ARXAN, MAE (0,32 a 0,47 m.s^{-1}), RMSE (0,41 a 0,64 m.s^{-1}) e MAPE (7,20 a 8,65%).

CARMO (2022) utilizou RNA (NAR e NARX) para previsão da irradiação horizontal global (IHG) em Brasília, DF. O intervalo considerado foi de abril de 2008 a outubro de 2009, a resolução dos dados era de um minuto e foi convertido para diários. As métricas estatísticas utilizadas para aferir a acurácia da previsão foram a MAPE e RMSE. A configuração das RNAs que ofereceram melhores respostas foram: Algoritmo de treinamento (Bayesian Reularization); Percentuais de treinamento (70%), validação (15%) e teste (15%); Janela de 30 dias para compor a previsão de um dia à frente; E quatro neurônios na camada escondida. Os erros de validação (V) e teste (T) para previsão foram: NAR, MAPE-V (10,33%), MAPE-T (13,39%), RMSE-V (39.119 W.m^{-2}) e RMSE-T (51.782 W.m^{-2}); NARX, MAPE-V (7,01%), MAPE-T (5,75%), RMSE-V (29.148 W.m^{-2}) e RMSE-T (29.383 W.m^{-2}).

GURLEK (2023) utilizou RNA (MLP) para previsão da umidade relativa do ar mensal em cinco estações da Sivas, Turquia. A estrutura da RNA foi: cinco variáveis na camada de entrada, uma camada escondida com sete neurônios e função de ativação

tangente hiperbólica, uma camada de saída com um neurônio e função de ativação linear, algoritmo de treinamento foi o Levenberg-Marquardt. Os dados da UR eram mensais com período de 19 anos (2000-2018) divididos em três partes, 80% (2000-2014) usados para treinamento, 10% (2015-2016) para teste e 10% (2017-2018) para validação. As métricas estatísticas usadas para a acurácia da previsão resultaram em: R^2 (0,952 - 0,965); MAE (1,916 - 2,586); MAPE (3,422 - 4,974); RMSE (2,472 - 3,391).

ASTSATRYAN et al. (2021) utilizaram RNA (MLP) combinado com a metodologia ARIMA para previsão da temperatura do ar em quatro estações (Ararat, Armavir, Artashat e Merdzavan) no vale do Ararat, Armenia. Os dados eram horários e o período de estudo cinco anos (2013-2017), sendo os três anos iniciais (2013-2015) usados para treinamento e os dois anos finais (2016-2017) usados para teste. Esse estudo utilizou quatro parâmetros (TA, UR, PA e ponto de orvalho) como dados de entrada para a previsão da TA no intervalo de três a 24 horas. As métricas estatísticas usadas para avaliar o erro do modelo combinado (RNA + ARIMA) foram: MSE (1,7956 a 3,4346 °C²) e RMSE (1,34 a 1,8533 °C).

4.4 Análise do perfil vertical do vento

A Figura 25 mostra a evolução temporal da velocidade do vento mensurada nos níveis de altura (4, 10, 14, 19, 30, 50, 70 e 100 m) chamados respectivamente de Z1, Z2, Z3, Z4, Z5, Z6, Z7 e Z8. Foram analisados 38 dias (06/12/2014 à 12/01/2015) período que apresentou baixa precipitação acumulada, elevadas velocidades do vento, predominância de direção em SE, relação inversa mais acentuada do aumento e diminuição da temperatura e umidade relativa, respectivamente, e início da fase El Niño classificado como muito forte de 2015 (Figura 23).

De modo geral, observa-se um espelhamento da VV em ambos os níveis de medição, a VV se intensifica gradualmente com o aumento da altura, isso é devido à interação do vento com fatores geográficos e climáticos, por exemplo, fisiografia local (relevo, vegetação, montanhas entre outros) e rugosidade superficial. Do nível Z1 até Z5 a VV apresenta pequenas oscilações e a partir do nível Z6 essas oscilações diminuem, isso ocorre porque o atrito do vento com a superfície diminui com o aumento da altura, o vento sofre mais interferência do solo em níveis mais baixos (CORRÊA, 2007; SATHE e BIERBOOMS, 2007; RAMOS et al., 2018; SILVA, 2018).

RAMOS et al. (2018) investigaram a relação da estrutura do vento e da estabilidade atmosférica na CLS do CLA, no Maranhão, durante dois períodos distintos de 30 dias referentes às estações seca (novembro/2016) e chuvosa (25/março a 24/abril de 2017). Os dados foram coletados em uma torre anemométrica de 100 m de altura com dez níveis de medição distribuídos entre 10 e 100 m, igualmente espaçados em 10 m e a resolução temporal destes dados é de 10 min. Os resultados mostraram que a incidência de ventos iguais ou maiores que 5 m.s⁻¹ é predominante em todo o período seco, principalmente durante o intervalo diurno, devido a maior magnitude da circulação da brisa marítima combinada com os ventos alísios de NE. No período chuvoso houve ventos entre 5 e 10 m.s⁻¹, mas com predominância de registros abaixo deste intervalo, principalmente durante e após os eventos pluviométricos.

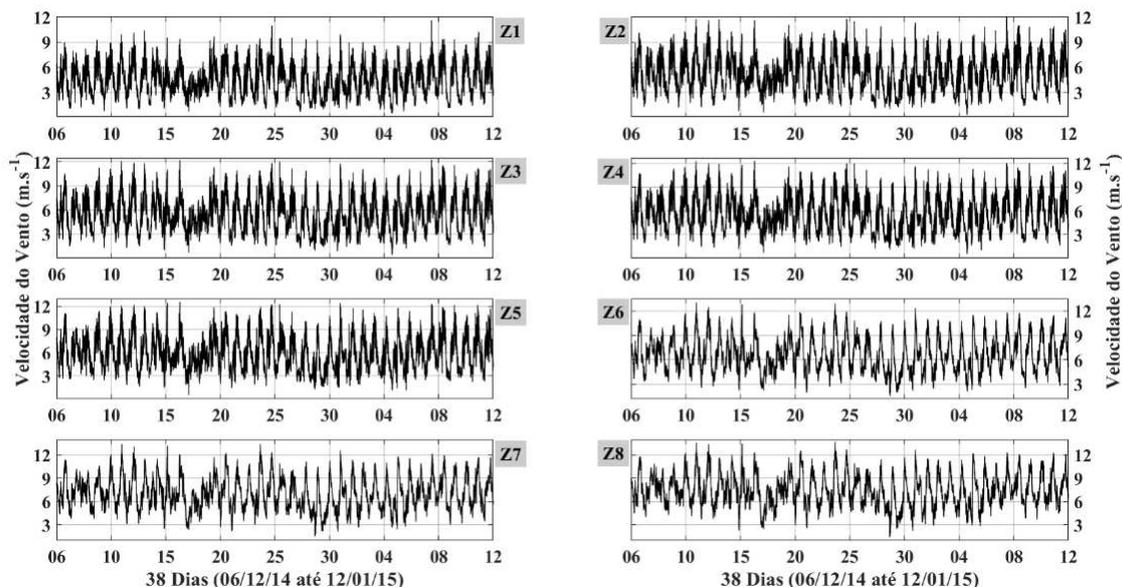


Figura 25. Evolução temporal da velocidade do vento nos oito níveis de medição. Fonte: Autor (2023).

PAULA et al. (2017) investigaram a espacialização da velocidade do vento no estado de Minas Gerais. Foram empregadas 73 estações meteorológicas distribuídas geograficamente em MG e nos estados que o circundam. O período médio de estudo foi de 50 anos (1960-2016) e a resolução dos dados é em média diárias e mensais (março, junho, setembro e dezembro). Os mapas de velocidade média do vento para as alturas 50, 75 e 100 m foram obtidos a partir de interpolação geoestatística (Krigagem Universal). Os resultados mostraram que as maiores frequência de ocorrência (FO) ocorreram na classe 2 – 2,5 m.s⁻¹ nos meses (março, junho e dezembro) em ambas as alturas, no mês de setembro as maiores FO ocorreram na classe 2,5 – 3 m.s⁻¹ nas alturas 50 e 75 m, e na classe 3 – 3,5 m.s⁻¹ na altura 100 m. As regiões N e NE, próximo aos estados da Bahia e Espírito Santo, foram as que apresentaram as maiores velocidades.

A Figura 26 mostra o CDM da VV distribuídas nos oito níveis de altura. Em todos os níveis a VV apresentou valores mínimos no intervalo de 05 a 07 horas e valores máximos no intervalo de 16 a 18 horas. Em baixos (altos) níveis as velocidades mínimas e máximas estiveram no limite inferior (superior) dos intervalos. Observa-se que o intervalo da intensidade da VV aumenta com a altura, começando de 2 a 7 m.s⁻¹ em Z1 e finalizando de 5 a 10 m.s⁻¹ em Z8. Através do CDM também é possível visualizar a presença de pequenas oscilações mais (menos) acentuadas em níveis mais baixos (altos), respectivamente.

A maior diferença entre as linhas de CDM da VV em ambos os níveis ocorre no período do nascer do sol entre 05 e 07 horas da manhã (Figura 26). Isso ocorre porque na camada limite superficial e nesse horário os gradientes verticais das variáveis (temperatura, umidade relativa, razão de mistura, velocidade do vento, entre outras) estão muito intensos e à medida que aumentamos a altura os gradientes verticais vão diminuindo gradativamente (STULL, 1988).

ASSIREU et al. (2019) fez uso, pela primeira vez no Brasil, de um veículo aeronáutico não tripulado (VANT) equipado com anemômetro, para medir diretamente o perfil vertical do vento influenciado por colinas. A região de estudo compreende o reservatório de Furnas, MG. O experimento foi realizado entre os dias 21 e 25 de novembro de 2016 em diferentes setores do reservatório. O perfil vertical com o VANT, até 100 m, consistiu em medidas a partir de três e cinco metros. Em cada um dos níveis o VANT realizou medições de um minuto de duração. Os resultados confirmam experimentalmente o fato de que o escoamento no topo de colinas tende a ser intensificado devido a conservação de massa associado ao adensamento das linhas de fluxo ao contornarem a colina. Assim verificou-se um aumento de 90% da velocidade do vento próximo a 20 m de altura, quando comparado as velocidades do vento no topo da colina com a base da colina (barlavento).

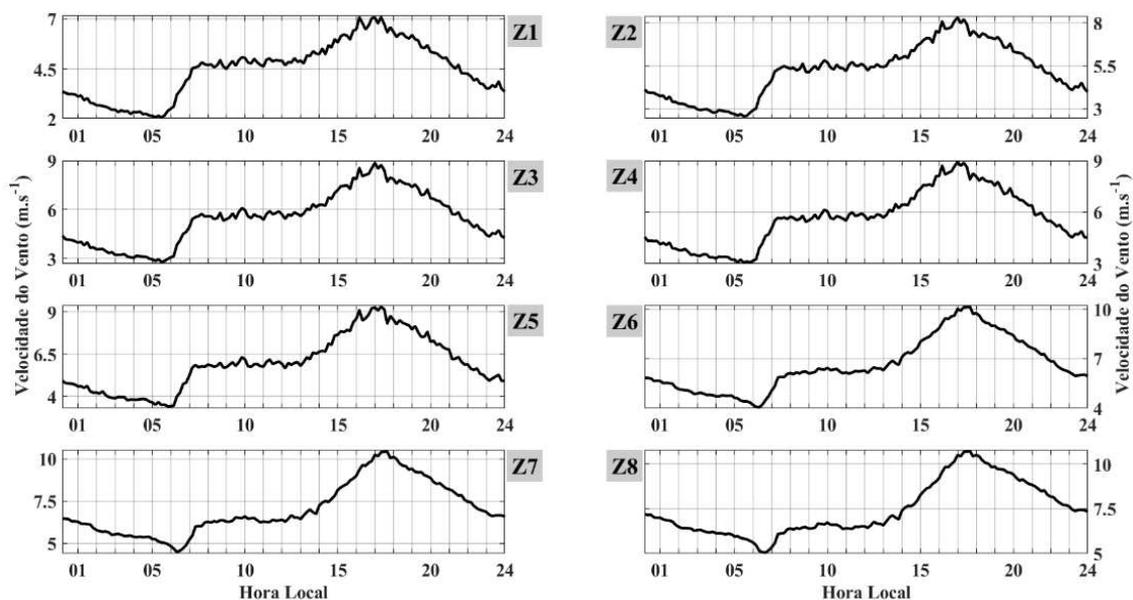


Figura 26. Ciclo diário médio da velocidade do vento nos oito níveis de medição. Fonte: Autor (2023).

A Figura 27 mostra diferentes tipos de gráficos a partir dos oito ciclos diários médios da velocidade do vento. A Figura 27a mostra um gráfico de superfície 3D, eixo-x hora local dados com resolução de 10 minutos completando 24 horas, eixo-y representa os oito níveis de medição e eixo-z é a velocidade do vento. Figura 27b mostra um gráfico de contorno preenchido, os níveis são as isolinhas e as cores indicam a intensidade da velocidade do vento. A Figura 27c mostra o gráfico de boxplot. A Figura 27d mostra o gráfico de evolução temporal dos valores médios com barras de desvio padrão.

De modo geral, em ambos os gráficos observamos as menores velocidades próximos de 05 horas e as maiores próximo de 18 horas. O intervalo de 06 a 08 horas apresentou *outliers*, as menores amplitudes interquartílicas e menores barras de desvio padrão. O período noturno (18 às 06 horas) apresentou as maiores amplitudes interquartílicas e as maiores barras de desvio padrão, o período diurno (06 às 18 horas)

as menores, conseqüentemente, a velocidade do vento cresce com baixa variabilidade durante o dia e decresce com alta variabilidade durante a noite.

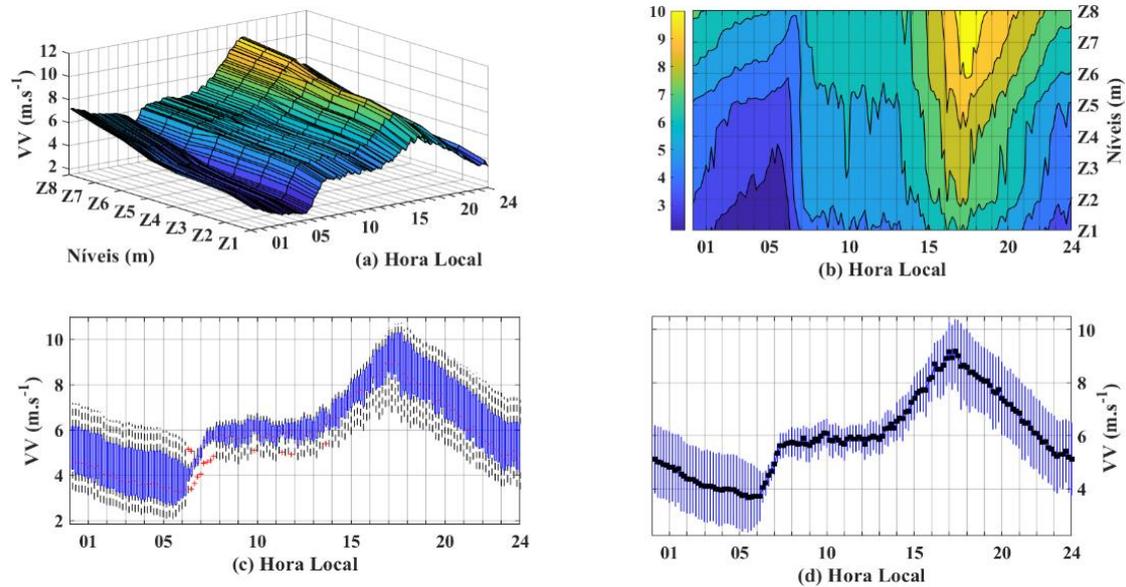


Figura 27. Diferentes tipos de gráficos do ciclo diário médio da velocidade do vento nos oito níveis de medição: (a) Gráfico de superfície 3D; (b) Gráfico de contorno; (c) Boxplot; (d) Gráfico de evolução temporal da média com barras de desvio padrão. Fonte: Autor (2023).

A Tabela 9 mostra uma ED detalhada da VV em ambos os níveis, adicionando o índice de turbulência e fator de rajada. Na VV Total, apenas os níveis Z8 e Z7 apresentaram velocidade média maior ou igual a 7 m.s^{-1} , os níveis Z6 e Z5 também atingem esse limiar porque apresentam variabilidade suficiente para isto. Os níveis inferiores não exibiram velocidades viável para construção de parques eólicos. A partir do DP e CV, vemos que a VV em Z1 mostrou a menor variabilidade e maior heterogeneidade, em Z5 a maior variabilidade e em Z8 é mais homogêneo, consequência da interação do vento com a rugosidade superficial.

Quanto maior o nível maior foram as velocidades M, Q1, MD, Q3 e Max, quanto menor o nível maior foram as métricas CV, IT e FR, conseqüentemente os níveis inferiores são mais turbulentos e mais susceptível a ocorrência de rajadas do que os níveis superiores. A VV em todos os níveis apresentou assimetria positiva, mas dentro do intervalo de simetria de Pearson (-1 a +1). A VV no nível Z8 foi quem mais apresentou características de distribuição normal, pois exibiu valores de CA e CC mais próximos de 0 e 3, respectivamente. Deste modo, em Z8 a VV é mais simétrica e suas “Caudas” têm mais expressividade na frequência de ocorrência de valores.

A partir da separação da VV dia e noite em ambos os níveis na Tabela 9, observamos que a VV durante o dia foi maior do que durante a noite, visto que apresentaram os maiores indicadores estatísticos, por exemplo, M, DP, Q1, MD, Q3, Max e AT. Durante a noite a VV é menos simétrica e com caudas mais expressivas do

que durante o dia. Os IT e FR atuaram de maneira diferente durante os períodos diurno e noturno, o IT pelo dia variou pouco entre 0,30 e 0,33, enquanto a noite decresceu de 0,44 e 0,24 à medida que aumentamos o nível. A FR é maior durante o período noturno do que no diurno em níveis inferiores, nos níveis superiores o FR apresenta valores semelhantes para ambos os períodos.

Tabela 9. Estatística descritiva da VV - velocidade do vento ($m.s^{-1}$) em oito níveis de altura durante o período de estudo (06/12/2014 até 12/01/2015) com três intervalos de medição Total e período do dia e noite separados. Métricas estatísticas: M - média, DP - desvio padrão, CV - coeficiente de variação, Min - mínimo, Q1 - primeiro quartil, MD - mediana, Q3 - terceiro quartil, AT - amplitude total, CA - coeficiente de assimetria, CC - coeficiente de curtose, IT - índice de turbulência, FR - fator de rajada. Fonte: Autor (2023).

VV Total	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8
M	4,47	5,19	5,49	5,64	5,96	6,65	7,03	7,45
DP	1,87	2,11	2,18	2,18	2,21	2,10	2,07	2,06
CV	0,42	0,41	0,40	0,39	0,37	0,32	0,30	0,28
Min	0,49	0,33	0,44	0,55	0,49	1,52	1,51	1,39
Q1	3,00	3,53	3,74	3,90	4,22	5,00	5,46	5,95
MD	4,33	5,08	5,31	5,45	5,77	6,48	6,87	7,32
Q3	5,82	6,73	7,05	7,15	7,53	8,14	8,48	8,87
Max	11,63	12,21	12,27	12,32	12,59	13,04	13,40	13,69
AT	11,14	11,88	11,83	11,77	12,10	11,52	11,89	12,30
CA	0,29	0,30	0,34	0,35	0,39	0,31	0,26	0,19
CC	2,45	2,42	2,44	2,47	2,51	2,41	2,49	2,54
IT	0,42	0,41	0,40	0,39	0,37	0,32	0,29	0,28
FR	2,60	2,35	2,23	2,18	2,11	1,96	1,91	1,83
VV Dia	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8
M	5,34	6,10	6,39	6,50	6,76	7,19	7,38	7,57
DP	1,72	1,98	2,10	2,13	2,23	2,21	2,26	2,30
CV	0,32	0,33	0,33	0,33	0,33	0,31	0,31	0,30
Min	0,71	0,60	0,71	0,71	0,49	1,52	1,51	1,39
Q1	4,06	4,65	4,86	4,97	5,13	5,54	5,69	5,85
MD	5,34	6,14	6,41	6,51	6,73	7,18	7,33	7,49
Q3	6,57	7,53	7,90	8,00	8,32	8,84	9,06	9,27

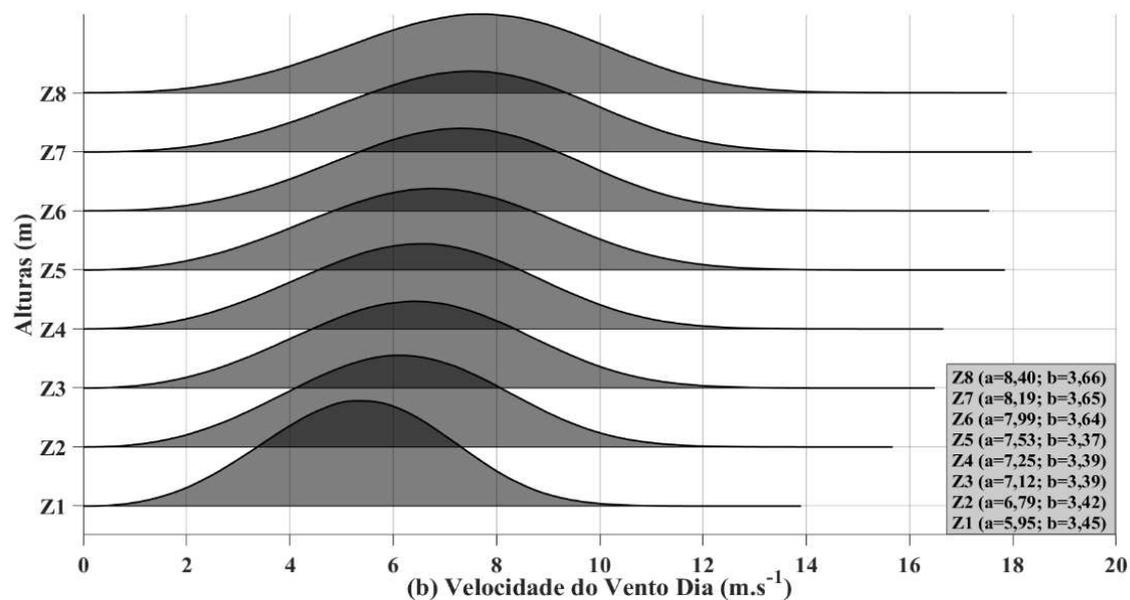
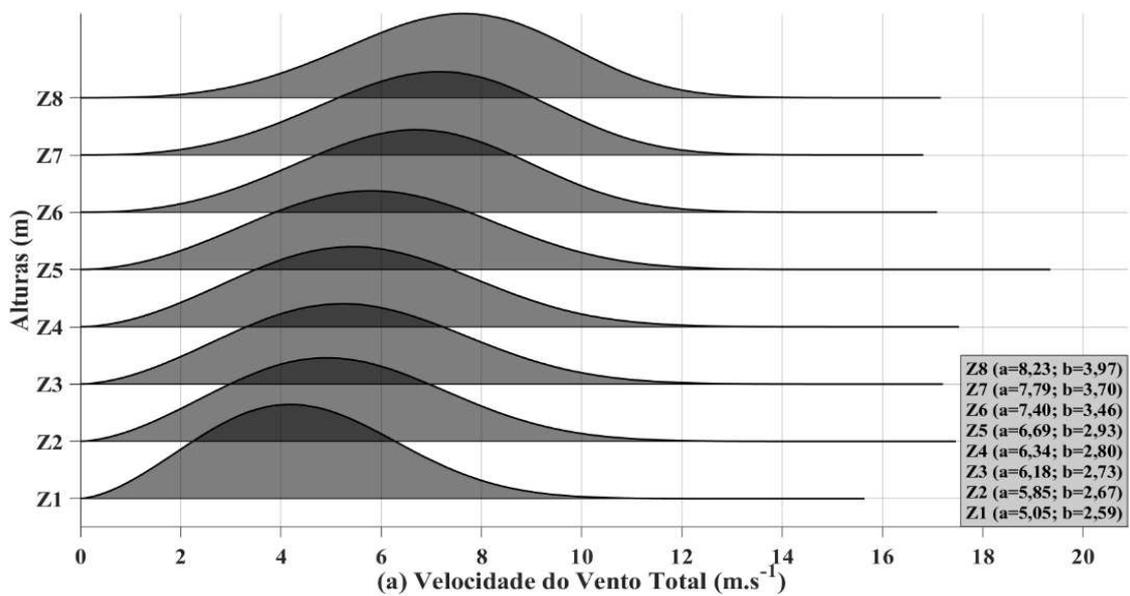
Max	11,63	12,21	12,27	12,32	12,59	13,04	13,40	13,69
AT	10,92	11,61	11,56	11,61	12,10	11,52	11,89	12,30
CA	0,06	0,02	0,03	0,03	0,04	0,03	0,06	0,09
CC	2,63	2,58	2,55	2,53	2,48	2,29	2,30	2,29
IT	0,32	0,32	0,33	0,33	0,33	0,31	0,31	0,30
FR	2,18	2,00	1,92	1,90	1,86	1,81	1,82	1,81
VV								
Noite	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8
M	3,49	4,17	4,45	4,65	5,05	6,03	6,63	7,32
DP	1,52	1,75	1,79	1,79	1,79	1,77	1,76	1,73
CV	0,44	0,42	0,40	0,38	0,35	0,29	0,27	0,24
Min	0,49	0,33	0,44	0,55	1,13	1,97	2,21	2,51
Q1	2,25	2,79	3,05	3,21	3,69	4,69	5,31	6,03
MD	3,32	3,96	4,22	4,38	4,76	5,79	6,43	7,21
Q3	4,44	5,24	5,50	5,77	6,14	7,14	7,76	8,44
Max	8,86	10,08	10,67	11,25	11,79	11,54	12,05	12,45
AT	8,37	9,75	10,23	10,70	10,66	9,57	9,84	9,94
CA	0,59	0,64	0,65	0,66	0,67	0,44	0,35	0,25
CC	2,88	2,93	2,93	2,98	3,01	2,59	2,62	2,65
IT	0,44	0,42	0,40	0,38	0,35	0,29	0,27	0,24
FR	2,54	2,42	2,40	2,42	2,33	1,91	1,82	1,70

Esses resultados corroboram com os estudos de LEMOS (2005) e SILVA (2011), em que a VV em níveis mais baixos são mais turbulentos. Ambos os níveis analisados estão dentro da Camada Superficial (CS), que durante o dia sofrem os impactos dos fluxos turbulentos, começando cerca de meia hora após o nascer do sol, o solo esquenta mais rápido que o ar atmosférico, com isso ocorre a convecção térmica, transferência de calor de uma superfície quente subindo do solo (nível Z0) para a atmosfera (níveis acima). Cerca de meia hora antes do pôr do sol, os termais e fluxos turbulentos diminuem e param de se formar. Durante a noite, a CS em contato com o solo sofre o resfriamento noturno, formando uma camada de inversão térmica e camada limite estável, nesse caso a turbulência é gerada mecanicamente pelo cisalhamento do vento em diferentes níveis de altura (STULL, 1988).

A Figura 28 mostra os Gráficos Ridgeline, conjunto de FDP Weibull sobrepostos, aplicado na VV distribuída nos oito níveis de medição, considerando os períodos do dia e noite juntos e separados. Os dois parâmetros de Weibull (escala e forma) apresentaram um desenvolvimento diferente para ambos os níveis e períodos. Em níveis inferiores (superiores) as curvas de ajuste são mais concentradas (distribuídas). No período Total, apenas nos níveis Z6, Z7 e Z8 a VV apresentou

frequência de ocorrência centralizada em 7 m.s^{-1} e de características de distribuição normal. Em ambos os níveis, os parâmetros de escala e forma aumentam com o aumento dos níveis, com exceção do parâmetro de forma da VV no período Dia.

Entre Dia e Noite separados, os parâmetros de escala foram maiores no período diário do que no noturno. Apenas nos níveis Z6, Z7 e Z8 os parâmetros de forma da VV Noite foram maiores do que no Dia. As maiores frequências de ocorrências da VV ocorreram no período diário e a partir do nível Z3 se concentrou em valores maiores ou iguais a 7 m.s^{-1} . Por fim, com base nos parâmetros de Weibull encontrados, o local de estudo indicou que a partir do nível Z7 a VV, no Dia e/ou Noite, pode ser aproveitada para fins de produção de energia eólica.



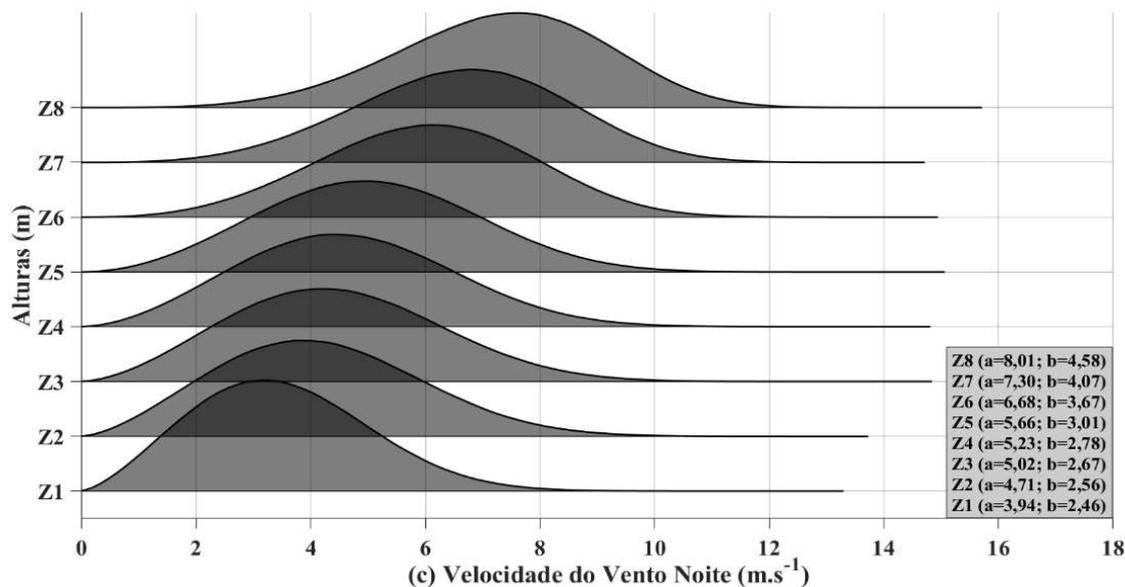


Figura 28. Gráficos Ridgeline de função densidade de probabilidade Weibull de dois parâmetros aplicado na velocidade do vento em oito níveis de medição considerando os períodos Total (a), Dia (b) e Noite (c). Fonte: Autor (2023).

GONÇALVES JÚNIOR et al. (2021) determinaram os dois parâmetros da FDP de Weibull e calcularam a densidade de energia eólica de Campos dos Goytacazes, Rio de Janeiro, para avaliar a possibilidade de instalação de um parque eólico, considerando as alturas 10, 50, 75 e 100m dos aerogeradores. A resolução dos dados eram horários, o período de estudo foi de um ano (01/03/2017 a 01/03/2018), os dados foram mensurados na altura de referência de 10m e extrapolados pela Lei de Potência para os demais níveis de medição. Os resultados mostraram que os parâmetros de Weibull aumentaram com a altura, escala (4,70 até 8,02 m.s⁻¹) e forma (1,99 até 2,18). Concluíram que o local de estudo é tecnicamente viável à instalação de um parque eólico, podendo abrigar aerogeradores de 50, 75 e 100m de altura.

A Figura 29 mostra o PVV média horária dos 38 dias estudados, são 24 PVV dividido em quatro grupos de seis perfis em sequência para cada gráfico. Em todos os perfis horários os níveis inferiores (superiores) apresentaram as menores (maiores) velocidades. Os perfis noturnos são diferentes dos diurnos devido à estabilidade atmosférica. A Figura 29a mostra os perfis horários noturno se desenvolvendo com características semelhantes, das 00:00 às 05:00 horas a intensidade da velocidade do vento diminui gradativamente.

A Figura 29b exibe perfis horários diurno com características distintas entre si e diferente dos perfis da Figura 29a, o perfil das 06:00 horas é completamente diferente dos perfis do seu grupo, principalmente a partir da altura 30, isso é porque nesse horário o sol está nascendo e ainda não interfere no desenvolvimento do PVV. O perfil das 07:00 horas foi o único perfil que apresentou diminuição de velocidade entre as alturas de 30 e 50m, devido a convecção térmica e fluxos turbulentos. Os demais perfis desse grupo apresentaram características semelhantes entre si.

A Figura 29c mostra os perfis horários diurno ambos com características equivalentes. Nesse grupo de perfis das 12:00 às 17:00 horas o gradiente vertical do vento é mais (menos) forte em níveis inferiores (superiores), visto que a velocidade do vento se intensifica mais rápido em baixas alturas (4 a 50m) do que em alturas mais altas (acima de 50m). Nesse grupo de perfis é possível visualizar que o PVV aumenta gradativamente com o passar das horas atingindo os maiores valores nos horários 16:00 e 17:00, respectivamente.

Por fim, a Figura 29d apresenta os perfis horários noturno, das 18:00 às 23:00 horas, se desenvolvendo com características análogas entre si. Nesse grupo de perfis a velocidade do vento diminui gradativamente com o passar das horas, consequentemente o perfil de 18:00 horas apresenta os maiores valores e o perfil de 23:00 apresenta os menores. O gradiente vertical do vento é mais forte entre as alturas 30 e 50m.

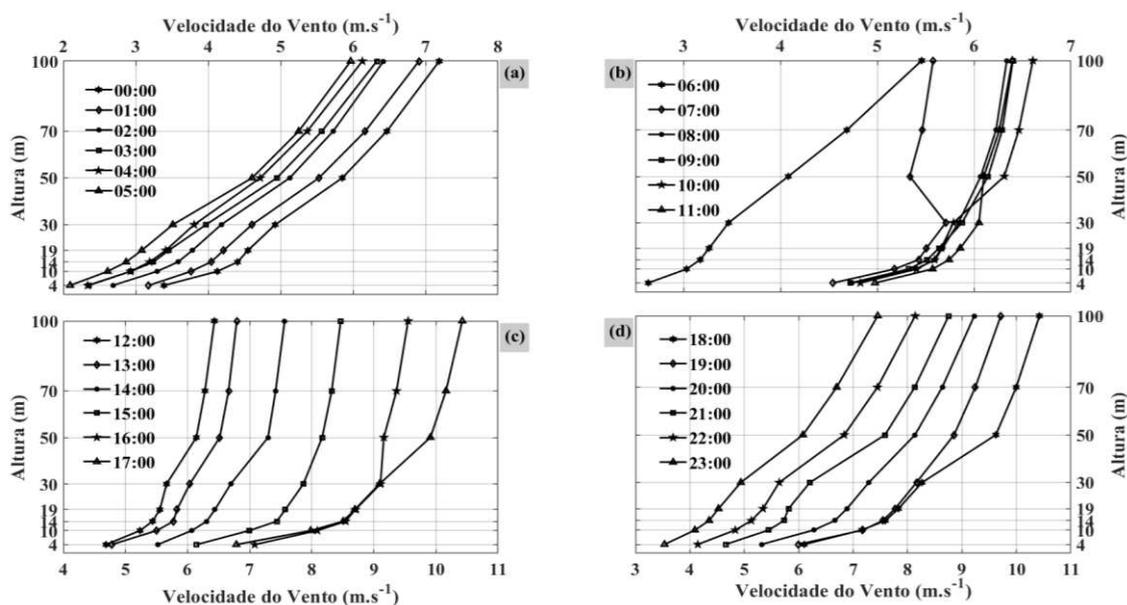


Figura 29. Perfil vertical da velocidade do vento média horária distribuído nos oito níveis de altura entre os dias 06/12/2014 e 12/01/2015. Fonte: Autor (2023).

A Figura 30 mostra a média diária do perfil vertical do vento distribuídos nos 38 dias estudados, divididos em quatro grupos, três gráficos de dez perfis em sequência e apenas o último grupo possui oito perfis.

De modo geral, em todos os grupos e perfis diários os níveis superiores (inferiores) apresentaram as maiores (menores) velocidades. Quase todos os perfis começam com velocidades entre 3 e 5 m.s^{-1} na altura 4m e se intensificam atingindo velocidade entre 6 e 9 m.s^{-1} na altura de 100m. As exceções foram os dias 17 e 18/12/14 (Figura 30b), 28 e 29/12/14 (Figura 30c) que apresentaram um PVV com as menores velocidades.

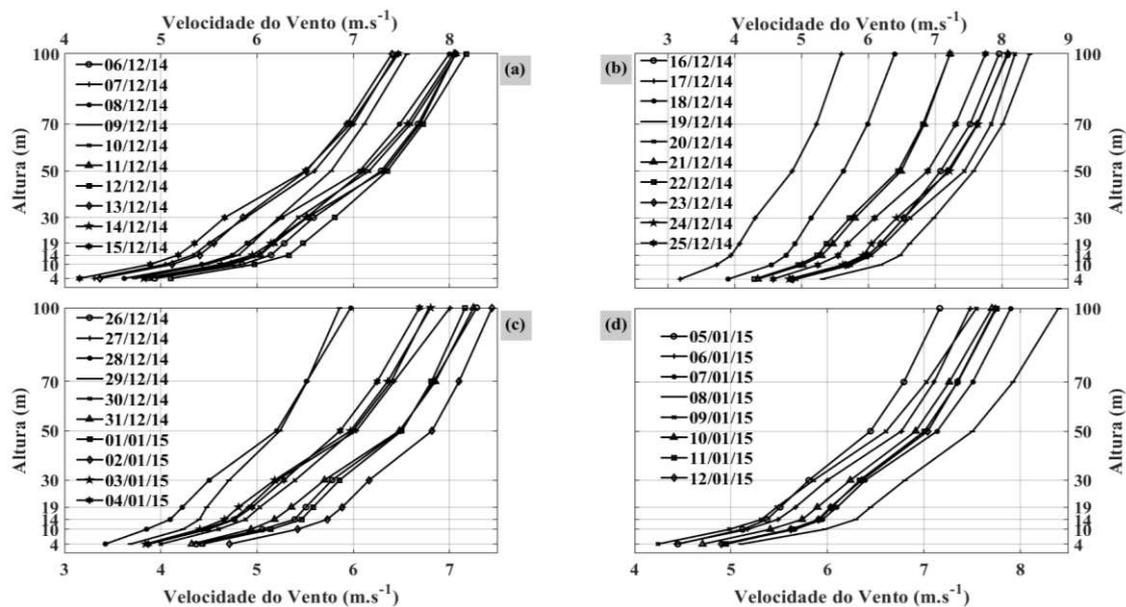


Figura 30. Perfil vertical da velocidade do vento da média diária nos oito níveis de altura. Fonte: Autor (2023).

A Figura 31 exibe o PVV média total dos 38 dias analisados, barras de erro horizontal (BEH) para mostrar os limites da variabilidade do PVV, Lei Logarítmica e Potência com seus respectivos parâmetros. As BEH correspondem ao DP da VV Total (Tabela 9). Entre as duas leis a LP coincidiu mais com o PVV Média Total do que a LL, mas ambas as leis estão dentro do intervalo de variabilidade do PVV e portanto perfeitamente aplicáveis. A altura de 30m apresentou a maior diferença entre os perfis, isso é consequência da convecção térmica e fluxos turbulentos que ocorrem aproximadamente as 07:00 horas.

SILVA (2018) utilizou dados observados de VV e DV para determinar os parâmetros aerodinâmicos da Lei da Potência e Logarítmica. Os dados foram distribuídos em cinco torres anemométricas localizadas nas mesorregiões (Sertão, Agreste e Leste) do Estado de Alagoas. Os dados foram armazenados em médias de 10 minutos, o período de estudo foi mensal e visa às estações do ano: Abril/2008 (outono), Junho/2008 (inverno), Outubro/2008 (primavera) e Janeiro/2009 (verão). Os resultados mostraram que a VV no Sertão e Agreste são maiores do que no Leste, a VV é mais intensa na estação seca do que na estação chuvosa e a DV predominante é SE. Os parâmetros aerodinâmicos da Lei Logarítmica não indicaram resultados coerentes. A Lei da Potência destacou a diferença entre litoral e interior, o coeficiente de camada limite no interior variou de 0,133 e 0,137 (Agreste e Sertão) e no litoral variou entre 0,16 e 0,178. Tendo em vista que o valor padrão do coeficiente de camada limite é de ordem de 0,15.

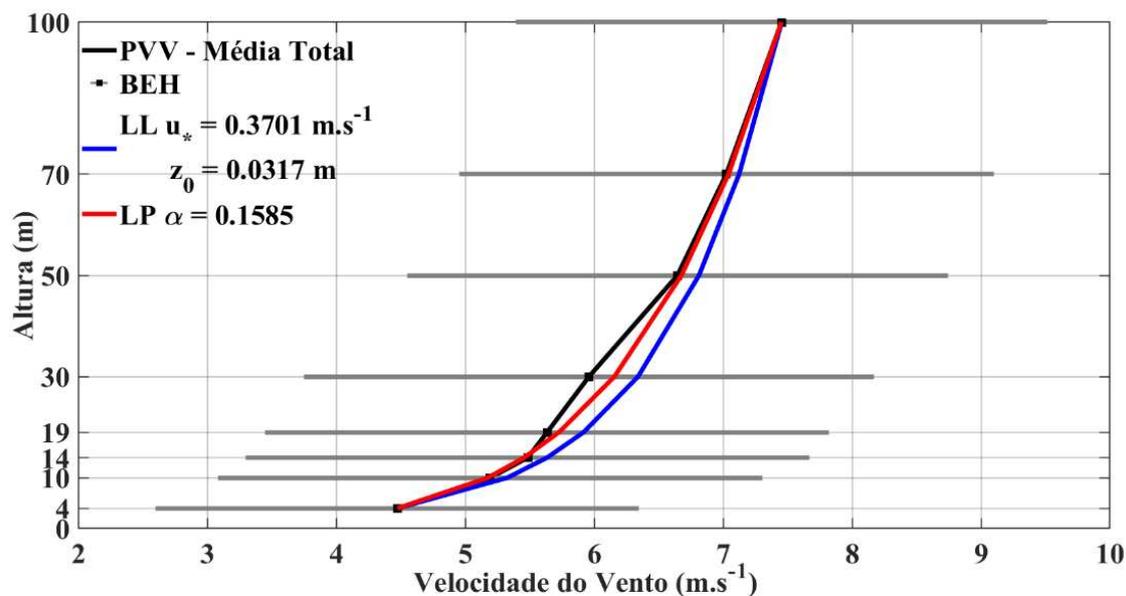


Figura 31. Perfil vertical da velocidade do vento média diária, barras de erro horizontal, lei logarítmica e lei da potência distribuídos nos oito níveis de altura. Fonte: Autor (2023).

OLIVEIRA e SOUZA (2017) através do perfil vertical da velocidade, obtido a partir da LP encontraram comprimento de rugosidade ($Z_0 = 0,03\text{m}$) e expoente de camada limite ($\alpha = 0,13$) para as mesorregiões (Agreste, Borborema e Sertão) da Paraíba, NEB do Brasil. ROBALLO e FISCH (2008) encontraram a velocidade de fricção (u_*) de $0,32 \pm 0,13 \text{ m.s}^{-1}$ ($0,46 \pm 0,11 \text{ m.s}^{-1}$), Z_0 foi de $0,19 \pm 0,32\text{m}$ ($0,06 \pm 0,05\text{m}$) e α foi de $0,19$ ($0,27$) para os meses de chuva (seco), mostrando uma sazonalidade e variação com a altura desses parâmetros, pesquisa realizada no Centro de Lançamento de Alcântara (CLA), litoral norte do Estado do Maranhão.

LOPEZ-VILLALOBOS et al. (2022) analisaram a influência do PVV na produção de energia eólica em Oaxaca, México. Os dados foram medidos a cada 10 minutos, período de estudo de um ano (01/12/2017 até 01/12/2018) e as alturas de medição foram 20, 40, 60 e 80m. Considerando a variabilidade sazonal e diurna, os parâmetros das leis LL e LP variaram em: u_* ($0,51$ até $0,97 \text{ m.s}^{-1}$); Z_0 ($0,20$ até $1,15\text{m}$); α ($0,14$ até $0,22$). Um comentário final desta pesquisa foi, se dados de velocidade do vento estiverem disponíveis em mais de uma altura, o método da variável α é recomendado para avaliação dos recursos eólicos.

5 CONCLUSÕES

Este trabalho teve como objetivo investigar as características individuais das VM (VV, DV, TA, UR e PA), identificar um padrão relacional dessas variáveis, avaliar técnicas de simulação desses elementos climáticos via inteligência artificial, além de examinar o perfil vertical do vento. Esses objetivos foram realizados com sucesso.

Nos períodos seco e transição, observa-se as maiores VV e TA, as menores taxas de UR e as menores PA. No período chuvoso as variáveis VV e TA apresentaram os menores valores e UR e PA apresentaram os maiores. A estatística descritiva das VM indica que a DV e UR apresentaram uma variabilidade maior do que a PA, VV e TA, respectivamente. A PA é a variável mais homogênea e a VV é a mais heterogênea.

Pelos resultados obtidos da velocidade e direção do vento, conclui-se que o Agreste alagoano é uma excelente região para implantação de parques eólicos com produção eficiente de energia, principalmente nos períodos seco e transição. A VV resultou nos valores mínimos próximos ao nascer do sol e os máximos próximos ao pôr do sol, com o período chuvoso apresentando as menores velocidades. A VV diária foi exclusivamente maior que a VV noturna, diferente de algumas pesquisas científicas realizadas próximo a região de estudo.

De várias maneiras distintas provamos que existe duas direções predominantes bem definidas ESE e SE. A DV nos períodos seco e transição é predominantemente SE e com direção secundária ESE, no período chuvoso ocorre o contrário. A DV no período chuvoso apresentou a maior variabilidade e no período seco a menor. A variabilidade diurna é maior do que a noturna. A amplitude da direção do vento mensal foi de $18,01^\circ$ menor que uma faixa intervalar de uma pétala de rosa dos ventos ($22,5^\circ$).

Os primeiros indícios de características inversas da TA e UR foram identificados nos primeiros resultados. A proporcionalidade inversa dessas variáveis está associada ao clima local, variação do fluxo de radiação solar e balanço de energia próximo à superfície.

A PA é a variável que apresentou o menor intervalo de variabilidade e menor amplitude. O maior destaque individual da PA foi no seu CDM que apresentou dois valores extremos, um local (noite) e outro absoluto (dia). O CDM da PA em ambos os períodos mostrou valores máximos e mínimos absolutos às 09 e 15 horas, mínimos e máximos locais ocorreram às 03 e 22 horas, respectivamente. A PA apresenta dois valores extremos, devido à interação gravitacional do sistema Terra-Sol-Lua.

A partir da TWC foi possível identificar a periodicidade de um dia em todas as VM, sendo a principal para a VV, DV, TA e UR, a PA apresentou periodicidade principal de 12 horas. A UR exibiu a maior potência espectral, seguido pela DV e TA, respectivamente. O espectro da PA e DV foram os mais irregulares dentre as VM, apresentando periodicidades de 12 horas, 1 dia e mensais. O escalograma das variáveis VV, TA e UR apresentaram diferença de magnitude entre os períodos, o período chuvoso foi menos intenso do que os períodos seco e transição, indicando que a precipitação altera a periodicidade das VM.

A FDP de Weibull com dois parâmetros ajusta-se melhor a série temporal da VV Total dia e noite, juntos e separados. Os parâmetros de Weibull para o período seco (chuvoso) foi mais concentrada nos maiores (menores) valores de escala e forma. As maiores porcentagens de densidade de probabilidade para ambos os períodos sazonais ocorreram entre as classes de 7 a 8 m.s^{-1} , a exceção foi o período chuvoso que apresentou as maiores porcentagens na classe de 6 m.s^{-1} .

Através dos gráficos de dispersão identifica-se um relacionamento linear inverso entre a TA e UR e entre a TA e PA, e um relacionamento linear direto entre UR e PA. Essa conexão inversa entre TA e UR é mais intensa no período seco e menor no período chuvoso, entre TA e PA é ao contrário mais forte no período chuvoso e menor no período seco. Os melhores ajustes da RLS ocorreram entre os pares TA e UR, TA e PA, UR e PA, pois resultaram nos maiores coeficientes de determinação (88%, 39% e 16%), respectivamente.

As correlações foram classificadas: quase perfeitas e negativa entre TA e UR (Total, períodos seco e transição) e muito alta (período chuvoso); alta e negativa entre TA e PA para ambos os períodos; moderada e positiva entre UR e PA em todos os períodos.

A WC informou ausência de coerência, coerências irregulares e mudanças de fase entre todas as duplas de variáveis e em períodos distintos. A DV é a variável que mais apresentou coerências irregulares e períodos de mudança de fase. A magnitude de coerência da DV com todas as variáveis no período chuvoso foi menor do que nos períodos seco e transição, isso indica que a precipitação altera a coerência da DV com as variáveis restantes.

As estatísticas de erros, correlação de Pearson e Diagrama de Taylor confirmaram que a RNA – NAR apresentou as melhores simulações das VM, seguido pelas RNAs – NARX e LSTM, respectivamente. A série VMW processou e conservou as características das VM. As simulações da DV apresentaram as piores métricas estatísticas e os prognósticos da PA foi quem mais se aproximou do melhor cenário. O Diagrama de Taylor confirma que as variáveis PA, UR e TA foram simuladas com mais precisão do que as simulações da DV e VV.

A estatística descritiva da VV indicou que nas maiores alturas, maiores foram os indicadores M, Q1, MD, Q3 e Max, em menores alturas, maiores foram as métricas CV, IT e FR, isso indica que os níveis inferiores são mais turbulentos e mais susceptíveis a ocorrência de rajadas de vento do que os níveis superiores. A lei da potência coincidiu mais com o perfil vertical do vento do que a lei logarítmica, mas ambas as leis estão dentro do intervalo de variabilidade do perfil vertical do vento e portanto perfeitamente aplicáveis.

Por fim, os resultados obtidos nesse trabalho mostram que os períodos seco e chuvoso são dois extremos opostos e o período de transição é mais semelhante ao período total, desta forma, podemos fazer uso de inferência estatística para obter conclusões acerca da população (período total) com base nas informações obtidas do conjunto amostral (período de transição). Esses resultados podem ser utilizados para energia eólica e conseqüentemente, mitigar os efeitos do aquecimento global, mudanças climáticas, eventos meteorológicos extremos, entre outros fatores.

5.1 Sugestões para trabalhos futuros

Diante dos resultados encontrado até o momento e tendo consciência de que os dados utilizados podem gerar muito mais informações, as sugestões para trabalhos futuros são:

- Utilizar dados meteorológicos distribuídos em outras regiões de Alagoas e/ou NEB para gerar resultados de evolução espaço-temporal.
- Desenvolver e aplicar mais estatísticas e gráficos de visualização dessas VM.
- A partir dessas VM calcular outras variáveis, índices climáticos e elementos meteorológicos úteis para energia eólica.
- Aplicar Wavelet nos dados com intervalo de medição horária, diária, mensal e anual.
- Desenvolver outras arquiteturas de RNA.
- Ampliar os estudos do perfil vertical do vento. Análise do perfil vertical do vento no período chuvoso e seco. Estabilidade atmosférica.

REFERÊNCIAS

- ABEEÓLICA. **Associação Brasileira de Energia Eólica**. Disponível em: <<http://abeeolica.org.br/>>. Acesso em: 12 mai. 2023.
- ALENCAR, C. A.; STEDILE, R.; URBANETZ JUNIOR, J. Estudo da complementaridade da geração de energia entre as fontes solar e hidráulica. **Revista Brasileira de Energia Solar**, v.9, n.1, 58-67, 2018. Disponível em: <<https://rbens.org.br/rbens/article/download/235/193>>. Acesso em 12 mai. 2023.
- ANJOS, P. S. **Correlações de longo alcance em séries temporais da velocidade do vento e radiação solar em Fernando de Noronha, Brasil**. 61 p. Dissertação (Mestrado em Biometria e Estatística Aplicada), Universidade Federal Rural de Pernambuco, Recife, 2013. Disponível em: <http://ppgbea.ufrpe.br/sites/www.ppgbea.ufrpe.br/files/documentos/dissertacao_final_priscilla_sales_dos_anjos.pdf>. Acesso em: 11 jan. 2024.
- ARANHA, T. R. B. T. **Análise numérica de variáveis atmosféricas influenciadas pelo espaço urbano de Campina Grande – PB**. Dissertação de Mestrado em Meteorologia, Universidade Federal de Campina Grande, Paraíba, 74 p., 2016. Disponível em: <www.dspace.sti.ufcg.edu.br/>. Acesso em: 05 set. 2023.
- ASSIREU, A. T.; MENDONÇA, J. C.; FREITAS, R. M.; PASSOS, R. B.; PELLEGRINI, C. C.; PIMENTA, F. M. Escoamento atmosférico sobre uma colina isolada revelado a partir de dados de um veículo aéreo não tripulado (VANT). **Revista Brasileira de Meteorologia**, v.34, n.2, 227-236, 2019. <[dx.doi.org/10.1590/0102-7786334002](https://doi.org/10.1590/0102-7786334002)>.
- ASTSATRYAN, H.; GRIGORYAN, H.; POGHOSYAN, A.; ABRAHAMYAN, R.; ASMARYAN, S.; MURADYAN, V.; TEPANOSYAN, G.; GUIGOZ, Y.; GIULIANI, G. Air temperature forecasting using artificial neural network for Ararat valley. **Earth Science Informatics**, v.14, 711-722, 2021. <doi.org/10.1007/s12145-021-00583-9>.
- AVDAKOVIC, S.; DEDOVIC, M. M.; DAUTBASIC, N.; DIZDAREVIC, J. The influence of wind speed, humidity, temperature and air pressure on pollutants concentrations of PM10 – Sarajevo case study using wavelet coherence approach. **XI International Symposium on Telecommunications (BIHTEL)**, 1-6, 2016. <[10.1109/BIHTEL.2016.7775719](https://doi.org/10.1109/BIHTEL.2016.7775719)>.
- AZAD, A. K.; RASUL, M. G.; ALAM, M. M.; UDDIN, S. M. A.; MONDAL, S. K. Analysis of wind energy conversion system using Weibull distribution. **Procedia Engineering**, v.90, 725-732, 2014. <doi.org/10.1016/j.proeng.2014.11.803>.
- BATISTA, E. D. A.; ARAÚJO, W. C.; LIRA, R. V.; BATISTA, L. I. A. Uso de machine learning e de deep learning para prever internações causadas por dengue na Paraíba. **Revista de Sistemas e Computação, Salvador**, v.11, n.3, 33-42, 2021. <[10.36558/rsc.v11i3.7475](https://doi.org/10.36558/rsc.v11i3.7475)>

BARLIK, NECLA. Effect of meteorological parameters on PM10 concentrations in Ardahan by wavelet coherence analysis. **Celal Bayar University Journal of Science**, v.17, Issue 1, 43-49, 2021. <10.18466/cbayarfbe.738596>.

BERREZZEK, F.; KHELIL, K.; BOUADJILA, T. Efficient wind speed forecasting using discrete wavelet transform and artificial neural networks. **Revue d'Intelligence Artificielle**, v.33, n.6, 447-452, 2019. <doi.org/10.18280/ria.330607>.

BILGILI, M.; SAHIN, BESIR. Comparative analysis of regression and artificial neural network models for wind speed prediction. **Meteorology and Atmospheric Physics**, v.109, 61-72, 2010. <10.1007/s00703-010-0093-9>.

BRITO COSTA, G. **Análise espacial e temporal do vento no Estado de Alagoas**. 149 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Alagoas, Maceió, 2009. Disponível em: <<https://www.repositorio.ufal.br/handle/riufal/861>>. Acesso em: 05 set. 2023.

BUSSAB, W. O.; MORETTIN, P. A. **Estatística Básica**. São Paulo: Saraiva, 2002. Disponível em: <https://edisciplinas.usp.br/pluginfile.php/7552971/mod_resource/content/0/Bussab%20e%20Morettin%20%282010%29%20A%20estat%20C3%ADstica%20b%20C3%A1sica_Cap6e7.pdf>. Acesso em: 11 jan. 2024.

CABRAL JÚNIOR, J. B.; LUCENA, R. L. Análises estatísticas da precipitação e temperatura do ar em ambientes semiáridos. **Entrelugar**, v.13, n.24, 170-191, 2021. <REL/DOI 10.30612>.

CAMELO, H. N.; LUCIO, P. S.; LEAL JUNIOR, J. B. V.; CARVALHO, P. C. M. Proposta para previsão de velocidade do vento através de modelagem híbrida elaborada a partir dos modelos ARIMAX e RNA. **Revista Brasileira de Meteorologia**, v.33, n.1, 115-129, 2018. <dx.doi.org/10.1590/0102-7786331005>.

CARGNELUTTI FILHO, A.; MATZENAUER, R.; MALUF, J. R. T. Variabilidade temporal e espacial do tamanho de amostra para estimativa das médias mensais de temperatura máxima do ar no Estado do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v.14, n.1, 87-95, 2006. Disponível em: <<https://www.sbagro.org/files/biblioteca/3943.pdf>>. Acesso em: 21 set. 2023.

CARMO, N. R. M. Uso de redes neurais artificiais para previsão de GHI. **Revista Virtual de Química**, v.14, n.1, 56-60, 2022. <doi.org/10.21577/1984-6835.20220013>.

CARVALHO, D.; ROCHA, A.; GÓMEZ-GESTEIRA, M.; SANTOS, C. A sensitivity study of the WRF model in wind simulation for an area of high wind energy. **Environmental Modelling & Software**, v.33, 23-34, 2012. <doi:10.1016/j.envsoft.2012.01.019>.

CASTELHANO, F. Análise da dinâmica dos ventos em Aracaju/Sergipe. **Revista OKARA: Geografia em debate**, v.16, n.1, 125-135, 2022. Disponível em: <<http://www.okara.ufpb.br>>. Acesso em: 31 ago. 2023.

CAVALCANTE, F. M. S. **Anomalias de chuva em anos de episódios extremos de ENOS: impactos ambientais no sistema Curemas-Mãe d' Água**. Trabalho de

Conclusão de Curso (Curso de Engenharia Ambiental) Universidade Federal de Campina Grande, Pombal, 2018. Disponível em: <dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/21276>. Acesso em: 15 jun. 2023.

CHANG, T. P.; LIU, F. J.; KO, H. H.; HUANG, M. C. Oscillation characteristic study of wind speed, global solar radiation and air temperature using wavelet analysis. **Applied Energy**, v.190, 650-657, 2017. <dx.doi.org/10.1016/j.apenergy.2016.12.149>.

CHAVES FILHO, J. B. **Variabilidade da velocidade do vento a 10 metros para a região Nordeste do Brasil**. 75 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Campina Grande, Paraíba, 2016. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/651>. Acesso em: 11 jan. 2024.

Ciências Atmosféricas – UNIFEI. (2023) Disponível em: <https://meteorologia.unifei.edu.br/teleconexoes>. Acesso em: 11 jan. 2024.

CORREIA FILHO, W. L. F.; SOUZA, P. H. A.; OLIVEIRA-JÚNIOR, J. F.; TERASSI, P. M. B.; GOIS, G.; SILVA-JUNIOR, C. A.; SOBRAL, B. S.; RANGEL, R. H. O.; PIMENTEL, L. C. G. Investigating the characteristics and predictability of measured wind speed data over Rio de Janeiro, Brazil. **Pure and Applied Geophysics**, v.178, 2333-2355, 2021. <doi.org/10.1007/s00024-021-02751-w>.

CORREIA FILHO, W. L. F.; SOUZA, P. H. A.; OLIVEIRA-JÚNIOR, J. F.; SANTIAGO, D. B.; LYRA, G. B.; ZERI, M.; CUNHA'ZERI, G. The wind regime over the Brazilian Southeast: Spatial and temporal characterization using multivariate analysis. **International Journal of Climatology**, v.42, 1767-1788, 2022. <doi.org/10.1002/joc.7334>.

CORRÊA, C. S. A ocorrência de fluxos no perfil vertical do vento na baixa atmosfera e seu efeito na intensidade do índice “K”. **Revista Brasileira de Meteorologia**, v.22, n.2, 129-133, 2007. Disponível em: <www.scielo.br/j/rbmet/a/yjJrpNc75YBdpYj4KmgpRsh/?format=pdf&lang=pt>. Acesso em 08 mai. 2023.

COSTA, G. B.; LYRA, R. F. F. Análise dos padrões de vento no Estado de Alagoas. **Revista Brasileira de Meteorologia**, v.27, n.1, 31-38, 2012. Disponível em: <https://www.scielo.br/j/rbmet/a/stsphfqxMnQyJrR9jV8YXn/?format=pdf&lang=pt>. Acesso em 11 jan. 2024.

COSTA, M. S.; OLIVEIRA-JÚNIOR, J. F.; SANTOS, P. J.; CORREIA FILHO, W. L. F.; GOIS, G.; BLANCO, C. J. C.; TEODORO, P. E.; SILVA JUNIOR, C. A.; SANTIAGO, D. B.; SOUZA, E. O.; JARDIM, A. M. R. F. Rainfall extremes and drought in Northeast Brazil and its relationship with El Niño Southern Oscillation. **International Journal of Climatology**, v.41, 2111-2135, 2020. <doi.org/10.1002/joc.6835>.

CPTEC. **Centro de Previsão do Tempo e Estudos Climáticos**. Clima análise boletim. Disponível em: <http://climanalise.cptec.inpe.br/~rclimanl/boletim/>. Acesso em: 01 jun. 2023.

CRUZ, N. S. D. **Comportamento do vento e aproveitamento eólico na região central de Alagoas (Craíbas)**. 83 p. Dissertação (Mestrado em Meteorologia),

Universidade Federal de Alagoas, Maceió, 2017. Disponível em: <<https://www.repositorio.ufal.br/handle/riufal/5564>>. Acesso em: 29 fev. 2024.

CRUZ, N. S. D.; LYRA, R. F. F.; CORREIA FILHO, W. L. F. Caracterização do vento na região de Craíbas – Al para fins eólicos. **Revista Brasileira de Energias Renováveis**, v.6, n.4, 811-823, 2017. <[dx.doi.org/10.5380/rber.v6i4.51444](https://doi.org/10.5380/rber.v6i4.51444)>.

DOUCOURE, B.; AGBOSSOU, K.; CARDENAS, A. Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data. **Renewable Energy**, v. 92, 202-211, 2016. <[dx.doi.org/10.1016/j.renene.2016.02.003](https://doi.org/10.1016/j.renene.2016.02.003)>.

ELETROBRÁS, **Atlas Eólico do Estado de Alagoas**. Maceió, Brasil. Disponível em: <<http://dados.al.gov.br/dataset/atlas-eolico-do-estado-de-alagoas>>. Acesso em: 31 mai. 2023.

ENFIELD, D. B.; MESTAS-NUÑEZ, A. M.; MAYER, D. A.; CID-SERRANO, L. How ubiquitous is the dipole relationship in tropical Atlantic Sea surface temperature? **Journal of Geophysical Research**, v.104, n.4, 7841-7848, 1999. <doi.org/10.1029/1998JC900109>.

FEDOROVA, N.; LEAVIT, V.; CRUZ, C. D. On Frontal Zone Analysis in the Tropical Region of the Northeast Brazil. **Pure Appl. Geophys.** v.173, 1403-1421, 2016. <[10.1007/s00024-015-1166-y](https://doi.org/10.1007/s00024-015-1166-y)>.

FERREIRA, L. G. C.; KEMENES, A. A influência dos eventos climáticos extremos na climatologia da planície litorânea piauiense. **Revista Brasileira de Climatologia**, v.32, 634-657, 2023. <<http://www.alice.cnptia.embrapa.br/alice/handle/doc/1154697>>.

FISCH, G. Características do perfil vertical do vento no Centro de Lançamento de Alcântara (CLA). **Revista Brasileira de Meteorologia**, v.14, n.1, 11-21, 1999.

FREITAS, I. G. F.; GOMES, H. B.; PEÑA, M.; MITSOPOULOS, P.; NOVA, T. S. V.; SILVA, K. M. R.; CALHEIROS, A. J. P. Evaluation of wind and wave estimates from CMEMS reanalysis for Brazil's offshore energy resource assessment. **Wind**, n.2, 586-598, 2022. <doi.org/10.3390/wind2030031>.

GONÇALVES, A. R. **Refinamento estatístico das previsões de vento do modelo ETA aplicado ao setor eólico-elétrico do nordeste brasileiro**. 180 p. Dissertação (Mestrado em Meteorologia), Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011. <sid.inpe.br/mtc-m19/2012/02.27.17.24-TDI>.

GONÇALVES JÚNIOR, E. R.; SOUZA, C. L. M.; ERTHAL JÚNIOR, M.; GONÇALVES, V. S. Análise do potencial de geração de energia eólica em Campos dos Goytacazes, RJ. **Pesquisa Operacional para o Desenvolvimento**, v.14, 1-12, 2021. <[10.4322/PODes.2021.011](https://doi.org/10.4322/PODes.2021.011)>.

GRIGOLETTI, G. C.; FLORES, M. G.; SANTOS, J. C. P. Tratamento de dados climáticos de Santa Maria, RS, para análise de desempenho térmico de edificações. **Ambiente Construído**, v.16, n.1, 123-141, 2016. <doi.org/10.1590/s1678-86212016000100064>.

- GRINSTED, A.; MOORE, J. C.; JEVREJEVA, S. Application of the cross wavelet transform and wavelet coherence to geophysical time series. **Nonlinear Processes Geophysics**, v.11, 561–566, 2004. Disponível em: <<https://hal.science/hal-00302394/document>>. Acesso em: 29 fev. 2024.
- GUAN, L.; YANG, J.; BELL, J. M. Cross-correlations between weather variables in Australia. **Building and Environment**, v.42, 1054-1070, 2007. <doi.org/10.1016/j.buildenv.2006.01.010>.
- GUO, Q.; HE, Z.; LI, S.; LI, X.; MENG, J.; HOU, Z.; LIU, J.; CHEN, Y. Air pollution forecasting using artificial and wavelet neural networks with meteorological conditions. **Aerosol and Air Quality Research**, v.20, 1429-1439, 2020. <doi.org/10.4209/aaqr.2020.03.0097>.
- GURLEK, CAHIT. Artificial neural networks approach for forecasting of monthly relative humidity in Sivas, Turkey. **Journal of Mechanical Science and Technology**, v.37, n.8, 4391- 4400, 2023. <[10.1007/s12206-023-0753-6](https://doi.org/10.1007/s12206-023-0753-6)>.
- HOPKINS, W. G. A new view of statistics: Correlation Coefficient. New York: Internet Society for Sport Science, 2009. Disponível em: <http://www.sportsci.org/resource/stats/correl.html>. Acesso: 28 jul. 2023.
- HUANG, B.; THORNE, P. W.; BANZON, V. F.; BOYER, T.; CHEPURIN, G.; LAWRIE, J. H.; MENNE, M. J.; SMITH, T. M.; VOSE, R. S.; ZHANG, H. M. Extended reconstructed Sea Surface Temperature, Version 5 (ERSSTv5): Upgrades, Validations and Intercomparisons. **Journal of Climate**, v.30, 8179-8205, 2017. <[10.1175/JCLI-D-16-0836.1](https://doi.org/10.1175/JCLI-D-16-0836.1)>.
- JOVIC, A. S.; KORUNOVIC, L. M.; DJOKIC, S. Z. Application of meteorological variables for the estimation of static load model parameters. **Energies**, v.14, 1-17, 2021. <doi.org/10.3390/en14164874>.
- KHELIL, K.; BERREZZEK, F.; BOUADJILA, T. GA-based design of optimal discrete wavelet filters speed forecasting. **Neural Computing and Applications**, v.33, 4373-4386, 2020. <doi.org/10.1007/s00521-020-05251-5>.
- KORUNOVIC, L. M.; JOVIC, A. S.; DJOKIC, S. Z. Measurement-based evaluation of static load characteristics of demands in administrative buildings. **Electrical Power and Energy Systems**, v.118, 1–8, 2020. <doi.org/10.1016/j.ijepes.2019.105782>.
- LEMOS, D. F. A. **Análise de projeto de turbina eólica de grande porte para as condições climáticas da região nordeste do Brasil**. 92 p. Dissertação (Mestrado em tecnologias energéticas e nucleares), Universidade Federal de Pernambuco, Recife, 2005. <https://repositorio.ufpe.br/bitstream/123456789/9913/1/arquivo9066_1.pdf>.
- LEONI, R. C.; SAMPAIO, N. A. S.; CORRÊA, S. M. Estatística multivariada aplicada ao estudo da qualidade do ar. **Revista Brasileira de Meteorologia**, v.32, n.2, 235-241, 2017. <<http://dx.doi.org/10.1590/0102-77863220005>>.
- LIMA, F. J. L. **Avaliação do potencial eólico no estado da Paraíba: Um estudo observacional e numérico**. 81 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Campina Grande, Paraíba, 2011. <<http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/8655>>.

LOPES, L. C. S.; JARDIM, C. H. Variações de temperatura e umidade relativa do ar em área urbana e rural durante o segmento temporal de inverno de 2011 em Contagem e Betim (MG). **Climatologia Geográfica**, Ed. Esp., 205-221, 2012. <DOI:10.5654/actageo2012.0002.0013>.

LYRA, G. B.; OLIVEIRA-JÚNIOR, J. F.; ZERI, M. Cluster analysis Applied to the spatial and temporal variability of monthly rainfall in Alagoas state, Northeast of Brazil. **International Journal of Climatology**, v.34, 3546-3558, 2014. <<https://doi.org/10.1002/joc.3926>>.

LYRA, M. J. A. **Vórtices ciclônicos de altos níveis do nordeste brasileiro: sua relação com o transporte de umidade da américa do sul e sua estrutura termodinâmica**. 167 p. Tese (Doutorado em Meteorologia), Universidade Federal de Campina Grande, Paraíba, 2022. <<http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/28310>>.

MACHADO, A. J. Previsibilidade da pressão atmosférica local a partir de flutuações altimétricas registradas no Oeste Paulista. **Revista Geográficas**, v.13, n.1, 96-111, 2017. Disponível em: <<https://periodicos.ufmg.br/index.php/geografias/article/download/13437/31669>>. Acesso em: 05 set. 2023

MAGNAGO, R.; FISCH, G.; MORAES, O. Análise espectral do vento no Centro de Lançamento de Alcântara (CLA). **Revista Brasileira de Meteorologia**, v.25, n.2, 260-269, 2010. Disponível em: <<https://www.scielo.br/j/rbmet/a/qwLRhWH9BLdwWK6Zz8R6S6y/?format=pdf&lang=pt>>. Acesso em 22 jun. 2023.

MANWELL, J. F.; MCGOWAN, J. G.; ROGERS, A. L. **Wind energy explained: theory, design and application**. United Kingdom: Wiley, 2009. Disponível em: <https://ee.tlu.edu.vn/Portals/0/2018/NLG/Sach_Tieng_Anh.pdf>. Acesso em: 08 mai. 2023.

MARKARD, J. PETERSEN, R. The offshore trend: structural changes in the wind power sector. **Energy Policy**, v.37, 3545–3556, 2009. <doi.org/10.1016/j.enpol.2009.04.015>.

MENEZES, H. E. A. **Influência da zona de convergência secundária do atlântico sul sobre a ocorrência de precipitação no leste do nordeste brasileiro**. 105 p. Tese (Doutorado em Meteorologia), Universidade Federal de Campina Grande, Paraíba, 2010. Disponível em: <<http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/4927>>. Acesso em: 11 jan. 2024.

MEYERS, S. D.; KELLY, B. G.; O'BRIEN, J. J. An introduction to wavelet analysis in oceanography and meteorology: With application to the dispersion of Yanai waves. **Monthly Weather Review**, v.121, 2858–2866, 1993. Disponível em: <<https://www.coaps.fsu.edu/bios/93-1.pdf>>. Acesso em: 29 fev. 2024.

MIAO, C.; HE, X.; XU, S.; CHEN, W. Vertical distribution of air pollutants in an urban street canyon during winter air pollution episodes in Shenyang, China. **Building and Environment**, v.245, 1-8, 2023. <doi.org/10.1016/j.buildenv.2023.110853>.

MILHAHN JÚNIOR, A. W. **Uma ferramenta para análise automática dos complexos convectivos de mesoescala no Nordeste do Brasil**. 45 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Alagoas, Maceió, 2016. <<https://www.repositorio.ufal.br/handle/riufal/1956>>.

MOLION, L. C. B.; BERNARDO, S. O. Uma revisão da dinâmica das chuvas no nordeste brasileiro. **Revista Brasileira de Meteorologia**, v.17, 1–10, 2002. Disponível em: <MOLION&BERNARDO_rbmet2002v17n1p1-10.pdf>. Acesso em: 11 jan. 2024.

MOREIRA, P. S. P.; DALLACORT, R.; GALVANIN, E. A. S.; NEVES, R. J.; CARVALHO, M. A. C.; BARBIERI, J. D. Ciclo diário de variáveis meteorológicas nos biomas do estado de Mato Grosso. **Revista Brasileira de Climatologia**, v.17, 173-188, 2015. <doi.org/10.5380/abclima.v17i0.41159>.

MONTEIRO, J. B. A influência de teleconexões e sistemas meteorológicos produtores de precipitação no semiárido nordestino. **Revista Brasileira de Geografia Física**, v.15, 312-332, 2022. <doi.org/10.26848/rbgf.v15.1.p312-332>.

MOURA, J. D. O. **Refinamento das simulações de vento do modelo WRF utilizando redes neurais e artificiais**. 43 p. Trabalho de Conclusão de Curso (Graduação em Meteorologia). Universidade Federal de Alagoas, Maceió, 2014.

MUANZA, G. A. **Padrões de circulação atmosférico associados á ligação da extremidade frontal com a ZCIT**. 73 p. Dissertação (Mestrado em Meteorologia). Universidade Federal de Alagoas, Maceió, 2018. <<https://www.repositorio.ufal.br/handle/riufal/3824>>.

NASCIMENTO, J. S. M.; AGUIAR, R. G.; WEBLER, A. D.; FISCHER, G. R.; AGUIAR, L. J. G.; RUEZZENE, C. B. Variáveis meteorológicas em áreas de floresta e pastagem na Amazônia Ocidental em anos de eventos extremos. **Ciência e Natura**, v.38, n. Especial, 217-224, 2016. <[10.5902/2179460X20185](https://doi.org/10.5902/2179460X20185)>.

NASCIMENTO, E. G. S.; MELO, T. A. C.; MOREIRA, D. M. A transformer-based deep neural network with Wavelet transforms for forecasting wind speed and wind energy. **Energy**, v.278, 1-11, 2023. <doi.org/10.1016/j.energy.2023.127678>.

NNAMCHI, H. C.; LI, J.; ANYADIKE, R. N. C. Does a dipole mode really exist in the South Atlantic Ocean? **Journal of Geophysical Research**, v.116, 1-15, 2011. <doi.org/10.1029/2010JD015579>.

NOAA - **National Oceanic and Atmospheric Administration**. Climate variability: Oceanic Niño Index. Disponível em: <<https://www.climate.gov/news-features/understanding-climate/climate-variability-oceanic-nino-index>>. Acesso em: 11 jan. 2024.

OLIVEIRA, S. S.; SOUZA, E. P. Análise de modelos de mesoescala para caracterização do potencial eólico do Estado da Paraíba. **Revista Brasileira de Meteorologia**, v.32, n.2, 277-291, 2017. <dx.doi.org/10.1590/0102-77863220009>.

PALÁCIOS, R. S.; MARQUES, J. B.; PRADO, M. J.; MUSIS, C. R.; SALLO, F. S.; SANCHES, L.; PAULO, S. R.; NOGUEIRA, J. S. Análise de espectro singular e Wavelet sobre série temporal de profundidade ótica de aerossóis no Pantanal do Brasil.

Revista Brasileira de Meteorologia, v.31, n.4, 527-537, 2016. <[dx.doi.org/10.1590/0102-778631231420150104](https://doi.org/10.1590/0102-778631231420150104)>.

PAULA, D. L. P.; CARDOSO, F. A. C.; CARDOSO, R. B.; CUNHA, G. P. Q.; VIEIRA, E. M. Modelagem espacial da velocidade do vento a 50, 75 e 100 metros de altura para o estado de Minas Gerais, Brasil, empregando geostatística. **Revista Brasileira de Geografia Física**, v.10, n.04, 1281-1295, 2017. <<https://doi.org/10.26848/rbgf.v10.4.p1281-1295>>.

PEREIRA, E. B.; MARTINS, F. R.; PES, M. P.; CRUZ SEGUNDO, E. I.; LYRA, A. A. The impacts of global climate changes on the wind power density in Brazil. **Renewable Energy**, v.49, 107-110, 2013. <[10.1016/j.renene.2012.01.053](https://doi.org/10.1016/j.renene.2012.01.053)>.

PEREIRA, D. P.; LIMA, J. S. S.; XAVIER, A. C.; PASSOS, R. R.; FIEDLER, N. C. Aplicação do Diagrama de Taylor para avaliação de interpoladores espaciais em atributos de solo em cultivo com eucalipto. **Revista Árvore**, v.38, 899-905, 2014. <<https://doi.org/10.1590/S0100-67622014000500014>>.

PEREIRA, F. F. C.; DAMASCENO, C. A. Desenvolvimento de um modelo para estimar a irradiação global em Fortaleza utilizando a metodologia de Bird. **VIII Congresso Brasileiro de Energia Solar – Fortaleza**. Disponível em: <<https://anaiscbens.emnuvens.com.br/cbens/article/view/739>>. Acesso em: 26 out. 2023.

PINTO, L. I. C.; LIMA, F. J. L.; MARTINS, F. R.; PEREIRA, E. B. Análise de agrupamento na otimização de futuras aplicações de modelagem numérica na estimativa e previsão de recurso eólico. **Revista Brasileira de Geografia Física**, v.10, n.6, 1698-1711, 2017. <[10.26848/rbgf.v10.6.p1698-1711](https://doi.org/10.26848/rbgf.v10.6.p1698-1711)>.

RAMOS, D. N. S. **Mapeamento eólico do estado de Alagoas utilizando ferramenta computacionais e dados observados**. 131 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Alagoas, Maceió, 2012. Disponível em: <<https://www.repositorio.ufal.br/handle/riufal/896>>. Acesso em: 11 jan. 2024.

RAMOS, D. N. S.; LYRA, R. F. F.; SILVA-JÚNIOR, R. S. Previsão do vento utilizando o modelo atmosférico WRF para o Estado de Alagoas. **Revista Brasileira de Meteorologia**, v.28, n.2, 163-172, 2013. Disponível em: <<https://www.scielo.br/j/rbmet/a/ZLbJJMLkGkCRPVkcb8CkWBh/?lang=pt&format=pdf>>. Acesso em: 11 jan. 2024.

RAMOS, D. N. S.; LYRA, R. F. F.; SILVA-JÚNIOR, R. S.; CAVALCANTE-SEGUNDO, G. H.; LOPES, G. E. V. Wind power in Girau do Ponciano, Alagoas, Brazil using anemometric data and microscale modeling. **Revista Brasileira de Meteorologia**, v.33, 279-288, 2018. <[dx.doi.org/10.1590/0102-7786332007](https://doi.org/10.1590/0102-7786332007)>.

RIBEIRO, B. Z. **Linhas de Instabilidade no Sul do Brasil**. 297 p. Tese (Doutorado em Meteorologia). Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2018. <sid.inpe.br/mtc-m21c/2018/04.30.13.39-TDI>.

ROBALLO, S. T.; FISCH, G. Escoamento atmosférico no Centro de Lançamento de Alcântara (CLA): Parte 1 – Aspectos Observacionais. **Revista Brasileira de Meteorologia**, v.23, n.4, 510-519, 2008. Disponível em:

<www.scielo.br/j/rbmet/a/NTcH9sqrCjz8FrDsdxy7kR/abstract/?lang=pt>. Acesso em: 26 jun. 2023.

ROCHA, A. F.; SILVA, E. P.; MUSIS, C. R. Topoclimate in Morlet, cross and coherence wavelet analyses in the Brazilian Cerrado. **Floresta e Ambiente**, v.25, 1-12, 2018. <doi.org/10.1590/2179-8087.107917>.

SAMET, H.; REISI, M.; MARZBANI, F. Evaluation of neural network based methodologies for wind speed forecasting. **Computers and Electrical Engineering**, v.78, 356-372, 2019. <doi.org/10.1016/j.compeleceng.2019.07.024>.

SANCHES, S. R.; SUSKI, C. A. Avaliação do desempenho na aquisição de dados meteorológicos de uma estação de baixo custo para praticantes de desportos aquáticos. **Ciência e Natura**, v.44, e7, 1-25, 2022. <doi.org/10.5902/2179460X63576>.

SANTOS, J. B. **Estudo da correlação entre variáveis meteorológicas e a incidência de casos de Dengue em Maceió**, Alagoas, Brasil. 97 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Alagoas, Maceió, 2016. Disponível em: <<https://www.repositorio.ufal.br/handle/riufal/1632>>. Acesso em: 11 jan. 2024.

SANTOS, I. G. S.; LYRA, R. F. F. Análise do potencial de previsão da velocidade do vento utilizando rede neural artificial. **Anuário do Instituto de Geociências – UFRJ**, v.43, n.4, 11-17, 2020. <dx.doi.org/10.11137/2020_4_11_17>.

SANTOS, I. G. S.; LYRA, R. F. F.; SILVA-JÚNIOR, R. S. Comparativo de prognósticos da velocidade do vento utilizando o modelo WRF e rede neural artificial. **Revista Brasileira de Meteorologia**, v.35, n. Especial, 1017-1027, 2020. <dx.doi.org/10.1590/0102-77863550103>.

SANTOS, I. G. S.; OLIVEIRA-JR, J. F.; SOUSA, F. A. S.; BARBOSA, I. I. Previsão de focos de calor na região metropolitana de Maceió utilizando rede neural artificial. **Revista Brasileira de Geografia Física**. v.15, n.5, 2313-2326, 2022. <[10.26848/rbgf.v15.5.p2313-2326](https://doi.org/10.26848/rbgf.v15.5.p2313-2326)>.

SANTOS, J. S.; OLIVEIRA-JÚNIOR, J. F.; COSTA, M. S.; CARDOSO, K. R. A.; SHAH, M.; SHAHZAD, R.; SILVA, L. F. F. F.; ROMÃO, W. M. O.; SINGH, S.; MENDES, D.; SANTOS, I. G. S.; SILVA JÚNIOR, R. S. Effects of extreme phases of El Niño-Southern Oscillation on rainfall extremes in Alagoas, Brazil. **International Journal of Climatology**, 1-22, 2023. <doi.org/10.1002/joc.8288>.

SARAIVA, S. V.; CARVALHO, F. O.; SANTOS, C. A. G.; BARRETO, L. C.; FREIRE, P. K. M. M. Daily streamflow forecasting in Sobradinho Reservoir using machine learning models coupled with Wavelet transform and bootstrapping. **Applied Soft Computing Journal**, v.102, 1-11, 2021. <doi.org/10.1016/j.asoc.2021.107081>.

SATHE, A.; BIERBOOMS, W. Influence of different wind profiles due to varying atmospheric stability on the fatigue life of wind turbines. **Journal of Physics**, v.75, 1-7, 2007. <[doi:10.1088/1742-6596/75/1/012056](https://doi.org/10.1088/1742-6596/75/1/012056)>.

SARAÇLI, S.; DOGAN, N.; DOGAN, I. Comparison of hierarchical cluster analysis methods by cophenetic correlation. **Journal of Inequalities and Applications**, v.203, n.1, 1-8, 2013. Disponível em: <<https://journalofinequalitiesandapplications.springeropen.com/articles/10.1186/1029-242X-2013-203>>. Acesso em: 11 jan. 2024.

SEDLIACKOVA, Z.; POBOCIKOVA, I.; MICHALKOVA, M.; JURASOVA, D. Wind speed modeling using Weibull distribution: A case of Liptovsky Mikulas, Slovakia. **MATEC Web of Conferences**, v.357, 1-10, 2022. <doi.org/10.1051/mateconf/202235708005>.

SEIFI, A.; EHTERAM, M.; NAYEBLOEI, F. SOROUSH, F. GHARABAGHI, B; HAGHIGHI, A. T. GLUE uncertainty analysis of hybrid models for predicting hourly soil temperature and application wavelet coherence analysis for correlation with meteorological variables. **Soft Computing**, v.25, 10723-10748, 2021. <doi.org/10.1007/s00500-021-06009-4>.

SEMARH. **Secretária de Estado do Meio Ambiente e dos Recursos Hídricos**. Disponível em: <<http://www.semarh.al.gov.br/>>. Acesso em: 10 jan. 2024.

SHI, H.; DONG, Z.; XIAO, N.; HUA, Q. Wind speed distributions used in wind energy assessment: A review. **Frontiers in Energy Research**, v.9, 1-14, 2021. <[10.3389/fenrg.2021.769920](https://doi.org/10.3389/fenrg.2021.769920)>.

SILVA, B. B.; ALVES, J. J. A.; CAVALCANTI, E. P.; DANTAS, R. T. Potencial eólico na direção predominante do vento no Nordeste brasileiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.6, n.3, 431-439, 2002. Disponível em: <<https://www.scielo.br/j/rbeaa/a/WVdrC3zjqXMpbWWmxRGQD6N/?format=pdf&lang=pt>>. Acesso em: 11 jan. 2024.

SILVA, J. K. A. **Caracterização do vento e estimativa do potencial eólico para a região de tabuleiros costeiros (Pilar, Alagoas)**. 83 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Alagoas, Maceió, 2007. Disponível em: <<https://www.repositorio.ufal.br/handle/riufal/859>>. Acesso em: 11 jan. 2024.

SILVA, B. F. P.; FEDOROVA, N.; LEVIT, V.; PERESETSKY, A.; BRITO, B. M. Sistemas sinóticos associados às precipitações intensas no estado de Alagoas. **Revista Brasileira de Meteorologia**, v.26, 323-338, 2011. Disponível em: <www.scielo.br/j/rbmet/a/cxh9LJCscNVR6KVKJFqXZwJ/?lang=pt&format=pdf>. Acesso em: 02 jun. 2023.

SILVA, P. K. O. **Análise multivariada aplicada ao vento na área costeira do Nordeste do Brasil**. 80 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Campina Grande, Paraíba, 2011. Disponível em: <<http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/15841>>. Acesso em: 11 jan. 2024.

SILVA, W. R. S. **Metodologia de monitoramento de epidemias: uma abordagem baseada em redes neurais artificiais**. 91 p. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal do Pará, Belém, 2018. Disponível em: <<https://repositorio.ufpa.br/handle/2011/10056>>. Acesso em: 11 jan. 2024.

SILVA, S. M. S. **Estudo dos parâmetros aerodinâmicos para melhoria da previsão do vento no Estado de Alagoas**. 67 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Alagoas, Maceió, 2018. Disponível em: <<https://www.repositorio.ufal.br/handle/riufal/4920>>. Acesso em: 11 jan. 2024

SILVA, E. M. S.; CORREIA FILHO, W. L. F.; OLIVEIRA JÚNIOR, J. F.; BARROS, H. G.; COSTA, M. S.; GOIS, G.; FALCÃO, N. A. M. Espaço-temporalidade dos focos

de calor na região metropolitana de Maceió. **Revista Brasileira de Meteorologia**, v.35, n. Especial, 1029-1043, 2020. <<http://dx.doi.org/10.1590/0102-7786355000091>>.

SILVA, D. T. C.; ALMADA, N. B.; MATIAS, L. V. S.; MACAMBIRA, A. C. S.; COSTA, G. B.; SOUSA, J. T. R.; HEIDEMANN, M. A. Caracterização climatológica da cidade de Manaus/AM. **Biodiversidade Brasileira**, v.11, n.4, 60-71, 2021. <[10.37002/biobrasil.v11i4.1780](https://doi.org/10.37002/biobrasil.v11i4.1780)>.

SILVA, K. M. R. **Climatologia das brisas marítima e terrestre no Estado de Alagoas**. 116 p. Dissertação (Mestrado em Meteorologia), Universidade Federal de Alagoas, Maceió, 2022. Disponível em: <<https://www.repositorio.ufal.br/jspui/handle/123456789/9647>>. Acesso em: 11 jan. 2024.

SILVA, L. S. O.; SILVA JUNIOR, R. S.; LYRA, R. F. F.; MARTINS, F. R.; MOURA, M. A. L.; LEAL JUNIOR, J. B. V.; CARDOSO, K. R. A. Avaliação de métodos para atualização do mapeamento eólico do Estado de Alagoas. **Research, Society and Development**, v.12, n.2, 1-18, 2023. <[dx.doi.org/10.33448/rsd-v12i2.40053](https://doi.org/10.33448/rsd-v12i2.40053)>.

SILVA, E. R. L. G. **Associação da variabilidade climática dos oceanos com a vazão de rios da Região Norte do Brasil**. 182 p. Dissertação (Mestrado em Geografia), Universidade de São Paulo, São Paulo, 2013.

SILVESTRE, M. R. **Técnicas estatísticas utilizadas em climatologia geográfica: diagnósticos e propostas**. 408 p. Tese (Doutorado em Geografia), Universidade Estadual Paulista, São Paulo, 2016. Disponível em: <<https://repositorio.unesp.br/items/b3d5e0d2-c389-4097-846b-598801c40e32>>. Acesso em: 11 jan. 2024.

SOKAL, R. R.; ROHLF, F. J. The comparison of dendrograms by objective methods. **Taxon**, v.11, n.2, 33-40, 1962. <<https://doi.org/10.2307/1217208>>.

SOUZA, A.; SANTOS, D. A. S. Análise das componentes principais no processo de monitoramento ambiental. **Nativa**, v.6, n.6, 639-647, 2018. <[dx.doi.org/10.31413/nativa.v6i6.6453](https://doi.org/10.31413/nativa.v6i6.6453)>.

SOUZA, C. A.; REBOITA, M. S. Ferramenta para o monitoramento dos padrões de teleconexão na América do Sul. **Terra e Didática**, v.17, 1-13, 2021. <doi.org/10.20396/td.v17i00.8663474>.

STULL, R. B. **An introduction to boundary layer meteorology**. Kluwer Academic Publishers. Dordrecht/Boston/London 670 pp. 1988. <doi.org/10.1007/978-94-009-3027-8>.

TANG, X.; HASAN, N.; MILANOVIC, J. V.; BAILEY, K.; STOTT, S. J. Estimation and validation of characteristic load profile through smart grid trials in a medium voltage distribution network. **IEEE Transactions on Power Systems**, v.33, n.2, 1848-1859, 2018. <[10.1109/TPWRS.2017.2740563](https://doi.org/10.1109/TPWRS.2017.2740563)>.

TAYLOR, K. E. Summarizing multiple aspects of model performance in a single diagram. **Journal of Geophysical Research**, v.126, 7183-7192, 2001. <<https://doi.org/10.1029/2000JD900719>>.

TEODORO, T. A.; REBOITA, M. S.; ESCOBAR, G. C. J. Caracterização da Banda Dupla da Zona de Convergência Intertropical (ZCIT) no Oceano Atlântico. **Anuário do Instituto de Geociências – UFRJ**, v.42, n.2, 282-298, 2019. <[dx.doi.org/10.11137/2019_2_282_298](https://doi.org/10.11137/2019_2_282_298)>.

TIAN, Z.; CHEN, H. Multi-step short-term wind speed prediction based on integrated multi-model fusion. **Applied Energy**, v.298, 1-15, 2021. <doi.org/10.1016/j.apenergy.2021.117248>.

TOLEDO, G. L.; OVALLE, I. I. **Estatística Básica**. São Paulo: Atlas, 1981. Disponível em: <<https://www.estantevirtual.com.br/livros/geraldo-luciano-toledo-e-ivo-izidoro-ovalle/estatistica-basica/3557792324#>>. Acesso em: 11 jan. 2024.

TORO, K.; BARTHOLY, J.; PONGRÁCZ, R.; KIS, Z.; KELLER, E.; DUNAY, G. Evaluation of meteorological factors on sudden cardiovascular death. **Journal of Forensic and Legal Medicine**, v.17, 236-242, 2010. <doi.org/10.1016/j.jflm.2010.02.008>.

TORRENCE, C.; COMPO, G. P. A practical guide to Wavelet analysis. **Bulletin of the American Meteorological Society**, v.79, 61–78. 1998. Disponível em: <https://atoc.colorado.edu/research/wavelets/bams_79_01_0061.pdf>. Acesso em: 29 fev. 2024.

VAGHETTI, N. N.; DINIZ, G.B.; SILVA, J. B. Climatologia da umidade relativa média mensal em regiões homogêneas do Estado do Rio Grande do Sul. **Sociedade Científica Revista Multidisciplinar**, v.2, n.9, 1-19, 2019. <[10.5281/zenodo.3488021](https://zenodo.org/record/3488021)>.

VALENS, C. **A Really Friendly Guide to Wavelets**. 19 p., 1999. Disponível em: <<http://www.staroceans.org/documents/A%20Really%20Friendly%20Guide%20to%20Wavelets.pdf>>. Acesso em: 29 fev. 2024.

VAREJÃO-SILVA, M. A. **Meteorologia e Climatologia**. Versão digital 2, Recife: 2006. Disponível em: <<https://icat.ufal.br>>. Acesso em: 28 jul. 2023.

VELASCO, V. M.; MENDOZA, B. Assessing the relationship between solar activity and some large scale climatic phenomena. **Advances Space Research**, v.42, 866-878, 2008. <[doi:10.1016/j.asr.2007.05.050](https://doi.org/10.1016/j.asr.2007.05.050)>.

VIGANÓ, H. H. G.; SOUZA, C. C.; CRISTALDO, M. F.; JESUS, L. Redes neurais artificiais na previsão de queimadas e incêndios no Pantanal. **Revista Brasileira de Geografia Física**, v.10, 1355-1367, 2017. <doi.org/10.26848/rbgf.v.10.p1355-1367>.

VILANI, M. T.; SANCHES, L.; Análise de Fourier e Wavelets aplicada à temperatura do ar em diferentes tipologias de ocupação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.17, n.12, 1340-1346, 2013. Disponível em: <www.agriambi.com.br>. Acesso em: 18 set. 2023.

WARD, J. H. Hierarchical grouping to optimize an objective function. **Journal of the American Statistical Association**, v.58, 236-244, 1963. Disponível em: <<https://iv.cns.iu.edu/sw/data/ward.pdf>>. Acesso em: 11 jan. 2024.

WENG, H. Y.; LAU, K. M. Wavelets, period doubling, and time: frequency localization with application to organization of convection over the tropical western pacific.

Journal of the Atmospheric Science, v.51, n.7, 2523-2541, 1994. <[doi.org/10.1175/1520-0469\(1994\)051<2523:WPDATL>2.0.CO;2](https://doi.org/10.1175/1520-0469(1994)051<2523:WPDATL>2.0.CO;2)>.

XU, W.; LIU, P.; CHENG, L.; ZHOU, Y.; XIA, Q.; GONG, Y.; LIU, Y. Multi-step wind speed prediction by combining a WRF simulation and an error correction strategy. **Renewable Energy**, v.163, 772-782, 2021. <doi.org/10.1016/j.renene.2020.09.032>.

YI, H.; SHU, H. The improvement of the Morlet wavelet for multi-period analysis of climate data. **Comptes Rendus Geoscience**, v. 344, 483-497, 2012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1631071312001848>>. Acesso em: 29 fev. 2024.

APÊNDICE A

Distância entre o local exato da torre anemométrica de Craíbas para o local de medição da PAM dados da SEMARH no município de Arapiraca.

```
% Universidade Federal de Campina Grande - UFCG
% Universidade Federal de Alagoas - UFAL
% Unidade Acadêmica de Ciências Atmosféricas - UACA
% Centro de Tecnologia e Recursos Naturais - CTRN
% Instituto de Ciências Atmosféricas - ICAT
% Laboratório de Meteorologia Aplicada e Meio Ambiente (LAMMA)
% Programa de Pós-Graduação em Meteorologia - PPGMet
% Doutorando: Iwldson Guilherme da Silva Santos
% Objetivo: APÊNDICE A, distância entre dois pontos, torre anemométrica de
% Craíbas e Precipitação Acumulada Mensal de Arapiraca dados do SEMARH.
% Craíbas: lat(-9.6667); lon(-36.8447); Alt(258)
% ARAPIRACA: lat(-9,804444); lon(-36,619167); Alt(236,84); DI(26/04/2008);
% N°(A353)
```

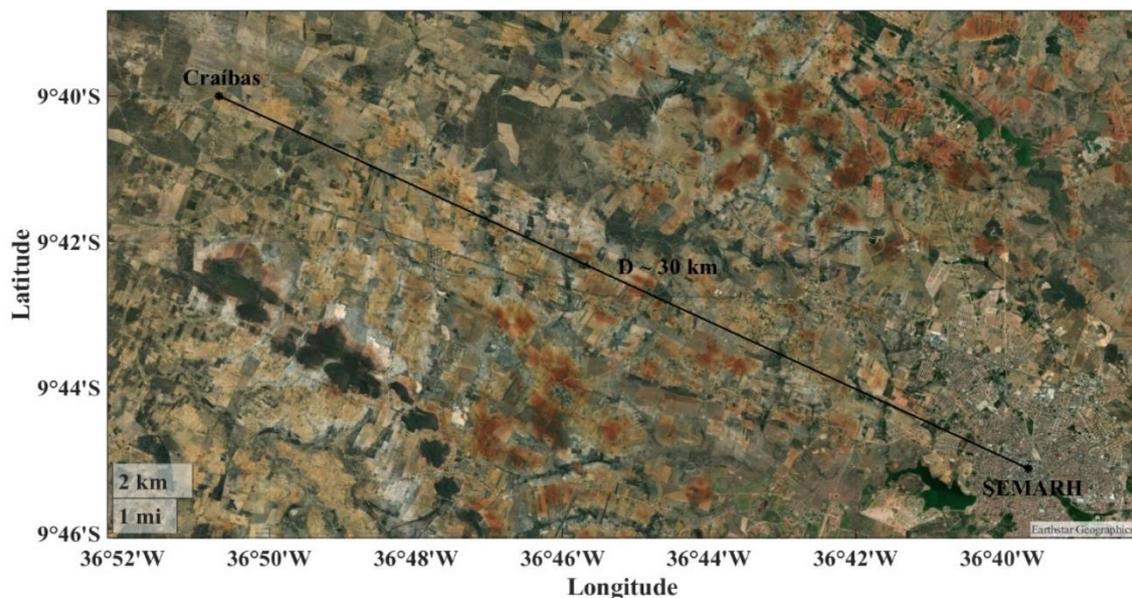
```
% Transformação de graus, minutos e segundos em graus decimais.
% gd = g + m/60 + s/3600
```

```
% Distância entre dois pontos (D) em graus decimais.
```

```
lat1 = -9.6667;
lon1 = -36.8447;
lat2 = -9.8044;
lon2 = -36.6192;
D = sqrt((-9.6667+9.8044)^2+(-36.8447+36.6192)^2);
```

```
% Um grau equivale a 111km, logo D em km é dado por (d).
d = D*111;
```

```
% Gráfico geoespacial mostrando a distância entre os pontos.
geoplot([lat1 lat2],[lon1 lon2],'k-*');
```



APÊNDICE B

Valor tabelado de t para níveis de significância.

Distribuição t-Student: valores t_c tais que $P(-t_c \leq t \leq t_c) = 1 - p$																	
$p \triangleright$	90%	80%	70%	60%	50%	40%	30%	20%	10%	8%	6%	5%	4%	2%	1%	0,2%	0,1%
1	0,158	0,325	0,510	0,727	1,000	1,376	1,963	3,078	6,314	7,916	10,579	12,706	15,895	31,821	63,657	318,309	636,619
2	0,142	0,289	0,445	0,617	0,816	1,061	1,386	1,886	2,920	3,320	3,896	4,303	4,849	6,965	9,925	22,327	31,599
3	0,137	0,277	0,424	0,584	0,765	0,978	1,250	1,638	2,353	2,605	2,951	3,182	3,482	4,541	5,841	10,215	12,924
4	0,134	0,271	0,414	0,569	0,741	0,941	1,190	1,533	2,132	2,333	2,601	2,776	2,999	3,747	4,604	7,173	8,610
5	0,132	0,267	0,408	0,559	0,727	0,920	1,156	1,476	2,015	2,191	2,422	2,571	2,757	3,365	4,032	5,893	6,869
6	0,131	0,265	0,404	0,553	0,718	0,906	1,134	1,440	1,943	2,104	2,313	2,447	2,612	3,143	3,707	5,208	5,959
7	0,130	0,263	0,402	0,549	0,711	0,896	1,119	1,415	1,895	2,046	2,241	2,365	2,517	2,998	3,499	4,785	5,408
8	0,130	0,262	0,399	0,546	0,706	0,889	1,108	1,397	1,860	2,004	2,189	2,306	2,449	2,896	3,355	4,501	5,041
9	0,129	0,261	0,398	0,543	0,703	0,883	1,100	1,383	1,833	1,973	2,150	2,262	2,398	2,821	3,250	4,297	4,781
10	0,129	0,260	0,397	0,542	0,700	0,879	1,093	1,372	1,812	1,948	2,120	2,228	2,359	2,764	3,169	4,144	4,587
11	0,129	0,260	0,396	0,540	0,697	0,876	1,088	1,363	1,796	1,928	2,096	2,201	2,328	2,718	3,106	4,025	4,437
12	0,128	0,259	0,395	0,539	0,695	0,873	1,083	1,356	1,782	1,912	2,076	2,179	2,303	2,681	3,055	3,930	4,318
13	0,128	0,259	0,394	0,538	0,694	0,870	1,079	1,350	1,771	1,899	2,060	2,160	2,282	2,650	3,012	3,852	4,221
14	0,128	0,258	0,393	0,537	0,692	0,868	1,076	1,345	1,761	1,887	2,046	2,145	2,264	2,624	2,977	3,787	4,140
15	0,128	0,258	0,393	0,536	0,691	0,866	1,074	1,341	1,753	1,878	2,034	2,131	2,249	2,602	2,947	3,733	4,073
16	0,128	0,258	0,392	0,535	0,690	0,865	1,071	1,337	1,746	1,869	2,024	2,120	2,235	2,583	2,921	3,686	4,015
17	0,128	0,257	0,392	0,534	0,689	0,863	1,069	1,333	1,740	1,862	2,015	2,110	2,224	2,567	2,898	3,646	3,965
18	0,127	0,257	0,392	0,534	0,688	0,862	1,067	1,330	1,734	1,855	2,007	2,101	2,214	2,552	2,878	3,610	3,922
19	0,127	0,257	0,391	0,533	0,688	0,861	1,066	1,328	1,729	1,850	2,000	2,093	2,205	2,539	2,861	3,579	3,883
20	0,127	0,257	0,391	0,533	0,687	0,860	1,064	1,325	1,725	1,844	1,994	2,086	2,197	2,528	2,845	3,552	3,850
21	0,127	0,257	0,391	0,532	0,686	0,859	1,063	1,323	1,721	1,840	1,988	2,080	2,189	2,518	2,831	3,527	3,819
22	0,127	0,256	0,390	0,532	0,686	0,858	1,061	1,321	1,717	1,835	1,983	2,074	2,183	2,508	2,819	3,505	3,792
23	0,127	0,256	0,390	0,532	0,685	0,858	1,060	1,319	1,714	1,832	1,978	2,069	2,177	2,500	2,807	3,485	3,768
24	0,127	0,256	0,390	0,531	0,685	0,857	1,059	1,318	1,711	1,828	1,974	2,064	2,172	2,492	2,797	3,467	3,745
25	0,127	0,256	0,390	0,531	0,684	0,856	1,058	1,316	1,708	1,825	1,970	2,060	2,167	2,485	2,787	3,450	3,725
26	0,127	0,256	0,390	0,531	0,684	0,856	1,058	1,315	1,706	1,822	1,967	2,056	2,162	2,479	2,779	3,435	3,707
27	0,127	0,256	0,389	0,531	0,684	0,855	1,057	1,314	1,703	1,819	1,963	2,052	2,158	2,473	2,771	3,421	3,690
28	0,127	0,256	0,389	0,530	0,683	0,855	1,056	1,313	1,701	1,817	1,960	2,048	2,154	2,467	2,763	3,408	3,674
29	0,127	0,256	0,389	0,530	0,683	0,854	1,055	1,311	1,699	1,814	1,957	2,045	2,150	2,462	2,756	3,396	3,659
30	0,127	0,256	0,389	0,530	0,683	0,854	1,055	1,310	1,697	1,812	1,955	2,042	2,147	2,457	2,750	3,385	3,646
31	0,127	0,256	0,389	0,530	0,682	0,853	1,054	1,309	1,696	1,810	1,952	2,040	2,144	2,453	2,744	3,375	3,633
32	0,127	0,255	0,389	0,530	0,682	0,853	1,054	1,309	1,694	1,808	1,950	2,037	2,141	2,449	2,738	3,365	3,622
33	0,127	0,255	0,389	0,530	0,682	0,853	1,053	1,308	1,692	1,806	1,948	2,035	2,138	2,445	2,733	3,356	3,611
34	0,127	0,255	0,389	0,529	0,682	0,852	1,052	1,307	1,691	1,805	1,946	2,032	2,136	2,441	2,728	3,348	3,601
35	0,127	0,255	0,388	0,529	0,682	0,852	1,052	1,306	1,690	1,803	1,944	2,030	2,133	2,438	2,724	3,340	3,591
36	0,127	0,255	0,388	0,529	0,681	0,852	1,052	1,306	1,688	1,802	1,942	2,028	2,131	2,434	2,719	3,333	3,582
37	0,127	0,255	0,388	0,529	0,681	0,851	1,051	1,305	1,687	1,800	1,940	2,026	2,129	2,431	2,715	3,326	3,574
38	0,127	0,255	0,388	0,529	0,681	0,851	1,051	1,304	1,686	1,799	1,939	2,024	2,127	2,429	2,712	3,319	3,566
39	0,126	0,255	0,388	0,529	0,681	0,851	1,050	1,304	1,685	1,798	1,937	2,023	2,125	2,426	2,708	3,313	3,558
40	0,126	0,255	0,388	0,529	0,681	0,851	1,050	1,303	1,684	1,796	1,936	2,021	2,123	2,423	2,704	3,307	3,551
45	0,126	0,255	0,388	0,528	0,680	0,850	1,049	1,301	1,679	1,791	1,929	2,014	2,115	2,412	2,690	3,281	3,520
50	0,126	0,255	0,388	0,528	0,679	0,849	1,047	1,299	1,676	1,787	1,924	2,009	2,109	2,403	2,678	3,261	3,496
55	0,126	0,255	0,387	0,527	0,679	0,848	1,046	1,297	1,673	1,784	1,920	2,004	2,104	2,396	2,668	3,245	3,476
60	0,126	0,254	0,387	0,527	0,679	0,848	1,045	1,296	1,671	1,781	1,917	2,000	2,099	2,390	2,660	3,232	3,460
70	0,126	0,254	0,387	0,527	0,678	0,847	1,044	1,294	1,667	1,776	1,912	1,994	2,093	2,381	2,648	3,211	3,435
80	0,126	0,254	0,387	0,526	0,678	0,846	1,043	1,292	1,664	1,773	1,908	1,990	2,088	2,374	2,639	3,195	3,416
90	0,126	0,254	0,387	0,526	0,677	0,846	1,042	1,291	1,662	1,771	1,905	1,987	2,084	2,368	2,632	3,183	3,402
100	0,126	0,254	0,386	0,526	0,677	0,845	1,042	1,290	1,660	1,769	1,902	1,984	2,081	2,364	2,626	3,174	3,390
110	0,126	0,254	0,386	0,526	0,677	0,845	1,041	1,289	1,659	1,767	1,900	1,982	2,078	2,361	2,621	3,166	3,381
120	0,126	0,254	0,386	0,526	0,677	0,845	1,041	1,289	1,658	1,766	1,899	1,980	2,076	2,358	2,617	3,160	3,373
∞	0,126	0,253	0,385	0,524	0,674	0,842	1,036	1,282	1,645	1,751	1,881	1,960	2,054	2,326	2,576	3,090	3,291

APÊNDICE C

Cálculos e procedimentos para determinar os parâmetros aerodinâmicos: u_* (Eq. (35)) velocidade de fricção, z_0 (Eq. (36)) comprimento da rugosidade do terreno e α (Eq. (37)) expoente da camada limite.

A partir da Lei Logarítmica:

$$x(z_r) = \frac{u_*}{k} \cdot \ln\left(\frac{z_r}{z_0}\right)$$

Para duas alturas distintas z_1 e z_2 , existem duas velocidades distintas dadas por:

$$x(z_1) = \frac{u_*}{k} \cdot \ln\left(\frac{z_1}{z_0}\right), \quad x(z_2) = \frac{u_*}{k} \cdot \ln\left(\frac{z_2}{z_0}\right)$$

Diferença entre $x(z_2)$ e $x(z_1)$ é:

$$\begin{aligned} x(z_2) - x(z_1) &= \frac{u_*}{k} \cdot \ln\left(\frac{z_2}{z_0}\right) - \frac{u_*}{k} \cdot \ln\left(\frac{z_1}{z_0}\right) = \frac{u_*}{k} \cdot \left(\ln\left(\frac{z_2}{z_0}\right) - \ln\left(\frac{z_1}{z_0}\right)\right) \\ &= \frac{u_*}{k} \cdot \ln\left(\frac{\frac{z_2}{z_0}}{\frac{z_1}{z_0}}\right) = \frac{u_*}{k} \cdot \ln\left(\frac{z_2}{z_1}\right) \Rightarrow \end{aligned}$$

$$x(z_2) - x(z_1) = \frac{u_*}{k} \cdot \ln\left(\frac{z_2}{z_1}\right) \Rightarrow u_* = \frac{k \cdot (x(z_2) - x(z_1))}{\ln\left(\frac{z_2}{z_1}\right)}$$

Portanto, a velocidade de fricção é dada por:

$$u_* = \frac{k \cdot (x(z_2) - x(z_1))}{\ln\left(\frac{z_2}{z_1}\right)} \blacksquare$$

Continuando com a Lei Logarítmica, agora dividindo $x(z_2)$ por $x(z_1)$, temos:

$$\frac{x(z_2)}{x(z_1)} = \frac{\frac{u_*}{k} \cdot \ln\left(\frac{z_2}{z_0}\right)}{\frac{u_*}{k} \cdot \ln\left(\frac{z_1}{z_0}\right)} = \frac{\ln\left(\frac{z_2}{z_0}\right)}{\ln\left(\frac{z_1}{z_0}\right)} = \frac{\ln z_2 - \ln z_0}{\ln z_1 - \ln z_0} \Rightarrow$$

$$\begin{aligned} x(z_1) \cdot (\ln z_2 - \ln z_0) &= x(z_2) \cdot (\ln z_1 - \ln z_0) \Rightarrow \\ x(z_1) \cdot \ln z_2 - x(z_1) \cdot \ln z_0 &= x(z_2) \cdot \ln z_1 - x(z_2) \cdot \ln z_0 \Rightarrow \\ x(z_2) \cdot \ln z_0 - x(z_1) \cdot \ln z_0 &= x(z_2) \cdot \ln z_1 - x(z_1) \cdot \ln z_2 \Rightarrow \\ \ln z_0 \cdot (x(z_2) - x(z_1)) &= x(z_2) \cdot \ln z_1 - x(z_1) \cdot \ln z_2 \Rightarrow \end{aligned}$$

$$\ln z_0 = \frac{x(z_2) \cdot \ln z_1 - x(z_1) \cdot \ln z_2}{x(z_2) - x(z_1)} \Rightarrow$$

$$z_0 = \exp\left(\frac{x(z_2) \cdot \ln z_1 - x(z_1) \cdot \ln z_2}{x(z_2) - x(z_1)}\right)$$

Portanto, o comprimento de rugosidade do terreno é dado por:

$$z_0 = \exp\left(\frac{x(z_2) \cdot \ln z_1 - x(z_1) \cdot \ln z_2}{x(z_2) - x(z_1)}\right) \blacksquare$$

A partir da Lei da Potência:

$$\begin{aligned} \frac{x(z_r)}{x(z_1)} &= \left(\frac{z_r}{z_1}\right)^\alpha \Rightarrow \\ \ln\left(\frac{x(z_r)}{x(z_1)}\right) &= \ln\left(\frac{z_r}{z_1}\right)^\alpha \Rightarrow \\ \alpha \cdot \ln\left(\frac{z_r}{z_1}\right) &= \ln\left(\frac{x(z_r)}{x(z_1)}\right) \Rightarrow \\ \alpha \cdot (\ln z_r - \ln z_1) &= \ln x(z_r) - \ln x(z_1) \Rightarrow \\ \alpha &= \frac{\ln x(z_r) - \ln x(z_1)}{\ln z_r - \ln z_1} \end{aligned}$$

Portanto, o expoente da camada limite é dado por:

$$\alpha = \frac{\ln x(z_r) - \ln x(z_1)}{\ln z_r - \ln z_1} \blacksquare$$