

Pontifícia Universidade Católica de Goiás
Programa de Mestrado em Engenharia de Produção e Sistemas

**ANÁLISE E MODELAGEM ESTATÍSTICA PARA
CARACTERIZAÇÃO CLIMÁTICA DA REGIÃO
HIDROGRÁFICA DO XINGU-PA**

Thiago Moura de Moraes

**ANÁLISE E MODELAGEM ESTATÍSTICA PARA CARACTERIZAÇÃO
CLIMÁTICA DA REGIÃO HIDROGRÁFICA DO XINGU-PA**

Thiago Moura de Morais

Dissertação de Mestrado apresentado ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica de Goiás, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Orientador: José Elmo de Menezes, *Dr.*

Coorientador: Felipe Corrêa Veloso dos Santos, *Dr.*

M828a Moraes, Thiago Moura de
 Análise e modelagem estatística para caracterização
 climática da Região Hidrográfica do Xingu-PA [recurso
 eletrônico]/ Thiago Moura de Moraes.-- 2018.
 141 f.; il.

 Texto em português com resumo em inglês
 Dissertação (mestrado) - Pontifícia Universidade Católica
 de Goiás, Programa de Pós-Graduação Stricto Sensu em
 Engenharia de Produção e Sistemas, Goiânia, 2018

 Inclui referências f. 120-141

 1. Geoestatística. 2. Climatometria. 3. Hidrologia
 Estatística. 4. Sazonalidade climática. 5. Séries temporais. I.
 Menezes, José Elmo de. II. Pontifícia Universidade Católica de
 Goiás. III. Título.

 CDU 551.583(043)

**ANÁLISE E MODELAGEM ESTATÍSTICA PARA CARACTERIZAÇÃO
CLIMÁTICA DA REGIÃO HIDROGRÁFICA DO XINGU-PA**

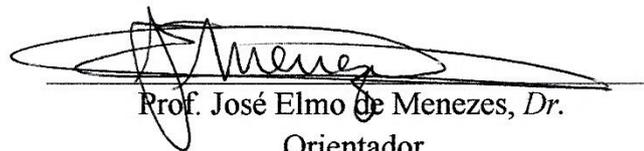
Thiago Moura de Morais

Esta dissertação foi julgada adequada para obtenção do título de Mestre em Engenharia de Produção e Sistemas, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica de Goiás em 02 de maio de 2018.

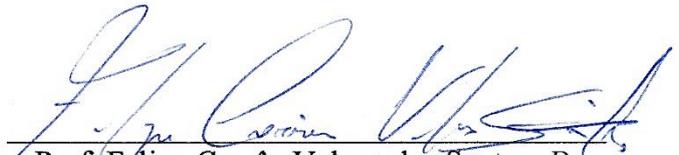


Prof. Marcos Lajoyc Carneiro, *Dr.*
Coordenador do Programa de Pós-Graduação em
Engenharia de Produção e Sistemas.

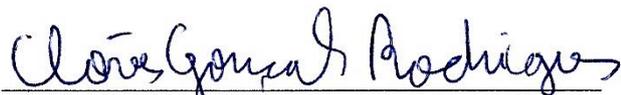
Banca Examinadora:



Prof. José Elmo de Menezes, *Dr.*
Orientador



Prof. Felipe Corrêa Veloso dos Santos, *Dr.*
Coorientador



Prof. Clóves Gonçalves Rodrigues, *Dr.*
Examinador Interno – PUC Goiás



Prof.ª Vladia Correchel, *Dra.*
Examinadora Externa – UFG

“Treine enquanto eles dormem, estude enquanto eles se divertem, persista enquanto eles descansam, e então, viva o que eles sonham”.

Provérbio japonês

AGRADECIMENTOS

Agradeço primeiramente a Deus pela dádiva da vida, por me dar força para seguir em frente com os meus objetivos, pelo conforto nos momentos de dificuldade e por mais esta conquista.

A minha mãe Marilda Correia de Moura que sempre acreditou em minha capacidade, me motivando e ensinando o verdadeiro sentido da vida com muito amor e carinho.

Agradeço imensamente à compreensão dos familiares e amigos que me apoiaram ao longo dessa trajetória. Obrigado pela paciência incansável e incentivos nos momentos de necessidade.

De maneira muito especial agradeço meu coorientador professor Dr. Felipe Corrêa Veloso dos Santos. Obrigado pela ajuda e grande dedicação empregada para realização deste estudo. Agradeço pela amizade, confiança depositada e inúmeras contribuições em minha vida profissional.

Ao meu orientador professor Dr. José Elmo de Menezes, pelo acolhimento e ensinamentos de forma objetiva.

E por fim, aos professores e colegas do Programa de Mestrado em Engenharia de Produção e Sistemas (MEPROS/PUC-Goiás) pela amizade e colaboração durante esse percurso.

Resumo da Dissertação apresentada ao MEPROS/PUC Goiás como parte dos requisitos necessários para obtenção do grau de Mestre em Engenharia de Produção e Sistemas (M.Sc.).

ANÁLISE E MODELAGEM ESTATÍSTICA PARA CARACTERIZAÇÃO CLIMÁTICA DA REGIÃO HIDROGRÁFICA DO XINGU-PA

Thiago Moura de Moraes

Maio/2018

Orientador: Prof. José Elmo de Menezes, *Dr.*

Coorientador: Prof. Felipe Corrêa Veloso dos Santos, *Dr.*

RESUMO

Devido as mudanças nos padrões climáticos nas últimas décadas, compreender os elementos climáticos e as incertezas que os permeiam são de extrema importância, para definição de medidas estratégicas e minimizar os possíveis riscos advindos com as mudanças no clima. Este estudo teve como objetivo analisar e caracterizar a variabilidade climática espaço-temporal da Região Hidrográfica do Xingu-PA relacionando ao fenômeno El Niño-Oscilação Sul. Os resultados mostram padrões climáticos com comportamento distintos entre as variáveis, onde a precipitação apresenta maior variabilidade, além do comportamento inverso ascendente na temperatura e descendente na umidade relativa do ar. Foi verificada relação altimétrica inversa com as variáveis precipitação e temperatura. Devido à alta variabilidade nos padrões climáticos, não houve ajuste à uma função densidade de probabilidade considerando todo o conjunto de dados, que só foi possível considerando períodos intervalares. Pela análise de *El Niño* e *La Niña* se verificou grande influência das anomalias no clima em diferentes períodos, justificando valores extremos identificados nas séries. Também foi verificada predominância de moderada e forte dependência espacial e baixo alcance variográfico, que inviabiliza estimativas de novos pontos de monitoramento, necessitando de novas abordagens para utilização conjunta. O modelo SARIMA se mostrou uma boa abordagem para modelagem de dados de temperatura e umidade relativa do ar com média mensal, no entanto, para precipitação acumulada mensal não apresentou bom desempenho. Os resultados apontam possíveis impactos na economia e na disponibilidade de água no sistema de drenagem da UHE Belo Monte à longo prazo.

Palavras-chave: Geoestatística. Climatometria. Hidrologia estatística. Sazonalidade climática. Séries temporais.

Resumo da Dissertação apresentada ao MEPROS/PUC Goiás como parte dos requisitos necessários para obtenção do grau de Mestre em Engenharia de Produção e Sistemas (M.Sc.).

ANALYSIS AND STATISTICAL MODELING FOR CLIMATE CHARACTERIZATION OF THE XINGU-PA HYDROGRAPHIC REGION

Thiago Moura de Morais

Maio/2018

Orientador: Prof. José Elmo de Menezes, *Dr.*

Coorientador: Prof. Felipe Corrêa Veloso dos Santos, *Dr.*

ABSTRACT

Because of the changes in weather patterns in recent decades, understanding the climatic elements and the uncertainties that permeate them are of extremely importance to define strategic measures and minimize the possible risks arising from changes in climate. This study aimed to analyze and characterize the space-time climatic variability of the Xingu-PA Hydrographic Region related to the phenomenon El Niño-Southern Oscillation. The results show climatic patterns with different behavior among the variables, where the precipitation presents greater variability, besides the inverse upward and downward temperature behavior in the relative humidity of the air. It was verified the inverse altimetric relation with the precipitation and temperature variables. Due to the high variability in the climatic patterns, there was no adjustment to a probability density function considering the entire dataset, which was only possible considering interval periods. By the analysis of *El Niño* and *La Niña* there was a great influence of the anomalies in the climate in different periods, justifying extreme values identified in the series. It was also verified a predominance of moderate and strong spatial dependence with low reach variographic, which makes it impossible to estimate new monitoring points, necessitating new approaches for joint use. The SARIMA model was shown to be a good approach for data modeling of temperature and relative air humidity with monthly mean, however, for monthly accumulated precipitation did not show good performance. The results indicate possible impacts on the economy and the availability of water in the drainage system of the Belo Monte Hydroelectric Power Plant in the long time.

Keywords: Geostatistics. Climatometry. Statistical hydrology. Climatic seasonality. Time series.

LISTA DE ILUSTRAÇÕES

Figura 1 – Efeito global da anomalia oceânica <i>El Niño</i> no verão (A) e inverso (B).....	28
Figura 2 – Efeito global da anomalia oceânica <i>La Niña</i> no verão (A) e inverso (B)	30
Figura 3 – Delimitação da região Norte do Brasil e seus principais rios	31
Figura 4 – Projeto da Usina Hidrelétrica Belo Monte no período de 1980 a 1990 (A) e projeto atualizado e em execução desde 2011 (B)	35
Figura 5 – Terras indígenas afetadas direta e indiretamente pela Usina Hidrelétrica Belo Monte.....	37
Figura 6 – Áreas de influência direta e indireta da construção da Usina Hidrelétrica Belo Monte.....	39
Figura 7 – Divisão hidrográfica do estado do Pará	43
Figura 8 – Regiões de monitoramento do NOAA com base na Temperatura de Superfície do Mar.....	44
Figura 9 – Distribuição das Estações Meteorológicas convencionais monitoradas pelo INMET no Brasil	46
Figura 10 – Limites de correlação das Estações Meteorológicas em função da temperatura média mensal	48
Figura 11 – Demarcação da Região Hidrográfica do Xingu-PA, Estações Meteorológicas utilizadas e localização da Usina Hidrelétrica Belo Monte	50
Figura 12 – Modelo de semivariograma experimental.....	57
Figura 13 – Representação do interpolador krigagem ordinária	59
Figura 14 – Padrão climático da Região Hidrográfica do Xingu-PA para registros de precipitação acumulada mensal	64
Figura 15 – Padrão climático da Região Hidrográfica do Xingu-PA para registros de temperatura média mensal	65
Figura 16 – Padrão climático da Região Hidrográfica do Xingu-PA para registros de umidade média mensal	65
Figura 17 – Comportamento e tendência de diferentes períodos para precipitação acumulada.....	66
Figura 18 – Comportamento e tendência de diferentes períodos para temperatura média	67
Figura 19 – Comportamento e tendência de diferentes períodos para umidade média ..	68

Figura 20 – Padrões de distribuição dos registros individuais das Estações Meteorológicas para precipitação acumulada mensal	69
Figura 21 – Padrões de distribuição dos registros individuais das Estações Meteorológicas para temperatura média mensal	70
Figura 22 – Padrões de distribuição dos registros individuais das Estações Meteorológicas para umidade média mensal	71
Figura 23 – Comportamento das massas de ar atuantes no Brasil em diferentes épocas	73
Figura 24 – Histograma de densidades para dados de precipitação acumulada mensal (A); temperatura média mensal (B); e umidade relativa do ar média mensal (C)	82
Figura 25 – Gráfico de probabilidade (Q-Q) das distribuições em diferentes intervalos para precipitação acumulada mensal	86
Figura 26 – Gráfico de probabilidade (Q-Q) das distribuições em diferentes intervalos para temperatura média mensal	87
Figura 27 – Gráfico de probabilidade (Q-Q) das distribuições identificadas para umidade média mensal	89
Figura 28 – Mapas de períodos considerados Neutros (A) e (B); com ocorrência de <i>El Niño</i> (C) e (D); e com ocorrência de <i>La Niña</i> (E) e (F).....	92
Figura 29 – <i>Boxplot</i> com informações das médias de precipitação acumulada mensal de 1980 a 2016 para episódios de <i>El Niño</i> , <i>La Niña</i> e anos Neutros.....	93
Figura 30 – <i>Boxplot</i> com informações das médias de temperatura mensal de 1980 a 2016 para episódios de <i>El Niño</i> , <i>La Niña</i> e anos Neutros	96
Figura 31 – Séries históricas das variáveis climáticas (1980-2016) e modelos estimados para a Região Hidrográfica do Xingu-PA	117

LISTA DE TABELAS

Tabela 1 – Relação entre umidade relativa do ar média e precipitação total anual em diferentes regiões do Brasil	22
Tabela 2 – Distribuição do fornecimento de energia elétrica doméstica no Brasil	26
Tabela 3 – Principais atividades econômicas praticadas no Brasil	41
Tabela 4 – Classificação da intensidade do Índice Oceânico Niño	44
Tabela 5 – Catalogação de <i>El Niño</i> e <i>La Niña</i> com base no Índice Oceânico Niño entre os anos de 1980 a 2016	45
Tabela 6 – Estações Meteorológicas utilizadas e suas respectivas latitude, longitude e altitude em relação ao nível do mar	49
Tabela 7 – Ranqueamento dos registros de precipitação acumulada entre os anos de 1980 a 2016	73
Tabela 8 – Ranqueamento dos registros de temperatura média entre os anos de 1980 a 2016	74
Tabela 9 – Ranqueamento dos registros de umidade média do ar entre os anos de 1980 a 2016	74
Tabela 10 – Estatísticas da relação entre precipitação acumulada, temperatura média e umidade relativa do ar média em função da altitude	75
Tabela 11 – Estatísticas da relação entre precipitação acumulada, temperatura média em função da altitude.....	76
Tabela 12 – Teste de normalidade dos resíduos da relação altimétrica com as variáveis climáticas.....	77
Tabela 13 – Verificação da homoscedasticidade dos resíduos pelo teste de Breusch-Pagan	77
Tabela 14 – Análise descritiva de precipitação acumulada, temperatura e umidade média mensal.....	78
Tabela 15 – Distribuição de frequências e densidade de precipitação acumulada mensal	79
Tabela 16 – Distribuição de frequências e densidade de temperatura média mensal.....	80
Tabela 17 – Distribuição de frequências e densidade de umidade relativa do ar média mensal.....	81
Tabela 18 – Análise descritiva dos dados de precipitação acumulada mensal para análise do período chuvoso e de estiagem da Região Hidrográfica do Xingu-PA	83

Tabela 19 – Análise descritiva dos dados de temperatura mensal para análise do período chuvoso e de estiagem da Região Hidrográfica do Xingu-PA	84
Tabela 20 – Análise descritiva dos dados de umidade relativa do ar mensal para análise do período chuvoso e de estiagem da Região Hidrográfica do Xingu-PA.....	84
Tabela 21 – Identificação do tipo de distribuição de probabilidade por intervalos para precipitação acumulada mensal	85
Tabela 22 – Identificação do tipo de distribuição de probabilidade por intervalos para temperatura média mensal	87
Tabela 23 – Identificação do tipo de distribuição de probabilidade por intervalos para umidade relativa do ar média mensal	88
Tabela 24 – Correlação entre precipitação acumulada, temperatura e umidade relativa do ar média mensal das séries históricas de 1980 a 2016.....	90
Tabela 25 – Ocorrência de <i>El Niño</i> , <i>La Niña</i> e períodos Neutros na Região Hidrográfica do Xingu-PA e área contigua entre 1980 a 2016.....	91
Tabela 26 – Médias mensais de precipitação acumulada para episódios de <i>El Niño</i> , <i>La Niña</i> e anos Neutros.....	93
Tabela 27 – Influência percentual média mensal de <i>El Niño</i> e <i>La Niña</i> em relação aos anos Neutros para precipitação acumulada	94
Tabela 28 – Médias mensais de temperatura para episódios de <i>El Niño</i> , <i>La Niña</i> e anos Neutros.....	95
Tabela 29 – Influência percentual média mensal de <i>El Niño</i> e <i>La Niña</i> em relação aos anos Neutros para temperatura	96
Tabela 30 – Correlação entre precipitação acumulada e temperatura média mensal para episódios de <i>El Niño</i> e <i>La Niña</i>	98
Tabela 31 – Parâmetros de dependência espacial para médias mensais de precipitação acumulada.....	99
Tabela 32 – Parâmetros de dependência espacial para médias mensais de temperatura	102
Tabela 33 – Parâmetros de dependência espacial para médias mensais de umidade relativa do ar	104
Tabela 34 – Métricas de avaliação dos modelos semivariográficos por validação cruzada para médias mensais de precipitação acumulada	111
Tabela 35 – Métricas de avaliação dos modelos semivariográficos por validação cruzada para médias mensais de temperatura	112

Tabela 36 – Métricas de avaliação dos modelos semivariográficos por validação cruzada para médias mensais de umidade relativa do ar	112
Tabela 37 – Teste de diferenciações de Dickey e Fuller para dos dados climáticos da Região Hidrográfica do Xingu-PA.....	115
Tabela 38 – Modelo de predição por SARIMA para as variáveis climáticas.....	115
Tabela 39 – Avaliação do p-valor do teste dos resíduos para normalidade e autocorrelação das variáveis climáticas	116
Tabela 40 – Avaliação de ajuste das variáveis climáticas para previsões	116
Tabela 41 – Tendências por década para as variáveis climáticas da Região Hidrográfica do Xingu-PA.....	117

SUMÁRIO

1 INTRODUÇÃO	14
1.1 Problemática	15
1.2 Justificativa	16
1.3 Objetivos	17
1.4 Estrutura da pesquisa	18
2 REVISÃO BIBLIOGRÁFICA	19
2.1 Variáveis climáticas	19
2.1.1 Temperatura	19
2.1.2 Umidade relativa do ar	21
2.1.3 Precipitação	23
2.2 Variações climáticas e geração de energia elétrica no Brasil	24
2.2.1 Anomalia oceânica El Niño	27
2.2.2 Anomalia oceânica La Niña	28
2.3 Caracterização da região Norte do Brasil	30
2.3.1 Panorama do estado do Pará	32
2.3.2 Usina Hidrelétrica Belo Monte	34
2.3.3 Principais impactos com a construção da Usina Hidrelétrica Belo Monte 36	
2.4 Economia e variações climáticas	40
3 MATERIAIS E MÉTODOS	43
3.1 Área de estudo e dados utilizados	43
3.2 Delimitação das Estações Meteorológicas	47
3.3 Análise dos dados	50
3.3.1 Regressão Linear Múltipla	50
3.3.2 Análise descritiva	52
3.3.3 Teste de aderência	54
3.4 Análise espacial	55
3.5 Validação	59

3.5.1 Métricas estatísticas de avaliação de ajuste	60
3.5.2 Validação Cruzada.....	61
3.6 Modelagem de séries temporais.....	61
4 ANÁLISE E DISCUSSÃO DOS RESULTADOS.....	63
4.1 Análise dos padrões climáticos da Região Hidrográfica do Xingu-PA.....	63
4.2 Altitude e variáveis climáticas	75
4.3 Análise descritiva dos padrões climáticos da Região Hidrográfica do Xingu-PA.....	78
4.4 Análise da distribuição de densidade de probabilidade.....	85
4.5 Análise do fenômeno El Niño-Oscilação Sul	90
4.6 Análise e validação dos parâmetros espaciais	98
4.7 Modelo de previsão climático	115
5 CONCLUSÕES.....	119
REFERÊNCIAS.....	120

1 INTRODUÇÃO

Existe grande diversificação nas atividades econômicas praticadas na região Norte do Brasil, porém, o foco consiste basicamente em atividades como: agricultura; pecuária; extrativismo vegetal, mineral e animal; e industrial (DOMINGUES *et al.*, 2011). Essas atividades são muito impactadas e vulneráveis às variações climáticas. De acordo com dados do IPCC (2007, 2014) o cenário global vem apontando grandes mudanças nos padrões climáticos nas últimas décadas que deverão continuar. Portanto, a análise e a compreensão da forma de atuação de elementos climáticos e as incertezas que os permeiam são de extrema importância, para definição de medidas estratégicas e preventivas frente aos possíveis riscos advindos com as mudanças no clima.

A Bacia Hidrográfica Amazônica é a maior do mundo e desempenha um papel considerável na regulação dos ciclos globais de água e carbono (JOETZJER *et al.*, 2013). Deste modo, as severas secas que à impactaram nas últimas décadas vêm causando grandes preocupações, como a seca de 2005 que causou grande perda da biomassa florestal, aumento da mortalidade de árvores e declínio em seu crescimento, reduzindo o grande reservatório de carbono a longo prazo (PHILLIPS *et al.*, 2009).

No ano de 2010 ocorreu uma das secas mais severas devido as variações climáticas, impactando principalmente o estado do Pará e extensa área contígua, com índices alarmantes apresentados nos baixos níveis dos rios da região, afetando fortemente a Floresta Amazônica, causando grande perda da capacidade de fotossíntese (LEWIS *et al.*, 2011). Também, pode-se relacionar como agente colaborador para as secas o desmatamento, que contribui para diminuição dos índices pluviométricos, aumento da temperatura e fluxo de umidade relativa do ar (POTTER *et al.*, 2011; XU *et al.*, 2011).

A precipitação em toda a Bacia Hidrográfica Amazônica é caracterizada por um ciclo sazonal acentuado, com variações de baixo nível. Porém, está sendo fortemente ligada a migração sazonal da Zona de Convergência Intertropical com notáveis mudanças nos índices pluviométricos, afetando principalmente as regiões norte e oeste da Bacia Hidrográfica Amazônica (LI *et al.*, 2006; RONCHAIL *et al.*, 2002; TANG; DUBAYAH, 2017; ZHANG *et al.*, 2017). Devido aos impactos locais e regionais das secas decorrentes principalmente das variações climáticas, é de fundamental importância compreender os mecanismos subjacentes às variabilidades da precipitação, temperatura e umidade relativa do ar (LI *et al.*, 2006; MARENGO; ESPINOZA, 2016).

Segundo Gonçalves *et al.* (2016) a precipitação no estado do Pará possui parâmetros que variam muito no tempo e espaço, sendo associados à influência de diferentes sistemas de mesoescala e grande escala. Outras prováveis causas das variações climáticas são as fases extremas do fenômeno El Niño-Oscilação Sul (ENOS) caracterizado por anomalias oceânicas positivas (*El Niño*) e negativas (*La Niña*) de Temperatura da Superfície do Mar (TSM), amplamente associadas a variações climáticas na Bacia Hidrográfica Amazônica (SOPPA *et al.*, 2011), que podem aumentar ou diminuir o regime pluviométrico na região.

Diversos estudos vêm sendo conduzidos para entendimento do comportamento e tendências climáticas, com ênfase no ciclo hidrológico da região a qual se deseja avaliar. Sendo assim, este trabalho buscou analisar as características e variabilidade climática espaço-temporal da Região Hidrográfica do Xingu, no estado do Pará, relacionando ao fenômeno ENOS. Para isso, foram analisados dados históricos considerando um período que compreende de 1980 a 2016 das seguintes variáveis climáticas: precipitação; temperatura; e umidade relativa do ar.

1.1 Problemática

O Brasil está entre os países com maior capacidade para geração de energia elétrica por meio de força hidráulica devido sua potencialidade hídrica. Porém, mesmo frente aos riscos de futuras alterações no ciclo hidrológico, o que diminuiria a disponibilidade de água no sistema de drenagem das barragens, comprometendo a geração de energia elétrica (SOITO; FREITAS, 2011), é previsto que o Brasil continue investindo fortemente em sua capacidade hidrelétrica por ser considerada uma opção viável para operação em menor custo se comparada a outros meios de geração de energia, como as termoelétricas (CUERVO; BOTERO, 2014).

A construção de Usinas Hidrelétricas (UHEs) como Belo Monte, podem trazer grandes impactos na região de sua implantação, sejam ambientais, sociais e econômicos, devido as grandes áreas que necessitam ser inundadas para sua construção (HALL; BRANFORD, 2012), causando perda de biodiversidade, mudança nos níveis de água e cursos naturais dos rios, além do deslocamento da população ribeirinha dependente dos recursos fornecidos pelos rios para sua sobrevivência (RITTER *et al.*, 2017; WESTIN *et al.*, 2014).

Estudos de avaliação e vulnerabilidade climática em regiões de implantação das UHEs são de extrema importância, com ênfase na avaliação do ciclo de água que é diretamente influenciado pelos índices de precipitação, temperatura e umidade relativa do ar, podendo comprometer o desempenho econômico-financeiro do empreendimento, além de causar crise energética devido a insuficiência na geração e fornecimento de energia elétrica (ANDRADE, 2012).

Considerando a contextualização apresentada, avaliando a Região Hidrográfica do Xingu-PA este estudo busca responder as seguintes questões: de que maneira o uso da Geoestatística e séries temporais podem auxiliar na determinação dos indicadores climáticos? Qual a relação da altitude nos índices das variáveis climáticas? A distância entre as estações de monitoramento é satisfatória para estimativa de modelos climáticos confiáveis? As anomalias oceânicas *El Niño* e *La Niña* influenciam nos padrões climáticos da região?

1.2 Justificativa

Seja pelo aumento populacional ou devido aos impactos e intervenções no meio ambiente, as variações climáticas são cada vez mais notórias ao se observar as últimas décadas (IPCC, 2014), refletindo principalmente no ciclo hidrológico que atende diferentes demandas, inclusive para a geração de energia elétrica (HAGUNA *et al.*, 2014; PARKINSON; DJILALI, 2015; SCHAEFFER *et al.*, 2012). Portanto, entender os padrões e tendências climáticas através de estudos sistematizados com dados históricos, é de grande importância para tomada de decisões que possam mitigar os impactos advindos com essas variações (ABBASPOUR *et al.*, 2015), como o uso sustentável dos recursos hídricos.

Este estudo justifica-se devido algumas carências de pesquisas climáticas em algumas localidades do Brasil, como no estado do Pará, em que algumas lacunas acerca de anomalias climáticas devem ser preenchidas, como o conhecimento limitado da influência das anomalias oceânicas *El Niño* e *La Niña* na região (SILVA *et al.*, 2015). Nascimento e Oliveira (2016) completam que algumas regiões necessitam de apropriada rede de Estações Meteorológicas (EMs) para monitoramento do clima, referindo-se a região Norte do Brasil que possui distribuição desigual e rarefeita.

Este estudo também se justifica devido à importância do conhecimento do comportamento de variáveis climáticas (precipitação, temperatura, umidade relativa do ar, pressão atmosférica, direção e velocidade dos ventos, etc.) e suas variações, que podem influenciar fluxos de rios afetando as UHEs (AHMADI *et al.*, 2015; LÓPEZ-MORENO *et al.*, 2014), além de impactar no gerenciamento de recursos hídricos e na economia (agricultura, extrativismo vegetal, agropecuária, etc.) dependente e diretamente influenciada pelas variações climáticas não apenas em escalas regionais, mas também em escalas globais (LOBELL *et al.*, 2011; PARKINSON; DJILALI, 2015).

Sendo assim, a compreensão da forma de atuação de elementos atmosféricos e suas variações ao longo do tempo possibilita a previsão do comportamento climático em determinada região, auxiliando na estimativa do regime pluviométrico para melhor gerenciamento dos recursos, principalmente em regiões com grande dependência do ciclo hidrológico como é o caso do estado do Pará.

Devido a grande contribuição que representa no setor energético do Brasil e a enorme repercussão relacionada aos grandes impactos ambientais e sociais advindos com a construção da UHE Belo Monte no rio Xingu, além da quantidade limitada de estações de monitoramento de elementos climáticos, essa região foi escolhida para análise neste estudo.

1.3 Objetivos

Analisar as características e variabilidade climática espaço-temporal da Região Hidrográfica do Xingu-PA, relacionando ao fenômeno El Niño-Oscilação Sul (ENOS) para o período de 1980 a 2016. Os objetivos específicos deste estudo foram delimitados da seguinte forma:

- Caracterizar os padrões climáticos;
- Descrever a relação altimétrica com as variáveis climáticas;
- Determinar a função densidade de probabilidade das variáveis climáticas;
- Analisar a influência das anomalias oceânicas *El Niño* e *La Niña*;
- Analisar a variabilidade espaço-temporal climática;
- Estimar o comportamento climático.

1.4 Estrutura da pesquisa

Incluindo a Introdução, esta dissertação foi estruturada em cinco capítulos. O Capítulo 2 apresenta a revisão bibliográfica que fundamenta o estudo, expondo o estado da arte referente ao tema pesquisado. O levantamento dos dados, métodos e procedimentos utilizados são apresentados no Capítulo 3. No Capítulo 4 é apresentada a análise e discussão dos resultados com a aplicação de métodos estatísticos. As conclusões da pesquisa são apresentadas no Capítulo 5.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta um panorama da atual situação e variações climáticas identificadas nos últimos anos em um contexto geral e específico na região de estudo, levantando algumas variáveis climáticas que exercem grande influência na economia e na geração de energia elétrica no Brasil.

O estudo de variáveis climáticas é necessário para entendimento do comportamento e mudanças climáticas, possibilitando a previsão e estimativa das variações no clima de determinada região, que estão ligadas e influenciam o setor energético do Brasil, que investe fortemente na geração de energia por meio das UHEs, além de fatores econômicos uma vez que a economia está intimamente relacionada e dependente de fatores climáticos.

2.1 Variáveis climáticas

As variáveis climáticas que definem o estado da atmosfera estão relacionadas ao tempo e espaço, descrevendo suas condições em dado local e instante, como a temperatura, a precipitação, a umidade relativa do ar e todas as suas dependentes (FERNANDEZ, 2007; SAUCIER, 1969). As medições e monitoramento das variáveis são feitas regularmente e em diversas Estações Meteorológicas (EMs) para garantir a confiabilidade das estimativas climáticas.

2.1.1 Temperatura

A temperatura é a grandeza responsável por caracterizar o estado térmico de um sistema, ambiente ou região. Existem três escalas de medição da temperatura adotadas em diferentes países, sendo a escala em Celsius (°C), Fahrenheit (°F) e Kelvin (K). Contudo, a escala utilizada na maioria dos países, inclusive no Brasil, é a escala em Celsius, que tem como ponto de referência a temperatura do congelamento e ebulição da água, que varia de 0 °C a 100 °C (BITENCOURT *et al.*, 2016), podendo ser registrada por diferentes equipamentos, porém, os mais utilizados são os termômetros (máxima e mínima) e os termógrafos.

O termômetro consiste em um tubo fino capilar de vidro com graduação na escala de Celsius (°C) ou Fahrenheit (°F), que pode ser utilizado para medir a temperatura do ar.

Os termômetros podem obter valores imediatos de temperaturas máximas ou mínimas, podendo ser utilizados de forma combinada ou isolada (FERNANDEZ, 2007). A vantagem da utilização de termômetros combinados (máximo e mínimo) é que em uma só medida se obtém a maior e a menor temperatura diária de determinado ambiente. O termômetro de máxima é de mercúrio e sua construção é acima do bulbo, o que impede que a coluna retroceda com a queda de temperatura, permanecendo sempre na maior posição de temperatura registrada, já o termômetro de mínima utiliza álcool em sua construção, onde com a sua concentração pela queda da temperatura é conduzido pelo menisco permanecendo no marco da menor temperatura.

Outro equipamento para medir a temperatura bastante utilizado na meteorologia é o termógrafo, que registra continuamente as variações de temperatura por meio de coeficientes de dilatação diferentes que se deformam com a mudança na temperatura. Essa deformação é expressa graficamente, e o equipamento deve ser posicionado à sombra, em local protegido e ventilado (TUBELIS, 1983).

A tipologia da superfície da região, sua topografia e o ciclo de radiação solar influenciam diretamente a temperatura do ar. De acordo com o tipo de superfície, o ar atmosférico se aquece de maneira mais acelerada ou não, como é o caso das superfícies revestidas por vegetação que elevam a temperatura do ar mais lentamente, uma vez que utilizam da energia solar para evaporação de água e se aquecer (SILVA, R., 2014).

A temperatura do ar atmosférico tende a diminuir com o aumento da latitude, indo em direção aos polos saindo da região do Equador onde a radiação incide mais perpendicular, e com a altitude devido a maior distância entre a superfície da terra aquecida pelo Sol, ou seja, quanto mais longe do nível do mar maior a tendência de queda de temperatura (FERNANDEZ, 2007; TUBELIS, 1983).

A temperatura está intimamente relacionada a umidade relativa do ar, influenciando diretamente em sua saturação, seja em temperaturas mais elevadas onde o ar que está mais quente se expande, podendo aumentar a saturação do ar devido sua capacidade em reter maiores quantidades de vapor de água, ou na mudança da temperatura durante a noite, que atinge valores mínimos e a umidade do ar alcança valores máximos (ANDRADE *et al.*, 2016; TOKAIRIN *et al.*, 2010).

2.1.2 Umidade relativa do ar

Umidade relativa do ar é a quantidade de vapor de água presente na atmosfera, podendo ser sentida tanto na temperatura quanto no regime de chuva, já que altas taxas de umidade presentes no ar influenciam a ocorrência de precipitação, enquanto que regiões com baixas taxas de umidade no ar registram menores ocorrências de chuva (ANDRADE *et al.*, 2016; SILVA, R., 2014), o que torna esta variável um agente de grande relevância em estudos climáticos.

A umidade presente no ar pode fazer temperaturas quentes serem ainda mais quentes, em decorrência do seu calor específico, uma vez que a água presente no ar em forma de vapor colabora para a retenção de calor e tende a conserva-lo por mais tempo (ANDRADE *et al.*, 2016). Deste modo, regiões mais secas possuem maiores diferenças entre temperaturas mínimas e máximas, além de valores mais elevados na pressão atmosférica, uma vez que há menor retenção de calor devido à baixa umidade.

Fatores como a maritimidade influenciam diretamente a quantidade de umidade presente no ar em algumas regiões, como nas áreas litorâneas, em que devido a evaporação elevada das águas marítimas a umidade atmosférica é maior, o que não acontece em regiões continentais, onde o ar é mais seco (BITENCOURT *et al.*, 2016; GONZALEZ *et al.*, 2013; SILVA; MINUZZI, 2016; TOKAIRIN *et al.*, 2010). A movimentação das massas de ar também é responsável pelo transporte da umidade de um local a outro, já que massas de ar com altas taxas de umidade tendem a aumentar a incidência de chuvas, enquanto que massas de ar seco conservam igualmente o ambiente (BITENCOURT *et al.*, 2016; GONZALEZ *et al.*, 2013).

Outro agente de grande influência na umidade presente no ar é a vegetação, como é o caso da Floresta Amazônica, que emite por meio da evapotranspiração uma quantidade significativa de vapor de água na atmosfera, fazendo com que essa região apresente maiores taxas de umidade no ar, influenciando também outras regiões uma vez que o vapor de água é deslocado pelo vento (COELHO *et al.*, 2012; LINDNER *et al.*, 2014; PARTS *et al.*, 2013; SELLIN *et al.*, 2013).

A concentração de vapor de água presente na atmosfera é variável de acordo com a região e embora a concentração represente apenas 2% de toda a massa atmosférica com volume de 4%, é uma variável de extrema importância para determinação do clima (TORRES; MACHADO, 2012). Uma maneira de demonstrar a concentração de vapor de

água presente no ar é por meio da umidade absoluta, que é a quantidade de vapor de água por unidade de volume de ar.

Com o aumento da temperatura o ar se torna mais quente, sua saturação aumenta uma vez que se expande retendo mais vapor de água. Contudo, o ar também pode saturar caso a temperatura diminua, mesmo sem ocorrência do aumento do vapor de água na atmosfera (TORRES; MACHADO, 2012). Neste caso pode haver saturação quando a temperatura do ar muda durante a noite, onde a temperatura mínima ocorre e a umidade relativa do ar alcança valores máximos. Durante a noite a umidade relativa do ar tende a ser maior, ou seja, com o aumento progressivo da temperatura após o nascer do Sol, a umidade da mesma forma inicia sua progressiva queda, alcançando valores mínimos devido a ocorrência de temperaturas máximas, enquanto que com o pôr-do-Sol, com a queda da temperatura para valores mínimos há o aumento da umidade relativa do ar para valores máximos (SELLIN *et al.*, 2013; TORRES; MACHADO, 2012). Portanto, a umidade relativa do ar é tida como inversa à temperatura.

A umidade relativa do ar além de influenciar os índices de precipitação de determinada região, é uma das variáveis mais significativas para análise climática, influenciando diretamente a vida humana (NASCIMENTO *et al.*, 2016), uma vez que climas úmidos são mais propícios a proliferação de bactérias e fungos, aumentando as doenças, além do desconforto térmico e problemas em atividades agropastoris devido ao excesso de umidade no ar, como: colheita; processamento; armazenamento; e conservação dos produtos (TORRES; MACHADO, 2012).

Estudos realizados no Brasil apresentam a relação entre a umidade relativa do ar média com a precipitação total anual, que pode ser observada na Tabela 1 (GONÇALVES *et al.*, 2016; TORRES; MACHADO, 2012), em que, quanto maior o percentual da umidade relativa do ar, maior é o índice de precipitação registrado.

Tabela 1 – Relação entre umidade relativa do ar média e precipitação total anual em diferentes regiões do Brasil

Estados brasileiros	Umidade relativa do ar (%)	Precipitação (mm/ano)
Ceará	70	971
Bahia	72	1203
Mato Grosso	75	1404
Minas Gerais	76	1421
Rio Grande do Sul	77	1555
Pará	80	2000
Amazonas	87	2705

Fonte: Adaptado de Gonçalves *et al.* (2016), Torres e Machado (2012).

2.1.3 Precipitação

A precipitação é a principal conexão de reabastecimento de água, que prevê por meio da condensação a queda da água contida na atmosfera de volta à superfície terrestre, além de ser uma variável de grande relevância em pesquisas relacionadas ao meio ambiente e recursos hídricos, principalmente em regiões semiáridas, onde o desenvolvimento econômico está diretamente ligado e dependente de fenômenos climáticos como a precipitação (GARCIA, 2011), definida como qualquer forma de água (líquida ou sólida) que após condensação na atmosfera (nuvens), cai novamente à terra em forma de chuva, neve, orvalho, geada ou granizo (ZHANG *et al.*, 2017).

As nuvens são resultado de massas de ar elevadas na atmosfera que resfriaram por expansão adiabática, contendo pequenas gotículas de água condensadas que são muito pequenas para precipitarem, mas grandes suficientes para formação de nuvens visíveis, uma vez que a água está constantemente condensando e evaporando na atmosfera (GARCIA, 2011; PAZ, 2004). Desta forma, a precipitação é resultado de condições favoráveis uma vez que haja aumento das gotas de água na atmosfera até seu peso ser maior que as forças que as sustentam. O aumento das gotas de água se dá devido aos chamados núcleos de condensação presentes nas nuvens, que são basicamente sais, partículas orgânicas, cristais de gelo, etc. Essas gotas de água tendem a se condensar sobre tais partículas através de processos físicos, aumentando seu volume que ocorre em parte através do choque entre elas, até atingirem peso suficiente para precipitarem (GARCIA, 2011; ZHANG *et al.*, 2017).

A precipitação possui classificação devido sua respectiva característica de formação, podendo ser orográfica, convectiva e frontal (FERNANDEZ, 2007; GARCIA, 2011).

- **Precipitação orográfica**

A precipitação orográfica ocorre quando uma massa de ar carregada de umidade que se move é forçada a elevar-se ao encontrar uma elevação topográfica (montanha, serra, etc.) ocorrendo a queda da temperatura e posteriormente a condensação do vapor de água formando nuvens, provocando chuvas com características de longa duração, baixa intensidade e pequena extensão (FERNANDEZ, 2007; GARCIA, 2011). Geralmente existem áreas opostas as barreiras topográficas com baixos índices de precipitação chamadas “sombras pluviométricas”.

- **Precipitação convectiva**

A precipitação convectiva é decorrente da movimentação de massas de ar úmida com temperaturas mais elevadas que sobem por ser menos densas, ocorrendo a brusca ascensão dessas massas de ar que em altitudes mais elevadas sofrem um rápido resfriamento, o que gera precipitações intensas cobrindo pequenas áreas e duração rápida, porém de alta intensidade. Geralmente esse fenômeno ocorre em regiões equatoriais e sua causa principal é devido as diferenças de temperaturas próximas da atmosfera (FERNANDEZ, 2007).

- **Precipitação frontal**

A precipitação frontal é decorrente do encontro entre dois tipos de massas distintas de ar (quente e fria), em que a massa de ar quente sofre ascensão, se resfriando ocorrendo a precipitação. Esse tipo de precipitação é caracterizado por apresentar entre baixa e moderada intensidade, por ser contínua e cobrir uma extensa área (FERNANDEZ, 2007; GARCIA, 2011).

Os instrumentos utilizados para medir a precipitação de determinada região são os pluviógrafos e os pluviômetros. De acordo com Fernandez (2007) a medida registrada consiste na determinação da espessura da camada de água que se acumularia na superfície horizontal pela ocorrência da precipitação caso não ocorresse escoamento superficial, evaporação e infiltração.

É importante destacar que dificilmente as quantidades de precipitação registrada mensal, sazonal e anualmente, indicam confiabilidade e regularidade com as quantidades de precipitação esperada (ALEMAN *et al.*, 2016; LEI *et al.*, 2014; MESQUITA *et al.*, 2009). De acordo com Strahler (1997), existe um padrão de distribuição bastante complexo de precipitação sobre o globo, devido alguns fatores como a maritimidade, topografia e massas de ar.

2.2 Variações climáticas e geração de energia elétrica no Brasil

O Brasil possui as maiores reservas de águas superficiais do planeta e uma das maiores fontes de recursos em potencial (SOITO; FREITAS, 2011). Porém, devido as mudanças climáticas não se encontra em situação confortável em termos de disponibilidade de recursos hídricos, que pode ser observada nas secas recorrentes e degradação de rios em todo o país (CUERVO; BOTERO, 2014). As mudanças climáticas

podem alterar a temperatura, a pressão atmosférica, os padrões de vento e o ciclo hidrológico, diminuindo a disponibilidade de água no sistema de drenagem das barragens das UHEs, comprometendo o fornecimento de energia elétrica (SOITO; FREITAS, 2011; WESTIN *et al.*, 2014).

Além de serem consideradas fontes renováveis para geração de energia, as UHEs são uma opção legítima para operação em menor custo comparado a outros tipos de fontes geradoras de energia, como as usinas termoeletricas (CUERVO; BOTERO, 2014). Ainda segundo os mesmos autores, é previsto que o Brasil persista no desenvolvimento de sua capacidade hidrelétrica apesar do potencial decrescente, instabilidade climática e escassez de água identificada no país.

Embora o Brasil esteja entre os países com maior capacidade para geração de energia, o país importa parte da energia consumida de hidrelétricas argentinas (Yacerita e Garabi), além da própria Itaipu, em que parte da energia excedente produzida pertencente ao país vizinho (Paraguai), é vendida ao Brasil. Esse cenário serve como incentivo para propostas e projetos para criação de novas UHEs em território nacional na busca pela autossuficiência (CUERVO; BOTERO, 2014; GOLDEMBERG; MOREIRA, 2005).

A Agência Nacional de Energia Elétrica (ANEEL) listou as dez maiores UHEs em território brasileiro já em funcionamento, sendo: Itaipu (14.000 MW de potência instalada) no estado do Paraná; Belo Monte (11.233,1 MW de potência instalada) no estado do Pará; São Luiz do Tapajós (8.040 MW de potência instalada) no estado do Pará; Tucuruí (8.370 MW de potência instalada) no estado do Pará; Santo Antônio (3.568 MW de potência instalada) no estado de Rondônia; Ilha Solteira (3.444 MW de potência instalada) no estado de São Paulo; Jirau (3.750 MW de potência instalada) no estado de Rondônia; Xingó (3.162 MW de potência instalada) na divisa dos estados de Alagoas e Sergipe; Paulo Afonso IV (2.462 MW de potência instalada) no estado da Bahia; e Jatobá (2.338 MW de potência instalada) no estado do Pará.

Devido ao déficit hídrico registrado no Brasil nos últimos anos, houve grande redução no fornecimento de energia elétrica pelas UHEs, resultando no aumento da utilização de outros meios para geração de energia para suprimento da demanda do país (EPE, 2016; GADELHA, 2013). A energia hidrelétrica está entre os recursos mais afetados pelas variações climáticas, já que depende de fenômenos naturais como o clima e o fluxo de água (AHMADI *et al.*, 2015).

Como pode ser observado na Tabela 2, houve aumento na utilização de fontes de energia não-renováveis para geração de eletricidade doméstica (BERCHIN *et al.*, 2015). A diminuição da oferta hídrica implicou em maior diversificação da base energética e menor utilização das fontes de energia renováveis, que sozinhas não conseguem suprir a demanda de energia apresentando consideráveis reduções no fornecimento pelas UHEs nos últimos anos.

Tabela 2 – Distribuição do fornecimento de energia elétrica doméstica no Brasil

Geração de energia	2010	2011	2012	2013	2014	2015
Hidráulica	74%	81,9%	76,9%	70,6%	65,2%	64%
Biomassa	4,7%	6,6%	6,8%	7,6%	7,3%	8%
Eólica	0,4%	0,5%	0,9%	1,1%	2%	3,5%
Gás natural	6,8%	4,4%	7,9%	11,3%	13%	12,9%
Derivados de petróleo	3,6%	2,5%	3,3%	4,4%	6,9%	4,8%
Nuclear	2,7%	2,7%	2,7%	2,4%	2,5%	2,4%
Carvão e derivados	1,3%	1,4%	1,6%	2,6%	3,2%	4,5%
Importações	6,5%	0%	0%	0%	0%	0%
Total (MWh)	545.100.000	531.800.000	552.500.000	570.000.000	590.500.000	581.500.000

Fonte: Adaptado de Berchin *et al.* (2015).

O clima também é diretamente responsável pela formação de paisagens, influenciando as dinâmicas com impactos na organização dos fatores produtivos e sociais. Portanto, o estudo de vulnerabilidade climática é necessário uma vez que está condicionado ao setor básico da economia, bem como processo de ocupação e uso do espaço urbano (SILVA *et al.*, 2015), com ênfase para as regiões de implantação das fontes de geração e fornecimento de energia elétrica, avaliando o fluxo de água que pode ser impactado pelas variações do clima.

As alterações climáticas como o aumento na temperatura, podem levar a várias modificações no ambiente, entre elas a alteração do ciclo hidrológico, provocando impactos nos recursos hídricos, podendo afetar os padrões de pressão atmosférica, precipitação, umidade do ar e ventos (SENA *et al.*, 2012). Foi registrado aumento de 1-2 mm·ano⁻¹ no nível médio do mar durante todo o século XX, o que pode modificar as áreas de inundações e a influência da água marinha (IPCC, 2014; MESQUITA, 2003; SENA *et al.*, 2012).

Existem regiões no Brasil carentes de estudos climatológicos gerais e se tratando de forma específica, existem algumas lacunas que devem ser preenchidas, como exemplo disso é o conhecimento limitado de ações de fenômenos como *El Niño* e *La Niña* no clima do estado do Pará (SILVA *et al.*, 2015). A ocorrência das anomalias oceânicas *El Niño* e

La Niña tem sido mais frequente, duradoura e grave nos últimos trinta anos em comparação aos últimos cem anos (MOLINIER *et al.*, 2009; RONCHAIL *et al.*, 2002), alterando o clima em escala global, influenciando os padrões de ventos e índices pluviométricos em regiões de latitudes médias e tropicais como é o caso do Brasil (SANTOS *et al.*, 2011; SENA *et al.*, 2012).

2.2.1 Anomalia oceânica *El Niño*

O nome da anomalia *El Niño* tem origem espanhola, dado por pescadores da costa do Equador e Peru, se referindo ao surgimento de correntes marítimas de águas quentes ao longo da costa Norte do país na época do natal, que foi dado em homenagem ao menino (*El Niño*) Jesus. *El Niño* é um fenômeno climático que ocorre devido ao aquecimento anormal das águas superficiais do Pacífico, provocando mudanças nos padrões dos ventos, nos índices pluviométricos e deslocamento de massas de ar quente e úmida.

Algumas análises relacionadas a mudanças severas climáticas foram tratadas por Gonzalez *et al.* (2013), verificando os impactos de eventos incomuns no oceano Pacífico em conjunto ao ENOS na região Nordeste e Norte da América do Sul para avaliação da precipitação no período de 1900 a 2007. Seus resultados apontam que o padrão de precipitação se reforça por meio da configuração do gradiente interbacias no período inicial dos ENOS.

A ocorrência da anomalia *El Niño* também pode ser devastadora para a vida marinha, como apresentado por Kelmo e Attrill (2013) em estudos dos recifes de corais no norte da Bahia. O período de amostragem incluiu o evento de *El Niño* de 1997/1998, considerado um dos mais severos, associado a temperaturas máximas globais de água salgada e longa duração. Em seus resultados são ressaltados que foram necessários treze anos para plena recuperação do conjunto de corais, fato preocupante caso tais eventos sejam mais frequentes no futuro.

Os autores Assad *et al.* (2015) procuraram identificar e quantificar a possível variabilidade interanual e influências da anomalia *El Niño* no Sul do Brasil por meio da implementação de um modelo de circulação global oceânica de baixa resolução. Seus resultados indicam ocorrência de variação interanual nos transportes de volume oceânico meridional em três seções zonais diferentes, também indicando influência de um processo atmosférico em grande escala. O transporte no volume do oceano nas três seções

monitoradas indicaram um potencial domínio de outros processos oceânicos remotos, se observando também um pequeno intervalo de tempo entre as mudanças de transporte de volume meridional integrado em cada seção zonal monitorizada.

Os impactos de *El Niño* no Brasil são variados, pelo fato do país possuir elevada diversidade climática devido as dimensões continentais (MARENGO, 2007). Alguns estudos apontam as principais consequências para o Brasil, como: seca no Sul e aumento da temperatura no Sudeste, além de verão e inverno com menores índices de precipitação no Norte e Nordeste do país (Figura 1-A e B) (BRITTO *et al.*, 2008; CAVALCANTI, 1996; DINIZ, 1998; MELO, 1999; OLIVEIRA, 1999).

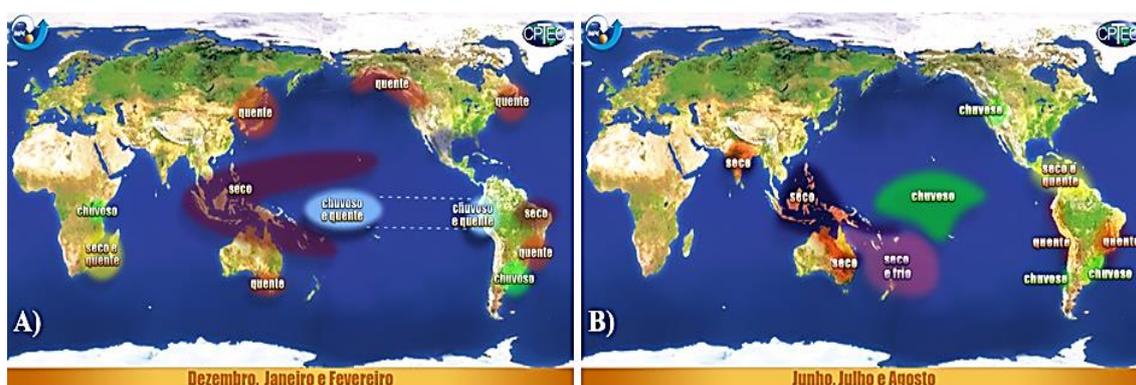


Figura 1 – Efeito global da anomalia oceânica *El Niño* no verão (A) e inverno (B)

Fonte: CPTEC/INPE (2017).

2.2.2 Anomalia oceânica *La Niña*

A terminologia *La Niña* vem do espanhol e significa “a menina”. *La Niña* é a anomalia caracterizada pelo resfriamento nas águas superficiais oceânicas (Pacífico Equatorial). *La Niña* intensifica os ventos alísios de leste a oeste na faixa equatorial, fazendo com que uma quantidade anormal de águas quentes seja acumulada no oceano Pacífico Equatorial Oeste, enquanto que em seu oposto (Pacífico Leste) se encontram águas mais frias, o que causa aumento no desnível do mar entre Pacífico Ocidental e Oriental.

Conforme Boening *et al.* (2012) os níveis do oceano Pacífico caíram entre março de 2010 e maio de 2011 sob condições de *La Niña*, onde as águas superficiais mais frias no leste do oceano Pacífico Equatorial contribuíram para precipitações mais intensas. Utilizando dados de satélites, os autores mostram que o declínio da massa do oceano coincide com o aumento equivalente no armazenamento de água terrestre, e essa mudança temporária das águas está relacionada com a transição das condições do *El Niño* de

2009/2010 para o forte *La Niña* de 2010/2011, que afetou os padrões de precipitação em todo o mundo. Segundo os mesmos autores, a anomalia vem aumentando o nível médio global do mar em cerca de 3 mm por ano durante grande parte dos últimos 18 anos.

Os autores Evans e Boyer-Souchet (2012) examinaram o papel desempenhado pelas altas temperaturas da superfície do mar em torno do Norte da Austrália na produção da grande quantidade de precipitação ocorrente durante o forte *La Niña* de 2010/2011. Utilizando simulações de modelos climáticos regionais, quantificados à contribuição das temperaturas observadas da superfície do mar, foi possível verificar que a presença de altas temperaturas da superfície do mar em torno do Norte da Austrália adicionou cerca de 25% do total de precipitação. As quantidades extremas de precipitação não puderam ser reproduzidas utilizando apenas as condições de *La Niña* em grande escala, sugerindo que também outros parâmetros devam ser observados.

Os estudos de Lim *et al.* (2016) conduzidos por uma série de experimentos de sensibilidade de previsão, tiveram como objetivo diagnosticar o impacto da variação da TSM dos últimos 50 anos na circulação extratropical anômala da precipitação do hemisfério Sul, na região da Austrália. Seus resultados destacam que, quer se desenvolva naturalmente ou forçada pela mudança climática antropogênica, a tendência da TSM pode desempenhar um papel importante na amplificação de condições extremas causadas pela variabilidade climática interanual.

Em estudos feitos no Brasil por Rodrigues e McPhaden (2014), foi observado que durante os eventos de *La Niña*, a precipitação sobre o Nordeste brasileiro é geralmente acima da média. Porém, durante o evento de *La Niña* de 2011/2012 a região passou por sua pior seca dos últimos 30 anos. Seus resultados mostram que a seca no Nordeste brasileiro associada a anomalia *La Niña* foi devido ao resfriamento concentrado do Pacífico Central que causou o gradiente meridional oposto à TSM no Atlântico Tropical. O evento de 2011/2012 foi o último desse tipo.

Estudos das consequências para o Brasil sob efeito de *La Niña* apontam as seguintes condições: inverno com seca na região Sul, queda nas temperaturas da região Sudeste e verão com maior precipitação no Norte e Nordeste do país (Figura 2-A e B) (BRITTO *et al.*, 2008; CAVALCANTI, 1996; DINIZ, 1998; MELO, 1999; OLIVEIRA, 1999).

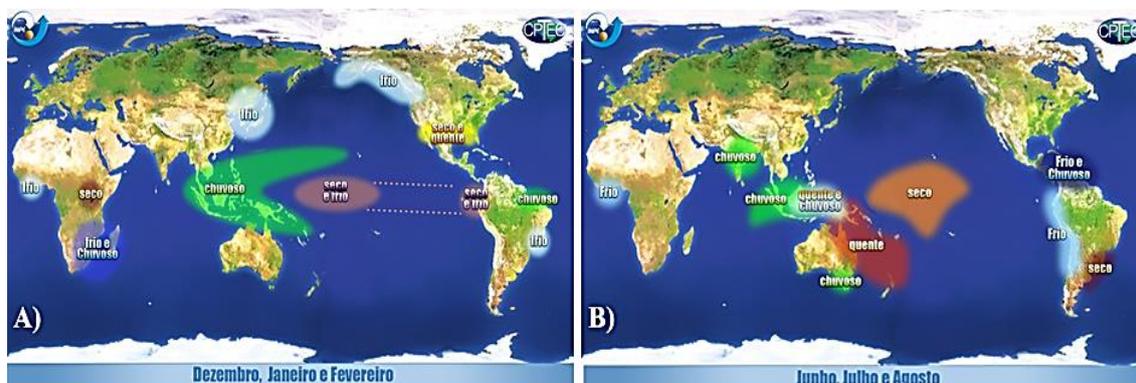


Figura 2 – Efeito global da anomalia oceânica *La Niña* no verão (A) e inverno (B)

Fonte: CPTEC/INPE (2017).

2.3 Caracterização da região Norte do Brasil

A região Norte é constituída por sete estados brasileiros, sendo eles: Acre, Amapá, Amazonas, Pará, Rondônia, Roraima e Tocantins. A região possui a maior área territorial do país com 3.853.676.948 km², que representa aproximadamente 42% do território total do Brasil, agregando dois dos maiores estados brasileiros, o Amazonas e o Pará. Embora a região seja a maior do Brasil, segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2010a) é a menos povoada, possuindo 15.864.454 habitantes. Contudo, grande parte da região Norte não é modelada pelos padrões demográficos convencionais, como é o caso de algumas ocupações indígenas e populações tradicionais ribeirinhas (BARBOSA *et al.*, 2012; DIAS, 2009).

A região Norte possui duas das grandes bacias hidrográficas, sendo a Bacia Amazônica que é a maior do mundo, formada pelo rio Amazonas contendo mais de mil afluentes, também presente em território internacional como Bolívia, Colômbia, Peru e Venezuela, composta por um sistema complexo de rios, córregos, ribeirões e outros cursos d'água que convergem ao rio Amazonas (ARGENTO, 2007; SILVA, P., 2014) e a Bacia do Tocantins, a maior inteiramente brasileira, constituída pelo rio Tocantins e seus afluentes.

Como pode ser observado na Figura 3, na delimitação da região Norte do Brasil estão destacados alguns dos principais rios da região, sendo eles: Amazonas, Tocantins, Xingu, Iriiri, Tapajós, Madeira, Solimões, Negro, Branco, Trombetas e Jari.



Figura 3 – Delimitação da região Norte do Brasil e seus principais rios

Fonte: Adaptado de IBGE (2010b).

A região Norte possui clima predominante equatorial úmido, tipificado pelas altas temperaturas e chuvas recorrentes durante todo o ano (FREITAS, 2017; LINTNER *et al.*, 2017). Contudo, algumas áreas se diferem em tais características climáticas como é o caso do estado do Tocantins e algumas áreas do estado do Pará e Roraima, que possuem clima tropical e equatorial semiúmido, respectivamente.

Embora a Floresta Amazônica possua homogeneidade em sua aparência, existem distinções quanto a formação de sua vegetação, variando de acordo com a topografia, sendo classificada em: Mata de Várzea; Mata de Igapó; Mata de terra semiúmida; e Mata de terra firme (ANDERSON *et al.*, 2005; FREITAS, 2017; GATTI *et al.*, 2014).

A Amazônia desempenha um papel de suma importância na regulação dos ciclos de carbono e hidrológico tropical (FU *et al.*, 1999; MORLEY, 2000). Atividades humanas ao longo dos anos vêm causando sérios danos ao ecossistema da Amazônia, por meio de desmatamentos, desenvolvimento agrícola, desenvolvimento industrial e exploração de recursos. Alguns estudos apontam sobre a transformação da região em pastagens e terras agrícolas, destacando que dependendo do tamanho da área perturbada, essa conversão modificaria o clima em escalas globais (COOK *et al.*, 2012; GONÇALVES *et al.*, 2016).

Os reflexos da desordem do ecossistema podem ser observados no clima, uma vez que a floresta desempenha um papel de extrema importância nos elementos climáticos,

causando preocupações acerca de suas perspectivas futuras, que segundo Joetzjer *et al.* (2013), as projeções do modelo de geração atual permanecem incertas quanto ao futuro clima amazônico.

2.3.1 Panorama do estado do Pará

Localizado no centro leste da região Norte do Brasil, o estado do Pará possui área territorial de aproximadamente 1.248.042,515 km² (GOVERNO DO PARÁ, 2010) e três aspectos de relevos distintos: planalto Norte-Amazônico; planície Amazônica; e planalto Sul-Amazônico. O clima úmido e de floresta tropical é característico em quase toda a região, com exceção de algumas áreas onde existem formações de pastagens nas proximidades do rio Trombetas e Arquipélago de Marajó (GOVERNO DO PARÁ, 2010).

A vegetação predominante em todo território do estado do Pará é constituída pela Floresta Amazônica, porém, em algumas regiões apresenta composição vegetal diferente. Tendo grande variedade vegetativa, as principais composições de cobertura vegetal da região dão origem a cinco tipos específicos de vegetação: Mata da terra firme (caracterizada por não sofrer inundações); Mata de Várzea (caracterizada por sofrer inundações uma vez que se localizam às margens de rios); Mangue (localizadas nas porções litorâneas); Cerrados; e Campos (FILGUEIRAS; SANTOS, 2007).

Conforme descrito por Gonçalves *et al.* (2016), o estado do Pará está localizado na zona equatorial, onde o clima é predominantemente quente e úmido, com ventos constantes e registros de altos índices pluviométricos com média anual aproximada de 2.000 mm. A temperatura anual é variante entre 24 e 26 °C, com umidade relativa do ar média em aproximadamente 80% (GONÇALVES *et al.*, 2016). Nas proximidades do Arquipélago do Marajó estão concentradas as áreas mais úmidas do estado, enquanto as áreas mais secas estão localizadas nas regiões do Baixo Amazonas.

De acordo com dados do IBGE (2010b), o estado do Pará é formado por 144 municípios que são agrupados e subdivididos de acordo com suas características similares socioeconômicas e geográficas. Por meio de divisões sucessivas pelo processo analítico, foram feitas as identificações às escalas regionais criando as mesorregiões: Baixo Amazonas; Marajó; Metropolitana de Belém; Nordeste Paraense; Sudeste Paraense; e Sudoeste Paraense.

No estado do Pará encontram-se alguns dos mais importantes afluentes do rio Amazonas, à sua margem esquerda estão os rios Curuá, Jari, Maicuru, Nhamundá, Paru e Trombetas, já à direita estão os rios Tapajós e Xingu. Existem rios que não são afluentes do rio Amazonas, porém, são de grande importância e contribuem para formação do complexo hidrográfico do Pará, além de influenciar na vida de milhares de pessoas (ribeirinhos) no transporte e pesca (BARBOSA *et al.*, 2012; DIAS, 2009), podendo-se mencionar os rios: Araguaia; Capim; Guamá; Gurupi; Itacaiúnas; Maracanã; Marajó; Marapanim; e Moju.

Baseando-se na delimitação e codificação descrita por Pfafstetter (1989), conforme descrito na Resolução nº 04 do Conselho Estadual de Recursos Hídricos de 2008, realizou-se a divisão e delimitação das regiões hidrográficas do estado do Pará, objetivando subsidiar o Sistema Nacional de Gerenciamento de Recursos Hídricos (SINGREH) em território nacional (CNRH, 2012). Dessa forma, o estado do Pará foi dividido em sete regiões hidrográficas, levando em consideração características geológicas, geomorfológicas, hidrográficas, fatores hidroclimáticos, solos, cobertura vegetal entre outros, sendo elas: Calha Norte, Tapajós, Baixo Amazonas, Xingu, Portel-Marajó, Tocantins-Araguaia e Costa Atlântica-Nordeste.

Em relação aos grupos de municípios que compõem cada região hidrográfica do estado do Pará, foram levadas em consideração algumas características para sua delimitação, como: limites geográficos das regiões coincidentes com divisores de água das bacias da região analisada; as regiões possuem homogeneidade em aspectos geofisiográficos; questões políticas como histórico de ocupação; e semelhança no desenvolvimento econômico.

Devido a potencialidade hídrica do Pará, o estado foi escolhido para a construção de algumas UHEs ao longo dos anos, podendo ser citadas: Belo Monte, Cachoeira do Caí, Cachoeira dos Patos, Curuá-Uma, Jamanxim, Jatobá, São Luiz do Tapajós, etc. Localizada na mesorregião Sudoeste Paraense, na Região Hidrográfica do Xingu, ainda em fase de construção, está a UHE Belo Monte no rio Xingu, nas proximidades da cidade de Altamira.

A UHE Belo Monte é um ponto chave para elaboração deste estudo, uma vez que com a sua construção, na criação de barragens e represamento de parte das águas do rio Xingu, vários impactos podem ser observados tanto à jusante quanto à montante (FEARNSIDE, 2016; RICHTER *et al.*, 2010), influenciando não só o ecossistema local,

mas também as perspectivas socioeconômicas da região (SOUSA JÚNIOR; REID, 2010). Os principais impactos decorrentes da construção da UHE Belo Monte serão discutidos mais adiante.

2.3.2 Usina Hidrelétrica Belo Monte

A construção da UHE Belo Monte foi idealizada no governo militar em 1975, sendo inicialmente chamado de Usina Kararaô (ELETROBRÁS, 2009). O projeto inicial era ainda mais ambicioso em comparação ao projeto atual, possuindo um total de seis barragens entre os rios Iriri e Xingu com potência instalada de 20.000 MW, maior que a UHE Itaipu considerada a segunda maior do mundo. O projeto inicial negligenciava várias questões ambientais, causando desde sua concepção inúmeros conflitos de natureza social e ambiental (FLEURY; ALMEIDA, 2013).

A UHE Belo Monte está localizada ao norte do estado do Pará, próxima a cidade de Altamira, tendo início de sua construção em 2011, com 11.233,1 MW de potência instalada, que é suficiente para abastecer uma população com mais de 18 milhões de pessoas (ELETROBRÁS, 2009). A construção se destaca pelas inúmeras discussões e conflitos de ordem econômica, política, sociológica e ambiental devido a extensão de seu projeto (ARAUJO *et al.*, 2014; CALILI *et al.*, 2014; LEITE *et al.*, 2013).

A UHE Belo Monte possui alagamento de 516 km², sendo que 382 km² da área alagada é no reservatório do Xingu e 134 km² no reservatório dos canais (EPE, 2011). Contudo, deve produzir anualmente cerca de 4.500 MW por operar com reservatório muito reduzido. Devido sua capacidade em potência instalada, a UHE Belo Monte fica atrás apenas da UHE Três Gargantas (chinesa) que possui 20.300 MW de potência instalada e da UHE Itaipu (brasileira/paraguaia) que possui 14.000 MW de potência instalada, tornando a UHE Belo Monte a maior hidrelétrica inteiramente brasileira e a terceira do mundo (BERCHIN *et al.*, 2015; IPEA, 2013).

O projeto de construção da UHE Belo Monte envolve a criação de três sítios distintos, sendo eles: Pimental (onde fica a casa de força auxiliar); Belo Monte (onde fica a casa de força principal); e Bela Vista (contendo um vertedouro complementar) (NORTE ENERGIA, 2011). O projeto se diferencia das demais usinas uma vez que arranjos envolvendo canais de derivação são mais utilizados em pequenas centrais hidrelétricas, onde geralmente as grandes hidrelétricas associam a casa de força e vertedouro lado a

lado, no mesmo local de barramento do rio (RIBEIRO; BASSANI, 2011; STICKLER *et al.*, 2013).

As alterações no projeto original em 2009 não foram apenas para mitigar impactos ambientais, mas para proporcionar um forte processo de planejamento para a construção do reservatório e desenvolvimento econômico da região (BRATMAN, 2014; CASTRO *et al.*, 2011; TUNDISI *et al.*, 2015). A principal alteração diz respeito ao alagamento, que antes era de 1.225 km² e contemplava terras indígenas, passando para 516 km² prevendo também um vertedouro complementar no sítio Bela Vista (NORTE ENERGIA, 2009). Contudo, embora o projeto original tenha sido alterado, a construção provocou grandes mudanças na geografia da região, como pode ser observado na Figura 4 (A – B) que apresenta o projeto original de estudos realizados entre 1980 a 1990 que inundava terras indígenas e o projeto aprovado e em execução desde 2011.

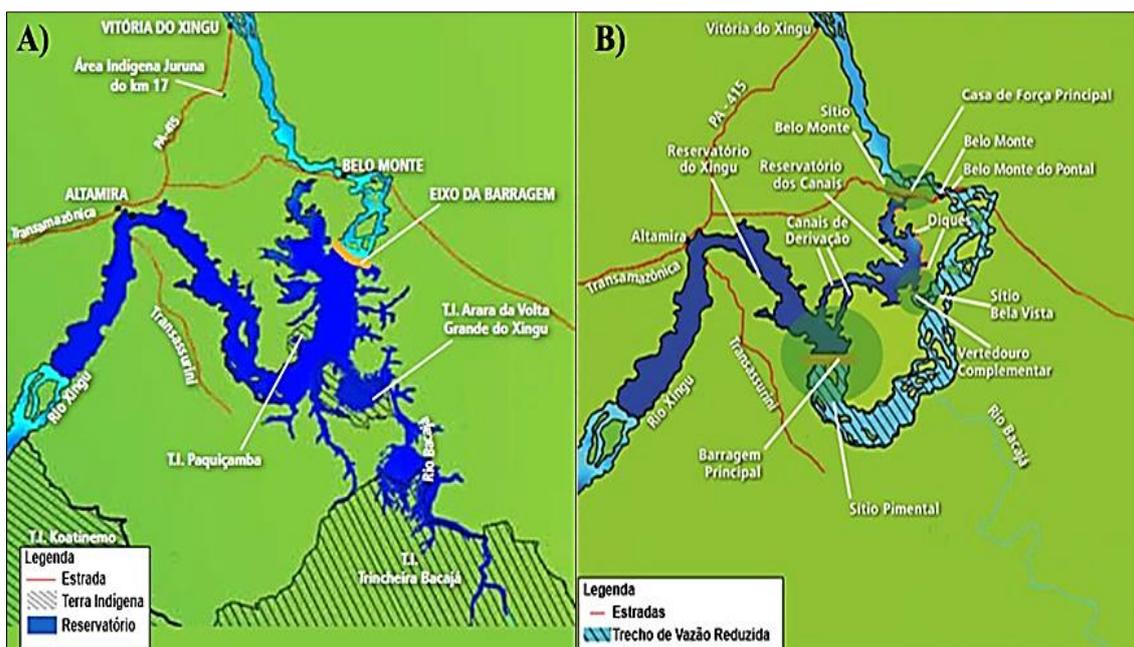


Figura 4 – Projeto da Usina Hidrelétrica Belo Monte no período de 1980 a 1990 (A) e projeto atualizado e em execução desde 2011 (B)

Fonte: Aproveitamento Hidrelétrico Belo Monte – RIMA (NORTE ENERGIA, 2009).

Outro fator importante a ser mencionado sobre o projeto da UHE Belo Monte é em relação ao valor de sua construção, que foi orçado inicialmente em R\$ 16 bilhões, posteriormente foi leilado por R\$ 19 bilhões e financiada por R\$ 28 bilhões, hoje já supera à marca dos R\$ 30 bilhões, podendo aumentar ainda mais até sua conclusão prevista para 2019 (BERCHIN *et al.*, 2015; PEREIRA, 2013).

Segundo Santos e Mello (2014) é esperado que haja alteração definitiva no modo de vida de Altamira e das cidades da região que podem dobrar sua população, devido a construção da UHE Belo Monte que ainda convive com carência de infraestrutura, sendo também considerado um ambiente com conflitos gerados por ocupações irregulares territoriais, exploração ilegal de madeira e grilagem de terras, além dos impactos devido as mudanças geográficas e novas possibilidades para exploração de recursos naturais em larga escala na região da Amazônia, que podem explicar as variações climáticas na região (IPCC, 2014), impactando diretamente na diminuição dos recursos hídricos que são fundamentais para geração de energia (HAGUNA *et al.*, 2014; PARKINSON; DJILALI, 2015; SCHAEFFER *et al.*, 2012).

2.3.3 Principais impactos com a construção da Usina Hidrelétrica Belo Monte

Atualmente, a solução energética para países subdesenvolvidos e emergentes como o Brasil é encontrada nas UHEs, que atendem aproximadamente 80% da necessidade total do país, uma vez que possui grandes corpos hídricos que ajudam a diminuir a dependência energética das fontes de combustíveis fósseis e importados, além de ser uma energia limpa e uma importante contribuição para o desenvolvimento do país (BERCHIN *et al.*, 2015).

Sem um planejamento cuidadoso, a criação de uma usina pode trazer grandes impactos não apenas ambientais, mas também sociais, devido as grandes áreas que precisam ser inundadas para sua implantação, causando perda da biodiversidade, deslocamento da população ribeirinha e mudança nos níveis de água e curso natural dos rios (SOUSA JÚNIOR; REID, 2010). Esses compromissos ambientais e sociais muitas vezes não são incorporados nos cálculos do projeto, como foi o caso de Belo Monte, onde oposições a este e outros projetos de barragens tem sido expresso em termos econômicos, ambientais e sociais (HALL; BRANFORD, 2012; WESTIN *et al.*, 2014).

Segundo Ritter *et al.* (2017) é importante observar que o processo para geração de energia pelas UHEs contribui para o aquecimento global, já que grandes quantidades de metano são produzidas quando os rios são transformados em lagos com baixa taxa do fluxo de água. Os mesmos autores concluem que existem efeitos indiretos adicionais, como o desmatamento em áreas em torno do projeto devido ao aumento populacional,

além da redução do volume de água também afetar a composição fluvial e da flora, que implica em impactos significativos sobre várias espécies de animais.

Segundo Jaichand e Sampaio (2013), a análise de como a construção da UHE Belo Monte afetaria os povos indígenas e como o governo consequentemente tem conduzido é revelador, onde a maioria dos conflitos sobre terra é complexo e requer um tratamento com mais sensibilidade e justiça. Ainda segundo os mesmos autores, o governo priva os povos indígenas ao valor mínimo de controle que deveriam ter em resultado de sua autodeterminação, os levando à restrição de propriedades, ameaçando diretamente o direito à vida, substituindo seu direito de viver de maneira diferente do resto da sociedade.

Observa-se na Figura 5 a localização das terras indígenas (declaradas, regularizadas e em estudo/restrrição) afetadas direta e indiretamente pela construção da UHE Belo Monte.



Figura 5 – Terras indígenas afetadas direta e indiretamente pela Usina Hidrelétrica Belo Monte

Fonte: Aproveitamento Hidrelétrico Belo Monte – RIMA (NORTE ENERGIA, 2009).

Para Fearnside (2016) e Richter *et al.* (2010), os impactos causados após a construção das barragens das usinas são bem maiores do que só os considerados na área inundada diretamente pelo reservatório, como os impactos à jusante (direção da correnteza da água na direção de sua foz rumo ao mar) e à montante (direção da nascente ou lado mais alto) que são amplamente ignorados.

- **Impactos à jusante**

A construção de Belo Monte não impacta apenas a qualidade de vida dos habitantes da região que se alimentam dos recursos fornecidos e utilizam o rio Xingu como meio de transporte, mas também existem consideráveis danos ambientais (SOUSA JÚNIOR; REID, 2010). Segundo dados da Eletrobrás (2009), o governo brasileiro não concede os mesmos direitos de consultas para as famílias (sejam indígenas ou não) que vivem à jusante em comparação com aquelas que tem a área diretamente inundada pelo reservatório, uma vez que não são consideradas impactadas diretamente.

Logo abaixo de Belo Monte existe uma área denominada “trecho seco”, que recebe esse nome pelo fato da represa desviar 80% da água por meio de uma série de canais que só retorna ao rio cerca de 100 km à jusante. Deste modo, o então chamado “trecho seco” tem diminuição do seu fluxo de água, impossibilitando a pesca aos povos indígenas residentes ao longo do trecho do rio e de outros moradores ribeirinhos, além de afetar o transporte pelo rio (FEARNSIDE, 2016; SOUSA JÚNIOR; REID, 2010).

A água segue quase sem oxigênio após sua passagem pelas turbinas e percorre longas distâncias sem repor os níveis de oxigênio necessários que seriam encontrados no curso natural do rio, matando a vida aquática (FEARNSIDE, 2002; KEMENES *et al.*, 2007), tornando dramática a subsistência das famílias residentes à jusante. Tais impactos são ignorados e não há compensação nas barragens já construídas que impedem as inundações naturais dos rios amazônicos, prejudicando até a agricultura local, que é dependente de grandes quantidades de água (cheias dos rios), dos sedimentos depositados no solo advindos com as cheias que servem como adubo natural e renovação da fertilidade do solo (FEARNSIDE, 2002; KEMENES *et al.*, 2007).

- **Impactos à montante**

Diferentes espécies de peixes são bloqueadas pelas barragens, impedidas de fazer a migração, subindo os afluentes para procriação na época das cheias do rio (CARVALHO; FABRÉ, 2006; QUEIROZ *et al.*, 2013). Após o nascimento, os alevinos com a ajuda da corrente do rio descem os afluentes e se desenvolvem até sua idade adulta, repetindo o ciclo e garantindo renovação dos recursos e equilíbrio do ecossistema. Porém, segundo Fearnside (2014) não é possível manter a migração dos peixes pelas passagens nas barragens rumo as cabeceiras do rio, tão pouco a prevenção da mortalidade dos alevinos descendo suas águas, havendo grande diminuição dos indivíduos de algumas espécies, podendo levar até mesmo a sua extinção.

Outro impacto importante à montante a ser citado é o aumento dos níveis do rio após entrada do mesmo em um reservatório em sua ponta à montante, onde sua velocidade diminui significativamente fazendo com que o fluxo de água se torne mais lento, desta forma os sedimentos contidos na água com partículas maiores como a areia caem até o fundo do reservatório, já os sedimentos mais finos ficam na extremidade inferior perto da barragem do reservatório (VAUCHEL, 2014). Ainda segundo o mesmo autor, esse acúmulo de sedimentos faz o papel de uma segunda barragem, preenchendo considerada parte do reservatório resultando em aumento no nível da água que pode causar inundações nos trechos do remanso superior.

É apresentado o mapa com as delimitações das áreas de influência direta e indireta da UHE Belo Monte (Figura 6) conforme apresentado no Relatório de Impacto Ambiental (RIMA) (ELETROBRÁS, 2009).



Figura 6 – Áreas de influência direta e indireta da construção da Usina Hidrelétrica Belo Monte

Fonte: Aproveitamento Hidrelétrico Belo Monte – RIMA (NORTE ENERGIA, 2009).

Existem grandes incertezas sobre a viabilidade técnica e econômica do projeto, necessitando de uma nova abordagem por parte do governo (CALIXTO, 2011). Segundo Barreto *et al.* (2011) a UHE Belo Monte poderia levar ao desmatamento mais de 5.100 km² de floresta tropical em um período de 20 anos, ou seja, dez vezes o tamanho da área de alagamento da barragem.

De acordo com estudos apresentados por Hall e Branford (2012), para ser um projeto financeiramente viável, novas barragens teriam que ser construídas à montante para estabilizar o abastecimento de água e para a produção de eletricidade devido ao aumento do risco de seca na Amazônia, que poderia comprometer a capacidade de geração de energia de Belo Monte tornando o esquema não econômico.

2.4 Economia e variações climáticas

Devido à grande extensão do território brasileiro, existem várias alternativas se referindo aos tipos de atividades econômicas que podem ser desenvolvidas no país, podendo mencionar desde a exploração das riquezas minerais até atividades que são predominantes em todo território brasileiro como a agricultura e pecuária (LIMA, 2002).

O Brasil desenvolveu atividades baseadas nos três setores da produção, sendo: setor primário (produção baseada na exploração dos recursos naturais, como agricultura, pecuária, mineração, extrativismo vegetal, pesca, caça, etc.); setor secundário (transformação das matérias-primas, dando origem a produtos acabados como roupas, máquinas, eletrônicos, automóveis, casas, etc.); e setor terciário (relacionado a prestação de serviços a terceiros, como comércio, saúde, educação, telecomunicação, serviços de limpeza, etc.).

Um dos fatores que solidifica a economia do Brasil é a grande variedade de produtos que são exportados para outros países, fortalecendo a economia (ALMEIDA; GUILHOTO, 2007). Dentre os produtos exportados pelo Brasil, se pode apontar como os principais os seguintes: aço; cana-de-açúcar; minério de ferro; soja e seus derivados; carne bovina e derivados; carne de frango; café; e madeira.

Conforme apresentado na Tabela 3, cada região do Brasil apresenta suas respectivas características referindo-se ao tipo de atividade econômica praticada. Grande parte das atividades econômicas do país estão condicionadas a fatores agrícolas, agropecuária e extrativismo vegetal, dependendo e sendo influenciadas diretamente pela variabilidade dos elementos climáticos, como pluviosidade, temperatura, umidade relativa do ar, radiação solar, etc. (LIMA, 2002). Ainda segundo o mesmo autor, as variações no clima causam graves efeitos sobre a agricultura, incidindo na produção e manejo das culturas, no controle de pragas, na irrigação, no armazenamento e no controle de doenças.

Tabela 3 – Principais atividades econômicas praticadas no Brasil

Regiões do Brasil	Atividades econômicas
Norte	A economia da região baseia-se principalmente na agropecuária e no extrativismo vegetal de produtos como madeira, látex, açaí e castanha. O extrativismo animal e mineração também são muito fortes na região, principalmente extração de ferro, cobre e ouro.
Nordeste	A economia dessa região é bem diversificada, o turismo é muito forte, agronegócio e exploração de petróleo. A cana-de-açúcar é o principal produto agrícola da região.
Centro-Oeste	A economia gira em torno da agropecuária (plantações de soja, milho, entre outros), pecuária bovina e indústrias.
Sudeste	Apresenta o maior parque industrial do Brasil, com as maiores montadoras e siderúrgicas do país. Os serviços e o comércio são diversificados, além de representar a principal atividade econômica da região.
Sul	A maior parte das riquezas provém do setor de serviços e o ramo industrial é representado principalmente pelos setores metalúrgico, automobilístico, têxtil e alimentício. A agropecuária é bem forte na região.

Fonte: Adaptado de Domingues *et al.* (2011), Guilhoto e Sesso (2005).

Diversos estudos vêm sendo conduzidos em escala global na tentativa de estimar os possíveis impactos ocasionados devido as variações climáticas sobre as produções agrícolas baseadas em Modelos de Circulação Geral (MCG), onde são apresentados que a produção nas áreas subtropicais e tropicais, principalmente na África Negra devido a predominância de áreas com climas árido, semiárido e sua dependência com a agricultura, seriam mais afetados que as regiões temperadas (JONES *et al.*, 1987 *apud* LIMA, 2002).

Conforme descrito por Margulis *et al.* (2010) as regiões do Brasil com maior vulnerabilidade às mudanças do clima são as regiões Nordeste e Norte. De acordo com suas previsões, a temperatura na Amazônia aumentaria 8 °C até 2100, resultando na retração da Floresta Amazônica em até 40% em sua região sul, sudeste e leste, havendo substituição pelo bioma Savana, influenciando os índices de precipitação local. Já na região Nordeste, haveria diminuição das chuvas em até 2,5 mm-dia⁻¹ para o mesmo período, causando enormes perdas na agricultura em toda a região, além da redução da capacidade pecuária devido ao déficit hídrico, favorecendo o retrocesso à pecuária de baixo rendimento, impactando diretamente a economia do país, além de afetar a geração de energia elétrica através das UHEs que teriam redução em suas vazões de até 90% entre os anos de 2070 e 2100 (MARGULIS *et al.*, 2010).

A maioria das empresas brasileiras realizam suas atividades sem contemplar os impactos relacionados às alterações climáticas (ANDRADE, 2012). Esse fato fica evidenciado ao se observar os relatórios das empresas que atuam no segmento de geração

e fornecimento de energia, que não contemplam estratégias frente aos riscos que essas variações climáticas podem trazer para o desempenho econômico-financeiro do empreendimento, que além de causar crise energética devido a insuficiência na geração de energia causada pelo déficit dos recursos hídricos, afeta também outros setores dependentes, impactando diretamente na economia do país.

3 MATERIAIS E MÉTODOS

O presente capítulo apresenta a região de estudo e descreve os dados utilizados. Expõe as metodologias e delimita as EMs usadas para caracterizar o clima da região em estudo, além de relacionar os procedimentos estatísticos e *softwares* utilizados, bem como as configurações do modelo. Este estudo consiste em uma pesquisa quantitativa, aplicada e exploratória, ou seja, gera conhecimento por meio de testes e teorias, visando o entendimento do comportamento e variações no ambiente através de análises e procedimentos estatísticos (MIGUEL *et al.*, 2012).

3.1 Área de estudo e dados utilizados

A região de estudo compreende as áreas de influência direta e indireta da UHE Belo Monte, que contempla um trecho da Região Hidrográfica do Xingu-PA e apresenta desde sua concepção vários impactos sociais e ambientais na região (NORTE ENERGIA, 2009), analisando as variações climáticas e correlacionando-as ao fenômeno climático ENOS. Contudo, levando em consideração características geológicas, geomorfológicas, hidrográficas, fatores hidroclimáticos, solos e para maior abrangência da análise, foi contemplada toda a Região Hidrográfica do Xingu-PA para estudo, conforme divisão hidrográfica apresentada na Figura 7.



Figura 7 – Divisão hidrográfica do estado do Pará

Fonte: Lima *et al.* (2012).

Para determinar a intensidade do ENOS foi utilizado o Índice Oceânico Niño (ION). O ION é um índice identificador das anomalias superficiais do oceano Pacífico por meio da média móvel a cada três meses, em que IONs com intensidade maior que 0,5 °C por no mínimo cinco períodos consecutivos são caracterizados por *El Niño*, enquanto que IONs com intensidade menor que -0,5 °C pela média móvel a cada três meses por no mínimo cinco períodos consecutivos como *La Niña* (MARCUIZZO; ROMERO, 2013). A classificação da intensidade dos IONs pode ser observada pela Tabela 4.

Tabela 4 – Classificação da intensidade do Índice Oceânico Niño

Eventos	Índice Oceânico (°C)	Intensidade
<i>El Niño</i>	0,5 a 0,9	Fraco
	1,0 a 1,4	Moderado
	$\geq 1,5$	Forte
<i>La Niña</i>	-0,5 a -0,9	Fraco
	-1,0 a -1,4	Moderado
	$\leq -1,5$	Forte

Fonte: Marcuzzo e Romero (2013).

Dentre as regiões de monitoramento com base na TSM (*Niño 1+2*, *Niño 3*, *Niño 3.4* e *Niño 4*), o *National Oceanic and Atmospheric Administration* (NOAA) utiliza a região de monitoramento *Niño 3.4* (5°N -5°S, 120° -170°W, sobre o Pacífico Equatorial Tropical) para aferir as anomalias de temperatura e caracterizar os períodos com base no ION (Figura 8), ao qual melhor se relaciona com as manifestações de *El Niño* e *La Niña* (HUANG *et al.*, 2017).

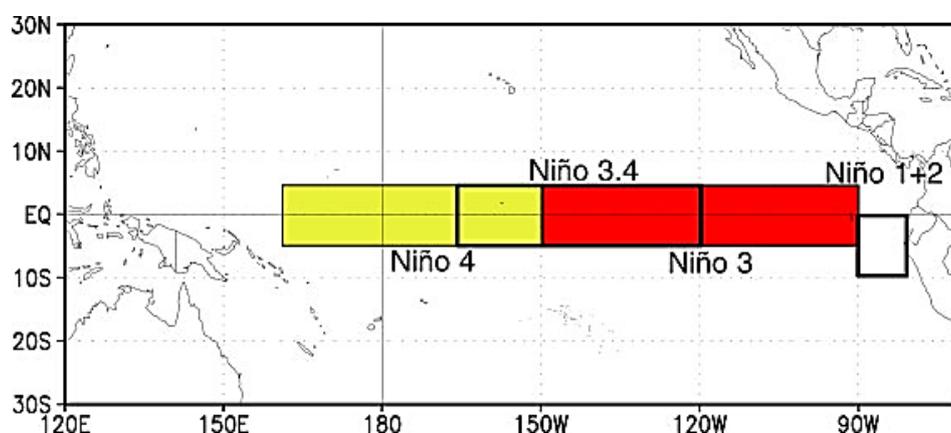


Figura 8 – Regiões de monitoramento do NOAA com base na Temperatura de Superfície do Mar

Fonte: CPC/NCEP/NOAA (2017).

Os índices históricos de intensidade do ENOS foram obtidos do banco de dados do NOAA considerando o período de 1980 a 2016. As intensidades do ENOS utilizando

o ION por meio das médias móveis trimestrais (DJF, JFM, ..., NDJ) podem ser observadas pela Tabela 5.

Tabela 5 – Catalogação de *El Niño* e *La Niña* com base no Índice Oceânico Niño entre os anos de 1980 a 2016

Anos	DJF	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ
1980	0.6	0.5	0.3	0.4	0.5	0.5	0.3	0.0	-0.1	0.0	0.1	0.0
1981	-0.3	-0.5	-0.5	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.2	-0.1
1982	0.0	0.1	0.2	0.5	0.7	0.7	0.8	1.1	1.6	2.0	2.2	2.2
1983	2.2	1.9	1.5	1.3	1.1	0.7	0.3	-0.1	-0.5	-0.8	-1.0	-0.9
1984	-0.6	-0.4	-0.3	-0.4	-0.5	-0.4	-0.3	-0.2	-0.2	-0.6	-0.9	-1.1
1985	-1.0	-0.8	-0.8	-0.8	-0.8	-0.6	-0.5	-0.5	-0.4	-0.3	-0.3	-0.4
1986	-0.5	-0.5	-0.3	-0.2	-0.1	0.0	0.2	0.4	0.7	0.9	1.1	1.2
1987	1.2	1.2	1.1	0.9	1.0	1.2	1.5	1.7	1.6	1.5	1.3	1.1
1988	0.8	0.5	0.1	-0.3	-0.9	-1.3	-1.3	-1.1	-1.2	-1.5	-1.8	-1.8
1989	-1.7	-1.4	-1.1	-0.8	-0.6	-0.4	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
1990	0.1	0.2	0.3	0.3	0.3	0.3	0.3	0.4	0.4	0.3	0.4	0.4
1991	0.4	0.3	0.2	0.3	0.5	0.6	0.7	0.6	0.6	0.8	1.2	1.5
1992	1.7	1.6	1.5	1.3	1.1	0.7	0.4	0.1	-0.1	-0.2	-0.3	-0.1
1993	0.1	0.3	0.5	0.7	0.7	0.6	0.3	0.3	0.2	0.1	0.0	0.1
1994	0.1	0.1	0.2	0.3	0.4	0.4	0.4	0.4	0.6	0.7	1.0	1.1
1995	1.0	0.7	0.5	0.3	0.1	0.0	-0.2	-0.5	-0.8	-1.0	-1.0	-1.0
1996	-0.9	-0.8	-0.6	-0.4	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5
1997	-0.5	-0.4	-0.1	0.3	0.8	1.2	1.6	1.9	2.1	2.3	2.4	2.4
1998	2.2	1.9	1.4	1.0	0.5	-0.1	-0.8	-1.1	-1.3	-1.4	-1.5	-1.6
1999	-1.5	-1.3	-1.1	-1.0	-1.0	-1.0	-1.1	-1.1	-1.2	-1.3	-1.5	-1.7
2000	-1.7	-1.4	-1.1	-0.8	-0.7	-0.6	-0.6	-0.5	-0.5	-0.6	-0.7	-0.7
2001	-0.7	-0.5	-0.4	-0.3	-0.3	-0.1	-0.1	-0.1	-0.2	-0.3	-0.3	-0.3
2002	-0.1	0.0	0.1	0.2	0.4	0.7	0.8	0.9	1.0	1.2	1.3	1.1
2003	0.9	0.6	0.4	0.0	-0.3	-0.2	0.1	0.2	0.3	0.3	0.4	0.4
2004	0.4	0.3	0.2	0.2	0.2	0.3	0.5	0.6	0.7	0.7	0.7	0.7
2005	0.6	0.6	0.4	0.4	0.3	0.1	-0.1	-0.1	-0.1	-0.3	-0.6	-0.8
2006	-0.8	-0.7	-0.5	-0.3	0.0	0.0	0.1	0.3	0.5	0.7	0.9	0.9
2007	0.7	0.3	0.0	-0.2	-0.3	-0.4	-0.5	-0.8	-1.1	-1.4	-1.5	-1.6
2008	-1.6	-1.4	-1.2	-0.9	-0.8	-0.5	-0.4	-0.3	-0.3	-0.4	-0.6	-0.7
2009	-0.8	-0.7	-0.5	-0.2	0.1	0.4	0.5	0.5	0.7	1.0	1.3	1.6
2010	1.5	1.3	0.9	0.4	-0.1	-0.6	-1.0	-1.4	-1.6	-1.7	-1.7	-1.6
2011	-1.4	-1.1	-0.8	-0.6	-0.5	-0.4	-0.5	-0.7	-0.9	-1.1	-1.1	-1.0
2012	-0.8	-0.6	-0.5	-0.4	-0.2	0.1	0.3	0.3	0.3	0.2	0.0	-0.2
2013	-0.4	-0.3	-0.2	-0.2	-0.3	-0.3	-0.4	-0.4	-0.3	-0.2	-0.2	-0.3
2014	-0.4	-0.4	-0.2	0.1	0.3	0.2	0.1	0.0	0.2	0.4	0.6	0.7
2015	0.6	0.6	0.6	0.8	1.0	1.2	1.5	1.8	2.1	2.4	2.5	2.6
2016	2.5	2.2	1.7	1.0	0.5	0.0	-0.3	-0.6	-0.7	-0.7	-0.7	-0.6

<i>El Niño</i>	<i>La Niña</i>	Neutro
----------------	----------------	--------

Fonte: CPC/NCEP/NOAA (2017).

O estudo consiste na análise de 37 anos (1980 a 2016) de dados climáticos históricos, obtidos do banco de dados do NOAA e do Instituto Nacional de Meteorologia (INMET) ao qual estão disponíveis 922 (NOAA) e 265 (INMET) EMs. As variáveis climáticas utilizadas neste estudo foram: precipitação acumulada mensal em milímetros (mm); temperatura média mensal em graus Celsius (°C); e umidade relativa do ar média mensal em porcentagem (%).

As séries históricas obtidas do INMET e do NOAA possuem dados faltantes. Portanto, para completar as falhas foram aplicados métodos como os descritos em Ferrari e Ozaki (2014) e Vicente-Serrano *et al.* (2010), que utilizam informações de EMs vizinhas para o preenchimento das falhas. Entretanto, devido a disponibilidade limitada das variáveis climáticas fornecidas pelo NOAA, seus dados não foram completados, mas aproveitados para preenchimento dos dados faltantes do INMET.

Mais detalhes sobre o preenchimento dos dados faltantes podem ser verificados em Merelles (2018), que determinou o melhor método para calcular a evapotranspiração quando existem falhas nos dados históricos, definindo primeiramente o método específico para preenchimento das falhas para cada variável climática considerando todas as EMs convencionais no Brasil monitoradas pelo INMET.

A Figura 9, gerada pelo *software R* (versão 3.4.3) apresenta a distribuição de todas as EMs convencionas do banco de dados do INMET no Brasil.

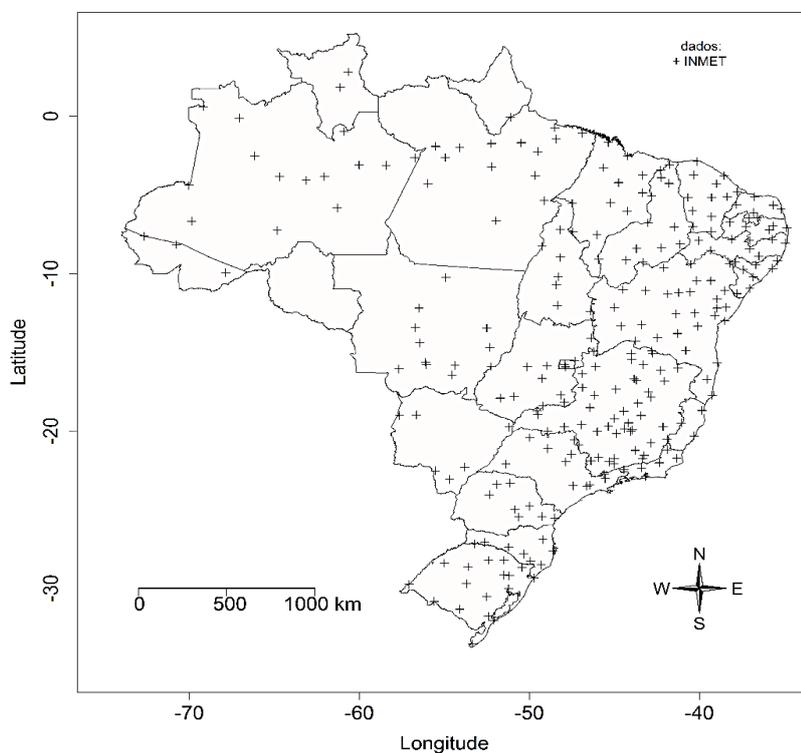


Figura 9 – Distribuição das Estações Meteorológicas convencionais monitoradas pelo INMET no Brasil

As EMs convencionais são compostas de vários sensores isolados, registrando interruptamente parâmetros meteorológicos como: direção e velocidade dos ventos; precipitação; pressão atmosférica; temperatura; umidade relativa do ar; e radiação solar.

Esses parâmetros posteriormente são lidos e anotados por um observador e enviados a um centro coletor para processamento, montando o conjunto de dados referente a cada EM.

3.2 Delimitação das Estações Meteorológicas

De acordo com a distribuição da rede de EMs convencionais do INMET, existem três estações contidas na região em estudo, sendo elas: Porto de Moz (PA), Altamira (PA) e São Félix do Xingu (PA), respectivamente. Para a escolha das demais EMs, verificou-se o nível de correlação tomando como referência cada EM contida na região, buscando verificar até que distância uma série que veio da mesma distribuição está correlacionada utilizando conceitos da modelagem estatística. Através da modelagem é possível determinar uma função que melhor descreve a interação entre os componentes de determinado sistema (MORAIS *et al.*, 2017).

As demais EMs foram selecionadas com base no (1) comprimento dos registros históricos, (2) integridade dos dados, (3) homogeneidade ou qualidade e (4) representatividade (CAMMARANO *et al.*, 2016). Para determinar quais EMs representam a Região Hidrográfica do Xingu-PA e área contigua, inicialmente foi determinada a matriz de ruídos aleatórios $\{ra_{tj}(k)\}$ das séries.

$$ra_{tj}(k) = Z_{tj}(k) - S_{tj}(k) - T_{tj}(k) \quad (3.1)$$

em que $ra_{tj}(k)$ são os ruídos aleatórios de variância constante das EMs tomadas como referência uma vez contidas na região de estudo; $Z_{tj}(k)$ são as séries observadas; $S_{tj}(k)$ são as sazonalidades; e $T_{tj}(k)$ são as tendências. Os índices t, j, k representam: j a EM observada (Porto de Moz, Altamira e São Félix do Xingu) com média zero no tempo (t) para as variáveis climáticas ($k =$ precipitação, temperatura e umidade do ar).

Posteriormente gerou-se a matriz de correlação para as k variáveis, onde as EMs com correlação superior a 30% foram agrupadas em relação as EMs de referência. Para isso, foi realizada a interpolação multivariada das componentes principais para obter os limites de correlação (AKIMA, 1978), gerando ilustrações para cada variável (precipitação, temperatura e umidade relativa do ar) em cada EM de referência, onde foi considerado para o estudo os limites de correlação da variável temperatura, uma vez que apresentou maior amplitude e representatividade, que pode ser observado na Figura 10.

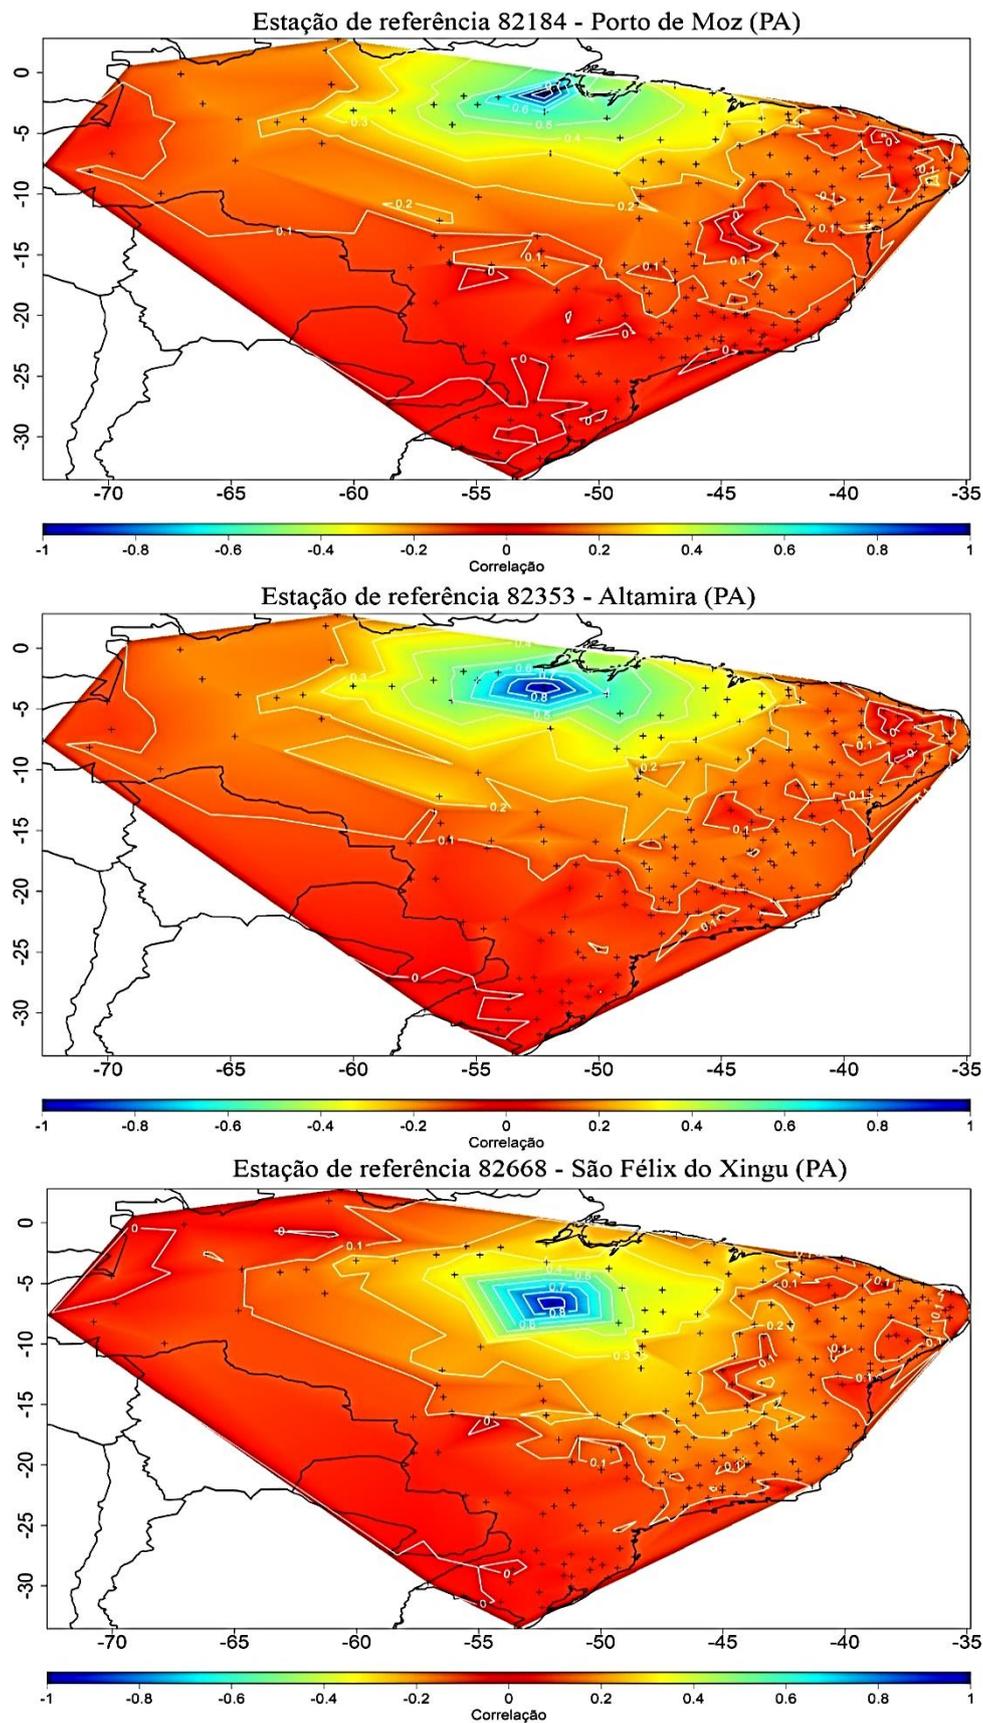


Figura 10 – Limites de correlação das Estações Meteorológicas em função da temperatura média mensal

Conforme Viviani e Manzato (2005), a inclusão de pontos (EMs) fora da delimitação da região em estudo, tem como objetivo evitar possíveis problemas resultantes do efeito de borda ao se fazer a interpolação e espacialização da área. Neste estudo, para evitar o efeito de borda, foram necessários considerar limites de correlação acima de 30%.

Devido a quantidade de EMs obtidas considerando limites de correlação acima de 30%, foi acrescentado o critério dos vizinhos mais próximos e algumas EMs foram eliminadas, considerando apenas as com maior proximidade da Região Hidrográfica do Xingu-PA, uma vez que se verificou EMs muito distantes da região em estudo. Pela Tabela 6 é possível observar as EMs que foram utilizadas, seus respectivos códigos de referência OMM (Organização Meteorológica Mundial), latitude, longitude e altitude em relação ao nível do mar.

Tabela 6 – Estações Meteorológicas utilizadas e suas respectivas latitude, longitude e altitude em relação ao nível do mar

Código - EMs	Latitude (S)	Longitude (W)	Altitude (m)
82098 – Macapá (AP)	00° 03' 00"	51° 07' 00"	14,46
82181 – Monte Alegre (PA)	02° 00' 00"	54° 06' 00"	145,85
82184 – Porto de Moz (PA)	01° 43' 60"	52° 13' 60"	15,93
82188 – Breves (PA)	01° 40' 60"	50° 28' 60"	14,74
82246 – Belterra (PA)	02° 37' 60"	54° 57' 00"	175,74
82353 – Altamira (PA)	03° 13' 00"	52° 13' 00"	74,04
82361 – Tucuruí (PA)	03° 46' 00"	49° 40' 00"	40
82445 – Itaituba (PA)	04° 16' 60"	55° 58' 60"	45
82562 – Marabá (PA)	05° 22' 00"	49° 07' 60"	95
82668 – São Félix do Xingu (PA)	06° 37' 60"	51° 58' 0 0"	206
82861 – Conceição do Araguaia (PA)	08° 16' 00"	49° 16' 0 0"	156,85
83064 – Porto nacional (TO)	10° 43' 00"	48° 25' 00"	239,2
83214 – Matupá (MT)	10° 15' 0 0"	54° 55' 00"	285

Fonte: BDMEP/INMET (2017).

Os pontos das EMs estão distribuídos geograficamente de forma irregular, sendo dez no estado do Pará, uma no estado do Mato Grosso, uma no estado do Tocantins e uma no estado do Amapá, totalizando treze EMs.

É possível visualizar pela Figura 11 a delimitação da Região Hidrográfica do Xingu-PA, a distribuição das EMs utilizadas e a localização da UHE Belo Monte, elaborada da base cartográfica do IBGE.

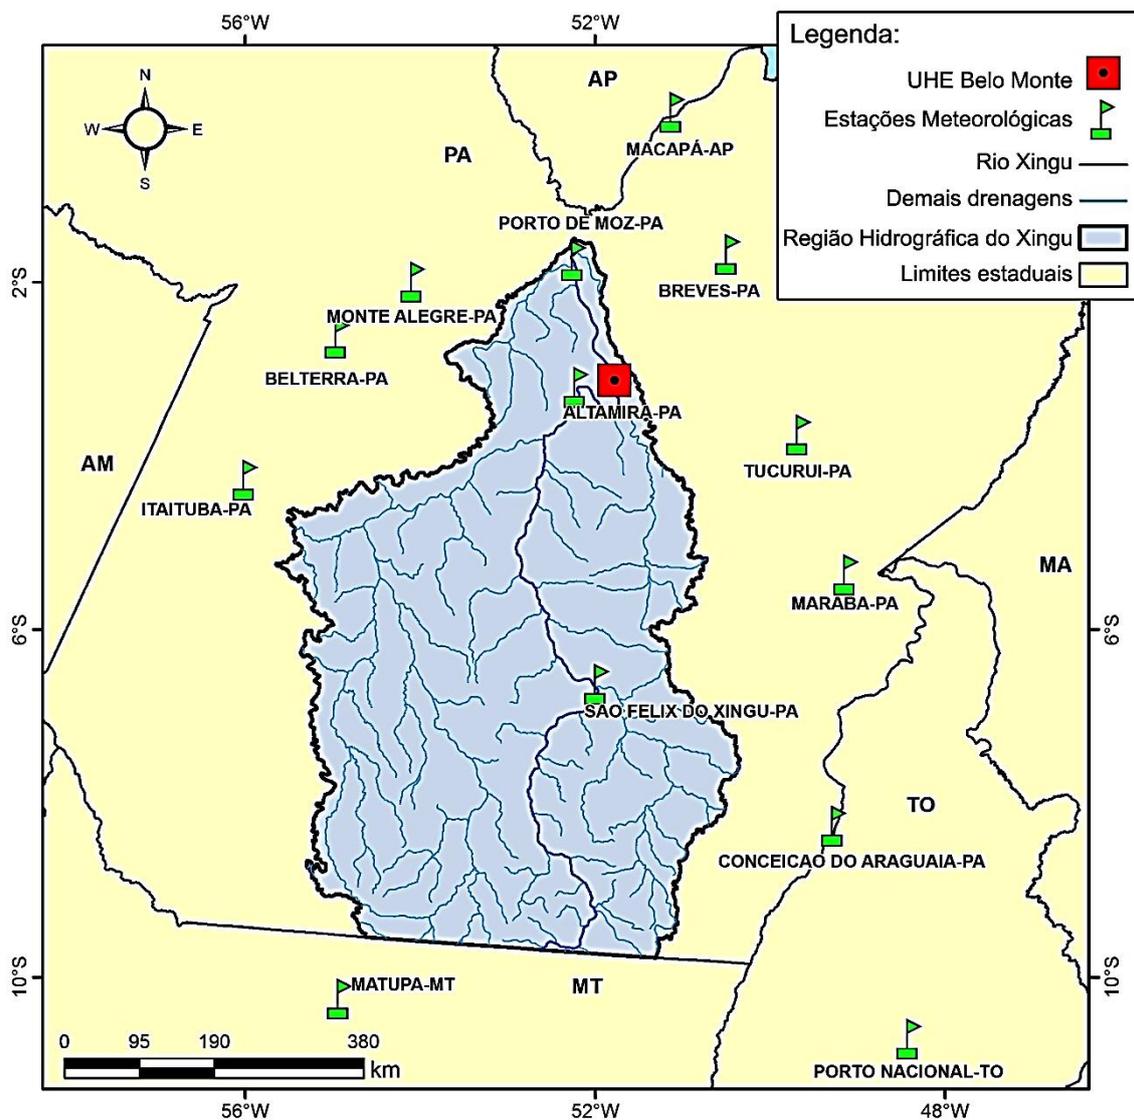


Figura 11 – Demarcação da Região Hidrográfica do Xingu-PA, Estações Meteorológicas utilizadas e localização da Usina Hidrelétrica Belo Monte

3.3 Análise dos dados

3.3.1 Regressão Linear Múltipla

A Regressão Linear Múltipla (RLM) é um conjunto de técnicas estatísticas utilizada para construção de modelos que descrevem a relação de determinada variável dependente entre duas ou mais variáveis independentes (LAZZARI *et al.*, 2011), advinda da Regressão Linear Simples que se restringe à apenas duas variáveis (x e y) e uma equação de primeiro grau funcional de ajustamento (CRUZ *et al.*, 2013). A equação geral que descreve o processo é apresentada a seguir (MONTGOMERY; RUNGER, 2016):

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i \quad i = 1, \dots, n \quad (3.2)$$

em que: Y_i é a variável dependente para o i -ésimo indivíduo; X_i ($X_{i1}, X_{i2}, \dots, X_{ik}$) é o vetor de observações das variáveis independentes para o i -ésimo indivíduo; β ($\beta_0, \beta_1, \beta_2, \dots, \beta_k$) é o parâmetro desconhecido do modelo (à estimar) ou vetor de coeficiente de regressão; ε é um componente do erro aleatório; e n é o número de indivíduos.

A RLM tem sido usada em diversas áreas de estudo, como: na avaliação de variáveis climáticas (CRUZ *et al.*, 2011; FERNANDES; CARVALHO, 2013; TONATO *et al.*, 2010), no preenchimento de falhas de séries históricas (BERTONI; TUCCI, 2007; OLIVEIRA *et al.*, 2010) e previsões de demanda para o transporte de energia elétrica (ZHANG M. *et al.*, 2009).

Com auxílio do *software R*, foi verificado a relação da altitude (Alt) entre as variáveis climáticas precipitação acumulada (P_{ac}), temperatura média ($T_{méd}$) e umidade média ($U_{méd}$), com dados das treze EMs selecionadas para estudo do comportamento climático da Região Hidrográfica do Xingu-PA através da RLM ao nível de significância de 5%, observando se a relação segue conforme apresentado em Zavattini (2009), que observou índices mais elevados de precipitação e umidade em EMs localizadas em maior altitude.

Para validação do modelo, foram verificadas três pressuposições nos resíduos gerados pela RLM, sendo: (1) normalidade na distribuição; (2) independência; e (3) homogeneidade de variância. Desta forma, para este trabalho foram definidas as seguintes hipóteses para avaliação geral de adequação do modelo gerado por RLM:

$$\begin{cases} H_0 = \text{modelo satisfatório (não há quebra de pressuposição);} \\ H_1 = \text{modelo não satisfatório (há pelo menos uma quebra de pressuposição).} \end{cases}$$

A verificação de normalidade nos resíduos se deu pelas estatísticas de Anderson-Darling, Kolmogorov-Smirnov, Shapiro-Wilk e Ryan-Joiner. Para verificação de independência foi considerado o teste generalizado de Durbin-Watson (VINOD, 1973), que possibilita detectar a presença de autocorrelação (dependência) de qualquer ordem (BARROSO *et al.*, 2012). A verificação de homogeneidade de variância (homoscedasticidade) se deu pelo teste de Breusch-Pagan, verificando a hipótese de igualdade de variância versus a hipótese da homoscedasticidade ser uma função multiplicativa de uma ou mais variáveis (HALUNGA *et al.*, 2017). A equação que fundamenta o teste pode ser verificada em Breusch e Pagan (1980).

3.3.2 Análise descritiva

Existe a necessidade da análise de consistência dos dados antes de uma avaliação mais detalhada utilizando recursos e métodos da Geoestatística (FERNANDES, 2009), que pode ser realizada por meio da estatística clássica. É importante realizar uma análise estatística antes do processamento dos dados, para que seja possível descrever e caracterizar as distribuições da amostra ou conjunto de dados para melhor entendimento do comportamento das variáveis de interesse (YAMAMOTO *et al.*, 2001).

Desta forma, para avaliar os dados com consistência, foram verificadas as medidas de tendências central (mediana e média) e os parâmetros de dispersão em torno da média (coeficiente de variação, variância e desvio padrão), conforme descrito em Chwif e Medina (2014), Montgomery e Runger (2016). A média amostral é dada por:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.3)$$

em que \bar{X} é a média amostral; n é o tamanho da amostra; $x_i = x_1, x_2, x_3, \dots, x_n$.

A mediana é o valor (pertencente ou não à amostra) que separa ao meio o conjunto de dados, ou seja, metade dos elementos amostrais são iguais ou menores que a mediana e a outra metade, iguais ou maiores que a mediana. As seguintes regras foram atribuídas depois da ordenação amostral dos n elementos: (1) a mediana é o elemento médio se n for ímpar; (2) os dois elementos médios por meio de uma semissoma darão origem a mediana caso n for par. A mediana obtida por interpolação, para dados agrupados é dada conforme Equação (3.4):

$$\text{mediana} = L_1 + \left(\frac{\frac{N}{2} + (\sum f)_1}{f_{\text{mediana}}} \right) c \quad (3.4)$$

em que: L_1 é o limite inferior da classe que contém a mediana; N é o total de dados; $(\sum f)_1$ é a soma das frequências das classes inferiores à mediana; f_{mediana} é a frequência da classe mediana; e c amplitude do intervalo da classe mediana.

A medida de dispersão variância (S^2), também denominada “desvio quadrático médio da média” é a mais empregada na prática quanto existe divergência de valores de uma distribuição com sua média, podendo ser calculada conforme a Equação (3.5):

$$S^2 = \frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n - 1} \quad (3.5)$$

Ao se aplicar a raiz quadrada na variância, obtém-se o desvio padrão (S), podendo ser aplicado por ser uma grandeza expressa com a mesma unidade dos valores iniciais, sendo expressa como:

$$S = \sqrt{S^2} \quad (3.6)$$

Por meio da divisão do desvio padrão (S) pela média (\bar{X}) se obtém o coeficiente de variação (CV) ou desvio padrão relativo, que é uma medida padronizada contida em uma distribuição de probabilidade ou distribuição de frequências, descrita como:

$$CV\% = \frac{S}{\bar{X}} * 100 \quad (3.7)$$

Pelo fato de ser uma medida adimensional, se permite a comparação relativa das variáveis com as diferentes distribuições, como exemplo, a classificação e comparação de depósitos minerais de acordo com sua variabilidade natural (FERNANDES, 2009; YAMAMOTO *et al.*, 2001).

O coeficiente de assimetria (C_s) possibilitou caracterizar a distribuição de acordo com sua assimetria (positiva ou negativa). Valores negativos indicam cauda da função densidade de probabilidade mais alongada à esquerda, enquanto valores positivos indicam cauda mais alongada à direita. O C_s pode ser expresso conforme Equação (3.8).

$$C_s = \frac{1}{n} \sum \left[\frac{(x_i - \bar{X})}{S} \right]^3 \quad (3.8)$$

em que: valores nulos ou próximos de zero indicam tendência a simetria, ou seja, os dados estão distribuídos relativamente iguais em ambos os lados da média.

As seguintes distribuições de frequências foram avaliadas neste estudo: frequência absoluta (f_i), definida pelos valores que representam os dados numéricos de cada classe; frequências relativas (f_{ri}), definida pela razão entre os valores da frequência absoluta e o número total de dados da amostra n ; frequência percentual (p_i), definida sendo o percentual de um determinado valor da amostra; e frequência acumulada (f_{ac}), que é o total das frequências de todos os dados inferiores ao limite superior do intervalo de uma determinada classe (CORREA, 2003; MARTINS; DOMINGUES, 2017).

Para definir o número de classes das distribuições de frequências foi utilizada a regra de Sturges, conforme apresentado em Chwif e Medina (2014) pela Equação (3.9):

$$k = 1 + 3,3 \log_{10}(n) \quad (3.9)$$

em que: k é o número de classes e n o tamanho do conjunto de dados.

Conforme apresentado em Silva E. (2014), para avaliar dados de determinada amostra, pode-se construir um histograma uma vez definido o número de classes, destacando dentre os critérios mais utilizados a regra de Sturges.

3.3.3 Teste de aderência

Para verificar a aderência dos dados de precipitação acumulada, temperatura e umidade média mensal, foram avaliados os seguintes modelos de distribuição: Normal; Log-Normal; Exponencial; Logística; Gama; Weibull; Gumbel; Cauchy; Rice; e Rayleigh. O *software* utilizado para auxílio na verificação foi o *Action Stat Pro* que utiliza linguagem de programação estatística *R*, vinculado às planilhas do *Microsoft Excel*®.

A verificação se deu pelas estatísticas de Anderson-Darling e Kolmogorov-Smirnov (JANTSCHI; BOLDOACA, 2009), usadas para calcular o p-valor para o teste de qualidade do ajuste, que ajuda a determinar o melhor modelo que se adapta a distribuição do conjunto de dados.

Pela avaliação do p-valor predefinido de 5%, foi possível verificar a adequação da amostra a um modelo de distribuição específico. As hipóteses definidas para análise foram as seguintes:

$$\begin{cases} H_0 = \text{a amostra segue um modelo de distribuição específico;} \\ H_1 = \text{a amostra não segue um modelo de distribuição específico.} \end{cases}$$

em que: p-valor $(x) \geq \alpha$, implica à não rejeição da hipótese nula (H_0); e p-valor $(x) < \alpha$, rejeita-se a hipótese nula (H_0) e aceita-se a hipótese alternativa (H_1). Para $x = x_1, x_2, \dots, x_n$ de modo que $1, 2, \dots, n$ são os p-valores calculados de cada distribuição ao nível de significância de 5% ($\alpha = 0,05$).

Para análise da relação entre as variáveis climáticas, foi utilizado o coeficiente de correlação de Spearman, sendo o mais indicado para uma distribuição não-paramétrica, expressa conforme à Equação (3.10).

$$\rho = 1 - \frac{6 \sum d_i^2}{(n^3 - n)} \quad (3.10)$$

em que: ρ é o coeficiente de Spearman; n o número de observações; e d é a diferença entre os postos de cada observação.

É importante analisar a correlação dos dados para entendimento da covariação entre as variáveis climáticas, que pode variar de -1 a 1. O sinal negativo indica correlação inversa entre as variáveis, 1 representa a correção perfeita e 0 indica que não há correlação (MUKAKA, 2012).

3.4 Análise espacial

O ramo da estatística espacial que utiliza conceitos de funções aleatórias incorporando a dependência espacial com modelos de variáveis georreferenciadas é denominado Geoestatística, que surgiu da necessidade do estudo estatístico de fenômenos naturais, caracterizada pela distribuição espacial de uma ou mais variáveis (JOURNEL; HUIJBREGTS, 1978), que não era possível utilizando apenas a estatística convencional.

A Geoestatística foi desenvolvida inicialmente para solucionar problemas de mineração (MATHERON, 1963, 1965, 1970), sendo mais difundida nesta área, embora cada vez mais tem sido utilizada em outras áreas de conhecimento, como no meio ambiente (PORTO JÚNIOR *et al.*, 2012), na agricultura (CUNHA *et al.*, 2013), nas ciências biomédicas (GOOVAERTS, 2000) e em estudos climáticos (YAMAMOTO; LANDIM, 2013).

Conforme apresentado por Fernandes (2009) e Matheron (1965), variáveis regionalizadas possuem as mesmas características qualitativas dos fenômenos por elas representadas que a estatística convencional não é capaz de demonstrar. Segundo os mesmos autores, estas variáveis regionalizadas podem apresentar algumas características, como: suporte, localização, anisotropia e continuidade. Conforme apresentado por Bubenicek e Haas (1969), as variáveis regionalizadas por apresentarem distribuição espacial variante aparente, não são passíveis de representação por funções determinísticas.

Admitindo-se uma característica dendrométrica Z , variante continuamente num determinado espaço em função das coordenadas geográficas em que cada valor verificado

$Z(x_i)$ em locais x_i , onde $i = 1, 2, 3, \dots, n$, e x_i demonstra em duas dimensões a coordenada geográfica, é possível obter a variável aleatória $Z(x)$. As variáveis aleatórias ou conjunto de variáveis $Z(x_1), \dots, Z(x_n)$ constituem um processo estocástico ou função aleatória.

Uma maneira de representar a variância de fenômenos regionalizados espacialmente de forma quantitativa é por meio da função do semivariograma $\gamma(h)$. Contudo, existe uma confusão na literatura em relação ao termo semivariograma e variograma (BACHMAIER; BACKES, 2011), sendo tratados de forma indistinta (GNEITING *et al.*, 2001; WACKERNAGEL, 2003) ou de forma distinta assumindo que o semivariograma representa a metade da função do variograma $2\gamma(h)$ (GRINGARTEN; DEUTSCH, 2001; STEIN, 1999). Neste estudo a função do semivariograma foi tratada conforme descrito em Camargo *et al.* (2004), Isaaks e Srivastava (1989), Yamamoto e Landim (2013), expressa pela Equação (3.11):

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (3.11)$$

em que: $N(h)$ é o número de pares de valores avaliados $Z(x_i + h)$, $Z(x_i)$, distanciados por h .

A Equação (3.11) possibilita a geração do semivariograma experimental, que por sua vez, permite o ajuste da função matemática que demonstra a estrutura de correlação espacial da característica observada.

A função semivariograma também pode ser descrita em termos de variância e covariância conforme Equação (3.12). A relação entre variância de dados e a covariância espacial é demonstrada em Yamamoto *et al.* (2001), Yamamoto e Landim (2013).

$$\gamma(h) = c(o) - c(h) \quad (3.12)$$

em que: $c(o)$ é a variância de dados; e $c(h)$ a correlação entre pontos separados por uma distância h .

Embora exista uma infinidade de funções que podem ser ajustadas aos semivariogramas, modelos fundamentados em suposições teóricas de variáveis regionalizadas vêm satisfazendo a maioria das aplicações (STURARO, 2015), onde destacam-se os modelos: com patamar (esférico, exponencial, gaussiano, cúbico ou aleatório); e sem patamar (modelo linear generalizado ou logarítmico).

O semivariograma possui algumas propriedades, definidas como: alcance (distância a partir da qual ocorre interdependência entre as amostras); patamar (valor máximo de variância); efeito pepita (descontinuidade próxima à origem do semivariograma); e a contribuição (diferença entre o patamar e o efeito pepita) (YAMAMOTO *et al.*, 2001; YAMAMOTO; LANDIM, 2013).

A Figura 12 exemplifica o semivariograma experimental e seus parâmetros, que permite analisar o grau de dependência espacial uma vez estimado o valor de semivariância avaliando diferentes combinações de pares de pontos, possibilitando definir os parâmetros para estimativas em locais não amostrados (COSTA, 2014; GUIMARÃES, 2004). A menor semivariância se dá pela proximidade entre os pontos amostrados uma vez que existe maior semelhança entre eles, logo, conforme a medida $\gamma(h)$ aumenta o esperado é que h também aumente.

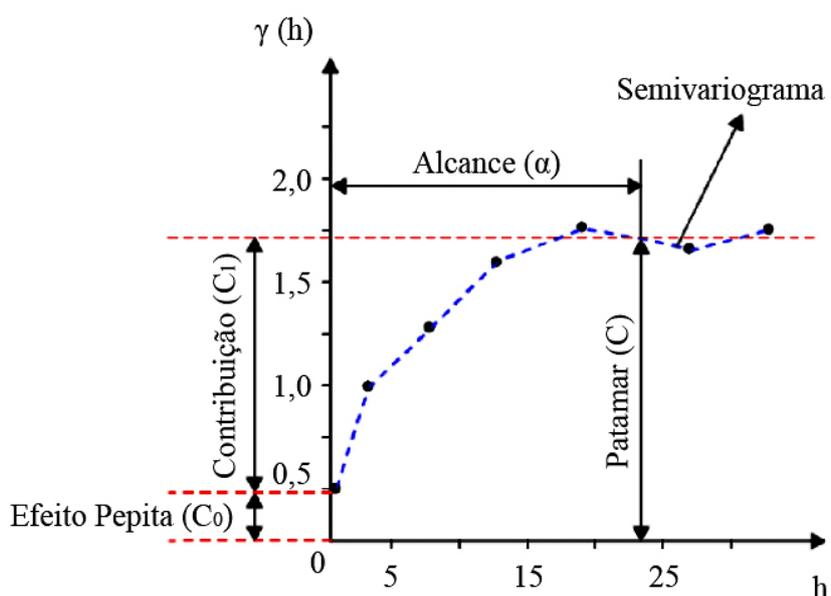


Figura 12 – Modelo de semivariograma experimental

Fonte: Adaptado de Guimarães (2004).

Para avaliação do Índice de Dependência Espacial (*IDE*) expresso pela relação entre o efeito pepita (C_0) e a contribuição (C_1) [Equação (3.13)], foi utilizado os intervalos propostos em Cambardela *et al.* (1994) que classificam a dependência espacial em fraca ($IDE > 75\%$), moderada ($25\% \leq IDE \leq 75\%$) e forte ($IDE < 25\%$) para avaliação do modelo obtido para cada variável climática em estudo.

$$IDE\% = \left(\frac{C_0}{C_0 + C_1} \right) * 100 \quad (3.13)$$

O semivariograma embora seja uma função direcional, não é vetorial (FERNANDES, 2009), ou seja, ao se escolher uma direção ou sentido, ela vale para ambos os lados, limitada lateralmente pela distância máxima e tolerância angular. Portanto, o semivariograma experimental pode ser calculado em várias direções ao se utilizar análises da Geoestatística, sendo da melhor maneira ajustado a uma função predefinida matematicamente (OLEA, 1991). Neste estudo o semivariograma foi definido com auxílio do *software R* com o implemento *GeoR* versão 2.4.1 (RIBEIRO JR; DIGGLE, 2001) e do *software PAST* versão 3.19. A utilização dos dois *softwares* se deu para verificação de ajuste e precisão.

Constantemente, dados meteorológicos geram a necessidade de se usar métodos de interpolação espacial para seu devido mapeamento, se destacando entre eles o método krigagem (CARVALHO *et al.*, 2012; FRANCO; UDA, 2015; VIOLA *et al.*, 2010), que se baseia na ideia de quanto maior a covariância entre o local de estimativa com determinada amostra, maior a contribuição dessa amostra com a estimativa (YAMAMOTO; LANDIM, 2013). A krigagem se baseia em um modelo de estimação local, onde por meio da vizinhança estacionária, busca a minimização sem viés do erro de estimação (CLARK, 1979; JOURNAL; HUIJBREGTS, 1978).

Alguns estudos (CARVALHO; ASSAD, 2005; CARVALHO *et al.*, 2012; MARTINS, 2016; VIOLA *et al.*, 2010) apresentam a krigagem ordinária (uma das técnicas contidas no método krigagem) como uma técnica univariada bastante utilizada devido sua eficiência em interpolação de dados climáticos. Jakob (2002) considera a krigagem ordinária uma boa opção para interpolação de dados, que utiliza de funções matemáticas atribuindo maiores pesos para posições com maior proximidade, já para posições mais distantes são atribuídos menores pesos, gerando novos pontos interpolados baseando-se nas combinações lineares dos dados.

Neste estudo, foi utilizada a técnica krigagem ordinária, pelos resultados que proporciona e simplicidade (YAMAMOTO; LANDIM, 2013) se destacando entre as técnicas contidas no método da krigagem (BERVEGLIERI *et al.*, 2011), que estabelece uma forma estimadora linear para variáveis regionalizadas atendendo a hipótese intrínseca, ou seja, não há necessidade do conhecimento antecipado da média, assumindo-se a hipótese da estacionaridade local (BERVEGLIERI *et al.*, 2011; LANDIM, 2003).

O estimador de krigagem ordinária $\{Z_{KO}^*(x_0)\}$ é definido pela Equação (3.14) (JOURNAL; HUIJBREGTS, 1978) a seguir:

$$Z_{KO}^*(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (3.14)$$

em que: λ_i representa os ponderadores, com $\sum_{i=1}^n \lambda_i = 1$; $Z(x_i)$ representa os dados experimentais; e n representa a totalidade dos dados.

Para cálculo dos pesos ótimos, duas condições de restrições devem ser levadas em consideração, em que (1) o estimador não deve estar enviesado e (2) a variância de estimativa deve ser mínima (YAMAMOTO; LANDIM, 2013).

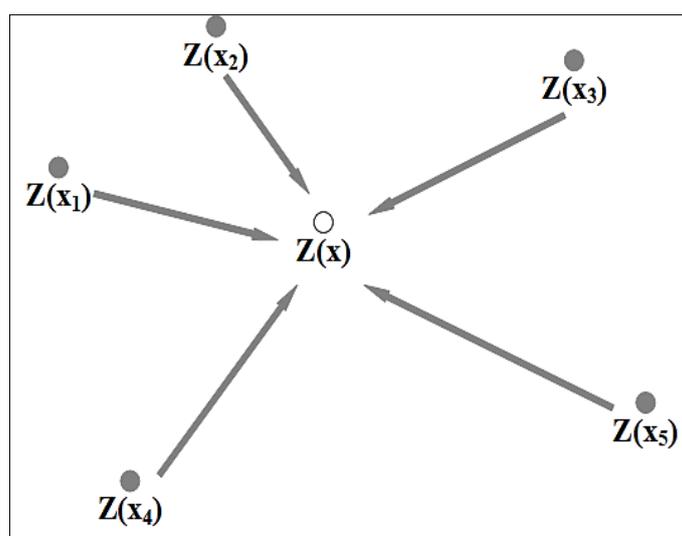


Figura 13 – Representação do interpolador krigagem ordinária

Fonte: Adaptado de Reuwsaat (2011).

Conforme apresentado em Reuwsaat (2011), a Figura 13 demonstra a forma genérica da krigagem ordinária, onde os dados do atributo Z , nas diferentes posições x_1 a x_5 são utilizados para fazer a estimativa do valor do atributo Z na posição de x .

As estimativas obtidas pela krigagem ordinária foram validadas utilizando o método estatístico não-paramétrico de validação cruzada.

3.5 Validação

Estimativas ótimas são aquelas que não possuem erros ou tendem a zero, ou seja, os valores que foram estimados são idênticos ou bem próximos dos valores reais. Sendo

assim, um conjunto de dados satisfatórios são aqueles em que a distribuição possui similaridade com a distribuição dos dados reais (CHWIF; MEDINA, 2014).

3.5.1 Métricas estatísticas de avaliação de ajuste

A maneira mais simples de avaliar um conjunto de dados ou método de estimativa é verificando se a distribuição do simulado é similar aos dados reais. Sendo assim, existem alguns critérios que podem ser aplicados para avaliar a qualidade de ajuste de um modelo (ALENCAR *et al.*, 2015).

Neste trabalho foram aplicadas as seguintes métricas estatísticas para avaliação de ajuste e qualidade dos modelos: coeficiente de determinação (R^2); raiz do erro quadrático médio ($RMSE$ – *Root Mean Squared Error*); e erro absoluto médio (MAE – *Mean Absolute Error*).

$$R^2 = 1 - \frac{\sum_{i=1}^n (W_i - W_i^*)^2}{\sum_{i=1}^n (W_i - \bar{W}_i)^2} \quad (3.15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |W_i - W_i^*|^2} \quad (3.16)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |W_i - W_i^*| \quad (3.17)$$

em que: W é um vetor com valores previsto; W^* é um vetor com os valores observado; e n é o número de amostras.

O coeficiente de determinação (R^2) é constantemente usado como medida de adequabilidade de uma modelagem realizada por regressão, expressando a quantidade de variabilidade apresentada nos dados. É esperado para um bom modelo de regressão, a explicação de pelo menos 70% da variabilidade das variáveis de interesse (VIRGILLITO, 2007).

Tanto a raiz do erro quadrático médio ($RMSE$) quanto o erro absoluto médio (MAE) expressam o erro de previsão do modelo médio em unidades da variável de interesse. A utilização das duas métricas para avaliação de ajuste se deu pelo fato do $RMSE$ penalizar somente os altos erros, sendo mais útil quando altos erros são

indesejáveis (VICENTE-SERRANO *et al.*, 2010). Com isso, a decisão de qual modelo utilizar não pode ser aplicado somente com sua análise, uma vez que a modelagem pode alterar valores extremos caso sejam identificados nas amostras.

3.5.2 Validação Cruzada

O método de validação cruzada surgiu da adaptação de métodos estatísticos não-paramétricos (DAVIS, 1987). O método é muito utilizado em validações das estimativas obtidas por krigagem (ISAAKS; SRIVASTAVA, 1989; REUWSAAT, 2011). É um conjunto de técnica que usa dados já existentes obtendo assim um conjunto de pares de valores estimados, o que permite sua comparação com os valores reais (REUWSAAT, 2011).

Conforme Fernandes (2009) o método de validação cruzada retira determinado valor do conjunto de dados e o estima com os mesmos parâmetros usados na interpolação de pontos não apresentados, ou seja, as condições de vizinhança e o modelo teórico do semivariograma. Posteriormente, se compara o valor estimado com o real, estimando por meio da observação o possível viés na estimativa.

A validação cruzada apesar de habitualmente utilizada apenas como método para comparação entre diferentes técnicas de estimativa, pode ser bastante valiosa em determinação de condições e setores em que um método de estimação apresenta problemas, como em locais que sistematicamente se verificam superestimativas ou subestimativas, por meio da análise da informação espacial dos resíduos adquiridos (SOARES, 2014).

3.6 Modelagem de séries temporais

Para projeção dos dados, foi utilizada a regressão de séries temporais. Uma série temporal pode ser decomposta em tendência, sazonalidade ou erro aleatório. Um processo apresentando característica estacionária (médias, variâncias e covariâncias constantes ao longo do tempo) pode ser aplicado os modelos de Box e Jenkins (BOX *et al.*, 2008). Caso a série apresente característica não-estacionária, existe a possibilidade de ajuste e transformação da série para obtenção da estacionaridade por meio das diferenciações.

Quando uma série temporal não apresenta sazonalidade, o modelo ARIMA (p, d, q) pode ser aplicado, já em séries com sazonalidade se aplica o modelo SARIMA $(p, d, q)(P, D, Q)[s]$ (MONTGOMERY *et al.*, 2015), onde: p é a quantidade de modelos autoregressivos; d é a quantidade de diferenciações; q é a quantidade de modelos de média-móvel; P é a quantidade de modelos autoregressivos sazonais; D é a quantidade necessária de *lags* para retirar a sazonalidade; Q é a quantidade de modelos de média-móvel sazonais; e s é a sazonalidade por período.

O ajuste do modelo foi realizado nas seguintes etapas: avaliação da necessidade de transformação dos dados para reduzir a variância; determinação das diferenciações; estimativa dos parâmetros desconhecidos; testes da acurácia dos resíduos; e validação da previsão (MORETTIN; TOLOI, 2011; TSENG; TZENG, 2002). As etapas foram realizadas no *software R* com o *script* de Hyndman e Khandakar (2008) que foi testado por Sousa (2012) verificando sua precisão, além de ser indicado por Montgomery *et al.* (2015).

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

De acordo com dados do IPCC (2007, 2014), o cenário global aponta mudanças climáticas com aumento nas temperaturas acima de 2 °C nas últimas décadas que deverão continuar. O aumento da temperatura ocasiona diversos impactos no ciclo hidrológico e ecossistemas, com alterações nos padrões de ventos, umidade relativa do ar, precipitação, pressão atmosférica, além de intensificar anomalias climáticas como o ENOS (SALVIANO *et al.*, 2016), podendo impactar em diversos setores do Brasil, como: na geração de energia elétrica (LUCENA *et al.*, 2010; SOITO; FRETAS, 2011; WESTIN *et al.*, 2014); na pecuária e agricultura (PINTO *et al.*, 2001); na fauna e flora (PBMC, 2013); ocorrência de desastres naturais (MARENGO, 2010); e abastecimento de água (TORRENTE, 2014).

O Brasil investe fortemente em sua capacidade hidrelétrica devido a disponibilidade de recursos hídricos (LUCENA *et al.*, 2010) apesar do seu potencial decrescente, instabilidades nas condições climáticas e escassez de água identificadas em todo o país (CUERVO; BOTERO, 2014). Portanto, é de fundamental importância estudos sistematizados do comportamento climático nas regiões em que estão localizadas as principais fontes geradoras de energia do país (ANDRADE, 2012), em que boa parte das empresas brasileiras, realizam suas atividades de geração e transmissão de energia elétrica sem contemplar possíveis mudanças climáticas na região, comprometendo tanto o desempenho econômico-financeiro do empreendimento, quanto a economia do país dependente do produto por elas geradas.

4.1 Análise dos padrões climáticos da Região Hidrográfica do Xingu-PA

O estudo de tendências permite analisar o comportamento climático, identificando por meio de registros históricos, alterações nos padrões das variáveis climáticas de determinada região, que podem estar relacionadas a vários fatores, desde os de origem antrópicas, como a urbanização desenfreada e o desmatamento (SALVIANO *et al.*, 2016), as não antrópicas, como as anomalias climáticas *El Niño* e *La Niña*, além da intensificação da ação solar (MARENGO, 2010).

Por meio da média dos dados mensais das variáveis climáticas das treze EMs, gerou-se novos conjuntos de dados para descrever o comportamento climático geral da Região Hidrográfica do Xingu-PA. Posteriormente, gerou-se gráficos de contorno

representativos dos padrões climáticos para cada variável climática, com vistas a subsidiar apontamentos para discussões a respeito do comportamento e tendências climáticas para os 37 anos observados (1980 – 2016).

Analisando a Figura 14, se observam padrões com variância uniforme, com maiores índices pluviométricos de janeiro a maio, seguido de menores índices que se intensificam entre os meses de junho a outubro. Alguns períodos apresentam padrões de chuva em maior intensidade de janeiro a abril, identificados nos anos de 1982, 1985, 1991, 2000, 2004, 2006, 2011 e 2012, indicando possíveis influências de anomalias oceânicas que podem intensificar o período chuvoso [dezembro, ..., abril (DIREH, 2013)] e de estiagem [junho, ..., outubro (DIREH, 2013)] na região (SANTOS *et al.*, 2014), explicando as variações nos padrões considerados atípicos em relação aos demais registros da série histórica.

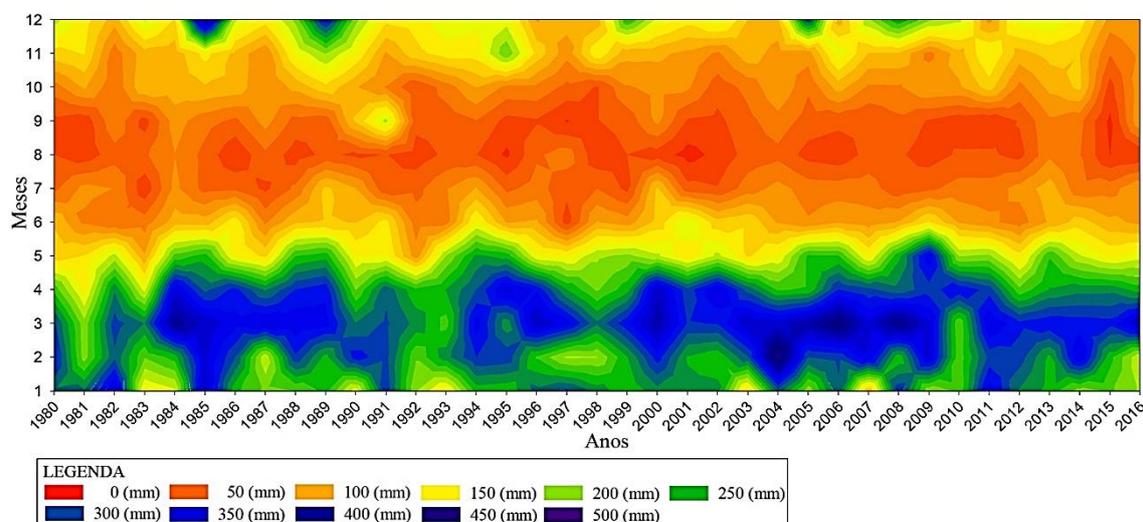


Figura 14 – Padrão climático da Região Hidrográfica do Xingu-PA para registros de precipitação acumulada mensal

Analisando os padrões climáticos de temperatura média mensal (Figura 15), se observa progressiva elevação nas temperaturas, com maior representatividade no período de estiagem, ocasionando antecipação de registros com temperaturas mais elevadas. De modo geral, a distribuição dos dados apresenta característica ascendente. No período chuvoso se verifica temperaturas mais baixas, com elevações ao longo dos anos. É possível identificar a relação oposta entre as variáveis precipitação e temperatura ao se comparar as Figuras 14 e 15, com menores temperaturas registradas em períodos que apresentam maiores índices pluviométricos, conforme descrito em Salviano *et al.* (2016) e Zhang W. *et al.* (2009).

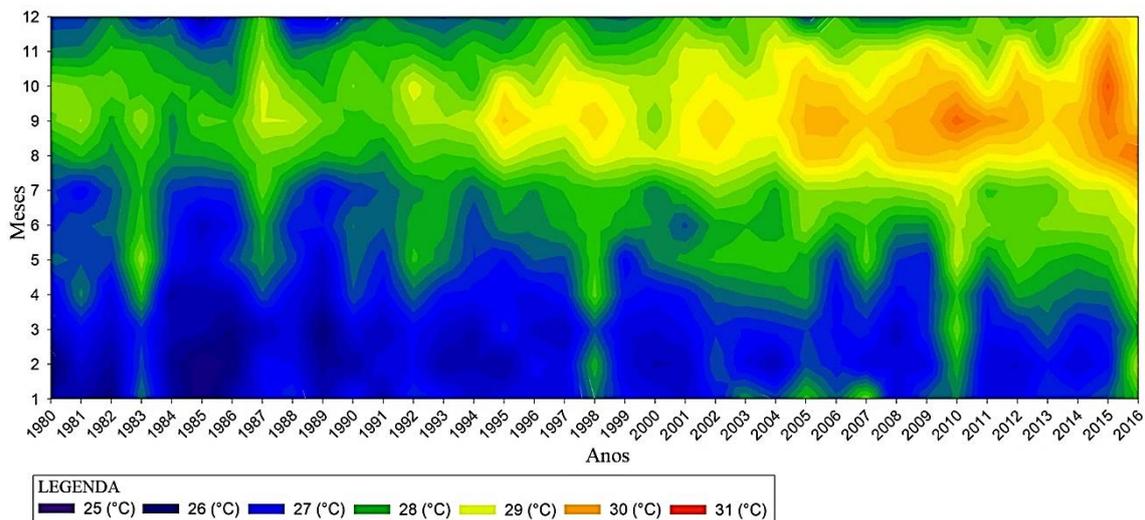


Figura 15 – Padrão climático da Região Hidrográfica do Xingu-PA para registros de temperatura média mensal

Observam-se padrões atípicos nos anos 1983, 1987, 1992, 1993, 1998, 2010 e 2016 (Figura 15), com temperaturas mais elevadas identificadas fora do padrão geral, apontando fortes indícios de influência de outros fatores ou anomalias climáticas. Avaliando o período chuvoso, entre dezembro e janeiro dos anos 2003, 2005 e 2007, também se observa padrões atípicos, uma vez que comportamento semelhante não é observado nos demais anos da série. Existem registros de temperaturas mais baixas nos anos de 1980 e 1982 (janeiro e fevereiro), 1984, 1985 e 1986 (janeiro a maio).

Através do gráfico de contorno de umidade média mensal (Figura 16), verifica-se semelhança inversa nos padrões e tendências em relação aos dados de temperatura (Figura 15), como também observado nos estudos de Vassoler e Zebende (2012).

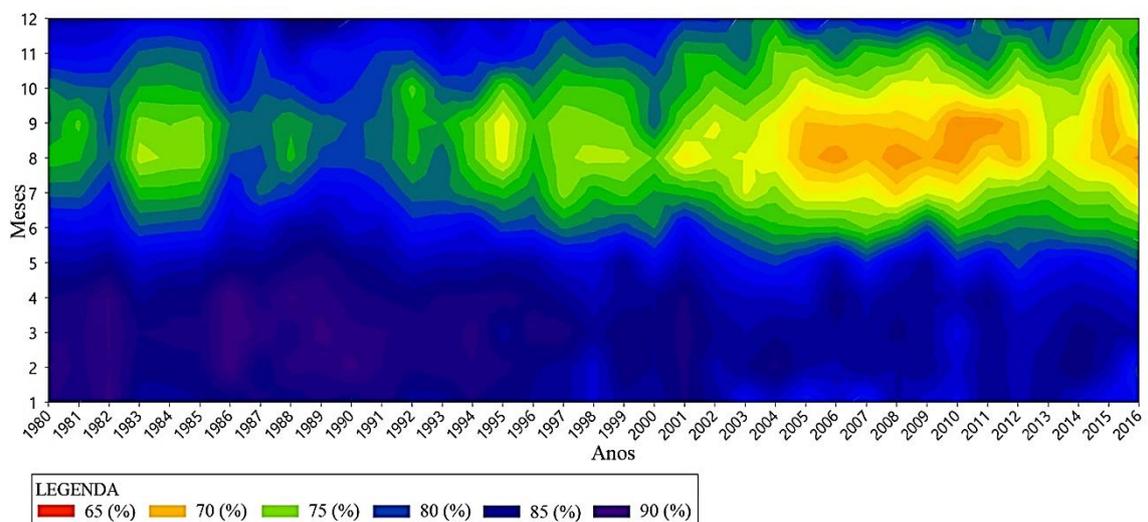


Figura 16 – Padrão climático da Região Hidrográfica do Xingu-PA para registros de umidade média mensal

Considerando o período chuvoso e de estiagem, a distribuição dos dados apresenta característica descendente, com maior intensidade no período de estiagem (Figura 16). Os anos de 1982, 1986, 1987, 1988, 1989, 1990 e 1991, apresentam comportamento atípico ao se comparar com os padrões gerais da série, com maiores taxas de umidade registradas tanto no período chuvoso quanto no de estiagem. De modo geral, de dezembro a maio de 1980 a 1997 se observam taxas de umidade relativa no ar acima de 85%, nos anos de 1998 a 2002 a mesma taxa é registrada de janeiro a maio, enquanto que nos anos de 2003 a 2016 para o mesmo período as taxas identificadas estão entorno de 80%.

As Figuras 17, 18 e 19 auxiliam na identificação de valores extremos (máximos e mínimos) para o período chuvoso, de estiagem, total anual acumulado (precipitação) e média anual (temperatura e umidade relativa do ar). Para a suavização das séries, utilizou-se a linha de tendência obtida pela média móvel a cada dois períodos, que facilita a detecção de tendências em séries temporais (QUEIROZ, 2013), sendo amplamente utilizada em dados de diferentes naturezas, como: demográficos; climáticos; hidrológicos; e fluxos econômicos (VAZ, 2008).

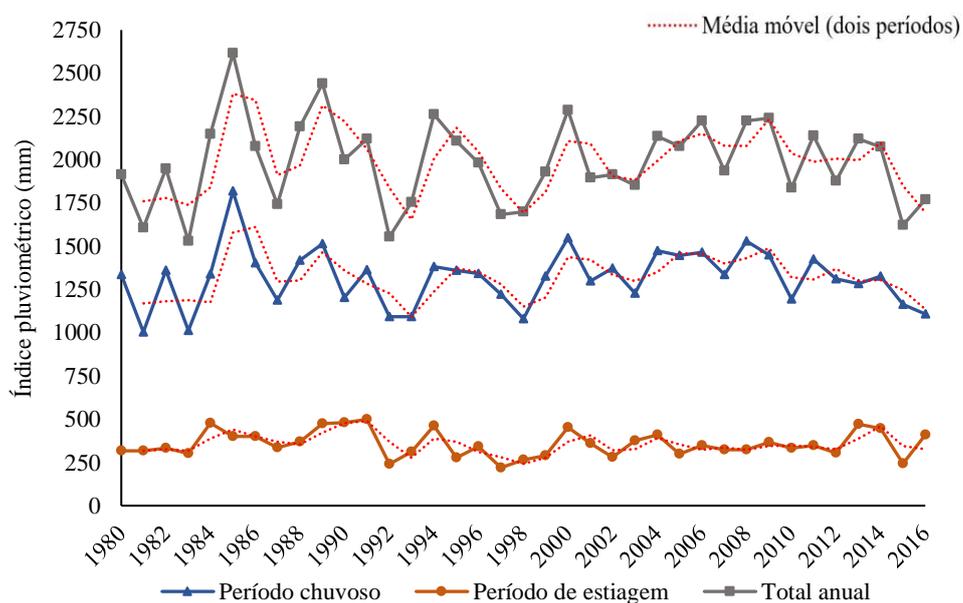


Figura 17 – Comportamento e tendência de diferentes períodos para precipitação acumulada

Analisando a distribuição total anual (Figura 17), se verifica menor índice pluviométrico no ano de 1983 (1530,11 mm), com aumento progressivo de 41,5% até o ano de 1985 (2614,74 mm) que foi o pico máximo da série. Esse aumento de 1084,63 mm entre os anos de 1983 a 1985 pode ser considerado atípico devido ao curto intervalo de

tempo. Comportamento semelhante pode ser observado nos anos de 1987 a 1989, 1992 a 1994 e 1998 a 2000, porém, em menor intensidade.

O comportamento da série para o período chuvoso retrata as mesmas características identificadas nos anos atípicos da distribuição total anual, que apresenta também para o ano de 1985 maior índice pluviométrico (1817,18 mm), enquanto que no ano de 1981 ocorreu o menor índice de toda a série. Verifica-se pela série do período de estiagem menor intensidade em relação a variação entre o menor registro no ano de 1997 (219,83 mm) e o maior registro no ano de 1991 (498,39 mm).

Os picos máximos e mínimos de temperatura média podem ser observados na Figura 18, com maiores variações na série do período chuvoso, como observado nos anos de 1983 a 1985, com queda de 2,5 °C e progressiva alta de 1985 a 1987 de 1,15 °C. De modo geral, a distribuição dos dados de temperatura para o período chuvoso, estiagem e média anual apresentam padrões semelhantes referindo-se a variância e amplitude. No ano 2008 verifica-se maior variação entre período chuvoso e estiagem (2,13 °C), já o ano de 1983 apresenta menor variação entre os períodos (0,75 °C).

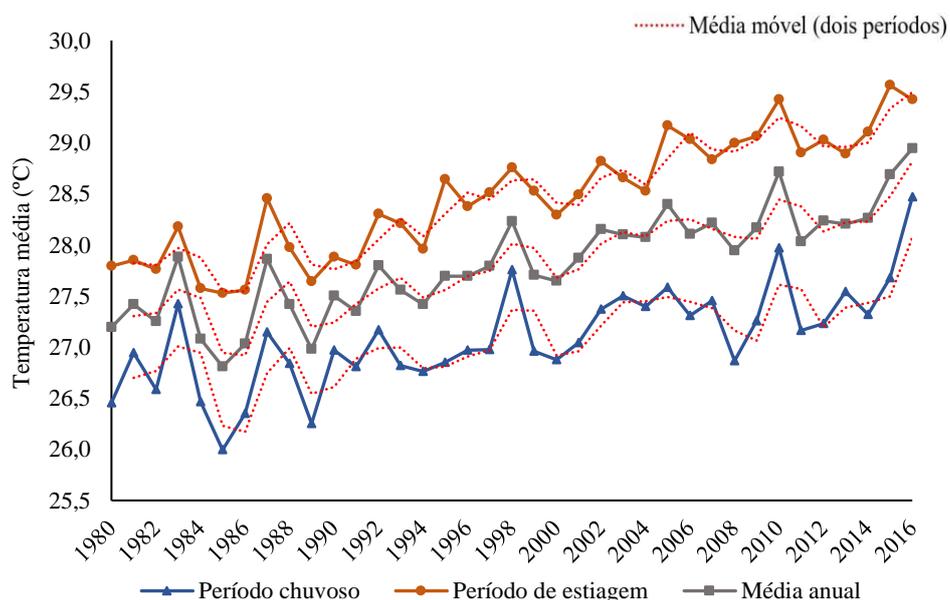


Figura 18 – Comportamento e tendência de diferentes períodos para temperatura média

As alterações nos padrões climáticos não são iguais em todas as regiões do globo, sendo mais ocorrentes nas regiões dos trópicos (MCAFEE, 2013) que apresentam para algumas regiões tendências de esfriar e para outras tendências de aquecer ao longo dos anos (BAJAT *et al.*, 2015), como é o caso da Região Hidrográfica do Xingu-PA. Na

Alemanha a primeira tendência climática foi observada em 1951 com duração de 25 anos e elevação ao longo da série de 1,5 °C na temperatura (TORGOVITSKI, 2015).

Verifica-se pela Figura 19 as séries de umidade relativa do ar média para o período chuvoso, estiagem e média anual, além das linhas de tendência pela média móvel. O padrão descendente apresenta desvios com maiores variações no período de estiagem, menos suavizada em relação aos demais períodos. Alguns intervalos indicam grandes variações, chegando a 4% nos anos de 1982 e 1983 (redução) e nos anos de 1985 e 1986 (aumento). Padrões semelhantes com anomalias foram identificados em Santos (2013) em estudos de determinação de regiões homogêneas no estado do Pará.

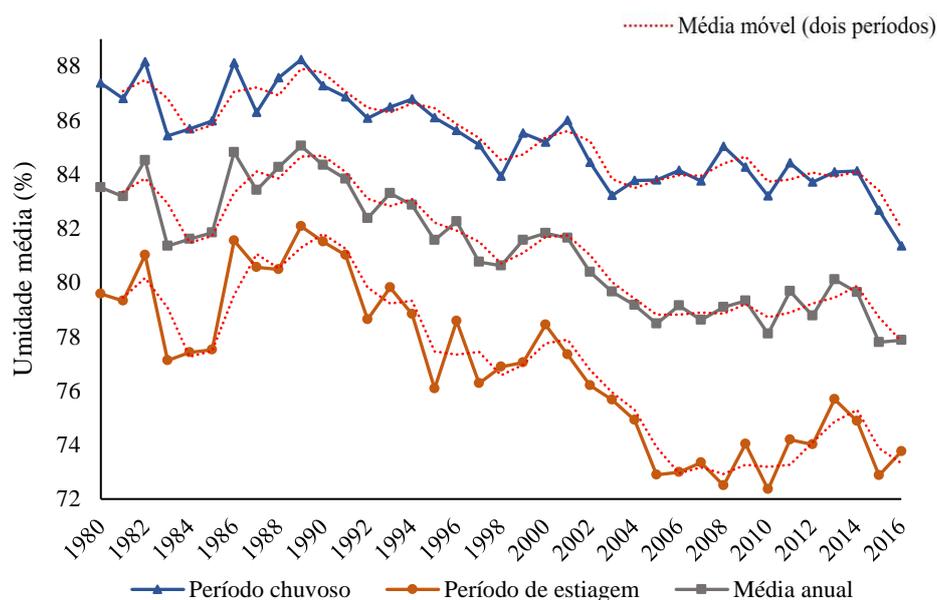


Figura 19 – Comportamento e tendência de diferentes períodos para umidade média

Verifica-se em 2008 (Figura 19) maior variação entre o período chuvoso e de estiagem (12,54%) e no ano de 1987 a menor variação (5,73%). A maior taxa de umidade relativa no ar foi registrada em 1989 (88,25% no período chuvoso), enquanto a menor taxa foi registrada em 2010 (72,35% no período de estiagem). Pode-se observar a alta variabilidade temporal entre os anos considerados atípicos (1982 a 1986) ao se comparar os padrões das séries de umidade relativa do ar (Figura 19) com as séries de precipitação (Figura 17) e temperatura (Figura 18), com altas variações devido as possíveis influências decorrentes das anomalias *El Niño* e *La Niña* na região.

Para amplitude da análise dos padrões climáticos, se verificou de forma isolada os registros das variáveis climáticas das treze EMs delimitadas nesse estudo.

Para dados de precipitação acumulada mensal se observa uniformidade, com alguns padrões mais e menos acentuados identificados em algumas EMs (Figura 20). Para o período chuvoso se verifica de modo geral, padrões semelhantes em todas as EMs, enquanto que no período de estiagem os padrões são bem definidos, indicando menores índices pluviométricos com anomalias observadas em algumas EMs.

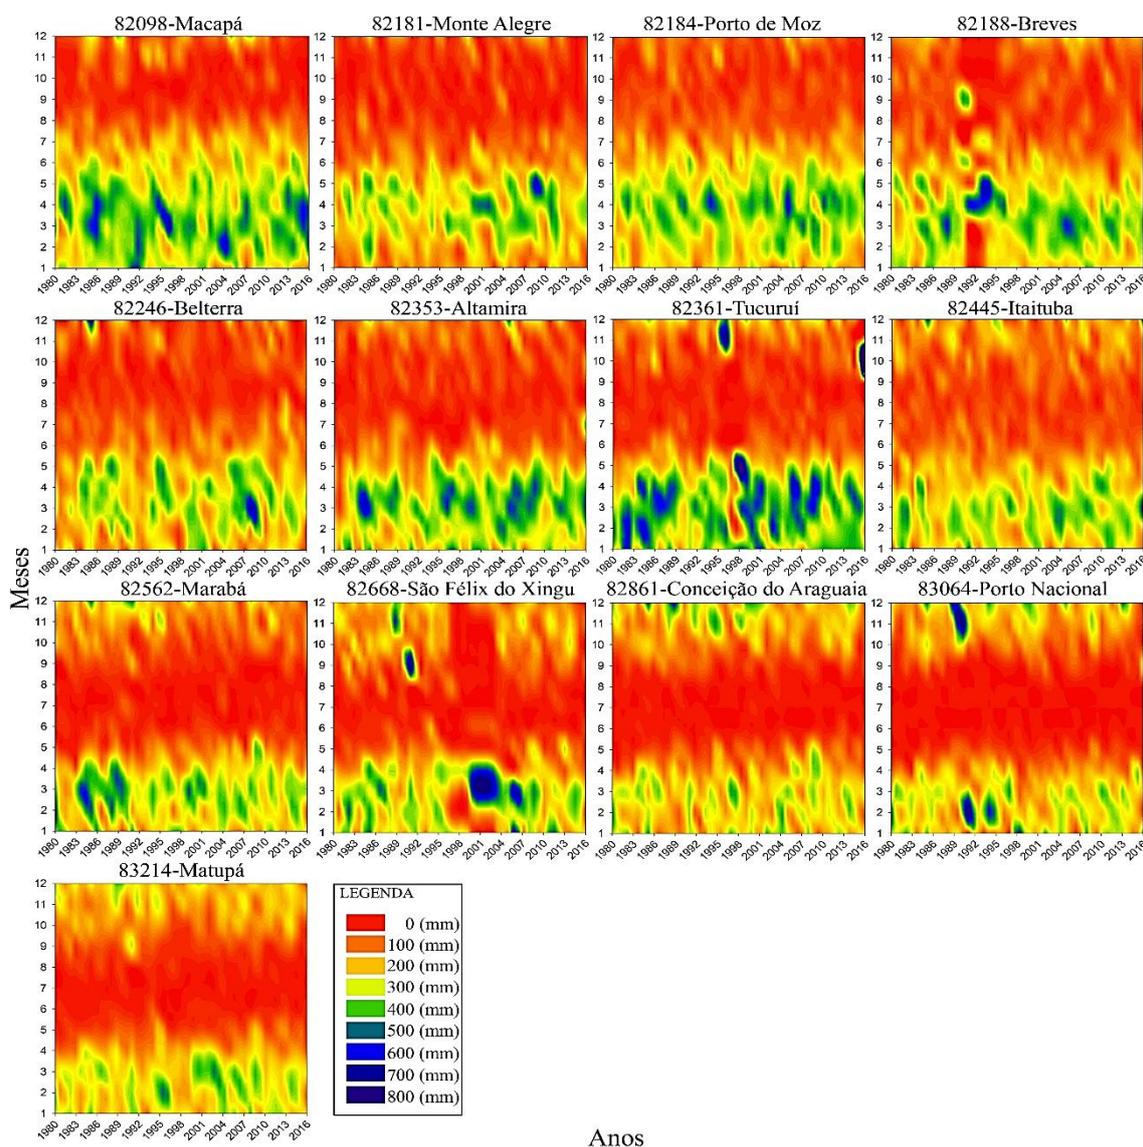


Figura 20 – Padrões de distribuição dos registros individuais das Estações Meteorológicas para precipitação acumulada mensal

É possível identificar períodos atípicos na EM Breves, com menores índices pluviométricos de 1991 a 1993 no período chuvoso, já o período de estiagem apresentou maiores quantidades de precipitação. Comportamento semelhante é observado na EM São Félix do Xingu de 2000 a 2004 no período chuvoso, com menores índices pluviométricos de dezembro a fevereiro, seguido de maiores índices de fevereiro a abril. A mesma EM também apresenta anomalias nos anos de 1989 a 1990 (outubro a dezembro) e 1991 a

1992 (agosto a outubro). Foi registrado na EM Tucuruí maior índice pluviométrico durante o período chuvoso, que estão bem distribuídos, com exceção dos anos 1998 e 2016 que apresentam anomalias no período chuvoso e de estiagem.

Verificam-se nas EMs Conceição do Araguaia, Porto Nacional e Matupá menores índices pluviométricos, com algumas anomalias, como observado na EM Porto Nacional no período de estiagem entre 1990 e 1991, com índice pluviométrico muito acima da média geral para toda a série. Observações semelhantes foram realizadas por Lopes *et al.* (2013), analisando a precipitação no estado do Pará.

As tendências e padrões dos registros de temperatura média mensal de cada EM podem ser observadas na Figura 21.

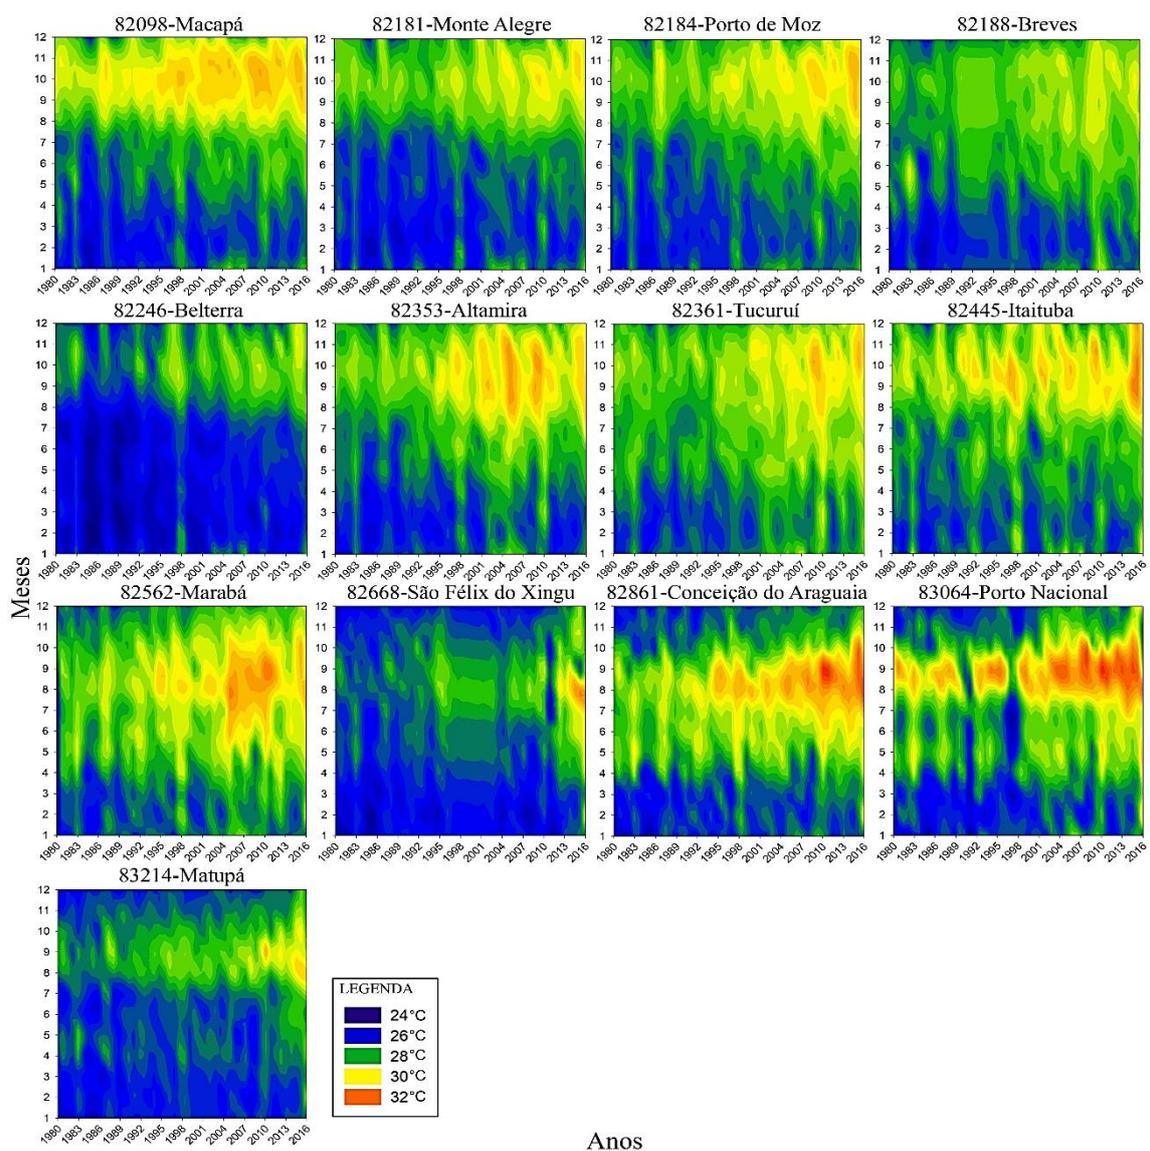


Figura 21 – Padrões de distribuição dos registros individuais das Estações Meteorológicas para temperatura média mensal

Na Figura 21, se observam registros de temperaturas mais elevadas ou fora do padrão em algumas EMs. Os picos máximos de temperatura são identificados entre os meses de agosto e novembro nas EMs Conceição do Araguaia e Porto Nacional que excede 32 °C. A menor temperatura foi registrada em fevereiro de 1985 (24,45 °C) na EM Belterra. Anomalias também são observadas na EM São Félix do Xingu entre os meses de julho a outubro de 2011, com registros de baixas temperaturas no período de estiagem, além de maior variabilidade na distribuição. Padrões semelhantes são verificados na EM Porto Nacional entre os meses de agosto a outubro de 1991 e no ano de 1997.

As tendências e padrões dos registros de umidade média mensal de cada EM podem ser observadas na Figura 22.

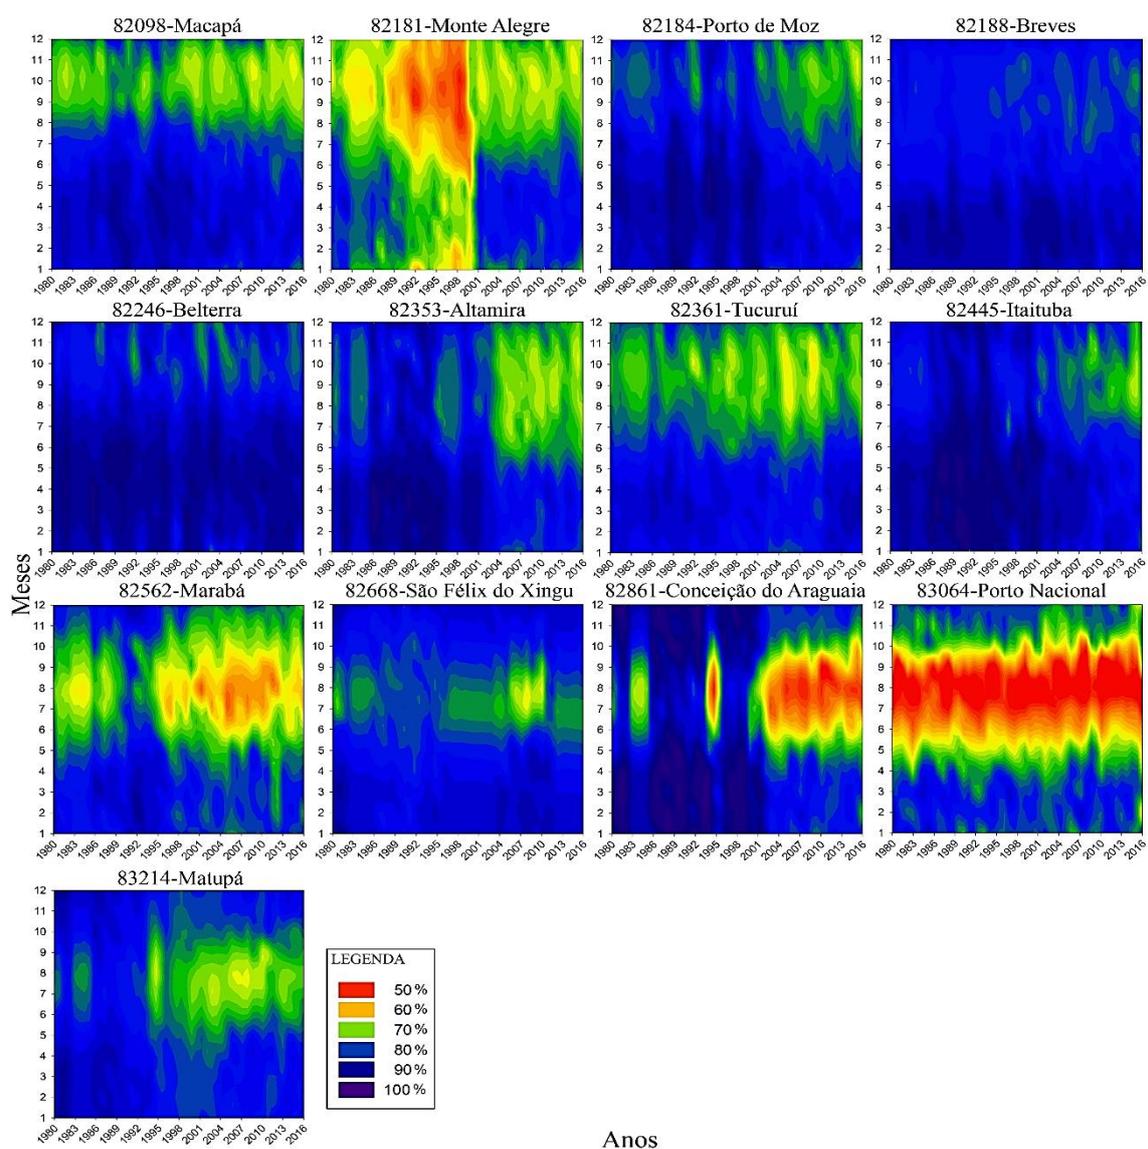


Figura 22 – Padrões de distribuição dos registros individuais das Estações Meteorológicas para umidade média mensal

Verifica-se para o período chuvoso altas taxas de umidade (Figura 22), excedendo em algumas EMs 90%. Na EM Monte Alegre verifica-se comportamento fora do padrão, indicando possíveis anomalias no período chuvoso, que registou menores taxas de umidade nos anos de 1984 a 1989 (janeiro a março), além de redução da umidade relativa do ar no período chuvoso e de estiagem entre os anos de 1989 a 2000. Para o período de estiagem, em todas as EMs se verifica registros médios com menores taxas de umidade relativa do ar, mesmo que sucintos como nas EMs Porto de Moz, Breves, Altamira (1980 a 2004), Belterra e Itaituba.

Embora existam períodos considerados atípicos, algumas EMs possuem padrões mais definidos analisando o período chuvoso e de estiagem, como as EMs Macapá, Tucuruí, Marabá e Porto Nacional. Na EM Porto Nacional, verificam-se as menores taxas de umidade relativa no ar, chegando em 50%. Características similares são observadas na EM Conceição do Araguaia a partir de 2002, além de anomalias nos anos 1983, 1984, 1994 e 1995 (junho a outubro).

As maiores taxas de umidade relativa no ar foram registradas nas seguintes EMs: Porto de Moz, Breves, Belterra, Itaituba e São Félix do Xingu (Figura 22). A partir de 1995, se verifica na EM Matupá queda nas taxas de umidade em todo o período de estiagem. As variações com diferentes padrões no comportamento das EMs em uma mesma região de estudo também foram observadas por Amanajás e Braga (2012) e Santos (2013).

Em regiões com topografia muito irregular, as massas de ar que vêm do oceano sobem ao se aproximar de montanhas atingindo menores temperaturas ocasionando a precipitação. Contudo, quando a umidade reduz drasticamente a partir de determinada altitude o efeito é inverso, reduzindo os índices pluviométricos (TUBELIS, 1983; FERNANDEZ, 2007), podendo ser uma das possíveis explicações para o comportamento de algumas EMs tratadas neste estudo localizadas em maior altitude registrarem menores índices pluviométricos.

O estado do Pará está localizado na zona equatorial, onde o clima é predominante úmido, com ventos constantes e umidade relativa do ar média entorno de 80% (GONÇALVES *et al.*, 2016). Existem padrões atípicos identificados em algumas EMs que apresentam em determinados períodos índices fora do padrão geral (para as três variáveis climáticas). Não é possível identificar analisando individualmente cada EM o comportamento ascendente ou descendente como identificado nas Figuras 15 e 16.

Foi realizada a classificação em posições de ordem decrescente para precipitação acumulada total, temperatura e umidade média das treze EMs para verificar a relação das variáveis climáticas em função da altitude. A classificação em posições dos registros totais de precipitação acumulada pode ser observada na Tabela 7.

Tabela 7 – Ranqueamento dos registros de precipitação acumulada entre os anos de 1980 a 2016

Código - Estação	Registro total (mm)	Altitude (m)
82098 - Macapá (AP)	93353,37	14,46
82184 - Porto de Moz (PA)	84994,19	15,93
82188 - Breves (PA)	80696,70	14,74
82353 - Altamira (PA)	77582,00	74,04
82445 - Itaituba (PA)	76970,81	45,00
82361 - Tucuruí (PA)	75736,44	40,00
82668 - São Félix do Xingu (PA)	69862,82	206,00
82246 - Belterra (PA)	69082,05	175,74
82562 - Marabá (PA)	68930,63	95,00
83214 - Matupá (MT)	67302,13	285,00
82181 - Monte Alegre (PA)	64864,36	145,85
82861 - Conceição do Araguaia (PA)	64706,32	156,85
83064 - Porto Nacional (TO)	61798,91	239,20

Como pode ser observado na Tabela 7, existem menores quantidades de precipitação registradas em EMs localizadas em pontos mais altos, comportamento inverso do esperado (ZAVATTINI, 2009), que pode ser explicado, dentre outros fatores, pelo posicionamento de locação da EM (zona rural ou urbana) e pela forte influência de massas de ar Equatorial Atlântica (mEa) que se formam nas proximidades da linha do Equador atuando na formação de ventos alísios e das massas de ar Equatorial Continental (mEc) com sua origem na Amazônia (BORSATO; MENDONÇA, 2015), conforme ilustrado na Figura 23 para as massas de ar atuantes no Brasil em diferentes épocas do ano.

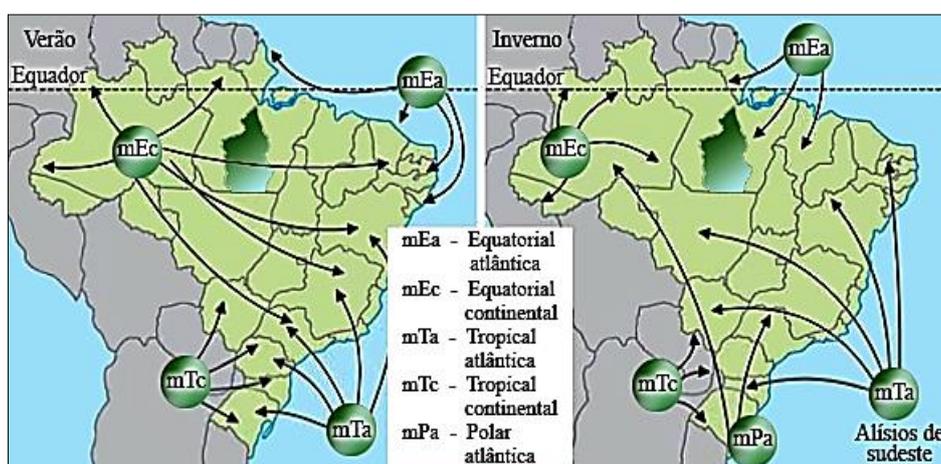


Figura 23 – Comportamento das massas de ar atuantes no Brasil em diferentes épocas

Fonte: Adaptado de Sene e Moreira (1998).

Ao analisar a classificação decrescente do valor médio de temperatura de cada EM em função da altitude (Tabela 8), conforme Fernandez (2007) e Tubelis (1983) que descrevem que a temperatura tende a diminuir com o aumento de altitude devido a maior distância entre a superfície da terra aquecida pelo Sol e em relação ao nível do mar, ou seja, quanto maior a altitude, maior a tendência de queda na temperatura, não se verifica valores inversamente proporcionais em relação à média das temperaturas com a altitude, necessitando de avaliação estatística para apropriada verificação.

Tabela 8 – Ranqueamento dos registros de temperatura média entre os anos de 1980 a 2016

Código - Estação	Média (°C)	Altitude (m)
82562 - Marabá (PA)	28,37	95,00
82361 - Tucuruí (PA)	28,24	40,00
82445 - Itaituba (PA)	28,21	45,00
82861 - Conceição do Araguaia (PA)	28,14	156,85
83064 - Porto Nacional (TO)	28,13	239,20
82098 - Macapá (AP)	28,10	14,46
82353 - Altamira (PA)	28,05	74,04
82184 - Porto de Moz (PA)	27,94	15,93
82188 - Breves (PA)	27,83	14,74
82181 - Monte Alegre (PA)	27,63	145,85
83214 - Matupá (MT)	27,23	285,00
82668 - São Félix do Xingu (PA)	27,05	206,00
82246 - Belterra (PA)	26,74	175,74

A classificação da média de umidade no ar pode ser observada na Tabela 9, que apresenta o mesmo comportamento distinto das variáveis climáticas precipitação e temperatura ao se analisar a relação entre altitude e as taxas médias registradas.

Tabela 9 – Ranqueamento dos registros de umidade média do ar entre os anos de 1980 a 2016

Código - Estação	Média (%)	Altitude (m)
83064 - Porto Nacional (TO)	87,51	239,20
82184 - Porto de Moz (PA)	86,71	15,93
82861 - Conceição do Araguaia (PA)	85,58	156,85
82445 - Itaituba (PA)	84,49	45,00
82181 - Monte Alegre (PA)	83,47	145,85
82353 - Altamira (PA)	83,38	74,04
83214 - Matupá (MT)	82,55	285,00
82562 - Marabá (PA)	81,49	95,00
82098 - Macapá (AP)	80,29	14,46
82246 - Belterra (PA)	78,85	175,74
82188 - Breves (PA)	76,88	14,74
82361 - Tucuruí (PA)	72,85	40,00
82668 - São Félix do Xingu (PA)	69,38	206,00

Verifica-se que os posicionamentos no ranking sofrem alterações de acordo com cada variável climática, com exceção da EM Porto de Moz que está igualmente ranqueada para registros de precipitação acumulada e umidade relativa do ar. A análise estatística que relaciona a altitude com as variáveis climáticas foi realizada por Regressão Linear Múltipla (RLM).

4.2 Altitude e variáveis climáticas

A aplicação da análise de RLM possibilitou a construção de modelos estatísticos que descrevem a relação entre as variáveis explicativas (precipitação acumulada, temperatura e umidade média) em função da altitude com dados das treze EMs (Tabela 7, 8, 9), adotando um nível de significância de 5%. O primeiro modelo proposto levou em consideração todas as variáveis climáticas, conforme a Equação (4.1).

$$Alt = \beta_0 + \beta_1 P_{ac} + \beta_2 T_{méd} + \beta_3 U_{méd} \quad (4.1)$$

em que: *Alt* é a variável dependente altitude (m); P_{ac} , $T_{méd}$ e $U_{méd}$ são as variáveis independentes (explicativas) precipitação acumulada, temperatura média e umidade relativa do ar média; e β_0 , β_1 , β_2 e β_3 os estimadores obtidos por RLM.

A Tabela 10 apresenta as principais estatísticas obtidas por RLM do modelo considerando todas as variáveis independentes (P_{ac} , $T_{méd}$ e $U_{méd}$).

Tabela 10 – Estatísticas da relação entre precipitação acumulada, temperatura média e umidade relativa do ar média em função da altitude

	Coefficientes	Erro padrão	Teste T	p-valor	R^2	$R^2_{ajustado}$	Erro padrão
Interseção	2593,6389	777,1478	3,3374	0,0087	0,7914	0,7219	48,5187
P_{ac}	-0,0069	0,0016	-4,1771	0,0024			
$T_{méd}$	-77,7348	31,4896	-2,4686	0,0357			
$U_{méd}$	2,3407	2,9132	0,8035	0,4424			

Hipóteses $\rightarrow H_0: \beta = 0$; e $H_1: \beta \neq 0$; em que $\beta = \beta_0, \beta_1, \dots, \beta_n$. A rejeição de H_0 (p-valor (x) < α) implica que as variáveis independentes contribuem significativamente para o modelo, em que $x = x_1, x_2, \dots, x_n$ e $1, 2, \dots, n$ são os p-valores das variáveis independentes ao nível de significância de 5%.

Contudo, como pode ser observado na Tabela 10, todas as estimativas foram satisfatórias com exceção da variável previsora para $U_{méd}$ pela análise do p-valor, não atendendo ao nível de significância predeterminado de 5% ($0,4424 > 0,05$). Desta forma, aceita-se a hipótese nula (H_0) assumindo que o valor estimado para β_3 (2,3407) seja estatisticamente igual a zero, não havendo assim, sentido em ser mantido no modelo uma vez que influenciaria os demais estimadores (β_0 , β_1 e β_2) reduzindo sua precisão.

Portanto, as demais estatísticas desse modelo não foram verificadas uma vez que o pressuposto referente ao nível de significância não foi atendido.

Posteriormente, novos modelos foram gerados e por meio das análises do nível de significância, coeficiente de determinação (R^2 e $R^2_{ajustado}$) e avaliação dos resíduos (verificação de normalidade, independência e homogeneidade de variância), foi possível identificar o melhor modelo que descreve a relação das variáveis em função da altitude.

Tabela 11 – Estatísticas da relação entre precipitação acumulada, temperatura média em função da altitude

	Coefficientes	Erro padrão	Teste T	p-valor	R^2	$R^2_{ajustado}$	Erro padrão
Interseção	2503,6528	755,2847	3,3148	0,0078	0,7764	0,7317	47,6512
P_{ac}	-0,0072	0,0016	-4,5980	0,0010			
$T_{méd}$	-66,8196	27,9006	-2,3949	0,0376			

Hipóteses $\rightarrow H_0: \beta = 0$; e $H_1: \beta \neq 0$; em que $\beta = \beta_0, \beta_1, \dots, \beta_n$. A rejeição de H_0 (p-valor (x) $< \alpha$) implica que as variáveis independentes contribuem significativamente para o modelo, em que $x = x_1, x_2, \dots, x_n$ e $1, 2, \dots, n$ são os p-valores das variáveis independentes ao nível de significância de 5%.

Conforme a Tabela 11, todos os estimadores dos parâmetros calculados por RLM foram significativos ao nível de 5%. Pela análise do coeficiente de determinação (R^2), verifica-se que 77,64% dos dados podem ser explicados pelo modelo, utilizando como variáveis explicativas apenas a P_{ac} e a $T_{méd}$, sendo considerado um bom modelo conforme apresentado em Virgillito (2007) definido para valores acima de 70%. O modelo pode ser expresso conforme a Equação (4.2).

$$Alt = -0,0072P_{ac} - 66,8196T_{méd} + 2503,6528 \quad (4.2)$$

Pela Equação (4.2) se verifica que, assumindo valores iguais a zero para dados de P_{ac} e $T_{méd}$, obtém-se um valor fixo de Alt igual a 2503,6528 (m). Porém, dado cada acréscimo de unidade para P_{ac} e $T_{méd}$, se tem um decréscimo de 0,0072 (P_{ac}) e 66,8196 ($T_{méd}$) unidades na Alt , ou seja, quanto maiores os índices de P_{ac} e $T_{méd}$, menor será a Alt ao nível de 95% de confiabilidade. Portanto, o modelo possibilita compreender melhor a dinâmica do regime climático da região no período observado.

A validação se deu pela análise dos resíduos gerados pela regressão, verificando primeiramente se os valores seguem uma distribuição normalizada conforme apresentado na Tabela 12 para os testes de Anderson-Darling, Kolmogorov-Smirnov, Shapiro-Wilk e Ryan-Joiner, que não apresentam indícios para rejeição da hipótese H_0 , ao nível de significância de 5%.

Tabela 12 – Teste de normalidade dos resíduos da relação altimétrica com as variáveis climáticas

Testes	Estatísticas	p-valor
Anderson - Darling	0,569772	0,1127
Kolmogorov - Smirnov	0,180602	0,2925
Shapiro - Wilk	0,891721	0,1030
Ryan - Joiner	0,951807	0,1502

Hipótese: H_0 = possui distribuição normal (p-valor $(x) \geq \alpha$); H_1 = não possui distribuição normal (p-valor $(x) < \alpha$); em que $x = x_1, x_2, \dots, x_n$ e 1, 2, ..., n são os p-valores calculados de cada teste para $\alpha = 0,05$.

A homogeneidade de variância (homoscedasticidade) dos resíduos, foi verificado pelo teste de Breusch-Pagan, uma vez verificada a normalidade nos resíduos. O teste verifica a hipótese de igualdade da variância dos resíduos versus a hipótese da homoscedasticidade ser uma função multiplicativa de uma ou mais variáveis pertencentes ou não ao modelo em questão. Os resultados podem ser verificados na Tabela 13.

Tabela 13 – Verificação da homoscedasticidade dos resíduos pelo teste de Breusch-Pagan

Qui-Quadrado	Grau de liberdade	p-valor
0,0629	1	0,8019

Hipótese: H_0 = possuem homogeneidade de variância (p-valor $\geq \alpha$); H_1 = não possuem homogeneidade de variância (p-valor $< \alpha$); nível de significância adotado de 5% ($\alpha = 0,05$).

Portanto, considerando o nível de significância de 5%, é possível verificar que não houve violação da homogeneidade de variância para os resíduos, dessa forma, aceita-se a hipótese H_0 assumindo homoscedasticidade pela análise do p-valor ($0,8019 > 0,05$) pelo teste de Breusch-Pagan. Para análise de independência dos resíduos, assume-se essa suposição uma vez que a própria estrutura de coleta dos dados assume essa independência, pela forma de coleta dos dados ao longo do tempo e aos distintos pontos de coleta (EMs), dispensando testes para a verificação de independência. O mesmo critério para independência dos dados climáticos foi adotado em Lazzari *et al.* (2011), Melo *et al.* (2017) e Souza *et al.* (2017).

Desta forma, não houve quebra das pressuposições ao nível de significância predefinido e validação pela análise dos resíduos, uma vez constatado a normalidade, homogeneidade de variância e assumindo independência, ou seja, assume-se a hipótese H_0 (pág. 51) para o modelo utilizando as variáveis explicativas P_{ac} e $T_{méd}$.

Em estudos para análise da correlação entre precipitação e temperatura em relação a altitude, Pacheco *et al.* (2012) utilizando regressão linear identificaram fraca correlação entre precipitação e altitude, enquanto que para temperatura e altitude o modelo

apresentou correlação moderada. Já Cruz *et al.* (2013) utilizaram a RLM para obter uma equação que correlacionasse fatores de localização espacial e valores anuais de precipitação para 58 postos distribuídos pelo estado de Sergipe. Seus resultados apresentaram coeficiente de determinação de 84,4%.

4.3 Análise descritiva dos padrões climáticos da Região Hidrográfica do Xingu-PA

Pela análise descritiva dos dados mensais de precipitação acumulada, temperatura e umidade média (Tabela 14), observa-se que as variáveis climáticas apresentam comportamentos distintos, sendo a precipitação a com maior variabilidade na distribuição dos dados, com registro mínimo (11,66 mm em agosto de 2001) muito distante do registro máximo (457,23 mm em fevereiro de 2004), verificado pelo coeficiente de variação (CV) com alta variabilidade, conforme proposto em Warrick e Nielsen (1980) categorizando o CV em variabilidade baixa ($CV \leq 12\%$), média ($12\% < CV \leq 60\%$) e alta ($CV > 60\%$). As variáveis temperatura e umidade média mensal apresentaram baixa variabilidade.

Tabela 14 – Análise descritiva de precipitação acumulada, temperatura e umidade média mensal

Atributos	n	Média (\bar{X})	Mediana	Mínimo	Máximo	S	C_s	CV (%)
Precipitação	444	165,61	137,36	11,66	457,23	106,8	0,55	64,50
Temperatura	444	27,82	27,83	25,60	30,44	0,97	0,16	3,49
Umidade	444	81,25	81,86	68,97	89,96	4,94	-0,44	6,08

n : número de observações; S : desvio padrão; C_s : coeficiente de assimetria; CV : coeficiente de variação.

Resultados similares foram obtidos em Ramos *et al.* (2009), que constatou pelo CV alta variabilidade nos dados de precipitação e baixa variabilidade nos dados de temperatura e umidade média na cidade de Petrolina (PE), identificando meses sem e com baixos registros de chuva. Analisando dados de precipitação mensal em Uberaba (MG), Silva *et al.* (2003) observaram através do CV variação média à alta, devido a total ausência de chuva nos meses do período de estiagem em alguns anos, explicando a grande variabilidade nos dados. A alta variação em dados de precipitação também foi analisada por Cardim (2001) no estado de São Paulo.

Pela análise da média e mediana, um conjunto de dados pode ser negativamente assimétrico à esquerda (média < mediana) ou positivamente assimétrico à direita (média > mediana). Partindo deste pressuposto, os dados de precipitação possuem assimetria positiva, enquanto os dados de temperatura e umidade possuem assimetria negativa

(Tabela 14). Contudo, não é correto afirmar que a forma de distribuição dos dados de temperatura possui assimetria negativa. Conforme apresentado em Triola (2013), a verificação de assimetria da curva não pode ser realizada com base apenas na média e mediana, onde o coeficiente de assimetria (C_s) deve ser considerado como decisivo para definição da característica da curva, que sendo positivo a curva de densidade será assimétrica à direita e sendo negativo a curva será assimétrica à esquerda.

Considerando os conceitos descritos em Triola (2013), conforme verificado pelo C_s , os dados de precipitação e temperatura possuem assimetria positiva e os dados de umidade assimetria negativa (Tabela 14). Já o afastamento entre média e mediana como observado na precipitação, indica que valores no topo da distribuição estão muito distantes em comparação aos valores inferiores, o que indica registros muito acima da média, com maiores índices pluviométricos em alguns meses, enquanto outros apresentam baixos índices pluviométricos.

Com objetivo de facilitar a extração de informações sobre o comportamento dos dados de precipitação, temperatura e umidade relativa do ar, foi realizada uma análise por frequências, onde os dados (n) foram divididos em 10 classes pela regra de Sturges [Equação (3.9)], descrita em Chwif e Medina (2010).

A distribuição de frequência dos dados de precipitação acumulada mensal pode ser observada na Tabela 15, com intervalo de classe de 44,56 (mm).

Tabela 15 – Distribuição de frequências e densidade de precipitação acumulada mensal

Classe	f_i	f_{ri}	p_i	f_{ac}	Densidade	Ponto Médio
11,66 - 56,22	76	0,17	17,12	17,12	0,004	33,94
56,22 - 100,77	86	0,19	19,37	36,49	0,004	78,50
100,77 - 145,33	66	0,15	14,86	51,35	0,003	123,05
145,33 - 189,89	51	0,11	11,49	62,84	0,003	167,61
189,89 - 234,44	34	0,08	7,66	70,50	0,002	212,17
234,44 - 279,00	46	0,10	10,36	80,86	0,002	256,72
279,00 - 323,56	39	0,10	8,78	89,64	0,002	301,28
323,56 - 368,11	32	0,07	7,21	96,85	0,002	345,84
368,11 - 412,67	10	0,02	2,25	99,10	0,001	390,39
412,67 - 457,23	4	0,01	0,90	100,00	0,000	434,95

Precipitação acumulada mensal (mm); f_i : frequência absoluta; f_{ri} : frequência relativa; p_i : frequência percentual; f_{ac} : frequência acumulada.

Observa-se (Tabela 15) que o conjunto de valores extremos (compreende as duas classes extremas) correspondem a uma minoria dos valores na distribuição, representando apenas 3% dos registros observados. Também se verifica predominância de registros

abaixo da média ($\bar{X} = 165,61$ mm) totalizando 58% das observações, além de registros mínimos (mais distante da média) que correspondem 17%. Portanto, os dados de precipitação acumulada mensal apontam fortes indícios de influências de anomalias climáticas, uma vez identificados registros extremos (máximos e mínimos) distantes da média. O ponto médio é definido pela média dos limites superiores e inferiores de cada classe, respectivamente.

Registros e tendências de índices climáticos extremos foram estudados por Santos *et al.* (2012), baseados em dados de precipitação na região de Manaus-AM e região contigua entre os anos de 1971 a 2007, verificando forte influência de anomalias oceânicas em alguns períodos para registros máximos e mínimos de precipitação. Registros extremos distantes da média também foram verificados por Aguilar *et al.* (2009) em estudos sobre mudanças na temperatura e precipitação no oeste da África Central entre os anos de 1955 a 2006, devido as mudanças climáticas extremas globais.

Pela Tabela 16 pode-se observar a distribuição de frequência e densidade dos dados de temperatura média mensal. Considerando o número de amostras contidas em cada classe com intervalo aproximado de 0,48 (°C), é possível verificar que 49,8% das observações ($n = 444$) estão abaixo da média ($\bar{X} = 27,82$ °C).

Tabela 16 – Distribuição de frequências e densidade de temperatura média mensal

Classe	f_i	f_{ri}	p_i	f_{ac}	Densidade	Ponto Médio
25,60 - 26,09	7	0,02	1,58	1,58	0,033	25,84
26,09 - 26,57	34	0,08	7,66	9,23	0,158	26,33
26,57 - 27,05	70	0,16	15,77	25,00	0,326	26,81
27,05 - 27,54	69	0,16	15,54	40,54	0,321	27,30
27,54 - 28,02	79	0,17	17,79	58,33	0,367	27,78
28,02 - 28,51	74	0,16	16,67	75,00	0,344	28,27
28,51 - 28,99	52	0,12	11,71	86,71	0,242	28,75
28,99 - 29,48	37	0,08	8,33	95,05	0,172	29,23
29,48 - 29,96	17	0,04	3,83	98,87	0,079	29,72
29,96 - 30,44	5	0,01	1,13	100,00	0,023	30,20

Temperatura média mensal (°C); f_i : frequência absoluta; f_{ri} : frequência relativa; p_i : frequência percentual; f_{ac} : frequência acumulada.

Os registros extremos de temperaturas médias mais elevadas correspondem a 5% (duas classes), enquanto que os menores registros representam 10% (duas classes). De modo geral, os dados estão em sua maioria variando em torno da média. As observações ($f_i = 5$) que representam os registros mais elevados da série correspondem a 1%, enquanto que as observações dos menores registros ($f_i = 7$) representam 2% do total dos dados, apresentando valores extremos.

Resultados semelhantes foram verificados em Aguilar *et al.* (2009) no oeste da África Central, em Barbosa *et al.* (2014) na cidade de Viçosa-MG, em Ramos *et al.* (2009) na cidade de Petrolina-PE e Santos (2013) em estudos realizados no estado do Pará.

Pela Tabela 17 verifica-se a distribuição de frequências para dados de umidade relativa do ar média mensal com intervalo de classe 2,1 (%). Como pode ser observado, a média ($\bar{X} = 81,25\%$) e a mediana (81,86%) não ficaram contidas na mesma classe apesar da proximidade, o que indica maior variabilidade dos dados em comparação com os dados de temperatura média mensal. Verifica-se que 52,71% das observações estão abaixo da média, já na avaliação considerando as classes se verifica 51% abaixo da média.

As observações indicam que os menores registros (considerando três classes) que representam 14% das observações não influenciam na média geral, que apresentou assim como descrito em Gonçalves *et al.* (2016), umidade relativa média mensal aproximada de 80%. Os picos extremos máximos correspondem a 5% das observações, enquanto que os picos mínimos correspondem a 4% (Tabela 17).

Tabela 17 – Distribuição de frequências e densidade de umidade relativa do ar média mensal

Classe	f_i	f_{ri}	p_i	f_{ac}	Densidade	Ponto Médio
68,97 - 71,07	16	0,04	3,60	3,60	0,017	70,02
71,07 - 73,17	15	0,03	3,38	6,98	0,016	72,12
73,17 - 75,27	29	0,07	6,53	13,51	0,031	74,22
75,27 - 77,37	43	0,10	9,68	23,20	0,046	76,32
77,37 - 79,47	49	0,11	11,04	34,23	0,053	78,42
79,47 - 81,57	63	0,14	14,19	48,42	0,068	80,52
81,57 - 83,67	62	0,14	13,96	62,39	0,067	82,62
83,67 - 85,77	73	0,16	16,44	78,83	0,078	84,72
85,77 - 87,87	72	0,16	16,22	95,05	0,077	86,82
87,87 - 89,96	22	0,05	4,95	100,00	0,024	88,91

Umidade relativa do ar média mensal (%); f_i : frequência absoluta; f_{ri} : frequência relativa; p_i : frequência percentual; f_{ac} : frequência acumulada.

Para representar o histograma com as curvas de densidade de probabilidade normal e não-paramétrica para avaliação de ajuste das variáveis climáticas, a altura de cada barra foi definida pela densidade, sendo a frequência relativa (f_{ri}) dividida pelo intervalo de classe referente a cada variável climática.

Conforme apresentado na Figura 24, podem ser observados a distribuição dos dados de precipitação acumulada, temperatura e umidade relativa do ar média mensal no histograma combinado com as curvas de densidade de probabilidade normal e não-paramétrica.

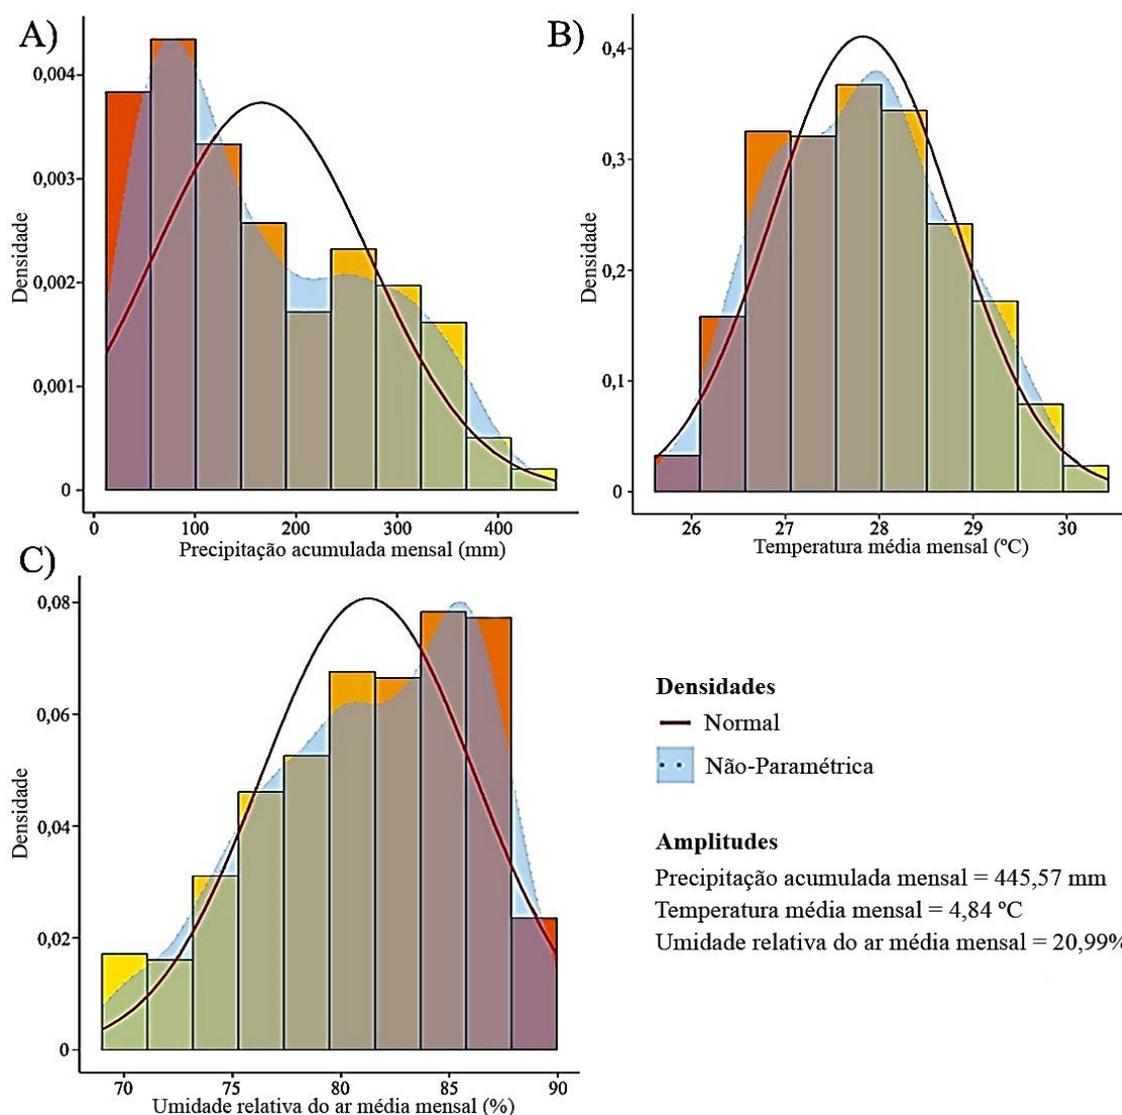


Figura 24 – Histograma de densidades para dados de precipitação acumulada mensal (A); temperatura média mensal (B); e umidade relativa do ar média mensal (C)

Conforme a Figura 24, observa-se pelas curvas de densidade que os conjuntos de dados não possuem distribuição normalizada, sendo caracterizadas como não-paramétricas. Verificam-se mudanças no comportamento das curvas não-paramétricas, que apresentam picos distintos caracterizando-as como bimodal, que pode ser explicada pela mudança nas tendências e variações devido aos registros de valores extremos no conjunto de dados tendenciando a média.

Com intuito de identificar os meses com maior variabilidade, foram realizadas verificações enfatizando os períodos chuvoso e de estiagem. As análises descritivas referentes a cada mês podem ser observadas nas Tabelas 18, 19 e 20, onde foram destacados o período chuvoso (em azul), de estiagem (em vermelho) e de transição (em branco) para as séries das variáveis climáticas.

Para dados de precipitação acumulada mensal (Tabela 18) no período chuvoso, se observa comportamento com padrões mais variados no mês de dezembro ($CV = 39,05\%$), com valor máximo no ano de 1985 muito distante do mínimo no ano de 2015, com alto desvio padrão, caracterizando como registros atípicos. Para o período de estiagem, se verifica maior variabilidade no mês de setembro ($CV = 57,97\%$). Todos os meses são caracterizados com média variabilidade de acordo com os limites propostos em Warrick e Nielsen (1980). Os meses de março ($CV = 16,04\%$) e junho ($CV = 29,11\%$) apresentam menor variabilidade para os períodos chuvoso e estiagem.

Tabela 18 – Análise descritiva dos dados de precipitação acumulada mensal para análise do período chuvoso e de estiagem da Região Hidrográfica do Xingu-PA

Meses	<i>n</i>	Média (\bar{X})	Mediana	Mínimo	Máximo	<i>S</i>	C_s	<i>CV</i> (%)
Janeiro	37	246,09	246,57	114,34	375,51	61,62	-0,003	25,04
Fevereiro	37	281,93	295,18	181,68	457,23	60,06	0,440	21,30
Março	37	335,39	347,96	207,30	434,67	53,80	-0,480	16,04
Abril	37	283,29	288,27	154,32	376,33	51,77	-0,320	18,27
Mai	37	189,87	184,11	89,02	352,50	53,09	0,630	27,96
Junho	37	104,70	101,71	30,91	179,67	30,47	0,200	29,11
Julho	37	69,11	68,15	26,06	124,67	23,80	0,540	34,44
Agosto	37	40,79	40,47	11,66	79,47	16,10	0,470	39,47
Setembro	37	55,92	47,92	15,38	186,64	32,41	1,940	57,97
Outubro	37	86,41	83,25	31,91	134,54	25,82	-0,170	29,88
Novembro	37	121,29	114,78	61,35	217,50	35,86	0,590	29,57
Dezembro	37	172,49	170,85	90,40	408,05	67,35	1,490	39,05

n: número de observações; *S*: desvio padrão; C_s : coeficiente de assimetria; *CV*: coeficiente de variação.

O mês de janeiro apresenta assimetria (C_s) negativa, porém próximo de zero, tendenciando a curva de probabilidade à simetria, com pequena variação entre média e mediana. O mês de março apresenta menor variabilidade (*CV*) e curva de probabilidade negativamente assimétrica à esquerda. Também se observa mudanças no C_s entre os meses, com ênfase para o período chuvoso, indicando variações no comportamento da curva de densidade.

Pela análise referente aos dados de temperatura mensal (Tabela 19) se verifica baixa variabilidade pela avaliação do *CV* (WARRICK; NIELSEN, 1980) em todos os meses observados, onde o período de estiagem se mostrou o mais variado. Pelo C_s se observam mudanças no comportamento da curva de densidade e assimetria no período chuvoso e estiagem. Os meses de janeiro ($CV = 2,34\%$) e agosto ($CV = 2,39\%$) apresentaram maior variabilidade nos períodos chuvoso e estiagem.

Tabela 19 – Análise descritiva dos dados de temperatura mensal para análise do período chuvoso e de estiagem da Região Hidrográfica do Xingu-PA

Intervalo	<i>n</i>	Média (\bar{X})	Mediana	Mínimo	Máximo	<i>S</i>	C_s	<i>CV</i> (%)
Janeiro	37	26,96	26,92	25,64	28,41	0,63	0,230	2,34
Fevereiro	37	26,70	26,67	25,60	28,68	0,61	0,970	2,30
Março	37	26,82	26,90	25,83	28,35	0,50	0,690	1,85
Abril	37	27,22	27,06	26,18	28,57	0,57	0,240	2,10
Maio	37	27,63	27,61	26,45	28,93	0,58	0,180	2,10
Junho	37	27,80	27,86	26,49	28,85	0,55	-0,240	1,98
Julho	37	27,98	28,01	26,85	29,36	0,62	-0,010	2,20
Agosto	37	28,72	28,85	27,71	30,24	0,69	0,150	2,39
Setembro	37	29,03	29,09	27,73	30,31	0,65	-0,060	2,22
Outubro	37	28,84	28,88	27,65	30,44	0,59	0,220	2,06
Novembro	37	28,39	28,23	27,44	29,96	0,59	0,510	2,07
Dezembro	37	27,77	27,73	26,19	29,39	0,65	0,120	2,33

n: número de observações; *S*: desvio padrão; C_s : coeficiente de assimetria; *CV*: coeficiente de variação.

Analisando a distribuição espacial e temporal em estudos utilizando o índice de anomalia de chuva para classificação de períodos úmidos e secos no estado do Mato Grosso, Marcuzzo e Melo (2011) observaram grande variação nos índices pluviométricos e temperaturas nos meses entre os anos de 1977 a 2006, que sofrem grande influência das massas de ar atuantes no Brasil e anomalias oceânicas como *El Niño* e *La Niña*.

Pelos dados de umidade relativa do ar mensal (Tabela 20), se verifica que todos os meses possuem baixa variabilidade de acordo com a classificação de Warrick e Nielsen (1980). O mês com maior variabilidade no período chuvoso foi dezembro ($CV = 3,10\%$) e no período de estiagem foi agosto ($CV = 4,82\%$). Pela avaliação do C_s se observam mudanças no comportamento da curva de densidade e assimetrias distintas em ambos os períodos. Esse comportamento pode ser relacionado as influências de anomalias oceânicas como descrito em Holanda *et al.* (2016) e Melo *et al.* (2015).

Tabela 20 – Análise descritiva dos dados de umidade relativa do ar mensal para análise do período chuvoso e de estiagem da Região Hidrográfica do Xingu-PA

Intervalo	<i>n</i>	Média (\bar{X})	Mediana	Mínimo	Máximo	<i>S</i>	C_s	<i>CV</i> (%)
Janeiro	37	85,11	85,47	80,85	89,43	2,03	-0,320	2,38
Fevereiro	37	86,40	86,35	80,53	89,71	1,85	-0,620	2,14
Março	37	86,71	87,02	82,61	89,84	1,52	-0,120	1,76
Abril	37	86,11	86,26	83,14	89,96	1,70	0,180	1,98
Maio	37	83,98	84,33	80,23	87,69	1,90	-0,280	2,26
Junho	37	80,32	80,39	75,84	85,43	2,60	0,170	3,24
Julho	37	77,23	77,46	71,59	82,97	3,06	0,050	3,97
Agosto	37	74,78	74,61	69,09	80,32	3,60	0,060	4,82
Setembro	37	75,20	75,56	68,97	80,51	3,37	-0,180	4,48
Outubro	37	77,26	77,12	70,38	82,56	2,85	-0,150	3,96
Novembro	37	79,69	79,90	73,91	84,14	2,47	-0,390	3,10
Dezembro	37	82,23	82,60	76,24	87,86	2,55	-0,390	3,10

n: número de observações; *S*: desvio padrão; C_s : coeficiente de assimetria; *CV*: coeficiente de variação.

Em estudos decorrentes de observações nas mesorregiões do estado do Pará para climatologia, tendências e variabilidade na precipitação entre os períodos de 1978 a 2008, Albuquerque *et al.* (2010) observaram grande variabilidade nos índices de precipitação na região sudeste e sudoeste, com tendências negativas no verão indicando diminuição das chuvas, como identificadas neste estudo.

Na avaliação mensal das séries de temperatura e umidade relativa do ar, foram verificadas baixa variabilidade (WARRICK; NIELSEN, 1980), embora existam fortes evidências da influência dos fenômenos *El Niño* e *La Niña* na região (DINEZIO *et al.*, 2017; SOUZA JÚNIOR *et al.*, 2009) que tiveram maior representatividade ao se analisar índices de precipitação.

4.4 Análise da distribuição de densidade de probabilidade

Foram verificadas pelo teste de aderência de Anderson-Darling e Kolmogorov-Smirnov a distribuição (Normal, Log-Normal, Exponencial, Logística, Gama, Weibull, Gumbel, Cauchy, Rice e Rayleigh) que melhor descreve as séries mensais das variáveis climáticas, onde não foi possível identificar para todo o intervalo (1980 a 2016) aderência às distribuições verificadas. Portanto, a verificação foi realizada por intervalos (anos), considerando toda a série, reduzindo-a gradativamente até se obter aderência a algum tipo de distribuição pela análise do p-valor ao nível de 5% de significância, observando o ano de ruptura ou mudança de comportamento dos dados para cada variável.

Pela Tabela 21 se observa o tipo de distribuição que melhor se aderiu considerando o maior intervalo possível para a série de precipitação acumulada mensal.

Tabela 21 – Identificação do tipo de distribuição de probabilidade por intervalos para precipitação acumulada mensal

Intervalo	Tipo de distribuição	p-valor
1980 - 1987	Log-Normal (log(mu) = 4,85069; log(sigma) = 0,729682)	0,0881
1988 - 1992	Weibull (Forma = 1,80741; Escala = 193,345)	0,0556
1993 - 1996	Weibull (Forma = 1,66833; Escala = 189,171)	0,0634
1997 - 2001	Weibull (Forma = 1,49149; Escala = 175,193)	0,0643
2002 - 2005	Log-Normal (log(mu) = 4,84389; log(sigma) = 0,764136)	0,1098
2006 - 2007	Log-Normal (log(mu) = 4,88103; log(sigma) = 0,777951)	0,3838
2008 - 2010	Weibull (Forma = 1,54177; Escala = 194,841)	0,0705
2011 - 2016	Gama (Forma = 2,18531; Taxa = 0,0135588)	0,1198

p-valor ($x \geq \alpha$) indica aderência a distribuição no intervalo observado, em que: $x = x_1, x_2, \dots, x_n$ e 1, 2, ..., n são os p-valores calculados de cada distribuição ao nível de significância de 5% ($\alpha = 0,05$).

Observam-se em diferentes intervalos sequenciais aderência ao mesmo tipo de distribuição, porém, com fatores de forma e escala (distribuição Weibull) log da média e log de sigma (distribuição Log-Normal) diferentes, indicando mudança nos padrões de comportamento climático na região (Tabela 21).

Quadros *et al.* (2011) verificaram ajuste à distribuição Gumbel em estudos para geração de equações de chuva em Cascavel-PR. Avaliando os dados de precipitação mensal no sudoeste do estado da Bahia, Murta *et al.* (2005) verificaram ajuste à distribuição Gama em duas séries históricas.

Identificadas as distribuições em cada intervalo, é possível verificar graficamente as mudanças de comportamento dos dados da série histórica. Verifica-se pela Figura 25 os gráficos Q-Q com 95% de confiança para os intervalos identificados distribuição para a série de precipitação acumulada mensal, conforme verificado na Tabela 21.

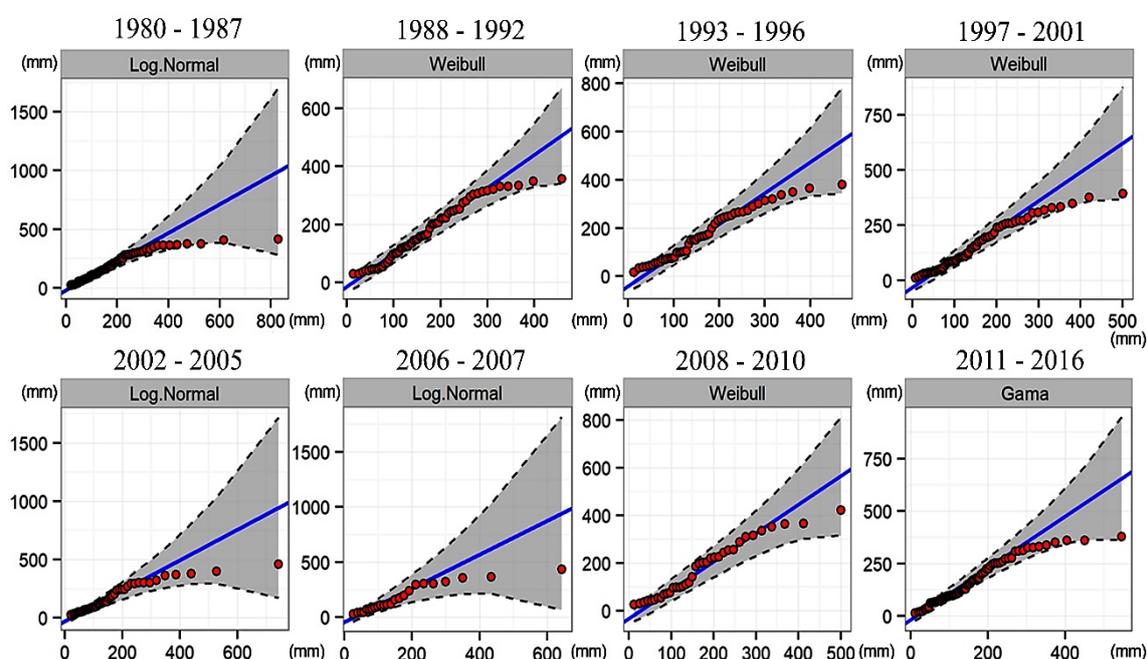


Figura 25 – Gráfico de probabilidade (Q-Q) das distribuições em diferentes intervalos para precipitação acumulada mensal

Os gráficos de probabilidade ou gráficos Q-Q são baseados em estimativas de quantil, possibilitando verificar visualmente o comportamento dos dados partindo da suposição de normalidade, em que, quanto mais próximos da reta (em azul), mais próximo os dados estão de uma distribuição normal (QUEIROZ, 2012).

O tipo de distribuição identificada que melhor se aderiu ($p\text{-valor} \geq 0,05$) em cada intervalo para a série de temperatura média mensal pode ser observada na Tabela 22.

Tabela 22 – Identificação do tipo de distribuição de probabilidade por intervalos para temperatura média mensal

Intervalo	Tipo de distribuição	p-valor
1980 - 2011	Log-Normal ($\log(\mu) = 3,32165$; $\log(\sigma) = 0,033420$)	0,0546
2012 - 2016	Normal ($\mu = 28,47$; $\sigma = 1$)	0,4035

p-valor ($x \geq \alpha$) indica aderência a distribuição no intervalo observado, em que: $x = x_1, x_2, \dots, x_n$ e $1, 2, \dots, n$ são os p-valores calculados de cada distribuição ao nível de significância de 5% ($\alpha = 0,05$).

Observando o ajustamento da série de temperatura média mensal (Tabela 22), nota-se pela verificação do p-valor distribuição do tipo Log-Normal entre o intervalo de 1980 a 2011, que corresponde 86% de toda a série, mudando o comportamento entre o intervalo de 2012 a 2016 que apresentou distribuição do tipo Normal. Os valores atípicos ou anos com mudanças de comportamento, coincidem com a ocorrência de anomalias oceânicas (ENOS), como o forte evento de *La Niña* de 2010/2011 que afetou em escala global índices de precipitação, temperatura e umidade relativa do ar (EVANS; BOYER-SOUCHET, 2012; LIM *et al.*, 2016).

Avaliando a distribuição de probabilidade que melhor se ajusta aos dados de temperatura da cidade de Iguatu-CE de uma série histórica de 1961 a 2005, Araújo *et al.* (2010) verificaram melhor aderência para distribuição do tipo Normal e o pior ajuste obtido para distribuição do tipo Gumbel. Já os autores Assis *et al.* (2009), analisando seis tipos de distribuições de probabilidade das séries históricas de temperatura média mensal em Mossoró-RN, verificaram melhor ajustamento considerando o intervalo entre os períodos de 1970 a 2007 pelas distribuições do tipo Normal e Log-Normal.

O comportamento da série pode ser observado graficamente na Figura 26, para o maior período identificado aderência para a distribuição dos dados de temperatura média mensal conforme verificado na Tabela 22.

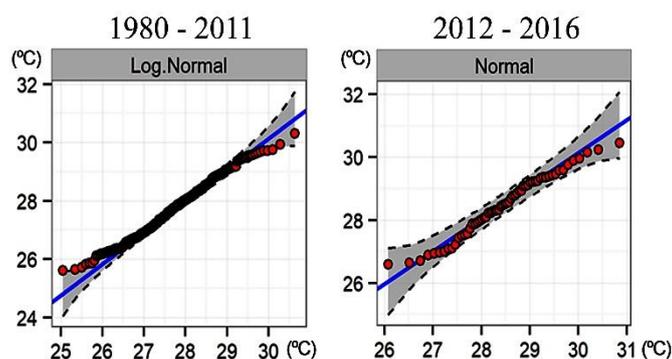


Figura 26 – Gráfico de probabilidade (Q-Q) das distribuições em diferentes intervalos para temperatura média mensal

Para a série de umidade relativa do ar média mensal, as distribuições identificadas em cada intervalo podem ser verificadas na Tabela 23, em que só foi possível identificar ajustamento com nível de significância de 5% aos tipos de distribuições propostas, considerando pequenos intervalos, e em alguns casos como os anos 2008 e 2009 apenas para os referidos anos.

Tabela 23 – Identificação do tipo de distribuição de probabilidade por intervalos para umidade relativa do ar média mensal

Intervalo	Tipo de distribuição	P-valor
1980 - 1983	Normal ($\mu = 83,14$; $\sigma = 4,1$)	0,1423
1984 - 1987	Weibull (Forma = 23,3034; Escala = 84,8291)	0,1679
1988 - 1989	Weibull (Forma = 29,685; Escala = 86,3246)	0,0797
1990 - 1992	Normal ($\mu = 83,51$; $\sigma = 3,5$)	0,1004
1993 - 1995	Weibull (Forma = 24,2025; Escala = 84,5337)	0,1220
1996 - 1998	Normal ($\mu = 81,22$; $\sigma = 4$)	0,0839
1999 - 2000	Log-Normal ($\log(\mu) = 4,40186$; $\log(\sigma) = 0,0475902$)	0,0719
2001 - 2003	Normal ($\mu = 80,56$; $\sigma = 4,6$)	0,1177
2004 - 2005	Log-Normal ($\log(\mu) = 4,36503$; $\log(\sigma) = 0,0652149$)	0,1187
2006 - 2007	Normal ($\mu = 78,88$; $\sigma = 5,6$)	0,1097
2008	Normal ($\mu = 79,09$; $\sigma = 6,5$)	0,0594
2009	Normal ($\mu = 79,32$; $\sigma = 6$)	0,0529
2010 - 2012	Weibull (Forma = 17,9994; Escala = 81,302)	0,0997
2013 - 2016	Log-Normal ($\log(\mu) = 4,36564$; $\log(\sigma) = 0,06254$)	0,0845

p-valor (x) $\geq \alpha$ indica aderência a distribuição no intervalo observado, em que: $x = x_1, x_2, \dots, x_n$ e $1, 2, \dots, n$ são os p-valores calculados de cada distribuição ao nível de significância de 5% ($\alpha = 0,05$).

Os autores Assis *et al.* (2013) verificando o ajuste de doze séries históricas para dados de umidade relativa mensal entre o período de 1970 a 2007 em Mossoró-RN à alguns modelos de distribuição de probabilidade, observaram superioridade na aderência as distribuições do tipo Gama, Gumbel e Normal pelo teste de Kolmogorov-Smirnov.

Em estudos realizados por Silva *et al.* (2002), avaliando o comportamento da umidade relativa mensal em Pelotas-RS com dados históricos do período de 1961 a 2000, verificaram que a umidade relativa do ar na região em estudo segue aproximadamente à distribuição do tipo Normal, não definindo um modelo de distribuição específico, uma vez que não foram considerados menores intervalos para verificação como realizados nesse estudo.

Verifica-se na Figura 27 os gráficos Q-Q com 95% de confiabilidade para os intervalos identificados distribuição na série de umidade relativa do ar média mensal, conforme observado na Tabela 23.

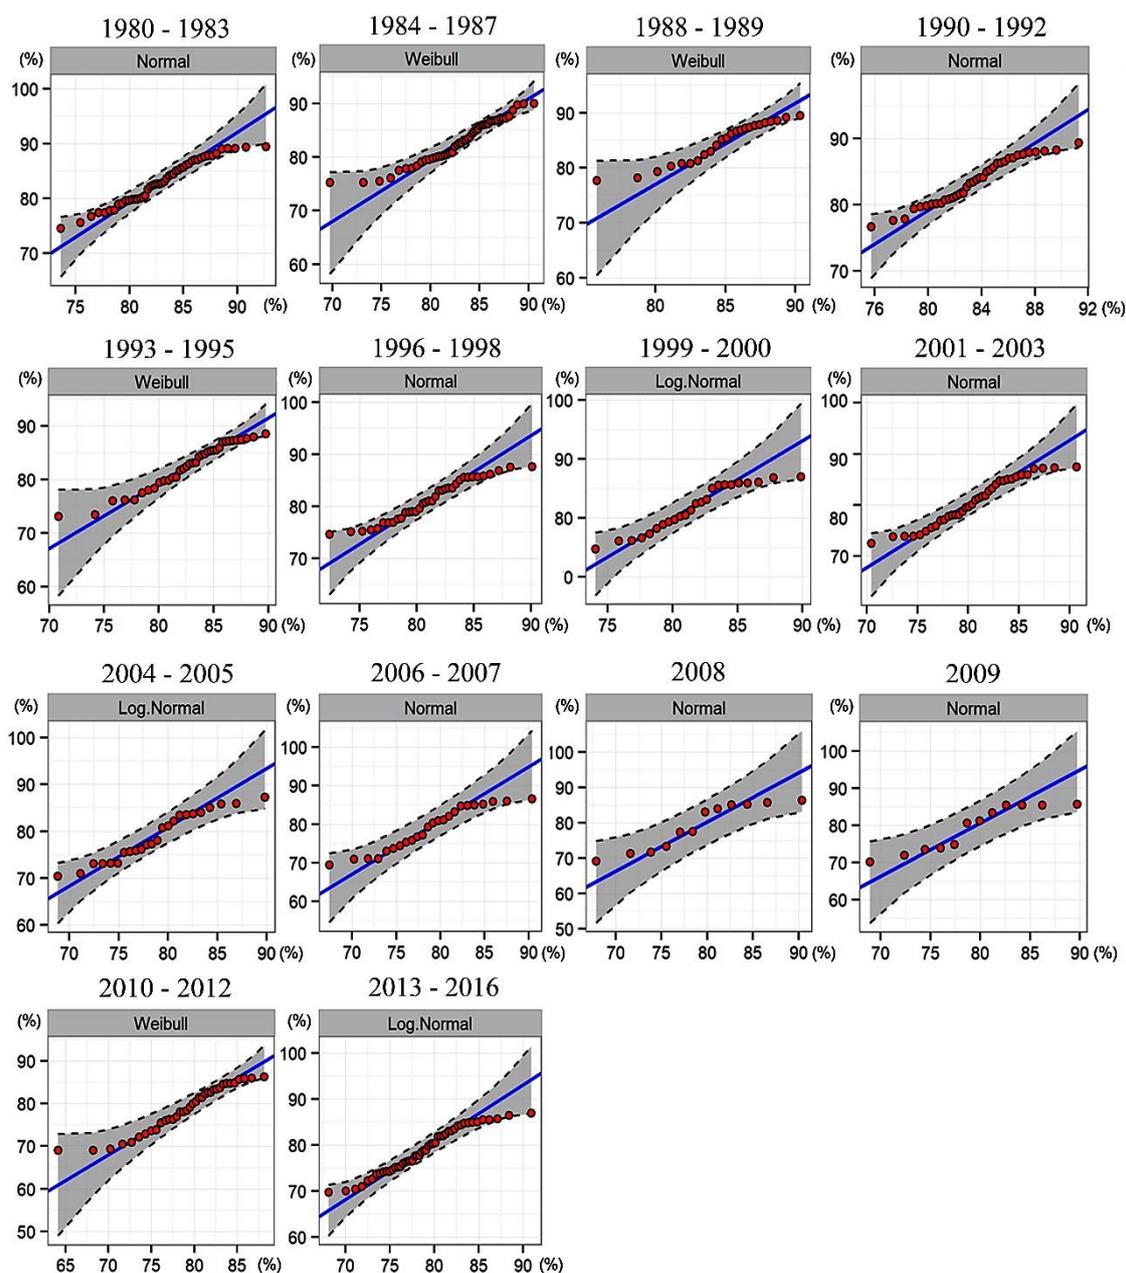


Figura 27 – Gráfico de probabilidade (Q-Q) das distribuições identificadas para umidade média mensal

Conforme observado nas Tabelas 21, 22 e 23, as séries não apresentam normalidade em toda sua distribuição, sendo assim, o coeficiente de correlação não-paramétrico de Spearman foi utilizado para verificar a relação entre as três variáveis climáticas, que varia entre -1 e 1, indicando pelo sinal a direção negativa ou positiva do relacionamento entre os dados (FIGUEIREDO FILHO; SILVA JÚNIOR, 2009), ou seja, o sinal negativo indica comportamento inverso entre a correlação e o valor sugere a força da relação. A correlação entre as variáveis climáticas precipitação acumulada, temperatura e umidade relativa do ar média mensal pode ser observada na Tabela 24.

Tabela 24 – Correlação entre precipitação acumulada, temperatura e umidade relativa do ar média mensal das séries históricas de 1980 a 2016

	$U_{méd.m}$	$T_{méd.m}$	$P_{ac.m}$
$U_{méd.m}$	1	-0,896	0,865
$T_{méd.m}$	-0,896	1	-0,786
$P_{ac.m}$	0,865	-0,786	1

$U_{méd.m}$: umidade relativa do ar média mensal; $T_{méd.m}$: temperatura média mensal; $P_{ac.m}$: precipitação acumulada mensal.

Independente do sinal, quanto mais próximo de 1 maior o grau de dependência entre as variáveis, por outro lado, quanto mais próximo de zero menor o grau de relação (FIGUEIREDO FILHO; SILVA JÚNIOR, 2009; MUKAKA, 2012), que pode ser classificada conforme apresentado em Dancey e Reidy (2006) em fraco (variando entre 0 a 0,39), moderado (variando entre 0,40 a 0,69) e forte (variando entre 0,70 a 1,00).

Como pode ser observado na Tabela 24, houve forte grau de relação entre as três variáveis climáticas. As correlações entre as variáveis umidade e temperatura (89,6%), temperatura e precipitação (78,6%) apresentaram sinal negativo, indicando comportamento inverso. Já a correlação entre as variáveis umidade e precipitação a relação foi de 86,5% com sinal positivo, indicando o mesmo comportamento.

4.5 Análise do fenômeno El Niño-Oscilação Sul

A ocorrência de anomalias oceânicas positivas (aquecimento), configura-se como *El Niño*, ao passo que as anomalias negativas (resfriamento) se referem a *La Niña* (CAI *et al.*, 2017). Esses fenômenos podem ocasionar mudanças no comportamento das chuvas, temperatura e umidade relativa do ar em escala global (BRITTO *et al.*, 2008; DINEZIO *et al.*, 2017; PAEK *et al.*, 2017). Portanto, foram analisadas as influências do ENOS nos índices pluviométricos e temperatura, com vistas a subsidiar apontamentos para discussões a respeito dos efeitos do *El Niño* e *La Niña* no clima da região em estudo.

A variável climática umidade relativa do ar não foi levada em consideração para estudo do ENOS, não comprometendo a análise (ANDRADE *et al.*, 2016) que busca verificar se as anomalias oceânicas interferem nos períodos chuvoso e de estiagem influenciando o regime de chuva, uma vez que se constatou forte correlação positiva com a variável precipitação acumulada mensal (86,5%).

Através dos registros de anomalias de TSM de 1980 a 2016, obtidos do banco de dados do NOAA, foram catalogados os meses com ocorrência de *El Niño*, *La Niña* e

aqueles considerados Neutros, levando em consideração a dinâmica dos padrões oceânicos por meio dos mapas de composições mensais dos padrões anômalos da TSM que atuaram sob a região e área contigua.

A catalogação dos meses com episódios de *El Niño*, *La Niña* e Neutros, foram mensurados com base nas Normais Climatológicas (1961 – 1990) para desvios de chuva acumulada mensal e Climatologia de Referência (1981 – 2010) para anomalias de temperaturas médias mensais, pode ser observado na Tabela 25 (INMET, 2017a-b).

Tabela 25 – Ocorrência de *El Niño*, *La Niña* e períodos Neutros na Região Hidrográfica do Xingu-PA e área contigua entre 1980 a 2016

Anos	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1980	El Niño	El Niño	Neutro									
1981	Neutro											
1982	El Niño											
1983	El Niño	Neutro	Neutro	Neutro	Neutro	Neutro	Neutro					
1984	Neutro	La Niña	La Niña	La Niña								
1985	La Niña	Neutro	Neutro	Neutro	Neutro	Neutro	Neutro					
1986	El Niño											
1987	El Niño											
1988	El Niño	El Niño	Neutro	Neutro	La Niña							
1989	La Niña	Neutro										
1990	Neutro											
1991	El Niño											
1992	El Niño	Neutro	Neutro	Neutro	Neutro	Neutro						
1993	Neutro											
1994	Neutro	El Niño	El Niño	El Niño								
1995	El Niño	El Niño	El Niño	Neutro	Neutro	Neutro	Neutro	La Niña				
1996	La Niña	La Niña	La Niña	Neutro								
1997	El Niño											
1998	El Niño	Neutro	La Niña									
1999	La Niña											
2000	La Niña											
2001	La Niña	La Niña	La Niña	Neutro								
2002	El Niño											
2003	El Niño	El Niño	Neutro									
2004	Neutro	Neutro	Neutro	Neutro	Neutro	Neutro	El Niño					
2005	El Niño	El Niño	El Niño	El Niño	Neutro							
2006	Neutro	El Niño										
2007	El Niño	Neutro	Neutro	Neutro	Neutro	Neutro	La Niña					
2008	La Niña	Neutro	Neutro	Neutro	Neutro	Neutro	Neutro					
2009	El Niño											
2010	El Niño	El Niño	El Niño	El Niño	Neutro	Neutro	La Niña					
2011	La Niña	La Niña	La Niña	La Niña	Neutro	Neutro	La Niña					
2012	La Niña	La Niña	La Niña	Neutro								
2013	Neutro											
2014	Neutro											
2015	El Niño											
2016	El Niño	Neutro	Neutro	Neutro	La Niña	La Niña	La Niña	La Niña				

El Niño

La Niña

Neutro

Alguns anos estiveram sob efeito das anomalias oceânicas durante todo o seu intervalo, como 1987 e 2015 sob efeito de *El Niño*, 1999 e 2000 sob efeito de *La Niña*. Os anos 1988, 1995, 1998, 2007, 2010 e 2016 apresentaram simultaneamente (em meses distintos) as duas anomalias (*El Niño - La Niña*), já os anos 1981, 1990, 1993, 2013 e 2014 não registraram episódios de *El Niño* e *La Niña*, sendo considerados Neutros.

Para exemplificar, alguns mapas com desvios mensais de precipitação (Normais Climatológicas 1961 – 1990) e anomalias de temperaturas médias mensais (Climatologia de Referência 1981 – 2010), relacionados à ocorrência do ENOS para o recorte espacial da Região Hidrográfica do Xingu-PA são ilustrados na Figura 28.

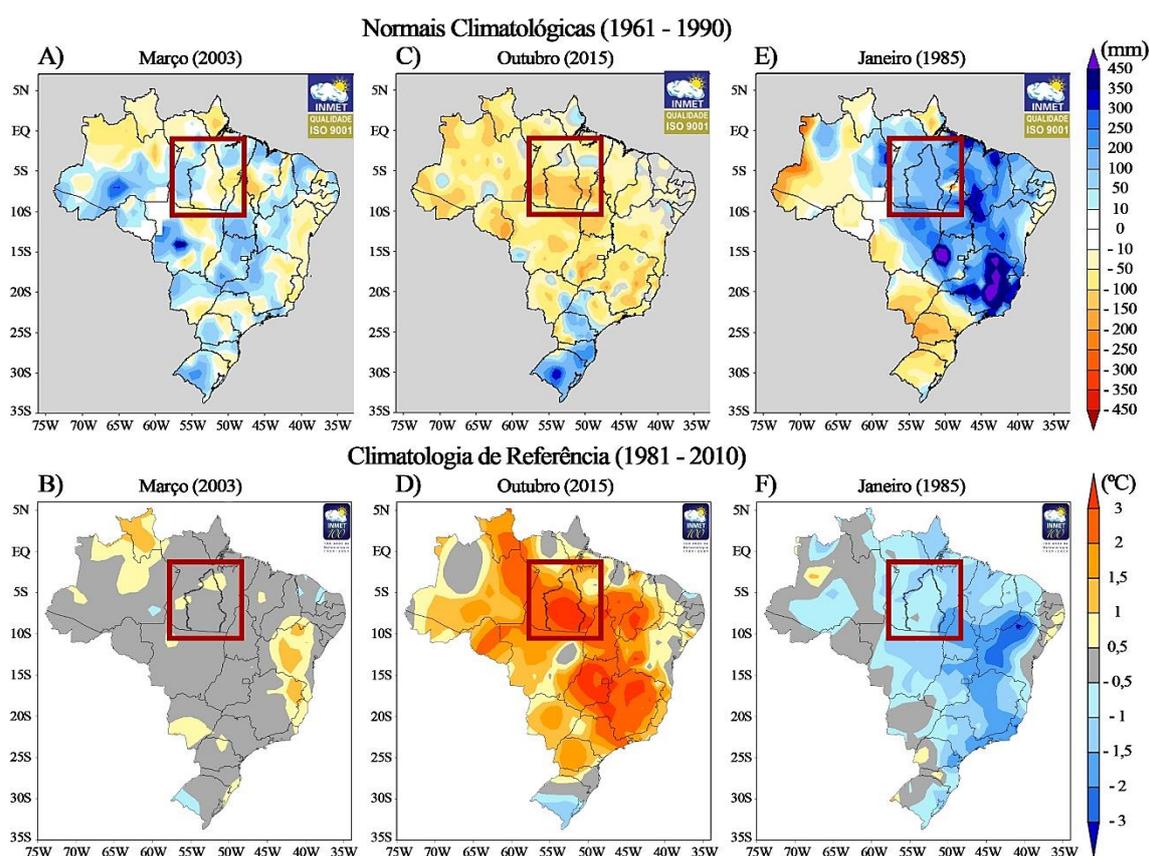


Figura 28 – Mapas de períodos considerados Neutros (A) e (B); com ocorrência de *El Niño* (C) e (D); e com ocorrência de *La Niña* (E) e (F)

Fonte: Adaptado de INMET (2017a-b).

Através dos dados de precipitação acumulada e temperatura, foram determinadas as médias mensais de cada anomalia (*El Niño* e *La Niña*) e analisadas em função da média dos anos Neutros para verificar a influência das anomalias na região.

As médias mensais podem ser observadas na Tabela 26 para os períodos com ocorrência de *El Niño*, *La Niña* e aqueles considerados Neutros para a série de precipitação acumulada.

Tabela 26 – Médias mensais de precipitação acumulada para episódios de *El Niño*, *La Niña* e anos Neutros

Eventos (mm)	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Neutro	251,9	301,7	334,6	287,8	193,4	110,1	73,6	42,1	55,3	89,1	130,2	201,1
<i>El Niño</i>	207,1	253,3	310,2	254,7	149,0	86,0	57,1	43,5	62,9	80,0	97,3	141,5
<i>La Niña</i>	292,7	285,0	362,3	309,6	230,8	109,0	70,1	34,5	49,3	89,0	133,4	160,8

Notas: período chuvoso (dezembro, ..., abril); período de estiagem (junho, ..., novembro) (DIREH, 2013).

Analisando a Tabela 26, com exceção dos meses agosto e setembro, a média dos registros históricos apresentam queda nos índices pluviométricos sob condições de *El Niño*, intensificando a seca no período de estiagem e diminuindo as chuvas no período chuvoso. Sob efeito de *La Niña*, não é possível definir um padrão para o período chuvoso, que apresenta redução e aumento nos índices pluviométricos em diferentes meses.

Se observa nos gráficos do tipo *Boxplot* a distribuição empírica dos dados de precipitação acumulada para avaliação da variabilidade e comparação entre os episódios de *El Niño*, *La Niña* e anos Neutros, além de identificação dos *outliers* (Figura 29).

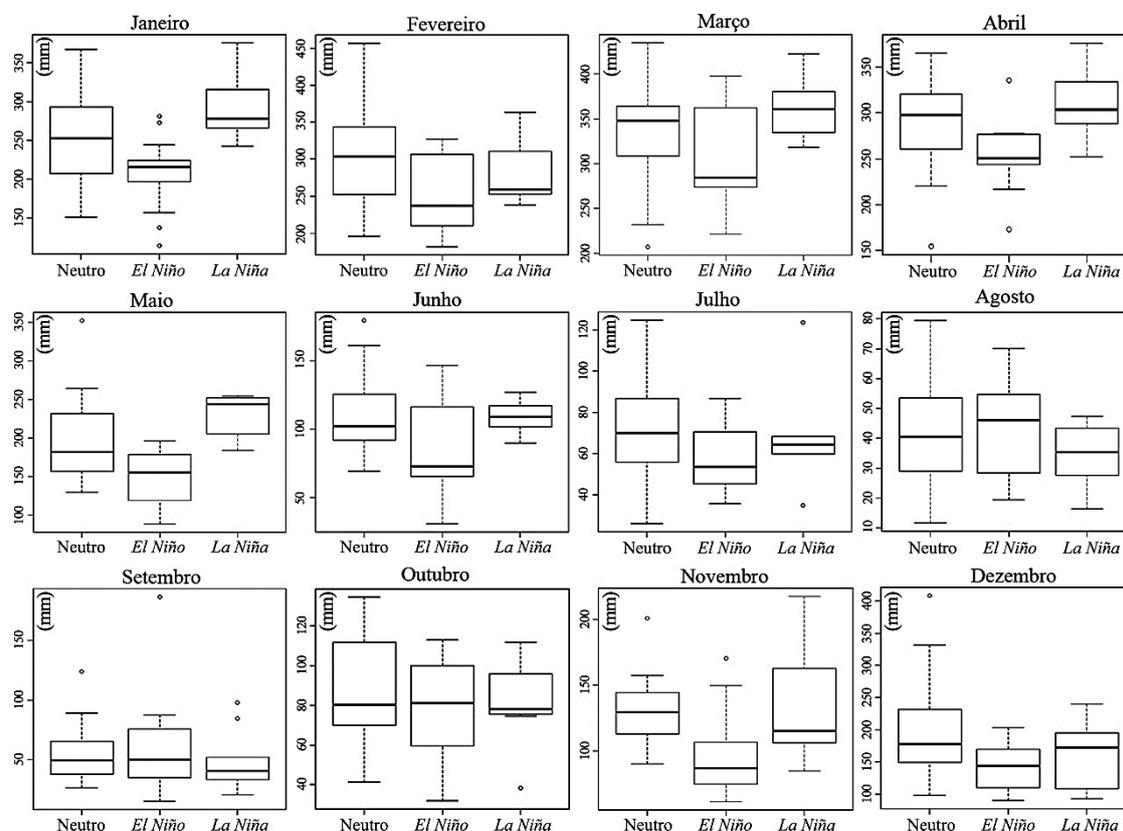


Figura 29 – *Boxplot* com informações das médias de precipitação acumulada mensal de 1980 a 2016 para episódios de *El Niño*, *La Niña* e anos Neutros

Os *outliers* são pontos que se diferenciam drasticamente dos demais valores observados ou valores extremos distanciados da média geral do conjunto de dados.

Portanto, verifica-se pela análise dos *outliers*, que determinados anos apresentam episódios de *El Niño* e *La Niña* com maior e menor intensidade em relação a média geral dos registros observados com e sem anomalia.

Pode ser observado na Tabela 27 a diferença percentual média da influência de *El Niño* e *La Niña* no índice pluviométrico da Região Hidrográfica do Xingu-PA em relação aos anos Neutros. O mês de dezembro apresentou maior alteração média nos episódios com ocorrência de ENOS, com redução no índice pluviométrico de 29,6% sob efeito de *El Niño* e 20% sob efeito de *La Niña*, que correspondem a 59,5 mm e 40,2 mm. Verifica-se que em média (Tabela 27), houve aumento anual no índice pluviométrico da região de 8,6% e 10,8%, e redução anual de 18,5% e 8,5% sob condições de *El Niño* e *La Niña*, nesta ordem.

Tabela 27 – Influência percentual média mensal de *El Niño* e *La Niña* em relação aos anos Neutros para precipitação acumulada

Eventos	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
<i>El Niño</i>	▼ 17,6	▼ 16,1	▼ 7,3	▼ 11,5	▼ 23	▼ 21,9	▼ 22,4	▲ 3,2	▲ 13,7	▼ 10,2	▼ 25,3	▼ 29,6
<i>La Niña</i>	▲ 16,2	▼ 5,6	▲ 8,3	▲ 7,6	▲ 19,3	▼ 1	▼ 4,8	▼ 18,1	▼ 10,8	▼ 0,12	▲ 2,5	▼ 20

Notas: ▲ aumento no índice pluviométrico (%); ▼ redução no índice pluviométrico (%).

Resultados semelhantes foram encontrados em Santos (2013) ao observar máximos e mínimos decorrentes da ocorrência dos fenômenos *El Niño* e *La Niña* no ciclo hidrológico no nordeste do estado do Pará, que altera o padrão de dipolo do oceano Atlântico e a circulação de Walker, exercendo influências no deslocamento Norte-Sul da zona de convergência intertropical.

Analisando de forma isolada os anos de 1997/1998, que de acordo com Kelmo e Attrill (2013) registraram um dos eventos considerados mais severos de *El Niño* em escala global, observa-se redução de 21% (58,7 mm) do índice pluviométrico no período chuvoso e 41% (30,1 mm) no período de estiagem. A redução na precipitação acumulada média anual para o evento de 1997/1998 foi de 22,3% (38,6 mm).

Para o *El Niño* de 2015/2016, que embora não tenha sido tão intenso quanto o de 1997/1998 em escala global, apresentou maior extensão geográfica, resultando em grandes regiões oceânicas com águas mais quentes (PAEK *et al.*, 2017; SÁNCHEZ-VELASCO *et al.*, 2017), foi verificado redução no índice pluviométrico de 12,4% (34,1 mm) no período chuvoso e 34,5% (25,5 mm) no período de estiagem.

O evento *La Niña* de 1984/1985 teve grande influência nos meses de janeiro e dezembro, com aumento de 49% (123,65 mm) e redução de 31,8% (63,91mm) no índice pluviométrico em relação ao mesmo período sem anomalia. No período de estiagem, o mês de outubro apresentou aumento de 25,4% (22,67 mm) no índice pluviométrico.

O evento *La Niña* de 1998/2001 foi o mais longo no intervalo observado, totalizando trinta e três meses, com início em julho de 1998 e termino em março de 2001. Contudo, com exceção dos meses de agosto e outubro que tiveram redução nos índices pluviométricos de 24%, e dezembro que apresentou redução de 13%, os demais meses apresentaram pouca interferência em relação aos padrões normais do ciclo hidrológico, com desvios médios mensais inferiores a 9%, para mais e para menos.

Analisando o forte *La Niña* de 2010/2011, que afetou os padrões de precipitação em todo mundo (BOENING *et al.*, 2012; EVANS; BOYER-SOUCHET, 2012; LIM *et al.*, 2016), se verifica forte influência nos índices pluviométricos no período chuvoso nos meses de dezembro (30,6% de redução) e janeiro (39,5% de aumento), e no período de estiagem nos meses de setembro (56,7% de redução) e outubro (27,1% de aumento). Embora não seja possível identificar um padrão que defina em média o mesmo comportamento para todos os meses no período chuvoso e de estiagem, de modo geral, houve intensificação em ambos os períodos durante o evento *La Niña* de 2010/2011.

Pela Tabela 28 se observam as médias mensais da série de temperatura para ENOS e anos Neutros. Em condições de *El Niño* é possível verificar aumento na temperatura média em todos os meses, sendo o período chuvoso o mais impactado. Sob condições de *La Niña* é possível verificar redução na temperatura média no primeiro semestre (janeiro a junho) e aumento no segundo semestre (julho a dezembro), apresentando variações opostas no primeiro mês de cada período em relação aos demais meses.

Tabela 28 – Médias mensais de temperatura para episódios de *El Niño*, *La Niña* e anos Neutros

Eventos (°C)	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Neutro	26,8	26,6	26,7	27,1	27,7	27,8	27,9	28,6	28,9	28,8	28,2	27,6
<i>El Niño</i>	27,4	27,1	27,3	27,8	28,0	27,9	28,1	28,7	29,0	28,9	28,6	28,1
<i>La Niña</i>	26,6	26,4	26,6	26,7	27,0	27,4	28,0	29,0	29,4	28,9	28,3	27,8

Notas: período chuvoso (dezembro, ..., abril); período de estiagem (junho, ..., novembro) (DIREH, 2013).

A distribuição dos dados mensais de temperatura média para comparação e avaliação de variabilidade entre episódios de *El Niño*, *La Niña* e anos Neutros pode ser observada nos gráficos do tipo *Boxplot* na Figura 30. Com exceção dos meses maio e

novembro, é possível identificar *outliers* nos registros médios na ocorrência das anomalias *El Niño* e *La Niña*, indicando que alguns anos foram mais impactados que outros. Os *outliers* apontam mudanças de tendências no comportamento do ENOS.

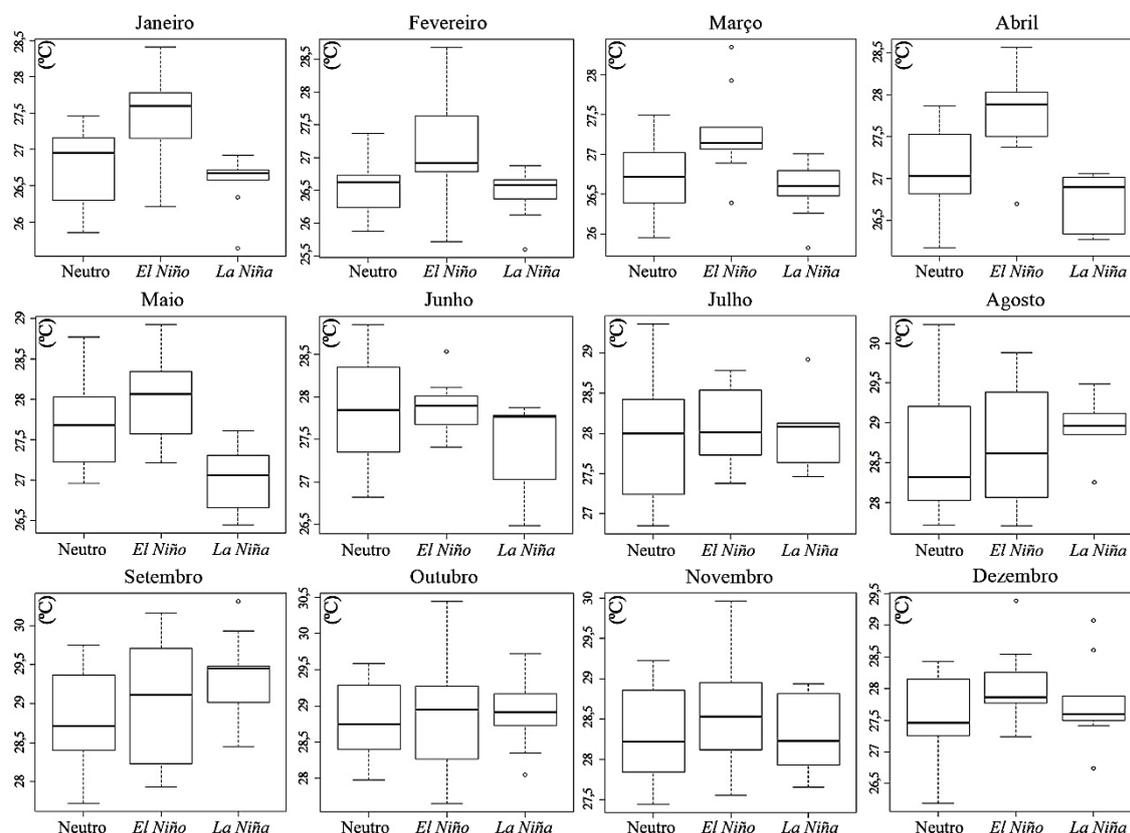


Figura 30 – *Boxplot* com informações das médias de temperatura mensal de 1980 a 2016 para episódios de *El Niño*, *La Niña* e anos Neutros

A diferença percentual da influência de *El Niño* e *La Niña* na temperatura média mensal da região em relação aos anos Neutros pode ser verificada na Tabela 29.

Tabela 29 – Influência percentual média mensal de *El Niño* e *La Niña* em relação aos anos Neutros para temperatura

Eventos	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
<i>El Niño</i>	▲ 2,24	▲ 1,88	▲ 2,25	▲ 2,58	▲ 1,08	▲ 0,36	▲ 0,72	▲ 0,35	▲ 0,35	▲ 0,35	▲ 1,42	▲ 1,81
<i>La Niña</i>	▼ 0,75	▼ 0,75	▼ 0,37	▼ 1,48	▼ 2,53	▼ 1,44	▲ 0,36	▲ 1,40	▲ 1,73	▲ 0,35	▲ 0,35	▲ 0,72

Notas: ▲ aumento na temperatura média mensal (%); e ▼ redução na temperatura média mensal (%).

Avaliando o ENOS, se observa maior influência de *El Niño* na região, com menor intensidade no período de estiagem e maior impacto no período chuvoso, que apresentou aumento na temperatura média de 2,15% (0,58 °C). Também se verifica aumento na temperatura média anual de 1,28% (0,35 °C) sob condições de *El Niño*. Em condições de

La Niña, se verifica de modo geral, menor influência nos índices médios de temperatura, com redução no período chuvoso e aumento no período de estiagem, com exceção dos meses dezembro e junho, onde se observa comportamento inverso.

Para o *El Niño* de 1997/1998, verifica-se aumento na temperatura média de 0,91 °C (3,37%) no período chuvoso e 0,1 °C (0,36%) no período de estiagem. Contudo, analisando isoladamente cada mês, verifica-se nos meses de fevereiro e abril maiores influências na temperatura média da região, com aumento de 1,4 °C (5,22%) e 1,16 °C (4,28%).

Para o *El Niño* de 2015/2016, verifica-se aumento na temperatura média de 1,15 °C (4,27%) no período chuvoso e 1,16 °C (4,06%) no período de estiagem. Embora possa ser identificado aumento na temperatura em todos os meses, em média, o mês mais impactado foi dezembro, que registrou aumento de 1,82 °C (6,61%) na temperatura. O mês de junho foi o menos impactado, com aumento médio na temperatura de 0,68 °C (2,45%). Verifica-se aumento na temperatura média anual de 1,17 °C (4,22%).

O *La Niña* de 1984/1985 apresentou as seguintes reduções nas temperaturas médias em relação aos anos Neutros: 1,15 °C em janeiro; 0,95 °C em fevereiro; 0,47 °C em março; 0,85 °C em abril; 1 °C em maio; 1,36 °C em junho; 0,76 °C em julho; 0,84 °C em agosto; 0,87 °C em setembro; 0,72 °C em outubro; 0,52 °C novembro; 0,15 °C em dezembro. Para o *La Niña* de 1998/2001, não se verificam alterações relevantes nos padrões de temperatura comparando-se as médias dos anos sem anomalia.

Para o evento *La Niña* de 2010/2011 não foi possível estabelecer um padrão para o período chuvoso, uma vez que se identificou variações de temperatura para mais e para menos em diferentes meses. Contudo, se verifica no período de estiagem que foi o mais afetado pela anomalia, aumento na temperatura média de 0,7 °C (2,45%).

Levando em consideração os episódios de ENOS sob a Região Hidrográfica do Xingu-PA, pela análise dos dados, infere-se que ambas as anomalias oceânicas (*El Niño* e *La Niña*) são capazes de influenciar nos desvios de precipitação acumulada e temperatura média mensal, podendo aumentar ou reduzir os índices das variáveis climáticas no período chuvoso e de estiagem.

Na avaliação de ocorrência de *El Niño* para registros de precipitação acumulada mensal, observa-se maiores impactos em relação aos episódios de *La Niña*, reduzindo as chuvas no período chuvoso e de estiagem, intensificando a seca na região. Resultados

semelhantes foram encontrados em Marcuzzo e Oliveira (2012) em estudos sobre precipitação máxima diária no estado do Mato Grosso do Sul.

Foi verificado a relação das variáveis climáticas precipitação acumulada e temperatura média mensal, considerando apenas os episódios de *El Niño* e *La Niña* pelo coeficiente de correlação de Spearman ao nível de 95% de confiança, conforme apresentado na Tabela 30.

Tabela 30 – Correlação entre precipitação acumulada e temperatura média mensal para episódios de *El Niño* e *La Niña*

	<i>El Niño</i>		<i>La Niña</i>		
	P_{ac}	$T_{méd}$	P_{ac}	$T_{méd}$	
P_{ac}	1	-0,839	P_{ac}	1	-0,881
$T_{méd}$	-0,839	1	$T_{méd}$	-0,881	1

$P_{ac.m}$: precipitação acumulada mensal; $T_{méd.m}$: temperatura média mensal.

Existe forte grau de relação (DANCEY; REIDY, 2006) entre as variáveis climáticas avaliando os episódios de *El Niño* e *La Niña* na região. O valor negativo indica comportamento inverso entre as variáveis climáticas, que apresentou correlação de 83,9% sob condições de *El Niño* e 88,1% sob condições de *La Niña*.

4.6 Análise e validação dos parâmetros espaciais

Através da estatística espacial foi possível definir o semivariograma e verificar os principais parâmetros de dependência espacial, considerando os intervalos identificados na análise da distribuição de densidade de probabilidade dos dados climáticos (Tabela 21, 22, 23), avaliando médias mensais das variáveis precipitação acumulada, temperatura e umidade relativa do ar.

Os *softwares* utilizados foram otimizados para obter modelos e parâmetros que forneçam a menor soma residual de quadrados no semivariograma considerando modelos Omnidirecionais (isotropia) pelo método dos mínimos quadrados ordinários. Para avaliação de dependência espacial, foi considerada a classificação descrita em Cambardella *et al.* (1994) em forte ($IDE < 25\%$), moderada ($25\% \leq IDE \leq 75\%$) e fraca ($IDE > 75\%$). Os modelos de semivariogramas identificados, suas características e dependência espacial para cada intervalo de aderência das variáveis climáticas podem ser observados nas Tabelas 31, 32 e 33.

Tabela 31 – Parâmetros de dependência espacial para médias mensais de precipitação acumulada

1980 – 1987							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	437,98	800,64	1238,62	5,50	35,36	Moderada
Fev	Cúbico	215,57	901,78	1117,35	5,50	19,29	Forte
Mar	Cúbico	417,48	366,52	784,00	5,50	53,25	Moderada
Abr	Cúbico	470,61	532,45	1003,05	5,50	46,92	Moderada
Mai	Esférico	378,34	919,76	1298,10	5,50	29,15	Moderada
Jun	Esférico	469,24	869,54	1338,78	5,50	35,05	Moderada
Jul	Cúbico	497,01	418,30	915,32	5,50	54,30	Moderada
Ago	Cúbico	72,62	207,95	280,57	5,50	25,88	Moderada
Set	Cúbico	87,38	267,61	354,99	5,50	24,61	Forte
Out	Cúbico	74,05	883,62	957,67	5,50	7,73	Forte
Nov	Cúbico	255,94	251,94	507,88	5,50	50,39	Moderada
Dez	Esférico	526,02	724,87	1250,89	5,50	42,05	Moderada
1988 – 1992							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	2117,2	2663,32	4780,56	5,50	44,29	Moderada
Fev	Cúbico	1395,5	3507,67	4903,20	5,50	28,46	Moderada
Mar	Cúbico	1060,5	1481,95	2542,40	5,50	41,71	Moderada
Abr	Esférico	224,90	1222,50	1447,40	6,56	15,54	Forte
Mai	Esférico	638,22	1735,13	2373,35	5,50	26,89	Moderada
Jun	Esférico	445,38	1006,05	1451,43	5,50	30,69	Moderada
Jul	Cúbico	111,07	303,99	415,06	5,50	26,76	Moderada
Ago	Cúbico	255,05	141,91	396,96	10,41	64,25	Moderada
Set	Cúbico	351,51	5641,24	5992,75	5,50	5,87	Forte
Out	Cúbico	298,22	387,07	685,29	5,50	43,52	Moderada
Nov	Cúbico	40,91	1207,01	1247,92	5,50	3,28	Forte
Dez	Cúbico	1143,7	1002,79	2146,48	5,50	53,28	Moderada
1993 – 1996							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	907,99	732,85	1640,84	5,50	55,34	Moderada
Fev	Cúbico	812,99	685,79	1498,78	5,50	54,24	Moderada
Mar	Cúbico	2053,6	725,30	2778,89	5,50	73,90	Moderada
Abr	Cúbico	1409,0	1280,29	2689,31	5,50	52,39	Moderada
Mai	Cúbico	1563,9	1686,10	3250,08	5,50	48,12	Moderada
Jun	Esférico	907,31	1098,08	2005,39	5,50	45,24	Moderada
Jul	Cúbico	771,49	1417,92	2189,41	5,50	35,24	Moderada
Ago	Cúbico	97,21	145,89	243,10	5,50	39,99	Moderada
Set	Esférico	0,14	400,04	400,17	5,71	0,03	Forte
Out	Cúbico	340,46	720,82	1061,28	5,02	32,08	Moderada
Nov	Cúbico	1326,3	1333,30	2659,64	5,50	49,87	Moderada
Dez	Cúbico	681,46	1849,79	2531,25	5,50	26,92	Moderada

(continua)

Tabela 31 – Parâmetros de dependência espacial para médias mensais de precipitação acumulada

(continuação)							
1997 – 2001							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	1234,3	1068,00	2302,26	6,64	53,61	Moderada
Fev	Cúbico	362,50	1833,26	2195,76	5,50	16,51	Forte
Mar	Esférico	1588,6	951,78	2540,37	5,50	62,53	Moderada
Abr	Cúbico	499,68	3138,75	3638,43	5,50	13,73	Forte
Mai	Cúbico	252,86	927,38	1180,24	5,50	21,42	Forte
Jun	Esférico	1016,2	738,10	1754,34	5,50	57,93	Moderada
Jul	Cúbico	785,21	510,02	1295,23	5,50	60,62	Moderada
Ago	Cúbico	258,59	189,50	448,09	5,50	57,71	Moderada
Set	Cúbico	186,04	407,92	593,96	5,50	31,32	Moderada
Out	Cúbico	231,62	965,99	1197,61	5,50	19,34	Forte
Nov	Cúbico	6,91	426,48	433,39	5,44	1,59	Forte
Dez	Cúbico	96,72	2118,44	2215,16	5,50	4,37	Forte
2002 – 2005							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	406,66	1815,43	2222,09	5,50	18,30	Forte
Fev	Cúbico	545,28	1468,87	2014,15	5,50	27,07	Moderada
Mar	Cúbico	18,16	5071,76	5089,92	5,50	0,36	Forte
Abr	Cúbico	1004,6	1684,28	2688,85	5,50	37,36	Moderada
Mai	Cúbico	490,39	960,87	1451,26	5,50	33,79	Moderada
Jun	Cúbico	799,74	596,28	1396,02	5,50	57,29	Moderada
Jul	Esférico	520,08	858,65	1378,73	5,50	37,72	Moderada
Ago	Esférico	122,66	76,54	199,20	5,50	61,58	Moderada
Set	Esférico	125,10	73,72	198,82	5,50	62,92	Moderada
Out	Esférico	336,64	231,17	567,812	5,50	59,29	Moderada
Nov	Esférico	61,09	550,96	654,77	10,17	9,98	Forte
Dez	Cúbico	499,81	747,51	1247,32	5,50	40,07	Moderada
2006 – 2007							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	122,10	3411,89	3533,99	5,50	3,46	Forte
Fev	Esférico	1819,1	3804,57	5623,67	5,50	32,35	Moderada
Mar	Cúbico	235,87	5039,54	5275,41	5,50	4,47	Forte
Abr	Cúbico	1126,7	3613,04	4739,77	5,50	23,77	Forte
Mai	Esférico	1144,7	726,08	1870,76	5,50	61,19	Moderada
Jun	Cúbico	512,10	2432,86	2944,96	5,50	17,39	Forte
Jul	Cúbico	371,20	1422,11	1793,31	5,50	20,70	Forte
Ago	Cúbico	61,21	601,21	662,41	5,50	9,24	Forte
Set	Cúbico	21,61	588,53	610,15	5,50	3,54	Forte
Out	Esférico	247,46	1100,29	1347,75	9,55	18,36	Forte
Nov	Cúbico	626,74	1642,83	654,77	5,50	27,62	Moderada
Dez	Cúbico	445,49	2476,90	2922,39	5,50	15,24	Forte

(continua)

Tabela 31 – Parâmetros de dependência espacial para médias mensais de precipitação acumulada

(continuação)

2008 – 2010							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	736,25	1856,07	2592,32	5,50	28,40	Moderada
Fev	Cúbico	555,33	409,20	964,53	5,50	57,58	Moderada
Mar	Cúbico	423,10	565,44	988,54	5,50	42,80	Moderada
Abr	Cúbico	1029,6	1218,58	2248,14	5,50	45,80	Moderada
Mai	Cúbico	1388,6	1827,97	3216,53	5,50	43,17	Moderada
Jun	Esférico	1093,8	1066,18	2159,99	5,50	50,64	Moderada
Jul	Esférico	64,82	741,02	805,84	5,66	8,04	Forte
Ago	Cúbico	117,47	171,47	288,94	5,50	40,65	Moderada
Set	Cúbico	179,64	501,06	680,69	5,50	26,39	Moderada
Out	Esférico	364,99	464,35	829,34	5,50	44,01	Moderada
Nov	Esférico	17,29	549,10	654,77	6,46	3,05	Forte
Dez	Esférico	470,76	295,75	766,50	5,50	61,42	Moderada
2011 – 2016							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	221,91	442,58	664,54	5,50	33,40	Moderada
Fev	Cúbico	748,81	1259,54	2008,39	5,50	37,29	Moderada
Mar	Cúbico	561,00	716,56	1277,56	5,50	43,91	Moderada
Abr	Cúbico	345,93	1785,04	2130,97	5,50	16,23	Forte
Mai	Esférico	1061,0	1005,05	2066,05	5,50	51,35	Moderada
Jun	Esférico	586,55	543,50	1130,05	5,50	51,90	Moderada
Jul	Cúbico	124,35	718,52	842,87	5,50	14,75	Forte
Ago	Esférico	164,14	66,40	230,54	5,50	71,20	Moderada
Set	Cúbico	111,32	165,91	277,23	5,50	40,15	Moderada
Out	Esférico	38,70	1301,43	1340,13	9,82	2,89	Forte
Nov	Esférico	10,27	1238,59	654,77	6,16	0,82	Forte
Dez	Cúbico	289,84	1439,65	1729,49	5,50	16,76	Forte

Classificação da dependência espacial: fraca ($IDE > 75\%$); moderada ($25\% \leq IDE \leq 75\%$); e forte ($IDE < 25\%$) (Cambardela *et al.*, 1994).

Analisando a Tabela 31 para médias mensais de precipitação acumulada, verifica-se pelos semivariogramas identificados, predominância ao modelo cúbico que representa 70,8% das observações, já o modelo esférico representa 29,2%. Existe forte e moderada dependência espacial nos intervalos pela análise do *IDE*. O intervalo 2006-2007 apresentou forte grau de dependência espacial em 75% das observações.

A amplitude variográfica é o alcance máximo em que é reconhecido correlação espacial dentro de um mesmo campo geométrico. O maior alcance obtido (10,41 km) foi no mês de agosto do intervalo 1988-1992, que apresentou moderada dependência espacial e semivariograma do tipo cúbico. Contudo, deve-se considerar o menor alcance obtido avaliando todos os intervalos para uma mesma série, caso se deseje prever novos pontos

a partir dos dados utilizados. Portanto, embora alcances variados tenham sido obtidos, o menor e predominante em todos os intervalos foi 5,50 km.

Mapeando a precipitação do município de Joinville-SC por meio de superfícies interpoladas, Mello e Oliveira (2016) identificaram utilizando o interpolador krigagem ordinária para dados de precipitação média anual e mensal, semivariograma do tipo esférico como predominante, com melhor desempenho pelas métricas de ajuste.

Objetivando selecionar o melhor interpolador espacial de intensidade máxima média de precipitação para diferentes localidades, Almeida (2017) obteve melhor ajuste por krigagem ordinária aos modelos de semivariograma gaussiano e esférico pela análise da métrica de ajuste *RMSE (Root Mean Square Error)*.

Utilizando krigagem ordinária para espacialização de chuva, Cunha *et al.* (2013) observaram melhor ajuste do semivariograma ao modelo esférico para precipitação anual e período de estiagem no estado do Espírito Santo, já para períodos chuvosos e para covariogramas cruzados, o modelo de semivariograma exponencial teve melhor ajuste. Em estudos semelhantes, porém espacializando a chuva com médias mensais de precipitação no estado do Espírito Santo, foi verificado por Silva e Lima (2011) melhor ajuste ao semivariograma do tipo esférico.

Pode ser observado na Tabela 32 os parâmetros de dependência espacial estimados para médias mensais de temperatura.

Tabela 32 – Parâmetros de dependência espacial para médias mensais de temperatura

1980 – 2011							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	0,039	0,083	0,123	5,50	31,97	Moderada
Fev	Cúbico	0,040	0,072	0,112	5,50	35,60	Moderada
Mar	Cúbico	0,048	0,069	0,117	5,50	41,01	Moderada
Abr	Cúbico	0,046	0,083	0,129	5,50	35,91	Moderada
Mai	Cúbico	0,061	0,106	0,167	5,50	36,41	Moderada
Jun	Cúbico	0,078	0,213	0,291	5,50	26,70	Moderada
Jul	Cúbico	0,116	0,175	0,291	5,50	39,72	Moderada
Ago	Cúbico	0,106	0,199	0,305	5,50	34,72	Moderada
Set	Cúbico	0,079	0,387	0,466	5,50	16,90	Forte
Out	Cúbico	0,084	0,288	0,371	5,50	22,50	Forte
Nov	Cúbico	0,091	0,157	0,248	5,50	36,57	Moderada
Dez	Cúbico	0,059	0,136	0,195	5,50	30,25	Moderada

(continua)

Tabela 32 – Parâmetros de dependência espacial para médias mensais de temperatura
(continuação)

2012 – 2016							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	0,054	0,038	0,092	5,50	59,07	Moderada
Fev	Cúbico	0,047	0,049	0,096	5,50	49,23	Moderada
Mar	Cúbico	0,046	0,062	0,108	5,50	42,82	Moderada
Abr	Cúbico	0,057	0,058	0,115	5,50	49,86	Moderada
Mai	Cúbico	0,051	0,064	0,115	5,50	44,55	Moderada
Jun	Esférico	0,054	0,094	0,148	5,50	36,73	Moderada
Jul	Cúbico	0,042	0,135	0,178	5,50	23,83	Forte
Ago	Cúbico	0,060	0,162	0,222	5,50	27,17	Moderada
Set	Cúbico	0,040	0,362	0,402	5,50	9,91	Forte
Out	Cúbico	0,067	0,190	0,257	5,50	26,06	Moderada
Nov	Cúbico	0,087	0,067	0,154	6,16	56,65	Moderada
Dez	Esférico	0,077	0,140	0,217	5,50	35,55	Moderada

Classificação da dependência espacial: fraca ($IDE > 75\%$); moderada ($25\% \leq IDE \leq 75\%$); e forte ($IDE < 25\%$) (Cambardela *et al.*, 1994).

Verifica-se pela Tabela 32, dependência espacial moderada predominante em todas as observações, com exceção dos meses setembro e outubro (1980-2011), julho e setembro (2012-2016) que apresentaram forte dependência espacial. Apenas os meses janeiro, junho e dezembro (2012-2016) tiveram melhor ajuste ao semivariograma do tipo esférico, para as demais observações considerando a menor soma residual de quadrados, verifica-se ajuste ao modelo cúbico.

O maior alcance obtido de 6,16 km foi em novembro (2012-2016) e o menor alcance de 5,50 km predominante nas demais observações, coincide com o menor alcance obtido para médias mensais de precipitação acumulada (Tabela 31).

Nascimento *et al.* (2011) avaliando a variação espacial da temperatura, umidade e luminosidade em estufa com tela antiafídica utilizando krigagem, identificaram para todas as variáveis melhor ajuste ao semivariograma do tipo esférico, com alta variabilidade espacial.

Analisando a dependência espacial-temporal da distribuição e variação da temperatura do ar no município de Caruaru – PE, Santos *et al.* (2011) verificaram melhor ajuste ao modelo de semivariograma exponencial pela avaliação do coeficiente de determinação (R^2) e pela soma dos quadrados dos resíduos ($MSE - Mean Square Error$).

Pela Tabela 33 se verifica os parâmetros de dependência espacial calculados para médias mensais de umidade relativa do ar.

Tabela 33 – Parâmetros de dependência espacial para médias mensais de umidade relativa do ar

1980 – 1983							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	5,543	3,098	8,641	5,50	64,15	Moderada
Fev	Exponencial	7,462	4,617	12,079	5,50	61,78	Moderada
Mar	Esférico	8,785	4,230	13,015	5,50	67,50	Moderada
Abr	Exponencial	6,293	11,880	18,173	5,50	34,63	Moderada
Mai	Exponencial	5,796	22,423	28,219	5,89	20,54	Forte
Jun	Exponencial	7,815	60,771	68,585	13,73	11,40	Forte
Jul	Esférico	11,300	53,700	65,000	16,51	17,39	Forte
Ago	Esférico	11,780	102,074	113,854	15,97	10,35	Forte
Set	Esférico	13,988	106,111	120,099	16,51	11,65	Forte
Out	Exponencial	22,900	43,065	65,964	5,50	34,72	Moderada
Nov	Exponencial	17,048	22,727	39,774	5,50	42,86	Moderada
Dez	Exponencial	19,313	14,346	33,659	5,50	57,38	Moderada
1984 – 1987							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	8,225	5,598	13,823	5,50	59,50	Moderada
Fev	Esférico	12,611	3,358	15,969	5,50	78,97	Fraca
Mar	Esférico	5,928	5,338	11,266	5,50	52,62	Moderada
Abr	Esférico	7,893	4,789	12,682	5,50	62,24	Moderada
Mai	Esférico	10,504	6,780	17,284	5,50	60,77	Moderada
Jun	Exponencial	10,647	29,552	40,199	5,50	26,49	Moderada
Jul	Exponencial	17,125	43,010	60,135	5,50	28,48	Moderada
Ago	Exponencial	17,701	70,804	88,505	5,50	20,00	Forte
Set	Exponencial	17,786	89,742	107,528	6,98	16,54	Forte
Out	Exponencial	21,090	16,258	37,349	5,50	56,47	Moderada
Nov	Exponencial	12,919	31,380	44,299	5,50	29,16	Moderada
Dez	Esférico	17,660	8,732	26,392	5,50	66,91	Moderada
1988 – 1989							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	13,314	10,251	23,565	5,50	56,50	Moderada
Fev	Cúbico	12,714	6,552	19,266	5,50	65,99	Moderada
Mar	Esférico	8,001	3,650	11,651	5,50	68,67	Moderada
Abr	Esférico	15,290	6,690	21,980	5,50	69,56	Moderada
Mai	Exponencial	17,338	28,877	46,215	5,50	37,52	Moderada
Jun	Exponencial	16,076	50,413	66,489	5,50	24,18	Forte
Jul	Esférico	21,236	78,354	99,590	10,20	21,32	Forte
Ago	Esférico	34,102	128,638	162,740	10,38	20,96	Forte
Set	Exponencial	30,656	152,982	183,638	6,69	16,69	Forte
Out	Exponencial	48,789	39,080	87,868	5,50	55,53	Moderada
Nov	Exponencial	22,634	17,160	39,794	5,50	56,88	Moderada
Dez	Esférico	20,773	6,024	26,798	5,50	77,52	Fraca

(continua)

Tabela 33 – Parâmetros de dependência espacial para médias mensais de umidade relativa do ar

(continuação)

1990 – 1992							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	34,661	10,489	45,150	5,50	76,77	Fraca
Fev	Cúbico	13,426	4,564	17,990	5,50	74,63	Moderada
Mar	Esférico	17,213	10,596	27,809	5,50	61,90	Moderada
Abr	Esférico	19,223	14,102	33,325	5,50	57,68	Moderada
Mai	Exponencial	28,261	25,688	53,949	5,50	52,39	Moderada
Jun	Exponencial	28,368	51,115	79,482	5,50	35,69	Moderada
Jul	Exponencial	37,314	100,142	137,456	5,50	27,15	Moderada
Ago	Exponencial	37,394	158,081	195,475	5,50	19,13	Forte
Set	Exponencial	38,764	145,877	184,641	5,50	20,99	Forte
Out	Esférico	40,265	45,192	85,457	5,50	47,12	Moderada
Nov	Esférico	34,866	20,516	55,382	5,50	62,96	Moderada
Dez	Cúbico	26,741	27,501	54,242	5,50	49,30	Moderada
1993 – 1995							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	31,834	10,766	42,600	5,50	74,73	Moderada
Fev	Esférico	21,455	8,146	29,601	5,50	72,48	Moderada
Mar	Esférico	20,412	7,119	27,531	5,50	74,14	Moderada
Abr	Esférico	20,855	7,298	28,152	5,50	74,08	Moderada
Mai	Esférico	25,017	17,179	42,196	5,50	59,29	Moderada
Jun	Esférico	32,732	15,449	48,181	5,50	67,94	Moderada
Jul	Esférico	39,459	25,121	64,581	5,50	61,10	Moderada
Ago	Esférico	44,218	42,973	87,191	5,50	50,71	Moderada
Set	Esférico	56,571	50,696	107,268	5,50	52,74	Moderada
Out	Esférico	49,765	19,804	69,569	5,50	71,53	Moderada
Nov	Esférico	37,896	10,503	48,399	5,50	78,30	Fraca
Dez	Esférico	34,571	16,122	50,693	5,50	68,20	Moderada
1996 – 1998							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	28,222	14,375	42,597	5,50	66,25	Moderada
Fev	Esférico	28,465	13,515	41,980	5,50	67,81	Moderada
Mar	Esférico	22,181	6,664	28,845	5,50	76,90	Fraca
Abr	Esférico	26,359	14,616	40,975	5,50	64,33	Moderada
Mai	Esférico	33,872	15,634	49,506	5,50	68,42	Moderada
Jun	Esférico	53,087	25,392	78,479	5,50	67,65	Moderada
Jul	Esférico	66,730	46,484	113,214	5,50	58,94	Moderada
Ago	Esférico	62,027	60,744	122,771	5,50	50,52	Moderada
Set	Esférico	61,855	44,198	106,053	5,50	58,33	Moderada
Out	Esférico	65,795	11,431	77,227	5,50	85,20	Fraca
Nov	Esférico	53,041	14,749	67,790	5,50	78,24	Fraca
Dez	Esférico	46,319	12,494	58,813	5,50	78,76	Fraca

(continua)

Tabela 33 – Parâmetros de dependência espacial para médias mensais de umidade relativa do ar

(continuação)

1999 – 2000							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	36,045	12,756	48,801	5,50	73,86	Moderada
Fev	Esférico	34,695	9,865	44,560	5,50	77,86	Fraca
Mar	Esférico	29,300	8,665	37,965	5,50	77,18	Fraca
Abr	Esférico	33,604	10,852	44,456	5,50	75,59	Fraca
Mai	Esférico	40,088	12,255	52,343	5,50	76,59	Fraca
Jun	Esférico	58,088	25,055	83,143	5,50	69,87	Moderada
Jul	Esférico	83,243	15,745	98,988	5,50	84,09	Fraca
Ago	Esférico	83,278	54,280	137,557	5,50	60,54	Moderada
Set	Exponencial	36,136	95,353	131,489	5,50	27,48	Moderada
Out	Exponencial	53,247	51,058	104,305	5,50	51,05	Moderada
Nov	Esférico	38,766	15,666	54,431	5,50	71,22	Moderada
Dez	Esférico	36,236	13,439	49,675	5,50	72,95	Moderada
2001 – 2003							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	5,843	6,912	12,754	5,50	45,81	Moderada
Fev	Cúbico	6,052	3,076	9,128	5,50	66,30	Moderada
Mar	Cúbico	5,104	5,191	10,294	5,50	49,58	Moderada
Abr	Esférico	5,389	3,802	9,191	5,50	58,63	Moderada
Mai	Esférico	8,093	4,007	12,100	5,50	66,88	Moderada
Jun	Esférico	8,316	4,628	12,944	5,50	64,25	Moderada
Jul	Cúbico	16,157	8,243	16,505	5,50	66,22	Moderada
Ago	Esférico	31,537	12,470	44,007	5,50	71,66	Moderada
Set	Esférico	28,002	14,792	42,794	5,50	65,44	Moderada
Out	Esférico	21,448	14,367	35,815	5,50	59,89	Moderada
Nov	Cúbico	9,541	16,678	26,218	5,50	36,39	Moderada
Dez	Cúbico	8,600	10,848	19,448	5,50	44,22	Moderada
2004 – 2005							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	5,869	5,819	11,688	5,50	50,22	Moderada
Fev	Cúbico	2,431	2,351	4,782	5,50	50,84	Moderada
Mar	Cúbico	2,613	2,506	5,119	5,50	51,05	Moderada
Abr	Esférico	2,578	1,573	4,151	5,50	62,11	Moderada
Mai	Esférico	2,637	1,953	4,590	5,50	57,45	Moderada
Jun	Esférico	6,147	4,635	10,782	5,50	57,01	Moderada
Jul	Esférico	10,035	7,349	17,384	5,50	57,73	Moderada
Ago	Cúbico	18,356	13,598	31,954	5,50	57,45	Moderada
Set	Esférico	6,470	40,873	47,343	5,50	13,67	Forte
Out	Cúbico	12,280	14,710	26,990	5,50	45,50	Moderada
Nov	Cúbico	11,070	15,190	26,260	5,50	42,16	Moderada
Dez	Cúbico	7,995	8,978	16,973	5,50	47,10	Moderada

(continua)

Tabela 33 – Parâmetros de dependência espacial para médias mensais de umidade relativa do ar

(continuação)

2006 – 2007							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	4,946	4,267	9,213	5,50	53,69	Moderada
Fev	Cúbico	4,029	2,021	6,049	5,50	66,59	Moderada
Mar	Cúbico	2,211	1,533	3,744	5,50	59,05	Moderada
Abr	Cúbico	1,980	1,559	3,539	5,50	55,95	Moderada
Mai	Esférico	2,337	2,151	4,488	5,50	52,07	Moderada
Jun	Cúbico	4,121	4,221	8,342	5,50	49,40	Moderada
Jul	Cúbico	7,864	3,906	11,770	5,50	66,81	Moderada
Ago	Cúbico	12,372	7,530	19,902	5,50	62,17	Moderada
Set	Cúbico	14,256	12,029	26,285	5,50	54,24	Moderada
Out	Cúbico	11,801	14,971	26,772	5,50	44,08	Moderada
Nov	Cúbico	11,688	6,990	18,678	5,50	62,58	Moderada
Dez	Cúbico	6,856	4,477	11,333	5,50	60,49	Moderada
2008							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	4,634	3,682	8,316	5,50	55,72	Moderada
Fev	Cúbico	3,691	4,163	7,854	5,50	47,00	Moderada
Mar	Cúbico	2,329	1,864	4,193	5,50	55,55	Moderada
Abr	Cúbico	1,828	1,905	3,733	5,50	48,97	Moderada
Mai	Cúbico	1,989	2,493	4,482	5,50	44,38	Moderada
Jun	Cúbico	5,322	8,372	13,694	5,50	38,86	Moderada
Jul	Esférico	8,681	7,529	16,210	5,50	53,55	Moderada
Ago	Esférico	12,729	9,635	22,364	5,50	56,92	Moderada
Set	Esférico	14,925	20,043	34,968	5,50	42,68	Moderada
Out	Exponencial	7,466	46,907	54,374	5,50	13,73	Forte
Nov	Esférico	14,585	7,354	21,939	5,50	66,48	Moderada
Dez	Esférico	6,584	3,220	9,804	5,50	67,16	Moderada
2009							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	2,816	2,582	5,398	5,50	52,17	Moderada
Fev	Cúbico	3,240	2,768	6,008	5,50	53,93	Moderada
Mar	Cúbico	2,421	1,883	4,304	5,50	56,25	Moderada
Abr	Cúbico	1,712	1,931	3,643	5,50	46,99	Moderada
Mai	Cúbico	1,772	1,276	3,048	5,50	58,14	Moderada
Jun	Cúbico	4,914	2,197	7,111	5,50	69,10	Moderada
Jul	Cúbico	8,448	4,226	12,674	5,50	66,66	Moderada
Ago	Esférico	9,811	9,396	19,207	5,50	51,08	Moderada
Set	Cúbico	16,824	12,377	29,201	5,50	57,61	Moderada
Out	Cúbico	16,286	13,059	29,345	5,50	55,50	Moderada
Nov	Cúbico	12,348	12,138	24,486	5,50	50,43	Moderada
Dez	Cúbico	2,057	9,919	11,975	5,50	17,18	Forte

(continua)

Tabela 33 – Parâmetros de dependência espacial para médias mensais de umidade relativa do ar

(continuação)

2010 – 2012							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Cúbico	3,074	2,234	5,308	5,50	57,91	Moderada
Fev	Cúbico	2,777	2,734	5,511	5,50	50,39	Moderada
Mar	Cúbico	3,717	1,981	5,698	5,50	65,23	Moderada
Abr	Esférico	3,019	2,014	5,033	5,50	59,98	Moderada
Mai	Cúbico	3,941	2,583	6,524	5,50	60,41	Moderada
Jun	Esférico	5,723	4,734	10,457	5,50	54,73	Moderada
Jul	Cúbico	8,443	8,013	16,456	5,50	51,31	Moderada
Ago	Esférico	14,469	19,306	33,775	5,50	42,84	Moderada
Set	Cúbico	9,904	37,440	47,344	5,50	20,92	Forte
Out	Cúbico	12,551	15,929	28,480	5,50	44,07	Moderada
Nov	Esférico	9,012	6,162	15,174	5,50	59,39	Moderada
Dez	Esférico	7,462	5,191	12,653	5,50	58,97	Moderada
2013 – 2016							
Mês	Modelo do Semivariograma	Efeito Pepita	Contribuição	Patamar	Alcance (km)	IDE (%)	Dependência espacial
Jan	Esférico	6,495	2,372	8,867	5,50	73,25	Moderada
Fev	Cúbico	2,964	2,322	5,286	5,50	56,07	Moderada
Mar	Esférico	1,793	1,117	2,910	5,50	61,62	Moderada
Abr	Esférico	2,646	0,992	3,638	5,50	72,73	Moderada
Mai	Esférico	2,528	1,171	3,699	5,50	68,34	Moderada
Jun	Esférico	4,900	1,895	6,795	5,50	72,11	Moderada
Jul	Esférico	7,295	7,087	14,382	5,50	50,72	Moderada
Ago	Cúbico	5,371	32,829	38,200	5,50	14,06	Forte
Set	Esférico	6,024	30,296	36,320	5,50	16,59	Forte
Out	Cúbico	7,577	15,405	22,982	5,50	32,97	Moderada
Nov	Esférico	10,559	7,964	18,523	5,50	57,01	Moderada
Dez	Cúbico	11,479	11,418	22,897	5,50	50,13	Moderada

Classificação da dependência espacial: fraca ($IDE > 75\%$); moderada ($25\% \leq IDE \leq 75\%$); e forte ($IDE < 25\%$) (Cambardela *et al.*, 1994).

Diferente das médias mensais de precipitação acumulada e temperatura (Tabela 31, 32), pela análise dos parâmetros de dependência espacial para médias mensais de umidade relativa do ar (Tabela 33), verifica-se fraca dependência espacial nos seguintes meses e intervalos: janeiro (1990-1992); fevereiro (1984-1987; 1999-2000); março (1996-1998; 1999-2000); abril, maio e julho (1999-2000); outubro (1996-1998); novembro (1993-1995; 1996-1998); e dezembro (1988-1989; 1996-1998). Do total das 168 observações, existe forte (11%), moderada (81%) e fraca (8%) dependência espacial segundo a classificação descrita em Cambardela *et al.* (1994).

Para o melhor ajuste dos parâmetros de dependência espacial, três modelos de semivariogramas foram identificados em diferentes intervalos, sendo eles: cúbico (33%

das observações), esférico (52% das observações) e exponencial (15% das observações). O maior alcance verificado foi no intervalo 1980-1983 (julho e setembro) de 16,51 km, com forte dependência espacial e semivariograma do tipo esférico (Tabela 33). Contudo, o menor alcance e predominante em todos os intervalos, como verificado para as médias mensais de precipitação acumulada e temperatura (Tabela 31, 32), foi de 5,50km.

Com objetivo de analisar a dependência espacial da variável umidade relativa do ar no interior de uma casa de vegetação em clima tropical com ventilação natural, Voltan *et al.* (2014) utilizando o método de krigagem, identificaram ajuste em diferentes períodos aos semivariogramas do tipo gaussiano, esférico e exponencial pela avaliação do coeficiente de determinação (R^2), com forte dependência espacial em todas as observações.

Analisando a estrutura de variabilidade espaço-temporal da temperatura e umidade relativa do ar utilizando métodos da Geoestatística para determinação do grau de dependência espacial em pomares pessegueiros, Terra (2012) identificou utilizando o interpolador krigagem melhor ajuste ao semivariograma do tipo exponencial.

O critério utilizado para as variáveis em estudo levou em consideração a eficiência de ajuste e não um modelo de semivariograma específico. Em estudos na Geoestatística, frequentemente são utilizados modelos de semivariogramas previamente definidos sem um critério estatístico adequado para sustentação do modelo definido (ALMEIDA, 2017; DIAS *et al.*, 2015; GOMES *et al.*, 2007; GREGO; VIEIRA, 2005; MELO JÚNIOR *et al.*, 2006; MIRANDA, *et al.*, 2016; SOUZA *et al.*, 2000), sendo bastante subjetivo e dependente da perícia dos pesquisadores.

Alguns fatores como as anomalias oceânicas *El Niño*, *La Niña*, as massas de ar atuantes no Brasil (mEa, mEc, mTa, mTc e mPa) e elementos topográficos (altitude, latitude e longitude) influenciam na distribuição espacial da região (CUNHA *et al.*, 2013; MELLO; SILVA, 2009), explicando a grande variabilidade nos padrões climáticos da região tratada neste estudo. Essa variabilidade é reforçada pela variação observada no efeito pepita (C_0) e contribuição (C_1) nos diferentes intervalos avaliando as médias mensais de precipitação acumulada.

Neste estudo, os conjuntos de dados foram divididos em intervalos para aderência à algum tipo de distribuição de probabilidade (Tabela 21, 22, 23), em que foram verificados para diferentes intervalos distribuição não-paramétrica. Desta forma, para a

análise espacial não houve qualquer manipulação nos dados para normalização ou exclusão de valores extremos, sendo uma das possíveis explicações para ajuste à modelos de semivariogramas incomuns (modelo cúbico) dos comumente encontrados na literatura, conforme descrito em Isaaks e Srivastava (1989), Mousinho *et al.* (2004) e Santos *et al.* (2011) que descrevem sobre a necessidade de normalização dos dados e inexistência de valores discrepantes ou extremos para melhor ajuste e facilidade na espacialização.

A análise espacial dos dados considerando as variáveis climáticas precipitação acumulada, temperatura e umidade relativa do ar, com preenchimento de dados faltantes, considerando intervalos de aderência às distribuições de probabilidade para cada variável demonstra que, a distância entre as posições das EMs para que se possa estimar e ter confiabilidade nos padrões climáticos da região em estudo, deveriam ter alcance aproximado de 5,50 km (Tabela 31, 32, 33). Esse alcance inviabiliza novos pontos de monitoramento climático (EMs), pois são caros e requerem avaliações constantes para medições e manutenção (MENDELSON *et al.*, 2007). Portanto, outras tecnologias de análise climática devem ser consideradas, como o monitoramento por satélite de sensoriamento remoto.

Para validação e estimativa dos modelos semivariográficos foi utilizado o método de validação cruzada, bastante utilizado para validar estimativas obtidas por krigagem em dados climáticos (ISAACS; SRIVASTAVA, 1989; REUWSAAT, 2011). As métricas de ajuste utilizadas para avaliação dos parâmetros de dependência espacial para as médias mensais de precipitação acumulada, temperatura e umidade relativa do ar podem ser observadas nas Tabelas 34, 35 e 36.

O conjunto de dados avaliados apresentaram picos extremos (para mais e para menos) devido à forte influência das anomalias oceânicas *El Niño* e *La Niña* na região. Desta forma, foi verificada diferença entre as métricas de avaliação de ajuste (*MAE* e *RMSE*) dos parâmetros espaciais, uma vez que o *RMSE* penaliza somente altos erros. Para precipitação acumulada (Tabela 34), a maior diferença percentual entre as métricas foi de 37% em março (2006-2007) e a menor foi 7% em julho (2010-2016). Para temperatura (Tabela 35), a maior diferença percentual foi em abril com 38% e a menor em setembro com 16% (ambas no intervalo 1980-2011). Já para umidade relativa do ar (Tabela 36), a maior e a menor diferença percentual foram em janeiro (33%) e novembro (6%) dos intervalos 1993-1995 e 2001-2003, respectivamente.

Tabela 34 – Métricas de avaliação dos modelos semivariográficos por validação cruzada para médias mensais de precipitação acumulada

1980 - 1987												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maiο	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (mm)	24,96	28,60	23,97	25,29	24,14	26,16	23,39	13,67	18,00	24,77	18,54	27,47
<i>RMSE</i> (mm)	31,66	34,67	26,53	36,06	29,86	30,79	28,90	17,90	23,26	29,59	22,73	33,79
1988 - 1992												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maiο	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (mm)	55,89	51,15	51,63	31,26	36,69	31,16	19,12	15,81	56,60	24,08	29,50	38,41
<i>RMSE</i> (mm)	64,61	58,94	59,51	36,93	45,09	40,61	21,41	22,19	82,63	27,07	34,63	51,62
1993 - 1996												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maiο	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (mm)	36,53	35,37	45,35	45,99	50,43	36,10	33,80	14,36	14,28	24,89	52,54	48,91
<i>RMSE</i> (mm)	46,48	43,93	61,35	53,35	63,38	42,95	46,22	19,66	17,60	34,05	60,54	57,81
1997 - 2001												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maiο	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (mm)	47,06	42,43	38,07	42,25	30,55	31,10	30,16	18,34	19,83	26,27	20,47	51,90
<i>RMSE</i> (mm)	62,38	58,49	47,86	60,69	36,48	39,42	36,35	20,97	26,38	34,46	24,15	61,20
2002 - 2005												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maiο	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (mm)	49,23	36,40	54,01	44,83	31,89	27,17	31,39	11,87	14,31	22,31	18,71	30,74
<i>RMSE</i> (mm)	63,39	45,45	72,44	55,71	40,66	35,63	36,56	14,25	17,39	26,16	28,06	39,53
2006 - 2007												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maiο	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (mm)	34,40	55,38	53,02	54,82	34,51	40,93	28,07	17,44	21,03	29,32	36,33	32,36
<i>RMSE</i> (mm)	43,25	62,20	84,28	78,13	51,75	50,74	34,00	22,96	25,63	38,66	42,01	38,66
2008 - 2010												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maiο	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (mm)	32,11	25,78	27,46	35,90	39,56	39,24	19,94	15,07	21,57	30,43	15,60	31,51
<i>RMSE</i> (mm)	41,59	33,40	33,42	45,13	51,38	51,70	25,53	17,53	29,13	36,81	20,21	34,67
2010 - 2016												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maiο	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (mm)	21,01	38,81	30,33	39,66	35,18	25,85	30,89	12,69	15,93	22,06	24,70	32,31
<i>RMSE</i> (mm)	25,32	49,71	38,70	46,52	49,63	31,14	33,24	15,90	19,41	32,07	30,44	41,84

Tabela 35 – Métricas de avaliação dos modelos semivariográficos por validação cruzada para médias mensais de temperatura

1980 - 2011												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (°C)	0,31	0,31	0,31	0,29	0,39	0,55	0,55	0,60	0,74	0,65	0,52	0,43
<i>RMSE</i> (°C)	0,45	0,43	0,42	0,47	0,54	0,71	0,70	0,74	0,88	0,79	0,64	0,57
2012 - 2016												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (°C)	0,31	0,29	0,32	0,32	0,32	0,35	0,39	0,45	0,65	0,53	0,38	0,47
<i>RMSE</i> (°C)	0,38	0,37	0,39	0,42	0,42	0,46	0,51	0,55	0,78	0,64	0,46	0,57

Tabela 36 – Métricas de avaliação dos modelos semivariográficos por validação cruzada para médias mensais de umidade relativa do ar

1980 - 1983												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (%)	2,62	2,86	3,14	3,59	4,35	5,38	6,45	8,41	8,38	6,95	5,36	4,96
<i>RMSE</i> (%)	3,31	3,73	4,11	4,78	5,73	7,00	8,15	10,77	10,38	8,25	6,45	5,99
1984 - 1987												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (%)	3,23	3,45	3,19	3,37	3,78	4,83	6,23	7,50	8,11	5,38	5,50	4,49
<i>RMSE</i> (%)	4,41	4,47	4,03	4,19	4,85	6,56	7,99	9,55	9,81	6,23	6,62	5,53
1988 - 1989												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (%)	4,40	4,10	3,04	4,25	5,91	6,76	8,58	10,58	10,50	7,91	4,99	4,20
<i>RMSE</i> (%)	5,57	5,02	3,86	5,46	7,66	9,03	11,63	14,18	13,36	9,92	6,58	5,79
1990 - 1992												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (%)	5,31	3,44	4,50	5,27	6,00	7,01	8,32	9,98	9,78	8,02	5,69	5,56
<i>RMSE</i> (%)	7,43	4,72	6,07	6,75	7,91	9,35	11,62	13,86	13,15	10,20	8,03	7,59
1993 - 1995												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (%)	4,78	4,12	4,12	4,44	5,06	5,41	6,20	7,48	8,64	7,08	5,60	5,64
<i>RMSE</i> (%)	7,10	5,98	5,79	5,94	7,09	7,40	8,35	9,60	10,78	9,02	7,93	8,10
1996 - 1998												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
<i>MAE</i> (%)	5,26	5,50	4,37	5,42	5,79	7,74	9,22	9,80	9,26	7,61	7,08	6,08
<i>RMSE</i> (%)	7,54	7,51	6,00	7,54	8,05	10,09	12,26	12,71	11,53	9,50	9,09	8,44

(continua)

Tabela 36 – Métricas de avaliação dos modelos semivariográficos por validação cruzada para médias mensais de umidade relativa do ar

(continuação)

1999 - 2000												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
MAE (%)	6,07	5,60	5,08	5,51	5,86	7,53	8,16	10,50	9,67	9,38	7,51	6,81
RMSE (%)	8,01	7,67	7,08	7,45	8,06	10,48	10,82	13,21	11,96	10,68	8,25	7,70
2001 - 2003												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
MAE (%)	3,59	3,08	3,43	3,17	3,53	3,66	4,94	6,45	6,49	6,09	5,37	4,01
RMSE (%)	3,88	3,38	3,67	3,52	4,00	4,07	5,76	7,27	7,22	6,74	5,70	4,56
2004 - 2005												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
MAE (%)	3,03	1,99	2,07	1,90	2,10	3,09	3,80	5,48	6,20	4,76	4,87	3,72
RMSE (%)	3,55	2,42	2,49	2,38	2,51	3,88	4,78	6,19	7,29	5,81	5,58	4,36
2006 - 2007												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
MAE (%)	2,85	2,22	1,75	1,67	2,08	2,96	3,42	4,40	4,85	5,09	4,00	2,98
RMSE (%)	3,28	2,69	2,19	2,13	2,52	3,53	3,91	5,01	5,61	5,70	4,73	3,59
2008												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
MAE (%)	2,55	2,39	1,89	1,67	2,02	3,62	3,50	4,31	5,21	5,57	4,29	2,71
RMSE (%)	3,33	3,03	2,31	2,09	2,55	4,35	4,48	5,09	6,23	6,70	5,36	3,60
2009												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
MAE (%)	2,22	2,44	2,05	1,84	1,71	2,66	3,35	4,40	4,91	5,11	5,02	3,26
RMSE (%)	2,78	3,01	2,58	2,39	2,16	3,12	4,07	5,09	6,02	6,48	6,09	3,93
2010 - 2012												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
MAE (%)	2,08	2,26	2,19	2,27	2,47	3,04	3,79	5,65	6,24	4,97	3,60	3,23
RMSE (%)	2,86	2,93	2,86	2,75	3,06	3,72	4,77	6,51	7,47	6,07	4,58	4,16
2013 - 2016												
Métricas de ajuste	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
MAE (%)	2,69	2,33	1,71	1,86	1,84	2,58	3,63	6,13	6,00	4,56	3,84	4,45
RMSE (%)	3,38	2,77	2,16	2,22	2,19	3,00	4,27	7,26	7,05	5,72	4,84	5,30

Notas: Métricas de avaliação de ajuste MAE (*Mean Absolute Error*) e RMSE (*Root Mean Square Error*) nos diferentes intervalos de aderência às distribuições de probabilidade das médias mensais de precipitação acumulada (Tabela 34), temperatura (Tabela 35) e umidade relativa do ar (Tabela 36).

Conforme apresentado na literatura (MENDONÇA; DUBREUIL, 2005; NASCIMENTO, 2017; YANG *et al.*, 2013), os satélites meteorológicos proporcionaram grandes avanços em pesquisas na Climatologia, pelo monitoramento e mensuração de fenômenos e elementos atmosféricos em escala sinótica e intervalos contínuos de tempo, possibilitando a compreensão da variabilidade, características espaciais e temporais do clima.

Comparando a eficácia de dados de EMs versus as medições de satélites de sensoriamento remoto para avaliação agroclimatológica, com dados de países com diferentes disponibilidades de EMs de superfície (Brasil, Estados Unidos e Índia), Mendelsohn *et al.* (2007) concluíram que: (1) embora dados de EMs possam conter falhas, são precisos em relação a eventos ao nível do solo, mas apenas em suas imediações; (2) as EMs são escassamente distribuídas, principalmente em países em desenvolvimento como o Brasil, devido aos custos de manutenção, comprometendo a confiabilidade de estimativas de padrões climáticos; (3) os satélites são capazes de medições precisas em todos os locais independente da distância, obtendo desempenho superior em variáveis como temperatura e umidade relativa do ar, contudo, apresentam medições de precipitação ligeiramente inferiores em relação as EMs de superfície.

De acordo com Oliveira *et al.* (2014), estimativas de precipitação pluvial providas de satélites são uma alternativa viável para suprir ausências de dados em EMs de superfície. Almeida *et al.* (2015) compararam estimativas de precipitação provenientes de EMs convencionais fornecidas pelo INMET com estimativas do satélite TRMM (*Tropical Rainfall Measuring Mission*) entre o período de 2004 a 2008 no estado do Amazonas. Os autores ressaltam que houve grande similaridade entre ambas as fontes de dados (EMs e TRMM) e as estimativas obtidas pelo TRMM são uma boa alternativa, representando de forma satisfatória a sazonalidade, ressaltando ainda como uma opção viável para homogeneização de dados de precipitação e preenchimento de falhas.

Portanto, baseando-se na contextualização apresentada e na inviabilidade de novos pontos de monitoramento (EMs) na região em estudo, sugere-se a utilização dos dados das EMs em conjunto com dados obtidos por satélites de sensoriamento remoto, como exemplo, o satélite TRMM (produto 3B43) que apresentou excelentes estimativas dos elementos atmosféricos para a região Norte do Brasil (ALMEIDA *et al.*, 2015), aumentando a confiabilidade dos dados climáticos uma vez que a região possui poucas EMs para monitoramento do clima.

4.7 Modelo de previsão climático

Para fazer a previsão dos dados foi utilizada a regressão de séries temporais. Os dados foram divididos em dois conjuntos, treinamento (1980-2009) e teste (2010-2016). A quantidade de diferenciações foi determinada pelo teste de Dickey e Fuller (DICKEY; FULLER, 1981) e os resultados obtidos são apresentados na Tabela 37.

Tabela 37 – Teste de diferenciações de Dickey e Fuller para dos dados climáticos da Região Hidrográfica do Xingu-PA

Estatística do teste	Valor crítico	Nível de significância		
		1%	5%	10%
Temperatura				
τ	-16,29	-2,58	-1,95	-1,62
Precipitação				
τ	-8,30	-3,44	-2,87	-2,57
ϕ	34,51	6,47	4,61	3,79
Umidade				
τ	-11,81	-3,44	-2,87	-2,57
ϕ	69,75	6,47	4,61	3,79

O ajuste dos parâmetros da série foi realizado aplicando o algoritmo (*script*) de Hyndman e Khandakar (2008), que percorreu os possíveis modelos e fez a identificação do melhor pelo Critério de Informação de Akaike (AIC) descrito em Akaike (1974). Devida a sazonalidade verificada na distribuição dos dados das variáveis climáticas, todas as três séries foram ajustadas ao modelo SARIMA. Os coeficientes estimados são apresentados na Tabela 38.

Tabela 38 – Modelo de predição por SARIMA para as variáveis climáticas

Modelo	Parâmetro estimado	Erro padrão	Intervalo de confiança 2,5%	Intervalo de confiança 97,5%	Critério de AIC
Temperatura SARIMA (1,1,0) (2,0,0) [12]					
ϕ_1	-0,3248	0,0472	-0,4172	-0,2323	509,05
Φ_1	0,4327	0,0439	0,3465	0,5187	
Φ_2	0,3940	0,0450	0,3056	0,4822	
Precipitação SARIMA (2,0,0) (1,0,0) [12] com média diferente de zero					
ϕ_1	0,2850	0,0543	0,1786	0,3913	4.869,63
ϕ_2	0,1172	0,0473	0,0244	0,2099	
Φ_1	0,7371	0,0363	0,6659	0,8082	
Média	164,2750	16,0112	132,8937	195,6563	
Umidade SARIMA (2,1,0) (1,0,0) [12] com drift					
ϕ_1	-0,3116	0,0519	-0,4132	-0,2099	1.755,09
ϕ_2	-0,1985	0,0505	-0,2974	-0,0995	
Φ_1	0,8658	0,0256	0,8156	0,9159	
<i>drift</i>	-0,0164	0,3438	-0,6902	0,6575	

Para a variável temperatura e umidade relativa do ar a quantidade de diferenciações necessárias foi apenas uma, enquanto que para precipitação não foi necessário fazer diferenciações (Tabela 38).

O teste de Anderson-Darling e Kolmogorv-Smirnov foram realizados para verificar se os resíduos possuem distribuição normalizada (Tabela 39). Para precipitação a hipótese de normalidade foi refutada pelos dois testes, porém, para temperatura (pelo teste de Kolmogorv-Smirnov) e umidade relativa do ar foi verificada distribuição Normal nos resíduos.

Tabela 39 – Avaliação do p-valor do teste dos resíduos para normalidade e autocorrelação das variáveis climáticas

Teste	Temperatura	Precipitação	Umidade
Normalidade			
Anderson-Darling	0,032	$1,28 \times 10^{-15}$	0,248
Kolmogorov-Smirnov	0,265	$3,17 \times 10^{-09}$	0,344
Autocorrelação			
Box-Pierce	0,2539	0,9819	0,7522
Ljung-Box	0,2523	0,9819	0,7513

Nível de significância 5%, em que: p-valor $(x) \geq \alpha$ (possui distribuição normal; não são correlacionados); e p-valor $(x) < \alpha$ (não possui distribuição normal; são correlacionados).

Também foram aplicados os testes de Box-Pierce e Ljung-Box para verificar a autocorrelação (Tabela 39), onde se verifica que os resíduos não são correlacionados. Portanto, o modelo estimado para temperatura e umidade relativa do ar foram considerados satisfatórios para realizar previsões.

Tabela 40 – Avaliação de ajuste das variáveis climáticas para previsões

Variável	R^2	RMSE	MAE
Calibração			
Temperatura	0,800	0,412	0,328
Umidade	0,881	1,635	1,272
Precipitação	0,705	58,858	44,147
Validação			
Temperatura	0,722	0,423	0,348
Umidade	0,917	1,212	0,913
Precipitação	0,689	59,313	45,201

As métricas de ajuste coeficiente de determinação (R^2), raiz do erro quadrático médio (RMSE) e erro absoluto médio (MAE) foram calculadas para verificar a precisão do modelo (Tabela 40). A temperatura e a umidade relativa do ar apresentaram baixo erro, já para precipitação apesar do valor R^2 satisfatório, o erro médio foi alto.

Com o modelo estimado, podem ser realizadas previsões para as variáveis climáticas (Figura 31). Em geral, as variáveis climáticas apresentam tendência linear, sendo observado um aumento de temperatura de 0,4 °C por década, e uma redução de 1,46 mm na precipitação e de 1,77% na umidade relativa do ar nesse mesmo período.

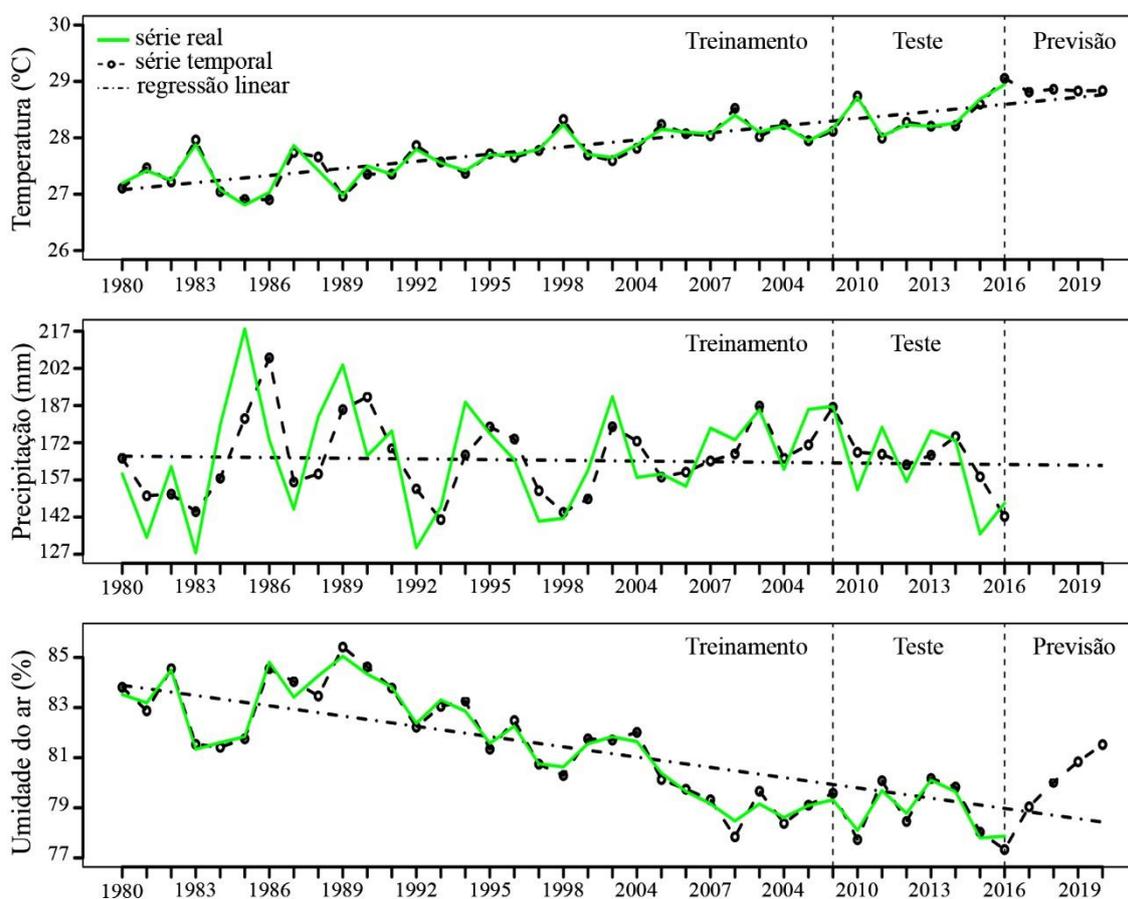


Figura 31 – Séries históricas das variáveis climáticas (1980-2016) e modelos estimados para a Região Hidrográfica do Xingu-PA

Também pode ser observada alteração nas médias por década (Tabela 41). Além do período estudado, foi realizada a previsão de 2020 a 2029 por regressão linear.

Tabela 41 – Tendências por década para as variáveis climáticas da Região Hidrográfica do Xingu-PA

Variável	1980-1989	1990-1999	2000-2009	2010-2019	2020-2029
Temperatura (°C)	27,29	27,67	28,07	28,56	28,96
Precipitação (mm)	168,43	159,10	173,22	159,99*	158,53
Umidade relativa (%)	83,35	82,34	79,73	79,19	77,42

* Média considerando o período de 2010 a 2016.

Mudanças na temperatura também foram encontradas em diferentes estudos nos continentes e oceanos (BREAKER, 2007; GUREVECH *et al.*, 2011; TORETI;

DESIATO, 2008; WANG *et al.*, 2015). Segundo Kerr (1992) as alterações na temperatura estão associadas ao aquecimento dos oceanos, que é derivado das correntes de ar. As alterações na temperatura podem ser positivas e/ou negativas (BAJAT *et al.*, 2015; BALLING-JR *et al.*, 1998).

O regime de chuva também está sofrendo alterações em outras regiões pelo globo, como nos Pampas na Argentina, onde a precipitação está aumentando (ASSENG *et al.*, 2013; VERÓN *et al.*, 2015) e no cinturão do trigo na Austrália, onde a precipitação está reduzindo (ASSENG; PANNELL, 2013).

Avaliando a UHE Belo Monte com base nas previsões realizadas neste estudo, é possível constatar inviabilidade no empreendimento a longo prazo, devido à redução na disponibilidade de água do sistema de drenagem da usina, que já opera com reservatório muito reduzido (BERCHIN *et al.*, 2015; IPEA, 2013), gerando e fornecendo energia elétrica com apenas 40% de sua capacidade instalada. Devido a predição que aponta redução de 1,46 mm na precipitação por década, avaliando o volume de água do reservatório que possui alagamento de 516 km², em média, haverá redução aproximada de 753.360.000 litros para o mesmo período.

Da mesma forma, levando em consideração as principais atividades econômicas praticadas no estado do Pará, dependentes e fortemente influenciadas pelas mudanças climáticas, em conjunto com a crise energética devido a insuficiência na geração de energia da UHE Belo Monte, existem evidências de impactos na economia pela avaliação da Região Hidrográfica do Xingu-PA.

5 CONCLUSÕES

Existe alta variabilidade nos índices pluviométricos mensais da Região Hidrográfica do Xingu-PA, com anomalias identificadas em diferentes períodos. Há forte correlação entre as variáveis climáticas precipitação acumulada, temperatura e umidade relativa do ar média mensal.

O modelo proposto para avaliar a relação altimétrica com as variáveis climáticas precipitação acumulada e temperatura média, possibilitou melhor compreensão da dinâmica do regime climático da Região Hidrográfica do Xingu-PA, que apresenta comportamento inverso, ou seja, para cada acréscimo de unidade nas variáveis climáticas à um decréscimo na altitude.

Considerando diferentes intervalos de aderência, foi possível determinar as distribuições densidade de probabilidade que melhor descrevem o comportamento das séries das variáveis climáticas. Não foi possível identificar aderência à algum tipo de distribuição considerando todo o conjunto de dados, o que demonstra a alta variabilidade climática na região, que apresenta em diferentes observações valores extremos.

Para episódios do fenômeno ENOS sob a Região Hidrográfica do Xingu-PA, tanto o *El Niño* quanto o *La Niña* são capazes de influenciar nos desvios de chuva e temperatura da região, podendo intensificar o período chuvoso e de estiagem. Existe forte correlação inversa entre a precipitação e a temperatura considerando os períodos com ocorrência das anomalias *El Niño* e *La Niña*.

Pela análise da variabilidade espaço-temporal das variáveis climáticas precipitação, temperatura e umidade relativa do ar, considerando intervalos de aderência às distribuições densidade de probabilidade, é possível inferir que a baixa amplitude variográfica inviabiliza a previsão de novos pontos de monitoramento, necessitando de novas tecnologias para utilização conjunta para se obter maior confiabilidade dos dados e eficiência nas estimativas.

O modelo de séries temporais SARIMA se ajustou bem para modelagem de temperatura e umidade relativa do ar com média mensal. Para precipitação acumulada mensal o modelo não apresentou bom desempenho em relação as demais variáveis climáticas. Os dados climáticos apresentam tendências, como aumentar para temperatura e diminuir para umidade relativa do ar e precipitação.

REFERÊNCIAS

- ABBASPOUR, K. C.; ROUHOLAHNEJAD, E.; VAGHEFI, S. *et al.* A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. **Journal of Hydrology**, vol. 524, p. 733-752, 2015.
- AGUILAR, E.; AZIZ BARRY, A.; BRUNET, M. *et al.* Changes in temperature and precipitation extremes in western central Africa, Guinea Conakry, and Zimbabwe, 1955-2006. **Journal of Geophysical Research**, vol. 114, D02115, 2009.
- AHMADI, M.; HADDAD, O. B.; LOÁICIGA, H. A. Adaptive reservoir operation rules under climatic change. **Water Resources Management**, vol. 29, n. 4, p. 1247-1266, 2015.
- AKIMA, H. A method of bivariate interpolation and smooth surface fitting for irregularly distributed data points. **ACM Transactions on Mathematical Software (TOMS)**, vol. 4, n. 2, p. 148-159, 1978.
- ALBUQUERQUE, M. F.; SOUZA, E. B.; OLIVEIRA, M. C. F.; SOUZA JÚNIOR, J. A. Precipitação nas mesorregiões do estado do Pará: climatologia, variabilidade e tendências nas últimas décadas (1978-2008). **Revista Brasileira de Climatologia**. Ano 6, vol. 6, p. 151-168, 2010.
- ALEMAN, J. C.; BLARQUEZ, O.; STAVER, C. A. Land-use change outweighs projected effects of changing rainfall on tree cover in sub-Saharan Africa. **Global Change Biology**, vol. 22 (9), p. 3013-3025, 2016.
- ALMEIDA, C. T.; DELGADO, R. C.; OLIVEIRA JUNIOR, J. F. *et al.* Avaliação das estimativas de precipitação do produto 3B43-TRMM do estado do Amazonas. **Revista Floresta e Ambiente**, vol. 22 (3), p. 279-286, 2015.
- ALMEIDA, E. S. D.; GUILHOTO, J. J. M. O custo de transporte como barreira ao comércio na integração econômica: o caso do Nordeste. **Revista Econômica do Nordeste**, vol. 38, n. 2, p. 224-243, 2007.
- ALMEIDA, L. T. **Espacialização de chuvas intensas: uma nova abordagem**. Universidade Federal de Viçosa, Programa de Pós-Graduação em Meteorologia Aplicada (Dissertação de mestrado). Viçosa, Minas Gerais, 2017.
- AMANAJÁS, J. C.; BRAGA, C. C. Padrões espaço-temporal Pluviométricos na Amazônia Oriental utilizando Análise Multivariada. **Revista Brasileira de Meteorologia**, vol. 27, n. 4, p. 323-338, 2012.
- ANDERSON, L. O.; ARAGÃO, L. E. O. C.; DE LIMA, A. *et al.* Detecção de cicatrizes de áreas queimadas baseada no modelo linear de mistura espectral e imagens índice de vegetação utilizando dados multitemporais do sensor MODIS/TERRA no estado do Mato Grosso, Amazônia brasileira. **Acta Amazonica**, vol. 35, p. 445-456, 2005.
- ANDRADE, E. S. M. **Geração Hidrelétrica no Nordeste: risco empresarial e ambiental para o setor elétrico brasileiro**. Tese de Doutorado 214f. Universidade

Federal do Rio de Janeiro – Programa de Pós-graduação em Planejamento Energético. Março, Rio de Janeiro, 2012.

ANDRADE, N. L. R.; SANCHES, L.; AGUIAR, R. G. *et al.* Seasonal and inter-annual variability of microclimate in forest area in southwestern Amazonia. **Ciência e Natura. Ed. Especial-IX Workshop Brasileiro de Micrometeorologia**, vol. 38, p. 169-176, 2016.

ARAÚJO, E. M.; SILVA, I. N.; OLIVEIRA, J. B. *et al.* Aplicação de seis distribuições de probabilidade a séries de temperatura máxima em Iguatu – CE. **Revista Ciência Agrônômica**, vol. 41, n. 1, p. 36-45, 2010.

ARAÚJO, M. M. V.; PINTO, K. DE JESUS.; MENDES, F. DE OLIVEIRA. A Usina de Belo Monte e os impactos nas terras indígenas. **Planeta Amazônia: Revista Internacional de Direito Ambiental e Políticas Públicas**. Macapá, n. 6, p. 43-51, 2014.

ARGENTO, M. S. F. Mapeamento geomorfológico. In: **GUERRA, A. J. T.; CUNHA, S. B. Geomorfologia: uma atualização de bases e conceitos**. 7. ed. Rio de Janeiro: Bertrand Brasil, p. 365-390, 2007.

ASSAD, L. P. F.; BÖCK, C. S.; CANDELLA, R. N. *et al.* Influence of *El Niño* Wind Stress Anomalies on South Brazil Bight Ocean Volume Transports. **International Journal of Oceanography**, vol. 2015, article ID 965314, 15 p., 2015.

ASSENG, S.; PANNELL, D. J. Adapting dryland agriculture to climate change: Farming implications and research and development needs in western Australia. **Climatic Change**, vol. 118, n. 2, p. 167-181, 2013.

ASSENG, S.; TRAVASSO, M. I.; LUDWIG, F.; MAGRIN, G.O. Has climate change opened new opportunities for wheat cropping in argentina? **Climatic Change**, vol. 117, n. 1-2, p. 181–196, 2013.

ASSIS, J. P.; BATISTA, B. D. O.; SOBRINHO, J. E. Ajuste de seis distribuições densidade de probabilidade a séries históricas de temperatura média mensal em Mossoró/RN. **XVI Congresso Brasileiro de Agrometeorologia**, 22 a 25 de setembro, Belo Horizonte-MG, 2009.

ASSIS, J. P.; SOUSA, R. P.; SILVA, R. M.; LINHARES, P. C. F. Ajuste de sete modelos de distribuições densidade de probabilidade às séries históricas de umidade relativa em Mossoró-RN. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, vol. 8, n. 1, p. 01-10, 2013.

BACHMAIER, M.; BACKES, M. Variogram or Semivariogram? Variance or Semivariance? Allan Variance or Introducing a New Term? **Mathematical Geosciences**, vol. 43, issue 6, p. 735-740, 2011.

BAJAT, B.; BLAGOJEVIC, D.; KILIBARDA, M.; LUKOVIC J.; TOSIC, I. Spatial analysis of the temperature trends in Serbia during the period 1961-2010. **Theoretical and Applied Climatology**, vol. 121, n. 1, p. 289-301, 2015.

BALLING-JR, R. C.; MICHAELS, P. M.; KNAPPENBERGER, P. Analysis of winter and summer warming rates in gridded temperature time series. **Climate Research**, vol. 9, n. 3, p. 175-181, 1998.

BARBOSA, E. C.; SILVA, C. H. O.; MANULI, R. C. *et al.* Distribuição generalizada de valores extremos (GVE): Um estudo aplicado a valores de temperatura mínima da cidade Viçosa-MG. **Revista da Estatística UFOP**, Edição especial: 59ª RBRAS. Vol. III (3), p. 387-391, 2014.

BARBOSA, M. J. S.; DIAS, M. C. S.; TEIXEIRA, M. J. A. *et al.* **Relatório Analítico do Território do Baixo Amazonas – Pará**. In: Grupo de Estudo e Pesquisa Trabalho e Desenvolvimento na Amazônia – GPTDA- Projeto Desenvolvimento Sustentável e Gestão Estratégica dos Territórios Rurais no Estado do Pará. Belém, 2012.

BARRETO, P.; BRANDÃO JR. A.; MARTINS, H. *et al.* **Risco de Desmatamento Associado a Hidrelétrica de Belo Monte**. Belém: Imazon. 98 p., 2011.

BARROSO, L. M. A.; NASCIMENTO, M.; SILVA, F. F. *et al.* Avaliação do teste generalizado de Durbin-Watson. **Revista Brasileira de Biometria**, São Paulo, vol. 30, n. 3, p. 432-441, 2012.

BDMEP/INMET – **Banco de Dados Meteorológicos para Ensino e Pesquisa**/Instituto Nacional de Meteorologia. Disponível em: <<http://www.inmet.gov.br/projetos/rede/pesquisa/>>. Acesso em 13 de jun. de 2017.

BERCHIN, I. I.; GARCIA, J.; HEERDT, M. L. *et al.* Energy production and sustainability: A study of Belo Monte hydroelectric power plant. **Natural Resources Forum, A United Nations Sustainable Development Journal**, vol. 39, issue 3-4, p. 224-237, 2015.

BERTONI, J. C.; TUCCI, C. E. M. Precipitação. In: Tucci, C. E. M. **Hidrologia: Ciência e aplicação**. Porto Alegre: UFRGS, p. 177-241, 2007.

BERVEGLIERI, A.; MENEGUETTE JUNIOR, M. PITERI, M. A. Aplicação do interpolador krigagem em modelos digitais de terrenos, comparando-se os casos de isotropia e anisotropia. **XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, Curitiba, PR, 2011.

BITENCOURT, D. P.; FUENTES, M. V.; CALEARO, D. S. Análise de Variáveis Atmosféricas Observadas em Alta Resolução Espaço-Temporal Durante um Experimento de 30 Dias na Mesorregião da Ilha de Santa Catarina. **Revista Brasileira de Meteorologia**, vol. 31, n. 2, p. 122-140, 2016.

BOENING, C.; WILLIS, J. K.; LANDERER, F. W. *et al.* The 2011 *La Niña*: So Strong, the oceans fell. **Geophysical Research Letters**, vol. 39 (19), L19602, doi:10.29/2012GL053055, 2012.

BORSATO, V. A.; MENDONÇA, F. A. Participação da massa polar atlântica na dinâmica dos sistemas atmosféricos no centro sul do Brasil. **Mercator**, Fortaleza, vol. 4, n. 1, p. 113-130, 2015.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**. 4th Edition: John Wiley & Sons, 2008.

BRATMAN, E. Z. Contradictions of green development: Human rights and environmental norms in light of Belo Monte dam activism. **Journal of Latin American Studies**, vol. 46 (2), p. 261-289, 2014.

BREAKER L. C. A closer look at regime shifts based on coastal observations along the eastern boundary of the north pacific. **Continental Shelf Research**, vol. 27, n. 17, p. 2250-2277, 2007.

BREUSCH, T.; PAGAN, A. The Lagrange multiplier test and its applications to model specification in econometrics. **The Review of Economic Studies**, vol. 47 (1), p. 239-253, 1980.

BRITTO, F. P.; BARLETTA, R.; MENDONÇA, M. Variabilidade espacial e temporal da precipitação pluvial no Rio Grande do Sul: influência do fenômeno El Niño Oscilação Sul. **Revista Brasileira de Climatologia**, vol. 3, p. 37-49, 2008.

BUBENICEK, L. HAAS, A. Method of calculation of the iron ore reserves in the Lorraine deposit. In: The decade of digital computing in the mineral industry. **The American Institute of Mining, Metallurgical and Petroleum Engineers**, Inc. New York. p. 179-210, 1969.

CAI, W.; WANG, G.; SANTOSO, A. *et al.* Definition of Extreme *El Niño* and its impact on projected increase in Extreme *El Niño* Frequency. **Geophysical Research Letters**, vol. 44 (21), p. 184-190, 2017.

CALILI, R. F.; SOUZA, R. C.; GALLI, A. *et al.* Estimating the cost savings and avoided CO2 emissions in Brazil by implementing energy efficient policies. **Energy Policy**, vol. 67, p. 4-15, 2014.

CALIXTO, B. (2011). **Se não for controlado, desmatamento indireto causado por Belo Monte pode passar de 5 mil km²**. Material online, abril de 2011. Disponível em: <<http://amazonia.org.br>>. Acesso em: 11 de mar. 2017.

CAMARGO, E. C. G.; FUCKS, S. D.; CÂMARA, G. **Análise espacial de superfícies**. Brasília: Embrapa, 2004.

CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M. *et al.* Field-Scale Variability of Soil Properties in Central Iowa Soils. **Soil Science Society American Journal**, vol. 58, n. 5, p. 1501-1511, 1994.

CAMMARANO, D.; ZIERDEN, D.; STEFANOVA, L. *et al.* Using historical climate observations to understand future climate change crop yield impacts in the southeastern US. **Climatic Change**, vol. 134, n. 1-2, p. 311-326, 2016.

CARDIM, M. **Mapeamento do comportamento multivariado das principais variáveis climáticas de interesse agrícola do estado de São Paulo**. 2001. 124 f. Tese

(Doutorado em Agronomia) Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agronômicas, Botucatu.

CARVALHO, A. R.; FABRÉ, N. N. Da foz do Amazonas aos Andes. **Ciência Hoje**, vol. 39 (233), p. 64-67, 2006.

CARVALHO, J. R. P.; ASSAD, E. D. Análise espacial da precipitação pluviométrica no Estado de São Paulo: comparação de métodos de interpolação. **Engenharia Agrícola**, vol. 25, p. 377-384, 2005.

CARVALHO, J. R. P.; ASSAD, E. D.; PINTO, H. S. Interpoladores geoestatísticos na análise da distribuição espacial da precipitação anual e de sua relação com altitude. **Pesquisa Agropecuária Brasileira**, vol. 47, p. 1235-1242, 2012.

CASTRO, N. J.; LEITE, A. L. S.; DANTAS, G. A. Análise comparativa entre Belo Monte e empreendimentos alternativos: impactos ambientais e competitividade econômica. In: **Grupos de Estudos do Setor Elétrico**, p. 1-13, Rio de Janeiro, 2011.

CAVALCANTI, I. F. A. Episódios El Niño Oscilação do Sul durante a década de 1986 a 1996 e suas influências no Brasil. **Climanálise** (São José dos Campos), 1996.

CHWIF, L.; MEDINA, A. C. **Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações**. 2ª ed. São Paulo: Editora dos Autores, 2010.

CHWIF, L.; MEDINA, A. C. **Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações**. 4ª edição. Editora Elsevier, São Paulo, 320 p., 2014.

CLARK, I. (1979) - **Practical geostatistics**. London: Applied Science Publishers, 129p. 1979.

CNRH – Conselho Nacional de Recursos Hídricos. (2012). **Política de recursos hídricos do estado do Pará. Governo do Pará - Secretaria de Estado de Meio Ambiente**. Disponível em: <https://www2.mppa.mp.br/sistemas/gcsubsites/upload/41/POLITICA_DE_RECURSOS_HIDRICOS_DO_ESTADO_DO_PARA.pdf>. Acesso em: 29 de abril de 2017.

COELHO, C. A. S.; CAVALCANTI, I. A. F.; COSTA, S. M. S. *et al.* Climate diagnostics of three major drought events in the Amazon and illustrations of their seasonal precipitation predictions. **Meteorological Applications**, vol. 19, issue 12, p. 237-255, 2012.

COOK, B.; ZENG, N.; YOON, J. H. Will Amazonia dry out? Magnitude and causes of change from IPCC climate model projections. **Earth Interactions**, vol. 16, n. 3, p. 1-27, 2012.

CORREA, S. M. B. B. **Probabilidade e Estatística**. 2ª edição. Belo Horizonte: PUC Minas Virtual, 116 p., 2003.

COSTA, F. M. **Distribuição e estrutura de dependência espacial em dados de área**. Programa de Pós-graduação em Estatística e Experimentação Agropecuária - Universidade Federal de Lavras-MG. Tese 113p. (doutorado). Minas Gerais. 2014.

CPC/NCEP/NOAA – Climate Prediction Center/National Centers for Environmental Prediction/ National Oceanic and Atmospheric Administration. **Cold & Warm Episodes by Season**. Disponível em: < http://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php>. Acesso em 12 de dezembro de 2017.

CPTEC/INPE – Centro de Previsão de Tempo e Estudos Climáticos/Instituto Nacional de pesquisas Espaciais. **Efeitos Globais dos ENOS**. Disponível em: <<http://enos.cptec.inpe.br>>. Acesso em dezembro de 2017.

CRUZ, M. A. S.; SOUZA, L. A.; ARAGÃO, R. *et al.* Aplicação de Regressão Linear Múltipla para estimativa da precipitação média anual considerando a variabilidade espacial no estado do Sergipe. **XX Simpósio Brasileiro de Recursos Hídricos**. Bento Gonçalves – RS, 17 a 20 de novembro, 2013.

CUERVO, F. I.; BOTERO, S. Aplicación de las opciones reales en la toma de decisiones en los mercados de electricidad. **Estudios Gerenciales**, vol. 30 (133), p. 397-407, 2014.

CUNHA, A. M.; LANI, J. L.; SANTOS, G. R. *et al.* Espacialização da precipitação pluvial por meio de krigagem e cokrigagem. **Pesquisa Agropecuária Brasileira**, vol. 48, n. 9, p. 1179-1191, 2013.

DANCEY, C.; REIDY, J. **Estatística sem matemática para psicologia: usando SPSS para Windows**. Porto Alegre, Artmed. 608 p., 2006.

DAVIS, S. B. Uses and abuses of cross-validation in geostatistics. **Mathematical Geology**, vol. 19, Issue 3, p. 241-248, 1987.

DIAS, M. C. S. (2009). **Qualificação e Capacitação no Plano Nacional de Fortalecimento da Agricultura Familiar (PRONAF): ressignificação do trabalho na agricultura familiar do Baixo Amazonas**. 248 p. Tese de Doutorado. Universidade Federal de Minas Gerais – UFMG. Belo Horizonte. MG.

DICKEY, D. A.; FULLER, W. A. Likelihood ratio statistics for autoregressive time series with a unit root. **Econometrica: Journal of the Econometric Society**, p. 1057–1072, 1981.

DINEZIO, P. N.; DESER, C.; KARSPECK, A. *et al.* A 2 year Forecast for a 60-80% chance of *La Niña* in 2017-2018. **Geophysical Research Letters**, vol. 44 (22), p. 624-635, 2017.

DINIZ, F. A. *El Niño* e sua influência no período de inverno de 1997 em algumas regiões do Brasil. **Bulletin de l'Institut français d'études andines**, vol. 27, n. 3, 1998.

DIREH - Diretoria de Recursos Hídricos. **Tabela das precipitações mensais do estado do Pará - Relatório técnico**. Belém - Pará. 2013.

DOMINGUES, E. P.; MAGALHÃES, A. S.; RUIZ, R. M. Cenários de mudanças climáticas e agricultura no Brasil: Impactos econômicos na região Nordeste. **Revista Econômica do Nordeste**, vol. 42, n. 02, p. 229-246, 2011.

ELETROBRÁS (Centrais Elétricas Brasileiras S/A). **Aproveitamento Hidrelétrico Belo Monte: Relatório de Impacto Ambiental - RIMA**. ELETROBRÁS, Rio de Janeiro, vol. 36. Maio de 2009.

EPE – EMPRESA DE PESQUISA ENERGÉTICA. (2011). **Projeto da Usina Hidrelétrica de Belo Monte – Fatos e dados**. Disponível em: <<http://www.epe.gov.br/leiloes/Documents/Leil%C3%A3o%20Belo%20Monte/Belo%20Monte%20-%20Fatos%20e%20Dados%20-%20POR.pdf>>. Acesso em: 29 de mar. 2017.

EPE - EMPRESA DE PESQUISA ENERGÉTICA. (2016). **Balanço energético nacional**. Disponível em: <https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2016.pdf>. Acesso em: 27 de mar. 2017.

EVANS, J. P.; BOYER-SOUCHET, I. Local sea surface temperatures add to extreme precipitation in northeast Australia during *La Niña*. **Geophysical Research Letters**, vol. 39, L10803, doi:10.1029/2012GL052014, 2012.

FEARNSIDE, P. M. Environmental and Social Impacts of Hydroelectric Dams in Brazilian Amazonia: Implications for the Aluminum Industry. **World Development**, vol. 77, p. 48-65, 2016.

FEARNSIDE, P. M. Greenhouse gas emissions from a hydroelectric reservoir (Brazil's Tucuruí Dam) and the energy policy implications. **Water, Air and Soil Pollution**, vol. 133, p. 69-96, 2002.

FEARNSIDE, P. M. Impacts of Brazil's Madeira River dams: Unlearned lessons for hydroelectric development in Amazonia. **Environmental Science & Policy**, vol. 38, p. 164-172. doi: 10.1016/j.envsci.2013.11.004, 2014.

FERNANDES, J. A. B. **Krigagem com deriva externa aplica à avaliação de recursos minerais de calcário e de minério laterítico**. Programa de Pós-Graduação em Recursos Minerais e Hidrogeologia, dissertação de mestrado. Instituto de Geociências da Universidade de São Paulo. São Paulo/SP. 2009.

FERNANDES, R. C.; CARVALHO, A. L. Espacialização da precipitação pluvial no município de Piranhas, Alagoas. **Ciência e Natura**, vol. 35, n. 2, p. 295-303, 2013.

FERNANDEZ, M. N. **Preenchimento de falhas em séries temporais**. Dissertação de mestrado em engenharia oceânica. Fundação Universidade Federal do Rio Grande. Rio Grande/RS. 2007.

FERRARI, G. T.; OZAKI, V. Missing data imputation of climate datasets: Implications to modeling extreme drought events. **Revista Brasileira de Meteorologia**. vol. 29, n. 1, p. 21-28, 2014.

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, vol. 18, n. 1, p. 115-146, 2009.

FILGUEIRAS, G. C.; SANTOS, J. N. A. APL no estado do Pará: caracterização e localização das atividades florestal e de madeira e mobiliário. **XLV Congresso da Sociedade Brasileira de Economia, Administração e Sociologia Rural – Sober**. Londrina – PR, 2007.

FLEURY, L. C.; ALMEIDA, J. A construção da Usina Hidrelétrica de Belo Monte: Conflito ambiental e o dilema do desenvolvimento. **Ambiente & Sociedade**. vol. 16, n. 4, p. 141-158. São Paulo v. XVI, 2013.

FRANCO, A. C. L.; UDA, P. K. Comparação de métodos de espacialização da precipitação na bacia do Alto Rio Negro, Santa Catarina. **XVII Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, João Pessoa-PB, p. 3052-3058, 2015.

FREITAS, E. **A Vegetação e o Clima da Região Norte**. (2017). Brasil Escola. Disponível em <<http://brasilecola.uol.com.br/brasil/a-vegetacao-clima-regiao-norte.htm>>. Acesso em 27 de abril de 2017.

FU, R.; ZHU, B.; DICKINSON, R. E. How Do Atmosphere and Land Surface Influence Seasonal Changes of Convection in the Tropical Amazon? **Journal of Climate**, vol. 12, p. 1306-1321, 1999.

GADELHA, S. R. B. (2013). **Consumo de eletricidade e crescimento econômico no Brasil**. Disponível em: <http://www.ime.unicamp.br/sinape/sites/default/files/ConsEletriCrescEcon_conident.pdf>. Acesso em: 27 de mar. 2017.

GARCIA, J. F. C. **Análise da precipitação no semi-árido Potiguar**. Dissertação de mestrado. Programa de Pós-graduação em Engenharia Sanitária, Universidade Federal do Rio Grande do Norte, Natal – RN, 2011.

GATTI, L. V.; GLOOR, M.; MILLER, J. B. *et al.* Drought sensitivity of Amazonian carbon balance revealed by atmospheric measurements. **Nature**, vol. 506, p. 76-80, 2014.

GNEITING, T.; SASVÁRI, Z.; SCHLATHER, M. Analogies and correspondences between variograms and covariance functions”. **Advances in Applied Probability**, vol. 33 (3), p.617-630, 2001.

GOLDEMBERG, J.; MOREIRA, J. R. Política energética no Brasil. **Estudos Avançados**, vol. 19, n. 55, 2005.

GOMES, N. M.; SILVA, A. M.; MELLO, C. R. *et al.* Métodos de ajuste e modelos de semivariograma aplicados ao estudo da variabilidade espacial de atributos físico-hídricos do solo. **Revista Brasileira de Ciências do Solo**, vol. 31, p. 435-443, 2007.

GONÇALVES, M. F.; BLANCO, C. J. C.; DOS SANTOS, V. C. *et al.* Identification of Rainfall Homogenous Regions taking into account *El Niño* and *La Niña* and Rainfall

Decrease in the state of Pará, Brazilian Amazon. **Acta Scientiarum**. Technology, vol. 38, n. 2, p. 209-216, Maringá – PR, 2016.

GONZALEZ, R. A.; ANDREOLI, R. V.; CANDIDO, L. A. *et al.* A influência do evento El Niño-Oscilação Sul e Atlântico Equatorial na precipitação sobre as regiões norte e nordeste da América do Sul. **Acta Amazônica**, vol. 43, n. 4, p. 469-480, 2013.

GOOVAERTS, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. **Journal of Hydrology**, vol. 228, p.113-129, 2000.

GOVERNO DO ESTADO DO PARÁ (2010). **Conheça o nosso Pará**. Governo do estado do Pará. Disponível em: <http://www.pa.gov.br/O_Para/opara.asp>. Acesso em: 26 de maio de 2017.

GREGO, C. R.; VIEIRA, S. R. Variabilidade espacial de propriedades físicas do solo em uma parcela experimental. **Revista Brasileira de Ciências do Solo**, vol. 29, n. 2, p. 169-177, 2005.

GRINGARTEN, E.; DEUTSCH, C. V. Teacher's Aide Variogram Interpretation and Modeling. **Mathematical Geology**, vol. 33, Issue 4, p. 507-534, 2001.

GUILHOTO, J. J. M.; SESSO FILHO, U. A. Estimação da matriz insumo-produto a partir de dados preliminares das contas nacionais. **Economia Aplicada**, vol. 9, n. 2, p. 277-299, 2005.

GUIMARÃES, E. C. **Geoestatística básica e aplicada**. Uberlândia – UFU. Apostila, 77 p. 2004.

GUREVICH, G.; HADAD, Y.; OFIR, A.; OHAYON, B. Statistical analysis of temperature changes in Israel: an application of change point detection and estimation techniques. **Global Nest Journal**, vol. 13, n. 03, p. 215-228, 2011.

HAGUNA, D.; LCONTE, R.; CÔTÉ, P. *et al.* Optimal Hydropower Generation Under Climate Change Conditions for a Northern Water Resources System. **Water Resources Management**, vol. 28, Issue 13, p. 4631-4644, 2014.

HALL, A. L.; BRANFORD, S. Development, Dams and Dilma: The Saga of Belo Monte. **Critical Sociology**, vol. 38, Issue 6, p. 1-12, 2012.

HALUNGA, A. G.; ORME, C. D.; YAMAGATA, T. A heteroskedasticity robust Breusch-Pagan test for Contemporaneous correlation in dynamic panel data models. **Journal of Econometrics**, vol. 198 (2), p. 209-230, 2017.

HOLANDA, R. M.; MEDEIROS, R. M.; SILVA, V. P. R. Recife-PE, **Brasil e suas flutuabilidades da precipitação decadal**. **Natureza, Sociobiodiversidade e Sustentabilidade**, 26 a 29 de outubro, 2016. Universidade Nacional, Sede Chorotega Nicoya, Costa Rica, p. 230-245. 2016.

HUANG, B.; THORNE, P. W.; BANZON, V. F. *et al.* Extended Reconstructed Sea Surface Temperature, Version 5 (ERSSTv5): Upgrades, Validations, and Intercomparisons. **Journal of Climate**, vol. 30, p. 8179-8205, 2017.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic Time Series Forecasting: The forecast Package for R. **Journal of Statistical Software**, vol. 27, n. 3, p. 1-22, 2008.

IBGE – Instituto Brasileiro de Geografia Estatística. (2010a). **Censo demográfico 2010**. Características da população e dos domicílios. Disponível em: <<http://www.ibge.gov.br/apps/snig/v1/?loc=1&cat=-1,-2,-3,128&ind=4707>>. Acesso em: 04 de fevereiro de 2017.

IBGE – Instituto Brasileiro de Geografia Estatística. (2010b). **Atlas Nacional do Brasil Milton Santos**. In: IBGE. Diretoria de Geociências. Rio de Janeiro, 307 p., 2010.

INMET – Instituto Nacional de Meteorologia. **Anomalias de Temperaturas Médias Mensais** (2017b). Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=clima/anomaliaTempMediaMensual>>. Acesso em 22 de outubro de 2017.

INMET – Instituto Nacional de Meteorologia. **Desvio de Chuva Acumulada total mensal** (2017a). Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=clima/desvioChuvaMensual>>. Acesso em 22 de outubro de 2017.

IPCC – Intergovernmental Panel on Climate Change. **Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 996 p., 2007.

IPCC - **Climate Change 2014: Synthesis Report**. Intergovernmental Panel on Climate Change. Geneva, 151 p., 2014.

IPEA - Instituto de Pesquisa Econômica Aplicada. **TD 1868 - A construção de grandes barragens no Brasil, na China na Índia: Semelhanças e peculiaridades dos processos de licenciamento ambiental em países emergentes**, texto para discussão. Rio de Janeiro, 2013.

ISAAKS, E. H.; SRIVASTAVA, R. M. **An introduction to applied geostatistics**. New York: Oxford University Press, 561 p., 1989.

JAICHAND, V.; SAMPAIO, A. A. “ Dam and Be Damned: The Adverse Impacts of Belo Monte on Indigenous Peoples in Brazil”. **Human Rights Quarterly**. vol. 35, p. 408-447, 2013.

JAKOB, A. A. E. A Krigagem como método de análise de dados demográficos. **XIII Encontro da Associação Brasileira de Estudos Populacionais**. Ouro Preto/MG, 2002.

JANTSCHI, L.; BOLBOACA, S. D. (2009). Distribution Fitting 2. Pearson-Fisher, Kolmogorov-Smirnov, Anderson-Darling, Wilks-Shapiro, Cramer-von-Mises and Jarque-Bera statistics. **Cornell University Library**, vol. 1, arXiv:0907.2832. 2009.

JOETZJER, E.; DOUVILLE, H.; DELIRE, C. *et al.* Hydrologic benchmarking of meteorological drought indices at interannual to climate change timescales: a case study over the Amazon and Mississippi river basins. **Hydrology and Earth System Sciences**, vol. 17, p. 4885-4895, 2013.

JONES, J. W.; PICKERING, N. B.; ROSENZWEIG, C. *et al.* Simulated impacts of global change on crops. Gainesville: University of Florida (**Technical Bulletin, 100**), p. 411-434, 1987.

JOURNAL, A. G.; HUIJBREGTS, J. C. H. **Mining geostatistics**. Academic Press, 600p., 1978.

KELMO, F.; ATTRILL, M. J. Severe Impact and Subsequent Recovery of a Coral Assemblage following the 1997–8 *El Niño* Event: A 17-Year Study from Bahia, Brazil. **PLoS ONE**, vol. 8 (5): e65073. <https://doi.org/10.1371/journal.pone.0065073>. 2013.

KEMENES, A.; FORSBERG, B. R.; MELACK, J. M. Methane release below a tropical hydroelectric dam. **Geophysical Research Letters**. 34: L12809. doi:10.1029/2007GL029479. 55, 2007.

KERR, R. A. Unmasking a shifty climate system. **Science**, vol. 255, n. 5051, p. 1508-1510, 1992.

LANDIM, P. M. B. **Análise estatística de dados geológicos**. 2ª edição. São Paulo: Unesp, 253 p., 2003.

LAZZARI, A. R.; CAMARGO, M. E.; SCHNEIDER, R. C. S. Análise de regressão múltipla das concentrações de PM₁₀ em função de elementos meteorológicos para Porto Alegre, Estado do Rio Grande do Sul, em 2005 e 2006. **Acta Scientiarum. Technology**, Maringá, vol. 33, n. 1, p. 49-55, 2011.

LEI, Q.; PAN, Z.; HERRMANN, R. B.; YANG, H. Hydrological Variability and Uncertainty of Lower Missouri River Basin Under Changing Climate. **Journal of the American Water Resources Association**, vol. 50 (1), p. 246-260, 2014.

LEITE, M.; AMORA, D.; KACHANI, M. *et al.*, (2013). **A batalha de Belo Monte**. Folha de São Paulo. Disponível em: <<http://arte.folha.uol.com.br/especiais/2013/12/16/belo-monte>>. Acesso em: 08 de mar. 2017.

LEWIS, S. L.; BRANDO, P. M.; PHILLIPS, O. L. *et al.* The 2010 Amazon drought. **Science**. Issue 6017, vol. 331:554, 2011.

LI, W.; FU, R.; DICKINSON, R. E. Rainfall and its seasonality over the Amazon in the 21st century as assessed by the coupled models for the IPCC AR4. **Journal of Geophysical Research: Atmospheres**, vol. 111, D02111, doi:10.1029/2005JD006355, 2006.

LIM, E. P.; HENDON, H. H.; ARBLASTER, J. M. *et al.* Interaction of the recent 50 years SST trend and *La Niña* 2010: amplification of the Southern Annular Model and Australian springtime rainfall. **Climate Dynamics**, vol. 47 (7), p. 2273-2291, 2016.

LIMA, A. M. M. *et al.* **Política de Recursos Hídricos do Estado do Pará / Secretaria de Estado de Meio Ambiente.** – Belém: SEMA. Governo do Pará, 2012.

LIMA, M. A. Agropecuária brasileira e as mudanças climáticas globais: caracterização do problema, oportunidade e desafios. **Caderno de Ciência & Tecnologia**, Brasília, vol. 19, n. 3, p. 451-472, set/dez. 2002.

LINDNER, M.; FITZGERALD, J. B.; ZIMMERMANN, N. E. *et al.* Climate change and European forests: what do we know, what are the uncertainties, and what are the implications for forest management? **Journal of Environmental Management**, vol. 146, p. 69-83, 2014.

LINTNER, B. R.; ADAMS, D. K.; SCHIRO, K. A. *et al.* Relationships among climatological vertical moisture structure, column water vapor, and precipitation over the central Amazon in observations and CMIP5 models. **Geophysical Research Letters**, vol. 44 (4), p. 1981-1989, 2017.

LOBELL, D. B.; SCHLENKER, W.; COSTA-ROBERTS, J. Climate Trends and Global Crop Production Since 1980. **Science**, vol. 333, Issue 6042, p. 616-620, 2011.

LOPES, M. N. G.; SOUZA, E. B.; FERREIRA, D. B. S. Climatologia regional da precipitação no estado do Pará. **Revista Brasileira de Climatologia**, vol. 12, p. 84-102, 2013.

LÓPEZ-MORENO, J. I.; ZABALZA, J.; VICENTE-SERRANO, S. M. *et al.* Impact of climate and land use change on water availability and reservoir management: Scenarios in the Upper Aragón River, Spanish Pyrenees. **Science of the Total Environment**, vol. 493, p. 1222-1231, 2014.

LUCENA, A.F.P; SCHAEFFER, R; SZKLO, A. **A Vulnerabilidade do Sistema de Energia Elétrica à Mudança Climática no Brasil.** FBDS (org) Mudanças Climáticas Eventos Extremos no Brasil, p. 20-33. FBDS & LLOYD'S. 2010.

MARCUZZO, F. F. N.; MELO, D. C. R. Distribuição Espaço Temporal e Sazonalidade das Chuvas no Estado do Mato Grosso. **Revista Brasileira de Recursos Hídricos.** Porto Alegre, v. 16, n. 4, p. 157-167, 2011.

MARCUZZO, F. F. N.; OLIVEIRA, N. L.; CARDOSO, M. R. D. Tendência do Número de Dias de Chuva no Estado do Mato Grosso e a Relação dos seus Extremos com o Fenômeno ENOS. **Ciência e Natura**, vol. 34, p. 59-82, 2012.

MARCUZZO, F. F. N.; ROMERO, V. Influência do *El Niño* e *La Niña* na precipitação máxima diária do estado de Goiás. **Revista Brasileira de Meteorologia**, vol. 28, n. 4, p. 429-440, 2013.

MARENGO, J. A. **Mudanças climáticas globais e seus efeitos sobre a biodiversidade – caracterização do clima atual e definição das alterações climáticas para o território brasileiro ao longo do século XXI.** 2ª ed. Brasília: Ministério do Meio Ambiente, vol. 1, 214 p., 2007.

MARENGO, J. A. **Mudanças Climáticas, Condições Meteorológicas Extremas e Eventos Climáticos no Brasil**. FBDS (org) Mudanças Climáticas Eventos Extremos no Brasil. p. 05-19. FDBS & LLOYD'S. 2010.

MARENGO, J. A.; ESPINOZA, J. C. Extreme seasonal droughts and floods in Amazonia: causes, trends and impacts. **International Journal of Climatology**, vol. 36, p. 1033-1050, 2016.

MARGULIS, S.; DUBEUX, C. B. S.; MARCOVITCH, J. **Economia da Mudança do Clima no Brasil: Custos e Oportunidades**. São Paulo: IBEP Gráfica, 2010.

MARTINS, A. P. Espacialização de dados pluviométricos: comparação entre métodos determinísticos e métodos geoestatísticos. In: **Simpósio Brasileiro de Climatologia Geográfica**, 2016, Goiânia. Anais do XII SBCG. Goiânia: UFG, vol. 1. pp. 2492 – 2503. 2016.

MARTINS, G. A.; DOMINGUES, D. **Estatística Geral e Aplicada**. 6º edição. Editora Atlas, São Paulo, 360 p., 2017.

MATHERON, G. **La théorie des variables regionalisées, et ses applications. Les Cahiers du Centre de Morphologie Mathématique de Fontainebleau**. École Nationale Supérieure des Mines de Paris, Fascicule 5. 212 p., 1970.

MATHERON, G. **Les variables régionalisées et leur estimation – Une Application de la Théorie des fonctions aléatoires aux Sciences de la Nature**. Paris, Masson et Cie, Éditeurs, 302p., 1965.

MATHERON, G. **Traité de Géostatistique Appliquée, Tome II: Mémoires du Bureau de Recherches Géologiques et Minières. Editions Technip**, vol. 24, n. 172, 333 p., 1963.

MCAFEE, S. A. Methodological differences in projected potential evapotranspiration. **Climatic change**, vol. 120, n. 4, p. 915-930, 2013.

MELLO, C. R.; SILVA, A. M. Modelagem estatística da precipitação mensal e anual e no período seco para o Estado de Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, vol. 13, p. 68-74, 2009.

MELLO, Y. R.; OLIVEIRA, T. M. N. Análise Estatística e Geoestatística da precipitação média para o município de Joinville (SC). **Revista Brasileira de Meteorologia**, vol. 31, n. 2, p. 229-239, 2016.

MELO, D. C.; FERREIRA, A. P.; CAMPOE, M. C. *et al.* Meteorological influence on a population of *Sula leucogaster* (Aves, Sulidae) at an Archipelago in the Southern of Brazil. **Neotropical Biology and Conservation**, vol. 12 (1), p. 59-67, 2017.

MELO, J. C. O fenômeno *El Niño* e as secas no Nordeste do Brasil. **Raízes**, vol. 18, n. 20, p. 13-21, 1999.

MELO, V. S.; MEDEIROS, R. M.; SOUZA, F. A. S. Variação média mensal e anual da umidade relativa do ar para 11 municípios no estado de Pernambuco, Brasil. **Congresso**

Técnico Científico da Engenharia e da Agronomia, CONTECC' 2015. Centro de Eventos do Ceará - Fortaleza – CE. 15 a 18 de setembro. 2015.

MENDELSON, R.; KURUKULASURIYA, P.; BASIST, A. Climate analysis with satellite versus weather station data. **Climatic Change**, vol. 81, edição 1, p. 71-83, 2007.

MENDONÇA, F.; DUBREUIL, V. Termografia de superfície e temperatura do ar na RMC (Região Metropolitana de Curitiba-PR). **Revista RA'E GA-O espaço geográfico em análise**, n. 9, p. 25-35, 2005.

MERELLES, L. R. O. **Influência das mudanças climáticas na produtividade de grãos.** Dissertação 97f. (Mestrado) – Pontifícia Universidade Católica de Goiás, Programa de Pós-Graduação Stricto Sensu em Engenharia de Produção e Sistemas, Goiânia, Goiás, 2018.

MESQUITA, A. R. de. Sea Level Variations Along the Brazilian Coast: A Short Review. **Jornal of Costal Research**, SI 35, p. 21-31, 2003.

MESQUITA, W. O.; GRIEBELER, N. P.; OLIVEIRA, L. F. C. Precipitações máximas diárias esperadas para as regiões central e sudeste de Goiás. **Pesquisa Agropecuária Tropical**, vol. 39, n. 2, p. 73-81, 2009.

MIGUEL, P. A. C; FLEURY, A.; MELLO, C. H. P. *et al.* **Metodologia de pesquisa em engenharia de produção e gestão de operações.** Rio de Janeiro: Elsevier ABEPRO, 2012.

MIRANDA, C. S.; PIRANHOS FILHO, A. C.; LASTORIA, G. Análise da variabilidade espacial da piezometria em aquífero livre: estudo de caso na Sub-Bacia da cabeceira do rio Coxim, Mato Grosso do Sul. **Anuário do Instituto de Geociências**, vol. 39, n. 1, p. 69-75, 2016.

MOLINIER, M.; RONCHAIL, J.; GUYOT, J. L. *et al.* Hydrological variability in the Amazon drainage basin and African tropical basins. **Hydrological Processes**, vol. 23 (22), p. 3245-3252, 2009.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting.** 2. ed. John Wiley & Sons, 2015. 671p.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para engenheiros.** 6ª edição. Editora LTC, 652 p., 2016.

MORAIS, T. M.; MENEZES, J. E.; SANTOS, F. C. V. *et al.* Modelagem e simulação utilizando o software Flexsim: estudo na busca por melhorias no processo produtivo de uma indústria alimentícia de Anápolis/Go. **XXXVII Encontro Nacional de Engenharia de Produção – ENEGEP.** Joinville/Santa Catarina, 10 a 13 de outubro, 2017.

MORETTIN, P. A.; TOLOI, C. **Análise de séries temporais.** 2. ed. Blucher, 2011. 538p.
MORLEY, R. J. **Origin and Evolution of Tropical Rain Forests**, 362 p. London: Wiley, 2000.

MOUSINHO, F. E. P.; ANDRADE JÚNIOR, A. S.; GONÇALVES, A. C. A.; FRIZZONE, J. A. Espacialização dos percentis 7₅ da precipitação pluviométrica anual para o estado do Piauí. **XXXIII Congresso Brasileiro de Engenharia Agrícola**. São Pedro – SP, 02 a 06 de agosto, 2004.

MUKAKA, M. M. A guide to appropriate use of Correlation coefficient in medical research. **Malawi Medical Journal**, vol. 24, n. 3, p. 69-71, 2012.

MURTA, R. M.; TEODORO, S. M.; BONOMO, P.; CHAVES, M. A. Precipitação pluvial mensal em níveis de probabilidade pela distribuição Gama para duas localidades do Sudoeste da Bahia. **Ciência e Agrotecnologia**, vol. 33, p. 261-270, 2005.

NASCIMENTO, D. T. F. **Chuvvas no estado de Goiás e no Distrito Federal a partir de estimativas por satélite e circulação atmosférica**. Tese 200f. (Doutorado em Geografia). Instituto de Estudos Socioambientais, Universidade Federal de Goiás, Goiânia, 2016.

NASCIMENTO, D. T. F.; OLIVEIRA, I. J. de. Variabilidade espaço-temporal da precipitação no estado de Goiás e no Distrito Federal a partir de estimativas satelitárias. In: **Simpósio Brasileiro de Climatologia Geográfica**, 2016, Goiânia. Anais do XII SBCG. Goiânia: UFG, vol. 1. p. 2290-2300, 2016.

NASCIMENTO, E. M. S.; SALES, F. A. L.; LUCAS, F. C. B.; DANTAS, M. J. F. Variabilidade espacial da temperatura do ar, umidade relativa e luminosidade em estufa com tela antiafídica. **II Simpósio de Geoestatística Aplicada em Ciências Agrárias**. UNESP, Botucatu-SP, 19 e 20 de maio, 2011.

NASCIMENTO, J. S. M.; AGUIAR, R. G.; WEBLER, A. D. *et al.* Meteorological Variables in Forest and Pasture Area in the Western Amazon in years of extreme events. **Ciência e Natura. Ed. Especial-IX Workshop Brasileiro de Micrometeorologia**, vol. 38, p. 217-224, 2016.

NORTE ENERGIA, S. A. 2009. **Aproveitamento Hidrelétrico Belo Monte - Relatório de Impacto Ambiental (RIMA)**. Disponível em: <http://norteenergiasa.com.br/site/wp-content/uploads/2011/04/NE.Rima_.pdf>. Acesso em: 09 de janeiro de 2017.

NORTE ENERGIA, S. A. UHE Belo Monte IBRACON. 2011. **53º Congresso Brasileiro de Concreto**. Florianópolis, SC, 3 de novembro de 2011. Disponível em: <<http://www.ibracon.org.br/eventos/53CBC/pdfs/IBRACON-FLORIANOPOLISNOV.2011.pdf>>. Acesso em: 07 março de 2017.

OLEA, R. A. **Geostatistical glossary and multilingual dictionary**. Oxford University Press. 175 p. 1991.

OLIVEIRA JUNIOR, J. F.; DELGADO, R. C.; GOIS, G. *et al.* Análise da precipitação e sua relação com sistemas meteorológicos em Seropédica, Rio de Janeiro. **Revista Floresta e Ambiente**, vol. 21 (2), p. 140-149, 2014.

OLIVEIRA, G. S. O. **El Niño e você: o fenômeno climático**. São José dos Campos: Transtec, 116 p., 1999.

OLIVEIRA, L. F. C.; FIOREZE, A. P.; MEDEIROS, A. M. M.; SILVA, M. A. S. Comparação de metodologias de preenchimento de falhas de séries históricas de precipitação pluvial anual. **Revista Brasileira de Engenharia Agrícola e Ambiental**, vol. 14, n. 11, p. 1186-1192, 2010.

PACHECO, B. L. S.; SILVA JÚNIOR, L. G.; OLIVEIRA, L. A. Estudo da relação entre temperatura/altitude e precipitação/altitude aplicando-se métodos de correlação e regressão. **Revista Geonorte**, Edição Especial 2, vol. 1, n. 5, p. 561-572, 2012.

PAEK, H.; YU, J. Y.; QIAN, C. Why were the 2015/2016 and 1997/1998 extreme *El Niños* different? **Geophysical Research Letters**, vol. 44, p. 1848-1856, 2017.

PARKINSON, S. C.; DJILALI, N. Robust response to hydro-climatic change in electricity generation planning. **Climatic Change**, vol. 130, Issue 4, p. 475-489, 2015.

PARTS, K.; TEDERSOO, L.; LÖHMUS, K. *et al.* Increased air humidity and understory composition shape short root traits and the colonizing ectomycorrhizal fungal community in silver birch stands. **Forest Ecology and Management**, vol. 310, p. 720-728, 2013.

PAZ, A. R. (2004). **Hidrologia Aplicada – Texto básico**. Universidade Estadual do Rio Grande do Sul, Caxias do Sul – RS. Disponível em: <http://www.ct.ufpb.br/~adrianorpaz/artigos/apostila_HIDROLOGIA_APLICADA_UERGS.pdf>. Acesso em: 25 de abril de 2017.

PEREIRA, R. 2013. **Orçamento em R\$ 16 bilhões, custo da Usina de Belo Monte já supera os R\$ 30 bilhões**. O Estado de S. Paulo, Economia & Negócios. Disponível em: <<http://economia.estadao.com.br/noticias/geral,orcado-em-r-16-bilhoes-custo-da-usina-de-belo-monte-ja-supera-os-r-30-bilhoes,153398e>>. Acesso em: 07 mar. 2017.

PFAFSTETTER, O. **Classificação de Bacias Hidrográficas – Metodologia de Codificação**. Rio de Janeiro, RJ: DNOS, 19 p., 1989.

PHILLIPS, O. L.; ARAGÃO, L. O. C.; LEWIS, S. L. *et al.* Drought sensitivity of the Amazon rainforest. **Science (New York, N.Y.)**, vol. 323, p. 1344-1347, 2009.

PINTO, H. S.; ASSAD, E. D.; ZULLO, J. R. *et al.* Impacto do Aumento da Temperatura no Zoneamento Climático do Café nos Estados de São Paulo e Goiás. Avaliação dos cenários do IPCC. **XII Congresso Brasileiro de Agrometeorologia**, p: 605-606. Fortaleza. 2001.

PORTO JÚNIOR, R.; PIRES, B. P.; GOUVEIA, G. R. *et al.* Caracterização geológico-geotécnica do movimento de massa ocorrido entre as praias da Prainha e Grumari, no Município do Rio de Janeiro, RJ. **Anuário do Instituto de Geociências**, vol. 35, p. 5-13, 2012.

POTTER, C.; KLOOSTER, S.; HIATT, C. *et al.* Changes in the carbon cycle of Amazon ecosystems during the 2010 drought. **Environmental Research Letters**, vol. 6, n. 3, 034024, 4 p., 2011.

QUADROS, L. E.; QUEIROZ, M. M. F.; BOAS, M. A. V. Distribuição de frequência e temporal de chuvas intensas. **Acta Scientiarum. Agronomy**, vol.33, p. 401-410, 2011.

QUEIROZ, G. de. **Métodos e interpretação de modelos estatísticos de análise de medidas repetidas: uma aplicação a ensaio clínico**. Dissertação 132p. (Mestrado) – Escola Nacional de Saúde Pública Sergio Arouca. Rio de Janeiro, 2012.

QUEIROZ, L. J.; OHARA, W.; ZUANON, J. *et al.* Um breve histórico sobre o conhecimento da fauna de peixes do Rio Madeira. (Eds.) **Peixes do Rio Madeira. Dialeto Latin American Documentary**, São Paulo, SP, vol. 1, p. 19-25, 2013.

QUEIROZ, M. A. **Avaliação de tendências em séries de precipitação diária máxima anual na faixa central do estado de Minas Gerais**. Dissertação 202f. (Mestrado em Saneamento, Meio Ambiente e Recursos Hídricos) – curso de pós-graduação da Universidade Federal de Minas Gerais. Belo Horizonte, MG. 2013.

RAMOS, C. M. C.; SILVA, A. F.; BASSOI, L. H. *et al.* Análise temporal de fatores climáticos em Petrolina-Pe. In: **X Congresso Argentino de Ingeniería Rural, 5; MERCOSUR, Rosário**, p. 1036-1041, 2009.

REUWSAAT, J. D. V. Estudo de alternativas de estimativa para jazidas de ferro utilizando dados heterotópicos. Dissertação de mestrado. **Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais (PPGEM)**. Universidade Federal do Rio Grande do Sul, Escola de Engenharia. Porto Alegre – RS, 2011.

RIBEIRO, V. W. S. M.; BASSANI, C. A questão da Hidrelétrica como fonte de energia essencial no modelo atual de sustentabilidade: O caso de Belo Monte. **VII Congresso Nacional de Excelência em Gestão**. Rio de Janeiro, 2011.

RICHTER, B. D.; POSTEL, S.; REVENGA, C. *et al.* Lost in development's shadow: The downstream human consequences of dams. **Water Alternatives**, vol. 3 (2), p. 14-42, 2010.

RITTER, C. D.; McCRATE, G.; HENRIK NILSSON, R. *et al.* Environmental impact assessment in Brazilian Amazonia: Challenges and prospects to assess biodiversity. **Biological Conservation**, vol. 206, p. 161-168, 2017.

RODRIGUES, R. R.; MCPHADEN, M. J. Why did the 2011-2012 *La Niña* cause a severe drought in the Brazilian Northeast? **Geophysical Research Letters**, vol. 41, issue 3, p. 1012-1018, 2014.

RONCHAIL, J.; COCHONNEAU, G.; MOLINIER, M. *et al.* Interannual rainfall variability in the Amazon Basin and sea-surface temperatures in the equatorial Pacific and the tropical Atlantic oceans. **International Journal of Climatology**, vol. 22 (13), p. 1663-1686, 2002.

SALVIANO, M. F.; GROppo, J. D.; PELLEGRINO, G. Q. Análise de tendências em dados de precipitação e temperatura no Brasil. **Revista Brasileira de Meteorologia**, vol. 31, n. 1, p. 64-73, 2016.

SÁNCHEZ-VELASCO, L.; BEIER, E., GODÍNEZ, V. M. *et al.* Hydrographic and fish larvae distribution during the “Godzilla *El Niño* 2015–2016” in the northern end of the shallow oxygen minimum zone of the Eastern Tropical Pacific Ocean. **Journal of Geophysical Research**. Vol. 122, Issue 3, p. 2156-2170, 2017.

SANTOS, C. A. C.; SATYAMURTY, P.; SANTOS, E. M. Tendências de índices de extremos climáticos para a região de Manaus-AM. **Acta Amazonica**, vol. 42 (3), p. 329-336, 2012.

SANTOS, J. M. L.; MELLO, S. C. B. Os significados de Belo Monte no discurso das mídias sociais. **Comunicação, mídia e consumo**, vol. 11, n. 30, p. 13-36, 2014.

SANTOS, N. B. F. dos, NASCIMENTO, D. T. F., BARROS, J. R. . Influência do fenômeno Índice de Oscilação Sul (*El Niño e La Niña*) na temperatura de superfície do bioma Cerrado. In: **Simpósio Internacional de Climatologia**, 2011, João Pessoa-PB. Anais do IV SIC, 2011.

SANTOS, S. R. Q. **Determinação de regiões homogêneas do índice de precipitação normalizada (SPI) no estado do Pará por meio da análise multivariada**. Dissertação 97f. (Mestrado) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais. Campina Grande – Paraíba, 2013.

SANTOS, S. R. Q.; BRAGA, C. C.; CAMPOS, T. L. O. B. *et al.* Variabilidade da Precipitação no Estado do Pará por meio de Análise em Componentes Principais. **Revista Brasileira de Geografia Física**, vol. 7, n. 3, p. 615-627, 2014.

SANTOS, T. O.; NETO, M. L. P.; ALMEIDA, G. L. P. *et al.* Análise temporal da variação da temperatura em uma região do agreste pernambucano utilizando-se a Geoestatística. **XVII Congresso Brasileiro de Agrometeorologia**. Guarapari – ES, 18 a 21 de julho, 2011.

SAUCIER, W. J. **Princípios de Análise Meteorológica**. Rio de Janeiro, 1969.

SCHAEFFER, R.; SZKLO, A. S.; LUCENA, A. F. P. *et al.* Energy sector vulnerability to climate change: a review. **Energy**, vol. 38 (1), p. 1-12, 2012.

SELLIN, A.; TULLUS, A.; NIGLAS, A. *et al.* Humidity-driven changes in growth rate, photosynthetic capacity, hydraulic properties and other functional traits in silver birch (*Betula pendula*). **Ecological Research**, vol. 28, issue 3, p. 523-535, 2013.

SENA, J. A.; de DEUS, L. A. B.; FREITAS, M. A. V. *et al.* Extreme Events of Droughts and Floods in amazonia: 2005 and 2009. **Water Resour Manage**, vol. 26, p. 1665-1676, 2012.

SENE, E.; MOREIRA, J. C. **Geografia geral e do Brasil**. Editora Scipione, 504 p., 1998.
SILVA, A.; MINUZZI, R. B. Modelagem estatística para previsão de geada de radiação. **Ciência e Natura**, vol. 38, n. 3, p. 1453-1460, 2016.

SILVA, D. A.; SANDER, C.; ARAÚJO JÚNIOR, A. C. R. *et al.* Análise dos ciclos de precipitação na região de Boa Vista – RR nos anos de 1910 a 2014. **Revista Geográfica Acadêmica**, vol. 9, n. 2, p. 34-49, 2015.

SILVA, E. N. **Viabilidade econômica em processos de rosqueamento utilizando machos de roscas com condicionador metálico**. Dissertação 95f. (Mestrado) – Programa de Pós-Graduação em Engenharia de Produção da Universidade Nove de Julho. São Paulo, 2014.

SILVA, J. B.; BURGUEÑO, L. E. T.; FERREIRA, C. C.; PEREIRA, R. S. Umidade relativa em Pelotas, RS. I – Análise estatística. **Revista Brasileira de Agrometeorologia**, vol. 10, n. 1, p. 129-134, 2002.

SILVA, J. W.; GUIMARÃES, E. C.; TAVARES, M. Variabilidade temporal da precipitação mensal e anual na estação climatológica de Uberaba - MG. **Ciência e Agrotecnologia**. Lavras, vol. 27, n. 3, p. 665-674, 2003.

SILVA, P. R. Os rios paraenses: uma breve descrição potamográfica. **Boletim Amazônico de Geografia** (ISSN: 2358-70 – online), Belém, vol. 1, n. 2, p. 88-104, 2014.

SILVA, R. B. C. 2014. **Influência das variáveis atmosféricas e do gás CO₂ na concentração populacional de vetores na região de Caxiuanã, Pará, Brasil**. Tese de Doutorado. Universidade de São Paulo. Instituto de Astronomia, Geofísica e Ciências Atmosféricas. São Paulo/SP.

SOARES, A. **Geoestatística para as ciências da terra e do ambiente**. Coleção ensino da ciência e da tecnologia, 3^a ed. I.S.T. Press, 232 p., 2014.

SOITO, J. L. S.; FREITAS, M. A. V. Amazon and expansion of hydropower in Brazil: vulnerability, impacts and possibilities for adaptation to global climate change. **Renewable and Sustainable Energy Reviews**, vol. 15 (6), p. 3165-3177, 2011.

SOPPA, M. A.; SOUZA, R. B.; PEZZI L. P. Variabilidade das anomalias de temperatura da superfície do mar no Oceano Atlântico Sudoeste e sua relação com o fenômeno El Niño-Oscilação Sul. **Revista Brasileira de Meteorologia**, vol. 26, n. 3, p. 347-363, 2011.

SOUSA JÚNIOR, W. C.; REID, J. Uncertainties in Amazon hydropower development: Risk scenarios and environmental issues around the Belo Monte dam. **Water Alternatives**, vol. 3 (2), p. 249-268, 2010.

SOUSA, A. P. **Análise comparativa de métodos de previsão de séries temporais através de modelos estatísticos e rede neural artificial**. Dissertação 101f. (Mestrado) – Pontifícia Universidade Católica de Goiás, Programa de Pós-Graduação Stricto Sensu em Engenharia de Produção e Sistemas, Goiânia, Goiás, 2012.

SOUZA JÚNIOR, J. A.; NECHET, D.; OLIVEIRA, M. C. F.; ALBUQUERQUE, M. F. Estudos do comportamento da temperatura e precipitação nos períodos chuvosos e menos chuvosos em Belém-PA em anos de fortes eventos de *El Niño* e *La Niña*. **Revista Brasileira de Climatologia**, vol. 5, p. 87-101, 2009.

SOUZA, A.; SANTOS, D. A. S.; ARISTONE, F. *et al.* Impacto de fatores meteorológicos sobre as concentrações de ozônio modelados por análise de séries temporais e métodos estatísticos multivariados. **Holos**, Ano 33, vol. 5, p. 2-16, 2017.

SOUZA, L. C.; QUEIROZ, J. E.; GHEYI, H. R.; Variabilidade espacial da salinidade de um solo aluvial no semi-árido paraibano. **Revista Brasileira Agrícola e Ambiental**, vol. 4, n.1, p. 35-40, 2000.

STEIN, M. L. **Interpolation of spatial data: some theory for kriging**. Springer, Berlin, 1999.

STICKLER, C. M.; COE, M. T.; COSTA, M. H. *et al.* Dependence of hydropower energy generation on forest in the Amazon Basin at local and regional scales. **Proceedings of the National Academy of Sciences of the United States of America (PNAS)**, vol. 110, n. 23, p. 9601-9606, 2013.

STRAHLER, A.; STRAHLER, A. **Introducing Physical Geography**. 2^a edition. New York, 1997.

STURARO, J. R. **Apostila de Geoestatística Básica**. UNESP/ Campus de Rio Claro. Departamento de Geologia Aplicada – IGCE. 2015.

TANG, H.; DUBAYAH, R. Light-driven growth in Amazon evergreen forests explained by seasonal variations of vertical canopy structure. **Proceedings of the National Academy of Sciences**, vol. 114 (10), p. 2640-2644, 2017.

TERRA, V. S. S. **Variabilidade espacial e temporal de atributos agronômicos em pomar de pessegueiro**. 103p. Tese (Doutorado em Agronomia), Universidade Federal de Pelotas, Pelotas-RS. 2012.

TOKAIRIN, T.; SOFVANB, A.; KITADAA T. Effect of land use changes on local meteorological conditions in Jakarta, Indonesia: Toward the evaluation of the thermal environment of megacities in Asia. **International Journal of Climatology**, vol. 30, n. 3, p. 1931-1941, 2010.

TONATO, F.; BARIONI, L. G.; PEDREIRA, C. G. S. *et al.* Desenvolvimento de modelos preditores de acúmulo de forragem em pastagens tropicais. **Pesquisa Agropecuária Brasileira**, Brasília, vol. 45, p. 522-529, 2010.

TORETI, A.; DESIATO, F. Temperature trend over Italy from 1961 to 2004. **Theoretical and Applied Climatology**, vol. 91, n. 1, p. 51-58, 2008.

TORGOVITSKI, L. A Darling–Erdős-type CUSUM-procedure for functional data. **Metrika**, vol. 78, n. 1, p. 1-27, 2015.

TORRENTE, M. **Influência da temperatura no consumo de água na região metropolitana de São Paulo**. Programa de Pós-Graduação em Administração da Universidade Nove de Julho – Dissertação de mestrado. São Paulo, 2014.

TORRES, F. T. P.; MACHADO, P. J. O. **Introdução à Climatologia – Série Textos Básicos de Geografia**. São Paulo: Cengage Learning, 2012.

TRIOLA, M. F. **Introdução à estatística: atualização da tecnologia**. 11ª edição, editora LTC, Rio de Janeiro. 740 p., 2013.

TSENG, F.-M.; TZENG, G.-H. A fuzzy seasonal ARIMA model for forecasting. **Fuzzy Sets and Systems**, vol. 126, n. 3, p. 367–376, 2002.

TUBELIS, A. **Meteorologia Descritiva: fundamentos e aplicações brasileiras**. São Paulo: Nobel, 1983.

TUNDISI, J. G.; MASTSUMURA-TUNDISI, T.; TUNDISI, J. E. M. Environmental Impact Assessment of reservoir construction: new perspectives for restoration economy, and development: the Belo Monte Power Plant case study. **Brasilian Journal of Biology**, vol. 75, n. 3 (suppl.), p. S10 – S15, São Carlos, 2015.

VASSOLER, R. T. ZEBENDE. G. F. DCCA cross-correlation coefficient apply in time series of air temperature and air relative humidity. **Physica A**, vol. 391, p. 2438-2443, 2012.

VAUCHEL, P. Estudo da cheia de 2014 na bacia do rio Madeira. **Institut de Recherche pour Développement - IRD**, Estudo do programa HYBAM, 2014.

VAZ, C. M. **Análise de tendência em séries de precipitação diária máxima anual**. 84f. Dissertação (Mestrado em Engenharia Civil) – Curso de pós-graduação em Engenharia Civil. Instituto Superior Técnico- Universidade Técnica de Lisboa, Lisboa, 2008.

VERÓN, S. R.; ABELLEIRA, D.; LOBELL, D. B. Impacts of precipitation and temperature on crop yields in the Pampas. **Climatic Change**, vol. 130, n. 2, p. 235–245, 2015.

VICENTE-SERRANO, S. M.; BEGUERÍA, S.; LÓPEZ-MORENO, J. *et al.* A complete daily precipitation database for northeast Spain: reconstruction, quality control, and homogeneity. **International Journal of Climatology**, vol. 30 (8), p. 1146-1163, 2010.

VINOD, H. D. Generalization of the Durbin-Watson statistic for higher order autoregressive process. **Communications in Statistic**, vol. 2, p. 115-144, 1973.

VIOLA, M. R.; MELLO, C. R.; PINTO, D. B. F. *et al.* Métodos de interpolação espacial para o mapeamento da precipitação pluvial. **Revista Brasileira de Engenharia Agrícola e Ambiental**, vol.14, pp. 970-978, 2010.

VIRGILLITO, S. B. **Estatística Aplicada – 3ª Edição**. Editora Edicon, 590 p., 2007.

VIVIANI, E.; MANZATO, G. G. Geração de modelos digitais de superfície por meio de plataformas computacionais com estrutura vetorial e raster. **Ciência e Engenharia**, vol. 15, p. 27-34, 2005.

VOLTAN, D. S.; BARBOSA, R. Z.; MARTINS, J. E. M. P. Variabilidade espacial da umidade relativa do ar no interior de uma casa de vegetação em clima tropical. **Revista Brasileira de Ciências Agrárias**, vol. 9, n. 2, p. 251-257, 2014.

WACKERNAGEL, H. (2003). 3^a edition. **Multivariate geostatistics: An Introduction with Applications**. Springer-Verlag, Berlin, 381 p., 2003.

WANG, H.; CHEN, Y.; LI, W. Characteristics in streamflow and extremes in the Tarim river, China: trends, distribution and climate linkage. **International Journal of Climatology**, vol. 35, n. 5, p. 761-776, 2015.

WARRICK, A.W.; NIELSEN, D. R. **Spatial variability of soil physical properties in the field**. In: Hillel, D. (Ed.). Applications of soil physics. New York: Academic Press, 385 p. 1980.

WESTIN, F. F.; SANTOS, M. A.; MARTINS, I. D. Hydropower expansion and analysis of the use of strategic and integrated environmental assessment tools in Brazil. **Renewable and Sustainable Energy Reviews**, vol. 37, p. 750-761, 2014.

XU, L.; SAMANTA, A.; COSTA, M. *et al.* Widespread decline in greenness of Amazonian vegetation due to the 2010 drought. **Geophysical Research Letters**, vol. 38 (7), p. 2-5, 2011.

YAMAMOTO, J. K.; BETTENCOURT, J. S.; MONTANHEIRO, T. J. Análise estatística In: Yamamoto, J.K. (org.). **Avaliação e classificação de reservas minerais**. São Paulo, Edusp. p. 67- 91, 2001.

YAMAMOTO, J. K.; LANDIM, P. M. M. **Geoestatística – conceitos e aplicações**. São Paulo: Oficina de textos, 215 p., 2013.

YANG, J.; GONG, P.; FU, R. *et al.* The role of satellite remote sensing in climate change studies. **Nature Climate Change**. DOI: 101038/NCLIMATE1908, vol. 3, 2013.

ZAVATTINI, J. A. **As Chuvas e as Massas de ar no Estado de Mato Grosso do Sul – Estudo Geográfico com vista à regionalização climática**. Editora da UNESP Cultura Acadêmica, São Paulo, 212 p. 2009.

ZHANG, M. MU, H.; LI, G.; NING, Y. Forecasting the transport energy demand based on pls method in China. **Energy**, vol. 34, n. 9, p. 1396-1400, 2009.

ZHANG, W.; VILLARINI, G.; VECCHI, G. A. Impacts of the Pacific Meridional Mode on June-August Precipitation in the Amazon River Basin. **Quarterly Journal of the Royal Meteorological Society**. Accepted Author Manuscript. 2017.

ZHANG, W.; YAN, Y.; ZHENG, J. *et al.* Temporal and spatial variability of annual extreme water level in the Pearl River Delta region, China. **Global and Planetary Change**, vol. 69 (1-2) p. 35-47, 2009.