



**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS**

CAMIL WADIH SALAME

**ANÁLISE DE TENDÊNCIAS HIDROCLIMÁTICAS NA BACIA HIDROGRÁFICA
ARAGUAIA-TOCANTINS E SUAS IMPLICAÇÕES NA AGRICULTURA IRRIGADA**

BELÉM-PARÁ

2023

CAMIL WADIH SALAME

**ANÁLISE DE TENDÊNCIAS DE VARIÁVEIS HIDROCLIMÁTICAS NA BACIA
HIDROGRÁFICA ARAGUAIA-TOCANTINS E SUAS IMPLICAÇÕES NA
AGRICULTURA IRRIGADA**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciências Ambientais, do Instituto de Geociências da Universidade Federal do Pará como requisito para a obtenção do título de Doutor em Ciências Ambientais.

Área de Concentração: Clima e Dinâmica Socioambiental Na Amazônia
Linha de Pesquisa: Interação Clima, Sociedade e Ambiente

Orientador: Prof. Dr. Everaldo Barreiros de Souza

Coorientador: Prof. Dr. Joaquim Carlos Barbosa Queiroz

BELÉM-PARÁ

2023

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a)
autor(a)**

S159a Salame, Camil Wadih.
Análise de tendências de variáveis hidroclimáticas na
bacia hidrográfica Araguaia-Tocantins e suas implicações na
agricultura irrigada / Camil Wadih Salame. — 2019.
165 f. : il. color.

Orientador(a): Prof. Dr. Everaldo Barreiros de Souza
Coorientador(a): Prof. Dr. Joaquim Carlos Barbosa
Queiroz

Tese (Doutorado) - Universidade Federal do Pará,
Instituto de Geociências, Programa de Pós-Graduação em
Ciências Ambientais, Belém, 2019.

1. Bacia hidrográfica. 2. Hidroclimatologia. 3. Box-
Jenkins. 4. Redes neurais artificiais. 5. Pivos centrais.
I. Título.

CDD 630.2516

CAMIL WADIIH SALAME

**ANÁLISE DE TENDÊNCIAS DE VARIÁVEIS HIDROCLIMÁTICAS NA BACIA
HIDROGRÁFICA ARAGUAIA-TOCANTINS E SUAS IMPLICAÇÕES NA
AGRICULTURA IRRIGADA**

Tese apresentada ao Programa de Pós-Graduação em Ciências Ambientais do Instituto de Geociências da Universidade Federal do Pará, como requisito para a obtenção do título de Doutor em Ciências Ambientais.

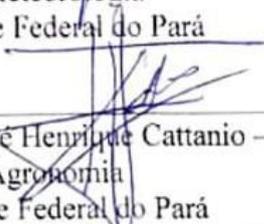
Área de Concentração: Clima e Dinâmica Socioambiental Na Amazônia
Linha de Pesquisa: Interação Clima, Sociedade e Ambiente

Aprovado em: 28/02/2019.

Banca examinadora:



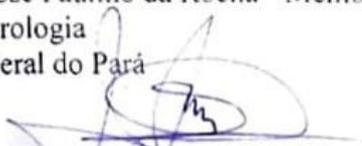
Prof. Dr. Everaldo Barreiros de Souza - Orientador
Doutor em Meteorologia
Universidade Federal do Pará



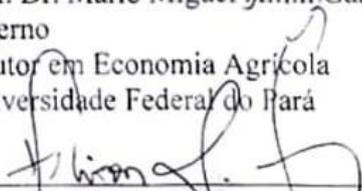
Prof. Dr. José Henrique Cattanio – Membro Interno
Doutor em Agronomia
Universidade Federal do Pará



Prof. Dr. Edson José Paulino da Rocha - Membro Interno
Doutor em Meteorologia
Universidade Federal do Pará



Prof. Dr. Mário Miguel Amin Garcia Herreros - Membro Externo
Doutor em Economia Agrícola
Universidade Federal do Pará



Prof. Dr. Heliton Ribeiro Tavares - Membro Externo
Doutor em Estatística
Universidade Federal do Pará

AGRADECIMENTOS

Ao Prof. Dr. Joaquim Carlos Barbosa Queiróz, que nos anos de convivência, muito me ensinou, contribuindo para meu crescimento científico e intelectual.

Ao Prof. Dr. Everaldo Barreiros de Souza, pela atenção e apoio durante o processo de definição e orientação.

Aos colegas do PPGCA da UFPA, pela amizade, discussões e contribuições na elaboração desta Tese.

Ao meu pai Wadih Salame e minha mãe Luiza Salame (*in memoriam*).

Às minhas duas “mães” Walide e Wardie, a quem foram entregues minha guarda permanente.

Aos meus queridos sobrinhos Samira, Jihad e Ramza, e ao príncipe Khaled.

Finalmente, aos meus abençoados filhos Kamii, Haila, Youssef e Samir.

À querida e inesquecível professora Maria José de Assunção Alves.

RESUMO

A Bacia Hidrográfica Araguaia-Tocantins (BHAT) é a mais extensa em área de drenagem dentro do território brasileiro, com processos de uso e ocupação cada vez mais crescentes em termos das demandas do agronegócio e exploração mineral. Nesta pesquisa realizou-se um estudo estatístico sobre as tendências hidroclimáticas (precipitação e vazão) na BHAT e suas relações com a agricultura irrigada. O mapeamento hidroclimático baseado na análise de agrupamento identificou quatro regiões homogêneas dentro da BHAT, duas ao norte com predominância de altos valores de chuva/vazão e alta disponibilidade hídrica e duas regiões se estendendo ao longo da bacia, com valores mais baixos de chuva e vazão e menor disponibilidade hídrica. O regime chuvoso da BHAT ocorre entre dezembro e março e o regime seco entre maio e setembro. Os meses de outubro/novembro e abril são de transição com variações pronunciadas no ciclo sazonal. O estudo geoestatístico de previsões chuva/vazão revelou que os resultados usando o modelo de Box-Jenkins é relativamente melhor quando comparado ao modelo de Redes Neurais Artificiais. A abordagem integrada das variáveis hidroclimáticas com os dados agropecuários dentro da BHAT revelaram um padrão significativo de tendências negativas de precipitação e vazões coincidentes espacialmente nas regiões de intensa produtividade de milho e soja e de rebanho bovino. Um resultado relevante foi a detecção de correlação espacial significativa entre o número de pivos centrais em regiões com baixa disponibilidade hídrica, os quais favorecem a produtividade das culturas temporárias.

Palavras-chave: bacia hidrográfica; hidroclimatologia; box-Jenkins; redes neurais artificiais; pivos centrais.

ABSTRACT

The Araguaia-Tocantins Hydrographic Basin (BHAT) is the most extensive in drainage area within the Brazilian territory, with processes of use and occupation increasing in terms of the demands of agribusiness and mineral exploration. In this research a statistical study was carried out on the hydroclimatic trends (precipitation and river flow) in BHAT and its relations with irrigated agriculture. The hydroclimatic mapping based on the cluster analysis identified four homogeneous regions within BHAT, two to the north with a predominance of high rainfall/flow rates and higher water availability and two regions extending along the basin, with lower rainfall/flow rates and less water availability. In the BHAR the rainy regime occurs between December to March and the dry regime between May and September. The months of October/November (dry to rainy) and April (rainy to dry) are transitional periods with pronounced variations in the seasonal cycle. The geostatistical study of rainfall/river flow forecasts revealed that the results using the Box-Jenkins model are relatively better when compared to the Artificial Neural Networks model. The integrated approach of hydroclimatic variables with agricultural data within BHTA revealed a significant pattern of negative trends in rainfall and flows that are spatially consistent in regions of intense productivity of corn and soybeans and cattle. A relevant result was the detection of a significant spatial correlation between the number of central pivots (irrigation) in regions with lower water availability, which favor the productivity of temporary crops.

Keywords: hidrological basin; hydroclimatology; box-Jenkins; artificial neural network; central pivot.

LISTA DE ILUSTRAÇÕES

Figura 1 - Bacia hidrográfica do Araguaia–Tocantins.....	21
Figura 2- Modelos de semivariograma esférico.	23
Figura 3 - Estações pluviométricas (A) e fluviométricas (B).	25
Figura 4 - Chuvas mensais observadas (linha cheia) e imputadas (linha tracejada), Estação Conceição do Tocantins (Tocantins).	27
Figura 5 - Regimes de Chuvas (mm) mensais para as 45 estações da Bacia do Tocantins.....	28
Figura 6 - Painéis dos regimes de chuvas mensais de 9 estações selecionadas da BHAT.....	28
Figura 7 - Regimes de Vazão (m^3/s) mensais para as estações com vazões médias mensais máxima abaixo de $600 m^3/s$ (A) a próximos de $15000 m^3/s$ (B) da BHAT.....	29
Figura 8 - Chuvas mensais (mm) para a Bacia do Araguaia-Tocantins.....	32
Figura 9 - Vazões mensais (m^3/s) para a Bacia do Araguaia-Tocantins.....	36
Figura 10 - Classificação de chuvas (a), vazões (b) e chuvas e vazões conjuntamente (c) baseada no método de k-Means.	40
Figura 11 - Grupos formados por k-means com base na chuva (A) e médias mensais (regimes) de cada grupo (B).....	45
Figura 12 - Grupos formados por k-means com base na vazão (A) e médias mensais de cada grupo (B)	46
Figura 13 - Grupos formados por k-means com base na vazão e chuva conjuntamente (A) e médias mensais de cada grupo para chuva (B) e vazão(C).....	47
Figura 14 - Mapa com os pivos (em pontos) e usinas hidrelétricas nas áreas irrigadas na bacia.....	50
Figura 15 - Bacia hidrográfica do Araguaia–Tocantins.....	56
Figura 16 - Percepção multicamada com uma camada oculta.....	58
Figura 17 - Série de chuvas mensais na estação Leverger (MT) de 1969 a 2017....	63
Figura 18 - Série de vazões mensais (m/s) na estação Travessão (GO) de 1974 a 2017.....	64
Figura 19 - FAC e FACP para as chuvas mensais. Serie Leverger	65
Figura 20 - FAC e FACP para as vazões mensais. Serie Travessão	65

Figura 21 - FAC e FACP dos resíduos para as chuvas mensais. Serie Leverger.....	67
Figura 22 - FAC e FACP dos resíduos para as vazões mensais. Serie Travessão ..	67
Figura 23 - Previsões com modelo BJ e valores observados para chuvas na estação Leverger para 2017 (A) e 2016-2017 (B) com IC de 95% (área cinza) ..	68
Figura 24 - Previsões com modelo BJ e valores observados para vazões na estação Travessão para 2017 (acima) e 2016-2017 (abaixo) com IC de 95% (área cinza)	69
Figura 25 - Diagrama do modelo MLP da RNI utilizada, com 12 entradas e 5 camadas ocultas	69
Figura 26 - Previsões com RN para chuvas. Estação Leverger para 2017 e 2016- 2017.....	70
Figura 27 - Previsões com RN para vazões. Estação Travessão para 2017 e 2016- 2017.....	71
Figura 28 - Previsões com BJ e RN para chuvas (mm) na estação Leverger para 2017 e 2016-2017.....	72
Figura 29 - Previsões com BJ e RN para vazões (m ³ /s) na estação Travessão para 2017 e 2016-2017.....	74
Figura 30 - Valores observados e previsões mensais de chuva para o ano de 2017 pelos métodos RN e BJ:.....	77
Figura 31 - Bacia hidrográfica do Araguaia–Tocantins subbacias.	93
Figura 32 - Diagrama de dispersão de Moran bivariado.....	99
Figura 33 - Série de chuvas (Goiatins) e vazões (Tocantinópolis) com linhas de tendência.....	102
Figura 34 - Médias anuais de chuvas (vermelho) e vazões (preto) e linhas de tendência. Bacia Araguaia-Tocantins. Grupos 1 e Grupo 2.....	104
Figura 35 - Médias anuais de chuvas (vermelho) e vazões (preto) e linhas de tendência. Bacia Araguaia-Tocantins. Grupos 3 e 4.....	106
Figura 36 - Médias anuais de chuvas (vermelho) e vazões (preto) e linhas de tendência. Bacia Araguaia-Tocantins. Todas as estações (Período de 1975 a 2012).....	108
Figura 37 - Chuvas e vazões na Bacia Araguaia-Tocantins. 1980 a 2010	111
Figura 38 - Mapa da BHAT com os pivos centrais (em pontos), principais rios e usinas hidrelétricas nas regiões com diferentes disponibilidades hídricas	114

Figura 39 - Relação de chuvas com Pivos (A), Cultura Temporaria (B), Rebanho Bovino (C) e Vazão (D).....	116
Figura 40 - Relação de vazões com Pivos (A), Cultura Temporaria (B), Rebanho Bovino (C)	117
Figura 41 - Rebanho Bovino (A) e Cultura Temporaria (B) de 2000 a 2007.....	118
Figura 42 - Grafico de dispersão Bivariado de Moran	120
Figura 43 - Mapas LISA para a chuva e vazao (A), pivos (B), Cultura Temporaria (C) e Rebanho Bovino (D)	122
Figura 44 - Mapas LISA para vazao e pivos (A), Cultura Temporaria (B) e Rebanho Bovino (C) e Pivos x Cultura Temporaria (D)	124

LISTA DE TABELAS

Tabela 1- Estatísticas da chuva (mm) para a Estação Conceição do Tocantins (Tocantins).	26
Tabela 2 - Parâmetros ajustados por modelos esféricos para os variogramas das chuvas (mm) e vazões (m ³ /s).	30
Tabela 3 - Estatísticas descritivas dos grupos formados por <i>k-means</i> para chuva e vazão.	42
Tabela 4 - Descritivas dos grupos formados por <i>k-means</i> para chuva e vazão conjuntamente.....	44
Tabela 5 - Medidas dos erros (RSME) nas previsões para cada modelo.....	74
Tabela 6 - Resultados para previsões com métodos BJ e RN. Ano de 2017	89
Tabela 7 - Modelos de tendencia linear ($y = \beta_0 + \beta_1x + \varepsilon$)	102
Tabela 8 - Medias anuais (Grupo 1)	105
Tabela 9 - Medias anuais (Grupo 2)	105
Tabela 10 - Medias anuais (Grupo 3)	107
Tabela 11 - Medias anuais (Grupo 4)	107
Tabela 12 - Medias anuais (Grupo 4)	108
Tabela 13 - Modelos de tendencia linear ($y = \beta_0 + \beta_1t + \varepsilon$)	109
Tabela 14 - Resultados das variáveis por grupos da BHAT	115
Tabela 15 - Indice Bivariado de Moran Global	119

LISTA DE SIGLAS

AEDE	Análise Exploratória de Dados Espaciais
ANA	Agência Nacional de Águas
ARIMA	Auto Regressivo Integrado de Médias Móveis
BHAT	Bacia Hidrográfica Araguaia Tocantins
BJ	Box-Jenkins
BLUP	<i>Best Linear Unbiased Prediction</i> (Melhor Preditor Linear não-Viesado)
CPTEC	Centro de previsão do Tempo e Estudos Climáticos
ELETROBRÁS	Eletronorte - Centrais Elétricas do Norte do Brasil S/A
FAC	Função Auto Correlação
FACP	Função auto correlação parcial
IBGE	Instituto Brasileiro de Geografia e Estatística
IC	Intervalo de Confiança
INPE	Instituto Nacional de Pesquisas Espaciais
LISA	<i>Local Indicator Spatial Statística</i>
MAE	Erro Absoluto Médio
MLP	<i>Multi-Layers Perceptron</i> (Percepção de multicamadas)
MMA	Ministério do Meio Ambiente
RNA	Rede Neural Artificial
RSME	<i>Root Mean Square Error</i> (Raiz Quadrada do Erro Médio)
SEPLAN	Secretaria de Estado de Planejamento
ST	Série Temporal
TSM	Temperatura de Superfície do Mar

SUMÁRIO

1 INTRODUÇÃO	14
1.1 Problema e Justificativa	15
1.2 Objetivos	17
1.2.1 Objetivo Geral.....	17
1.2.2 Objetivos Específicos.....	17
1.3 Estrutura da tese	17
2 CARACTERIZAÇÃO DA BACIA HIDROGRÁFICA ARAGUAIA-TOCANTINS COM BASE NOS REGIMES DE CHUVA E VAZÃO	19
2.1 Introdução	20
2.2 Material e Métodos	21
2.2.1 Área de estudo	21
2.2.2 Geoestatística.....	22
2.2.3 Método <i>k-means</i>	23
2.3 Resultados e Discussão	25
2.4 Conclusão	51
3 MAPEAMENTOS DE PREVISÕES DE CHUVAS NA BACIA ARAGUAIA-TOCANTINS	54
3.1 Introdução	55
3.2 Material e método	56
3.2.1 Área de Estudo.....	56
3.2.2 Redes Neurais Artificial.....	57
3.2.3 Modelos de Box-Jenkins para séries temporais	58
3.2.4 Geoestatística.....	60
3.3 Resultados e Discussão	63
3.4 Conclusão	89
4 TENDÊNCIAS HIDROCLIMÁTICAS E IMPLICAÇÕES NA AGRICULTURA IRRIGADA E PECUÁRIA	91
4.1 Introdução	92
4.2 Material e Métodos	93
4.2.1 Área de estudo	93
4.2.2 Geoestatística.....	94

4.2.3 Modelos de tendência	96
4.2.4 Análise exploratória de dados espaciais (AEDE).....	96
4.3 Resultados e Discussão.....	101
4.4 Conclusão	127
5 CONCLUSÃO GERAL.....	128
REFERÊNCIAS	130
APÊNDICE A1 - Estações pluviométricas utilizadas na avaliação dos níveis de chuva.....	131
APÊNDICE A2 - Outras Estações pluviométricas	133
APÊNDICE B1 - Estações fluviométricas utilizadas na avaliação dos níveis de vazão.....	133
APÊNDICE B2 - Outras Estações fluviométricas	133
APÊNDICE C - Códigos do R dos principais programas utilizados na implementação das análises	134

1. INTRODUÇÃO

A Bacia Hidrográfica Araguaia Tocantins é a mais extensa em área de drenagem totalmente contida em território brasileiro e palco de dinâmico processo de desenvolvimento socioeconômico que deverá se intensificar nas próximas décadas em função das demandas nacional e internacional por commodities. Por seu caráter estratégico para o país, as potencialidades hídricas, agropecuária, mineral, para navegação e geração de energia serão cada vez mais demandadas.

Segundo IBGE (2021), o Conselho Nacional de Recursos Hídricos estabeleceu a divisão do território nacional em 12 regiões hidrográficas, das quais a Bacia Hidrográfica Tocantins Araguaia (BHTA) é a mais extensa em termos da área de drenagem integralmente situada no território brasileiro. A região se caracteriza por uma área de drenagem de 918.822 km² (11% do país), se estende na direção sul-norte e abrange os estados do Pará (30% da área da região), Tocantins (30%) é o estado situado integralmente na região), Goiás (21%), Mato Grosso (15%) e Maranhão (4%), além do Distrito Federal (0,1%) totalizando 409 municípios com população de 7,2 milhões de habitantes (2000) apresenta baixa densidade demográfica de 7,8 hab./ km².

A Região Hidrográfica destaca-se por ser a segunda maior do país em termos de área e de vazão inferior apenas a do Amazonas e a maior do país com área de drenagem situada integralmente em território nacional. As dimensões equivalem a 1,5 vez a Bacia do Rio São Francisco e a vazão média de 13.799 m³/s (8% do total do país) resulta em elevado per capita de 60.536 m³/hab/ano (AQUINO et al., 2009).

As reservas hídricas subterrâneas exploráveis são de 996 m³/s, sendo que o seu potencial está concentrado nos sistemas aquíferos porosos pertencentes às bacias sedimentares do Urucuia e Parnaíba que ocorrem ao longo da porção leste. A ocupação da região, de forma mais intensa, foi iniciada nas décadas de 60 e 70 com a política de ocupação do interior do país e expansão da fronteira agropecuária. Essas atividades foram influenciadas pelos eixos rodoviários, em especial a rodovia Belém–Brasília.

Na década de 80, destacam-se a implantação da exploração mineral na Serra de Carajás (PA) e o aproveitamento do potencial hidroenergético iniciado com a Usina

de Tucuruí (PA) Em termos econômicos, atualmente as principais atividades são a agropecuária e a mineração.

Na agricultura de sequeiro existe uma área cultivada de soja, milho e arroz. Na agricultura irrigada, destacam-se as culturas do arroz, milho, feijão, soja e cana-de-açúcar. A região possui três importantes corredores ecológicos: Araguaia-Bananal, Jalapão-Mangabeiras e Paranã-Pireneus. No primeiro está localizada a Ilha do Bananal a maior ilha fluvial do mundo, que é formada pelo Rio Araguaia, e o Parque Nacional do Araguaia.

A Região Hidrográfica é a segunda maior do país em potencial hidro energético instalado com 11.573 MW (16% do país) e cinco grandes usinas em operação (11.460 MW), todas no Rio Tocantins. A Usina de Serra da Mesa tem o maior volume de reservatório do país e a de Tucuruí (8.365 MW), a maior capacidade de geração de uma usina nacional. O potencial hidrelétrico da região é de 23.825 MW.

1.1 Problema e justificativa

Nas conclusões para o Uso Sustentável dos Recursos Hídricos do Plano Estratégico de Recursos Hídricos da Bacia Araguaia Tocantins, proposto pelo Governo Federal em 2009 foi estabelecido que “*suas interfaces com o uso do solo, a proteção ambiental, o uso múltiplo e racional da água e o **preenchimento das lacunas de conhecimento atual da região**, complementam e dão consistência ao conjunto de ações*”.

Neste âmbito, a análise das variáveis hidroclimáticas com uso de modelos estatísticos, incluindo por exemplo, análise de séries históricas desses fenômenos é importante para uma série de procedimentos em geral interdependentes. Por exemplo, o modelamento de processos chuva-vazão e quantificação da disponibilidade hídrica de uma sessão hidrológica. Além de outros estudos relativos à gestão de recursos hídricos que utilizam as séries históricas.

Para tanto é necessário identificar se as séries históricas são homogêneas de modo a não considerar tendenciosidade nos dados de análise. Apesar dos esforços da Agência Nacional de Águas em ampliar a rede hidro meteorológica do País, observa-se nas séries de chuvas e vazões disponíveis falta de dados nas séries históricas. Devido à carência de dados, é necessário, muitas vezes, utilizar técnicas

de preenchimento de falhas e de consistência dos dados que, em muitos casos, só são possíveis com a utilização de estações vizinhas representativas.

Afirma que uma rede hidrométrica não cobre todos os locais de interesse necessários ao gerenciamento dos recursos hídricos de uma região. De forma que sempre existirão lacunas temporais e espaciais necessitando serem preenchidas com base em metodologias para estimativa dos dados de interesse em seções que não possuem medições.

Acrescenta que devido aos altos custos financeiros de implantação, operação e manutenção de uma rede hidrométrica, torna-se importante a otimização das informações disponíveis.

Visando suprir a deficiência no Brasil, uma técnica que tem sido utilizada com resultados satisfatórios é a regionalização hidrológica. De acordo com Fill (1987), em sentido amplo, entende-se por regionalização qualquer processo de transferência de informações das estações pluviométricas e fluviométricas para outros locais, em geral sem observações. Devido seu caráter aleatório, a distribuição de chuva no tempo e espaço são de grande importância no planejamento agrícola.

A análise realizada incluiu, entre outros, a verificação de padrões e fatores de influência do regime hidrológico, construção de mapas de previsões mensais de chuvas e estudos de tendências e relações espaciais entre variáveis hidroclimáticas e variáveis da agropecuária.

Neste sentido, a hipótese básica deste trabalho estabelece que os principais recursos hídricos (chuva e vazão) na BHTA interferem em atividades da agricultura e pecuararia.

1.2 Objetivos

1.2.1 Objetivo Geral

Analisar estatisticamente as características e tendências das variáveis hidroclimáticas na Bacia hidrográfica Araguaia-Tocantins e suas implicações na agricultura irrigada e pecuária.

1.2.2 Objetivos Específicos

- ✓ Elaborar os mapas de caracterização com base nos regimes de vazão e chuva da bacia hidrográfica Araguaia Tocantins;
- ✓ Construir os mapas de previsões de chuvas com uso de modelos temporais, espaciais e espaço-temporais;
- ✓ Estudar as tendências e relações espaciais entre variáveis hidroclimáticas e variáveis agropecuárias.

1.3 Estrutura da tese

No primeiro capítulo são apresentados a introdução, justificativa e objetivos do trabalho. Os capítulos seguintes foram organizados em forma de artigos científicos para submissão em revistas especializadas.

O segundo capítulo apresenta uma metodologia para a formação e caracterização de grupos (ou regiões) homogêneos na BHAT com base nos regimes de chuva e vazão, para identificação dos níveis de disponibilidade hídrica. A visualização espacial dos resultados será feita através de mapas construídos com o uso da geoestatística, que utiliza uma ferramenta denominada semivariogramas para a caracterização do padrão espacial das variáveis em estudo.

O terceiro capítulo utiliza modelos temporais e espaço-temporais para realização de mapas de previsão mensal de chuvas na bacia hidrográfica do Araguaia –Tocantins. Nas previsões foram utilizados dois métodos: Rede Neural artificial e modelos de previsão Box-Jenkins. Os mapas de previsão foram contruídos com auxílio de técnicas da geoestatística. O capítulo também apresenta uma breve bibliografia da aplicação às redes neurais artificias na modelagem do processo de previsão de chuvas

O quarto capítulo analisa a dinâmica da cobertura e uso da terra, com a utilização das variáveis cultura temporaria e o efetivo de rebanho bovino visando analisar a existência de possíveis relações espaciais entre as variáveis hidroclimáticas e agropecuarias.

2. CARACTERIZAÇÃO DA BACIA HIDROGRÁFICA ARAGUAIA-TOCANTINS COM BASE NOS REGIMES DE CHUVA E VAZÃO

Resumo

O comportamento do regime pluviométrico em uma região afeta o nível e vazão das bacias, pelo fato da chuva ser a principal moduladora da variação das vazões nas bacias hidrográficas. Logo, percebe-se a necessidade de buscar o entendimento do comportamento dinâmico do fenômeno chuva vazão. A caracterização dos regimes de chuvas e vazões com estudos de previsões de chuvas e possíveis enchentes e consequentes impactos socioeconômicos podem auxiliar na minimização de danos às populações ribeirinhas. Os regimes de chuva na bacia apresentam-se bastante diversificados com estações que apresentaram picos médios máximos mensais predominantes no primeiro semestre, entre os meses de janeiro a março e mínimos mensais no segundo semestre, entre os meses de junho a setembro. As vazões apresentam alta variabilidade, ocorrendo, de modo geral, picos máximos nos meses de fevereiro, março e abril e os picos mínimos entre os meses de junho a setembro. Quatro regiões dentro da bacia foram caracterizadas com base nos regimes de chuva e vazão, duas ao norte da bacia com predominância de altos valores de chuva e vazão, caracterizando alta disponibilidade hídrica, e duas se estendendo na maior parte da bacia, apresentando valores mais baixos de chuva e vazão, ou seja, com menor disponibilidade hídrica.

Palavras-chave: Bacia Hidrográfica do Araguaia-Tocantins, Regimes de chuva, Regimes de vazão, Geoestatística, *k-means*.

2.1 Introdução

A Bacia Hidrográfica Araguaia Tocantins é a segunda maior do país em potencial hidro energético instalado com 11.563 MW (16% do país) e 5 grandes usinas em operação (11.445 MW), todas no rio Tocantins. A usina de Serra da Mesa tem o maior volume de reservatório do país e a de Tucuruí (8.365 MW), a maior capacidade de uma usina nacional. O potencial hidrelétrico da região é de 23.825 MW.

Assim, a localização, abundância e potencial de utilização dos recursos naturais, especialmente da água, conferem à região um relevante papel no desenvolvimento do país. Apesar de a bacia estar contida numa região de baixa densidade populacional, fatores antropogênicos têm contribuído para alteração da cobertura vegetal do solo. A construção da rodovia Belém-Brasília, a usina hidrelétrica de Tucuruí, a expansão das atividades agropecuárias (principalmente soja e gado) e da mineração podem ser citados como principais causadores destas alterações.

Sabe-se que o desmatamento e as mudanças de uso da terra podem induzir alterações na variabilidade do clima e do ciclo hidrológico em escala local e em mesoescala, repercutindo com modificações na oferta de água disponível e no regime de cheias. Chuvas e vazões estão entre os principais processos do balanço hídrico, que incluem ainda, a evapotranspiração, temperatura e variação da umidade do solo. O estudo mais detalhado dessas variáveis (chuva e vazão) podem contribuir na discussão dos padrões que governam os processos hidro climáticos na região.

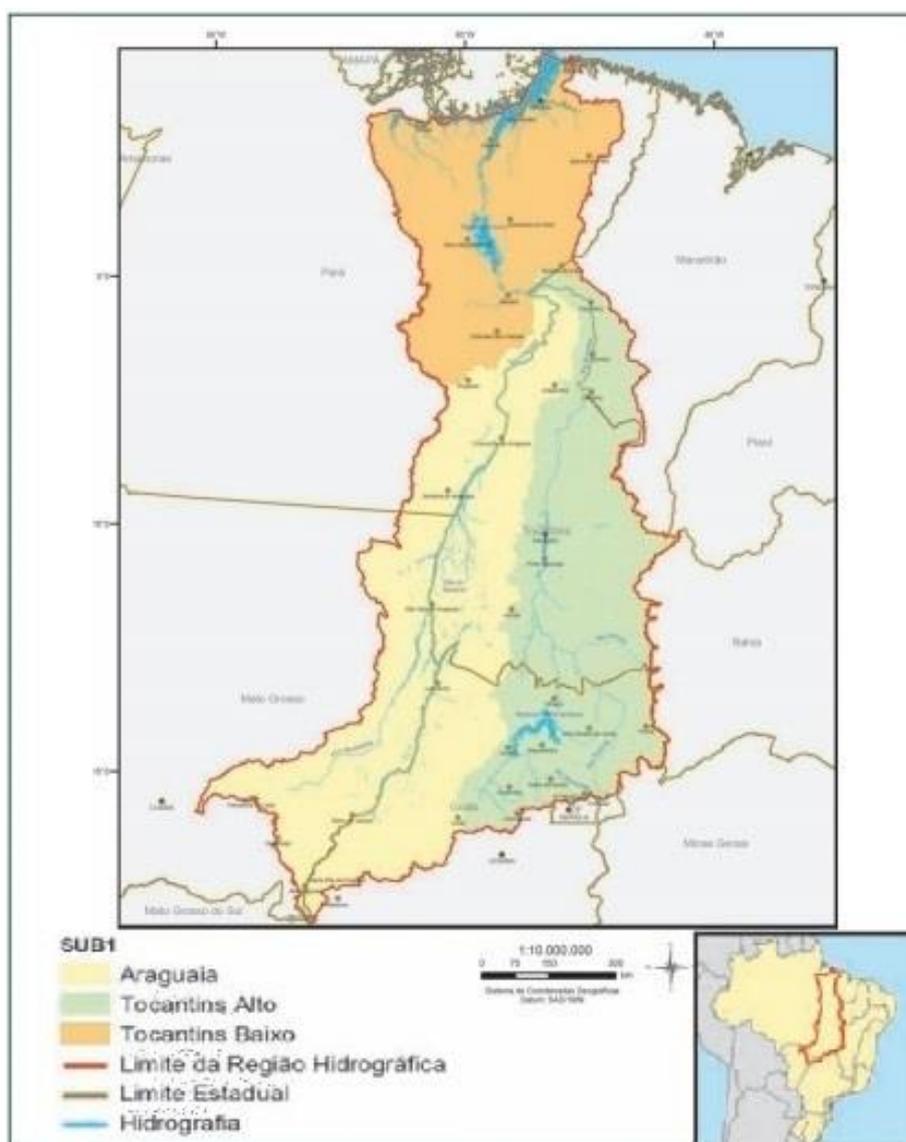
Entender o comportamento dos níveis de chuva e vazão na BHAT, é extremamente importante para contribuir em estudos de avaliação e/ou impacto ambiental, sustentabilidade, agroecuarria, mineração, recursos hídricos, planejamentos em diversas áreas como administrativos, economia, política etc.

2.2 Material e Métodos

2.2.1 Área de estudo

A região hidrográfica do Araguaia –Tocantins, mostrada na Figura 1, possui uma área de 921.921 km², equivalendo a aproximadamente 10,8% do território brasileiro. De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), em 2010 a referida região apresentava uma população de 8.610.721 habitantes, sendo 76% ocupando áreas urbanas, caracterizando uma densidade demográfica de 9,3 hab./, portanto, inferior à do país que era de 22,4 hab./km² (IBGE, 2010).

Figura 1 - Bacia hidrográfica do Araguaia–Tocantins



Fonte: (MMA, 2006).

2.2.2 Geoestatística

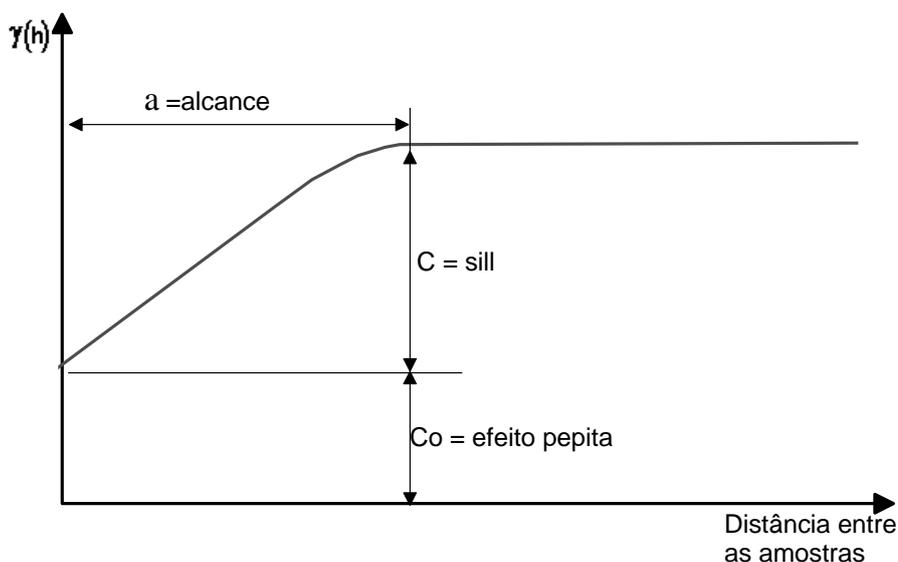
O mapeamento da distribuição das chuvas foi realizado com o uso da geoestatística que utiliza uma ferramenta denominada semivariogramas para a caracterização do padrão espacial da variável em estudo. Os conceitos e aplicações da geoestatística podem ser encontrados em livros textos como Journel (1989), Deustch e Journel (1996), Goovaerts (1997) e Deustch (2002).

O principal modelo de semi-variograma (GOOVAERTS, 1997) referido como *modelo esférico* e é expresso matematicamente, em termos gerais, como:

$$\begin{aligned} \gamma(\mathbf{h}) &= C_0 && \text{para } \mathbf{h} = 0 \\ \gamma(\mathbf{h}) &= C_0 + C \left(\frac{3a}{2\mathbf{h}} - \frac{a^3}{2\mathbf{h}^3} \right) && \text{para } 0 < \mathbf{h} \leq a \\ \gamma(\mathbf{h}) &= C_0 + C && \text{para } \mathbf{h} > a \end{aligned} \quad (1)$$

Onde C_0 é a variabilidade aleatória inerente das amostras na distância zero, denominado efeito pepita. A distância na qual as amostras tornam-se independente uma das outras é representada por a , referida como a faixa de influência (ou alcance). A semivariância constante onde os valores de $\gamma(h)$ são nivelados a distâncias maiores do que a , é representada por $C_0 + C$, onde C é referido como o *sill* (ou patamar) do semivariograma. Os parâmetros do modelo são determinados iterativamente por meio do ajuste do modelo aos resultados da análise do semivariograma amostral. O modelo resultante é uma medida da variabilidade da amostra e, assumindo que as amostras são representativas, uma medida da variabilidade da variável regionalizada.

Figura 2- Modelos de semivariograma esférico.



Fonte: Elaborado pelo autor.

A estimativa de valores de uma variável regionalizada em áreas não amostradas pode ser realizada pela aplicação de técnicas geoestatística como a krigagem. A krigagem é a designação genérica adotada na geoestatística para uma família de algoritmos de regressão por mínimos-quadrados baseados no estimador de regressão linear $Z^*(u)$ definido como:

$$Z^*(\mathbf{u}) - m(\mathbf{u}) = \sum_{\alpha=1}^{n(\mathbf{u})} \lambda_{\alpha}(\mathbf{u}) [Z(\mathbf{u}_{\alpha}) - m(\mathbf{u}_{\alpha})] \quad (2)$$

Onde (u) é o peso atribuído a cada valor observado $Z(u_{\alpha})$ localizado dentro de determinada vizinhança $W(u)$ centrado na localização u . Os pesos $\lambda_{\alpha}(u)$ são calculados de forma a minimizar a estimação ou erro da variância $\sigma_E^2(u) = \text{Var}[Z^*(\mathbf{u}) - Z(\mathbf{u})]$ sob a condição de não-tendenciosidade do estimador.

2.2.3 Método *k-means*

Para a formação de grupos (ou regiões) homogêneos foi utilizado o método *k-means*, que apresenta um procedimento simples de classificar um determinado conjunto de dados através de certo número de grupos fixados a priori. A idéia principal

é definir k centróides, um para cada grupo, que devem ser colocados o máximo possível longe um do outro. O próximo passo é tomar cada ponto pertencente a um determinado conjunto de dados e associá-lo ao centróide mais próximo. Quando nenhum ponto estiver pendente, o primeiro passo é concluído e uma grupagem inicial é feita. Neste ponto, deve-se recalculá-los k novos centróides como baricentros dos grupos resultantes do passo anterior. Em seguida, deve-se fazer uma nova ligação entre os mesmos pontos de ajuste de dados e o centróide novo mais próximo. Um *loop* foi gerado. Como resultado deste *loop*, pode-se notar que os k centróides mudam sua localização passo a passo até que não haja mais alterações feitas. Finalmente, esse algoritmo visa minimizar uma função objetiva, neste caso, uma função de erro ao quadrado definida como:

$$J = \sum_{j=1}^k \sum_{i=1}^n \|x_i^j - c_j\|^2 \quad (3)$$

onde $\|x_i^j - c_j\|^2$ é uma medida de distância escolhida entre um ponto de dados e o centro do grupo (MACQUEEN, 1967).

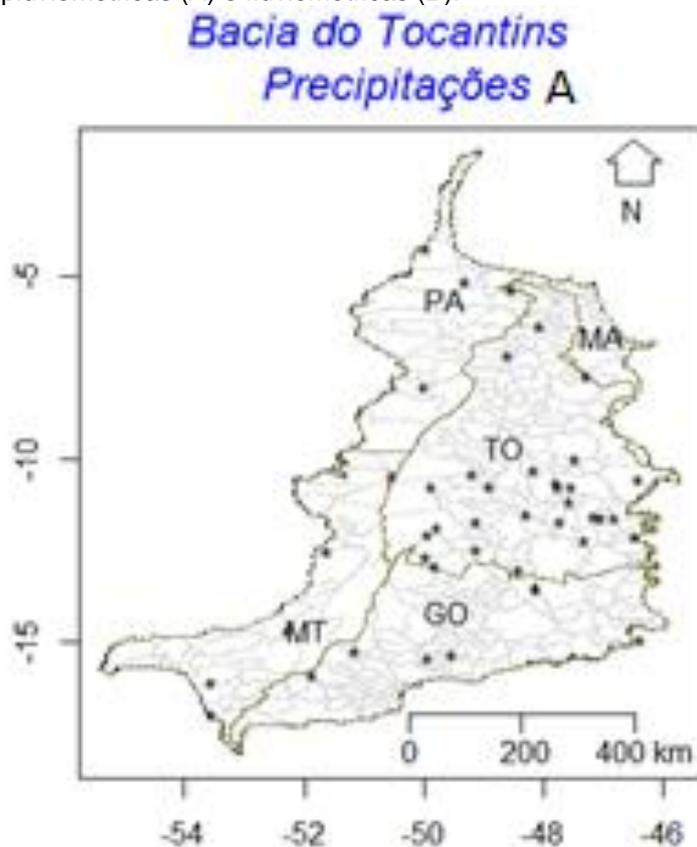
Araujo et al. (2015) utilizaram este método na determinação de áreas homogêneas (caracterização) em termos do regime de chuva no estado do Rio Grande do Norte.

O software utilizado para o desenvolvimento do trabalho foi o Programa R - The R Project for Statistical Computing (R Version 3.1.1. 2014).

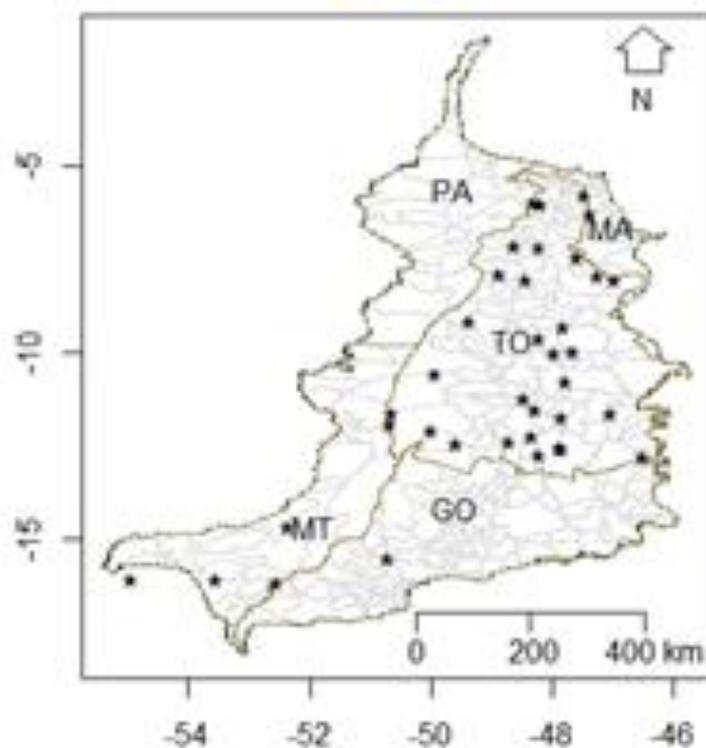
2.3 Resultados e Discussão

Foram utilizados dados das médias mensais de 45 estações pluviométricas (chuvas) e 37 estações fluviométricas (vazão) (Figura 3) da Agência Nacional de Águas (ANA) com registro contínuo, que variaram em um período de 1972 a 2017 para chuvas e 1955 a 2013 para vazões. Entretanto, esse banco de dados apresentou problema de dados faltantes para todas as estações. Esses valores faltantes foram estimados e as falhas preenchidas com o uso da técnica de *imputação múltipla (IM)*. (NUNES et al., 2009; CAMARGOS et al., 2011). Para Harrel Jr. (2001), em casos onde o número de dados faltantes é maior do que 15%, o uso de *imputação múltipla (IM)* é a mais indicado. Por exemplo, para a estação Conceição do Tocantins no município de Tocantins foram constatados 29 dados faltantes. Na Tabela 1 e Figura 4 são apresentados os resultados da imputação. Observa-se que a estatística dos dados observados e imputados mantém o padrão.

Figura 3 - Estações pluviométricas (A) e fluviométricas (B).



Bacia do Tocantins Vazões B



Fonte: Elaborado pelo autor.

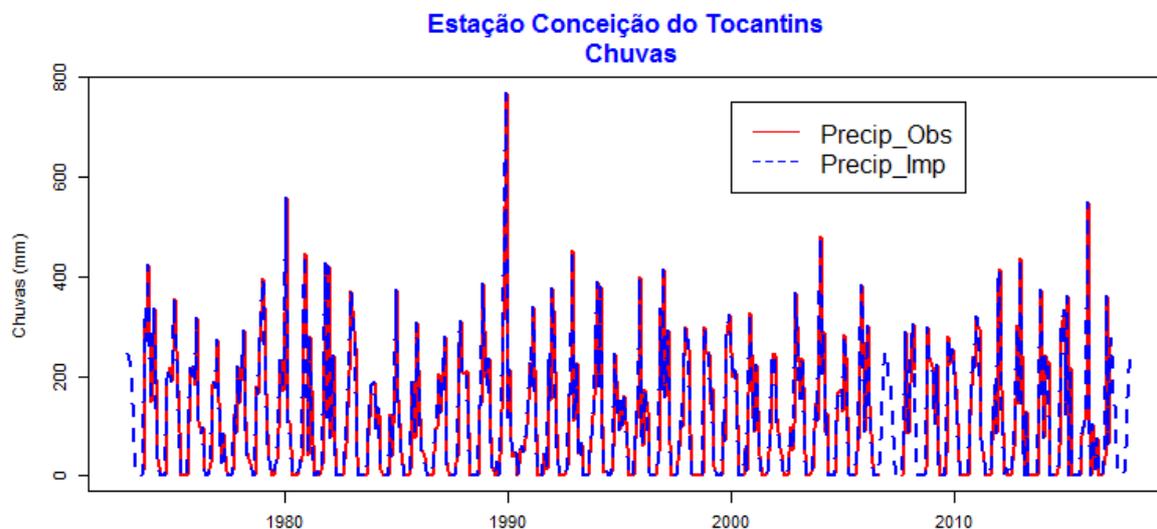
Tabela 1- Estatísticas da chuva (mm) para a Estação Conceição do Tocantins (Tocantins).

Dados	Min	1º Quartil	Media	Mediana	3º Quartil	Max	Faltantes
Observados	0	0,00	113,30	75,20	194,2	769,4	29
Imputados	0	0,20	129,90	77,65	195,0	769,4	

Fonte: Elaborado pelo autor.

Figura 4 - Chuvas mensais observadas (linha cheia) e imputadas (linha tracejada), Estação Conceição do Tocantins (Tocantins)

Figura 4 - Chuvas mensais observadas (linha cheia) e imputadas (linha tracejada), Estação Conceição do Tocantins (Tocantins).

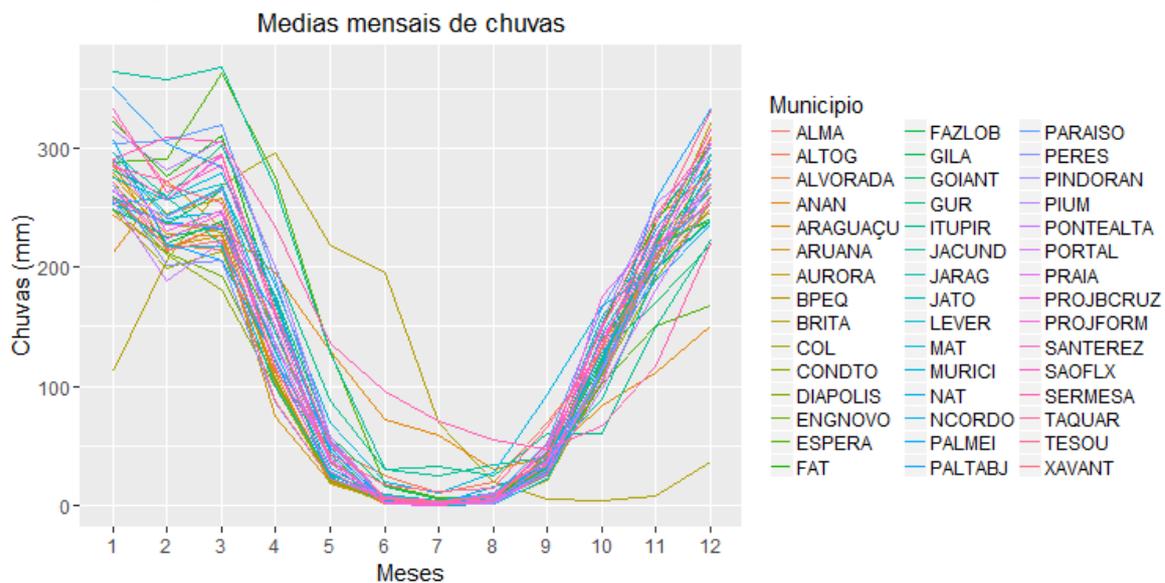


Fonte: Elaborado pelo autor.

Para se obter uma visualização geral das chuvas sobre a Bacia do Tocantins, foi construído, para cada estação, os regimes de chuvas e vazões mensais em períodos entre 1972 a 2017 (chuvas) e 1955 a 2013 (vazões). Para os regimes de chuva na Figura 5 são apresentados os resultados para todas as 45 estações e, na Figura 6, para 9 estações selecionadas para visualização das diferenças entre regimes de chuva, em painéis. Na maioria das estações o primeiro semestre é mais chuvoso em relação ao segundo semestre. As chuvas mínimas ocorrem, de modo geral, nos meses de maio a setembro. A partir de setembro observa-se uma tendência de aumento de chuvas. Valores máximos de chuvas ocorrem principalmente no primeiro semestre, embora em algumas estações se observe altos valores no mês de dezembro.

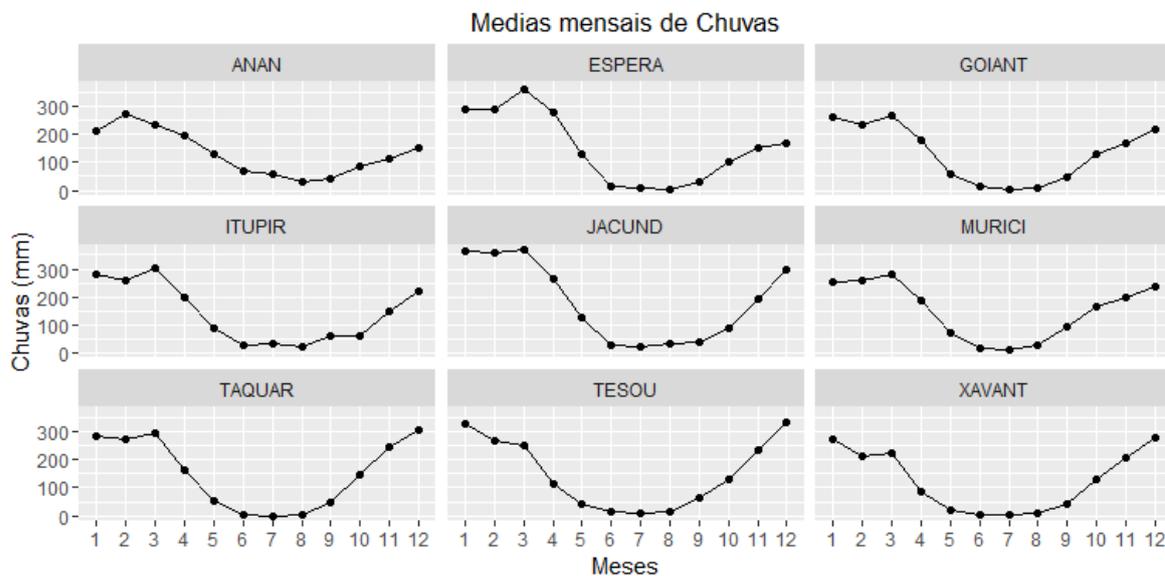
Os resultados para os regimes de vazão são apresentados nas Figuras 7a, para estações com valores médios mensais máximos abaixo de $600 \text{ m}^3/\text{s}$ e 7b para estações com valores médios mensais máximos próximos de $15000 \text{ m}^3/\text{s}$. Observa-se, portanto, neste caso, uma alta variabilidade nos níveis de vazão. De modo geral, os picos máximos de vazão ocorrem nos meses de fevereiro, março e abril e os picos mínimos entre os meses de junho a setembro. Tal como nos regimes de chuva, observa-se uma tendência de aumento nos níveis de vazão a partir de setembro.

Figura 5 - Regimes de Chuvas (mm) mensais para as 45 estações da Bacia do Tocantins.



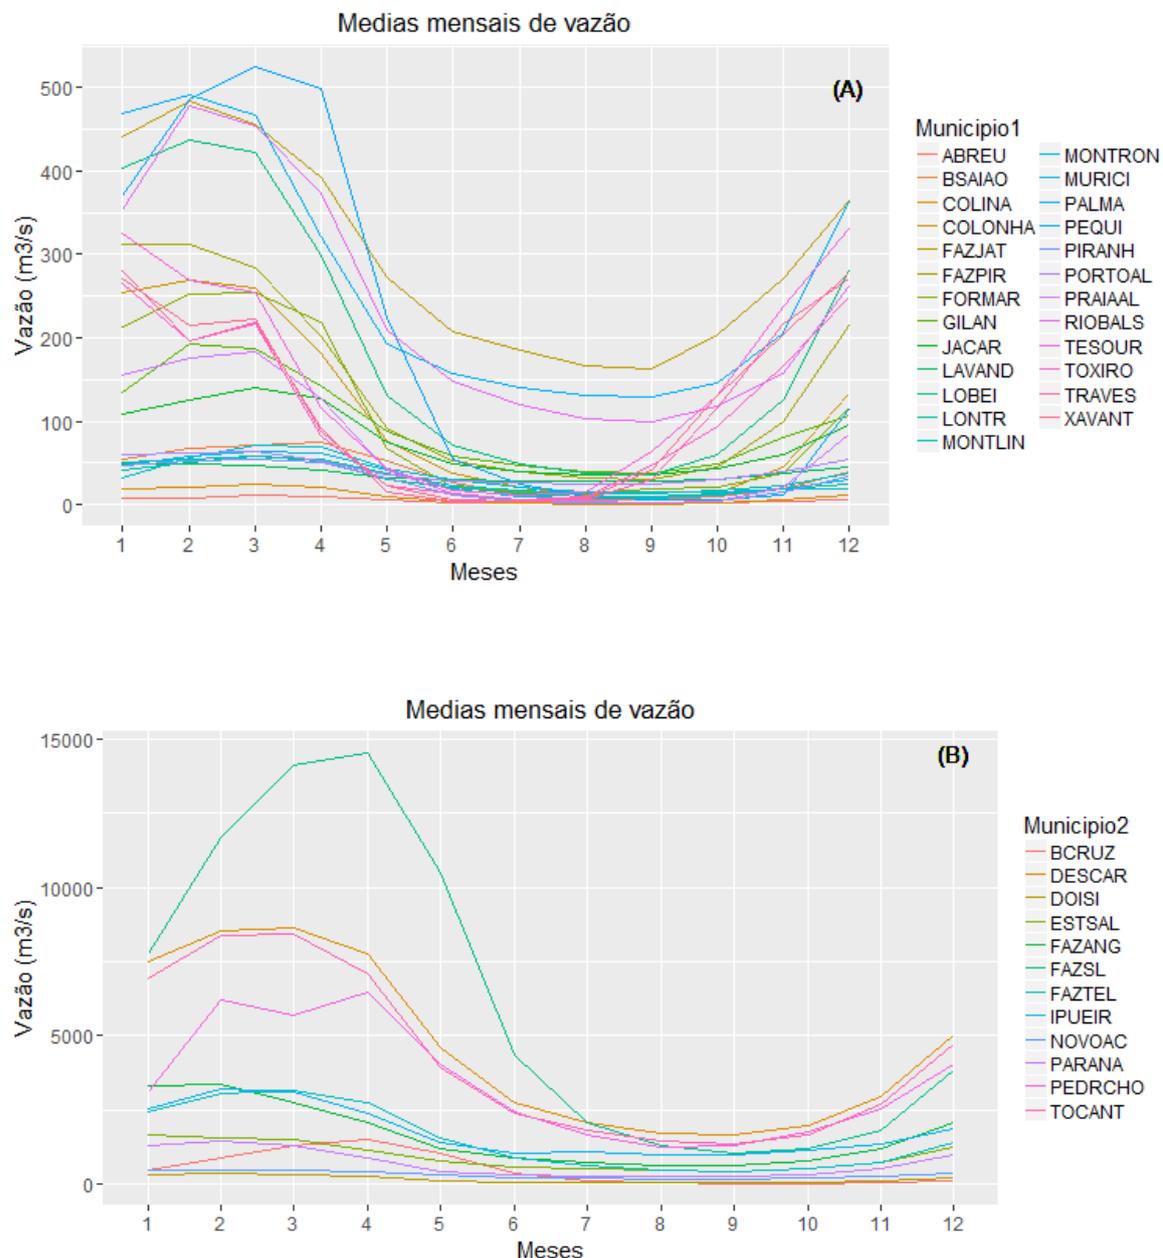
Fonte: Elaborado pelo autor.

Figura 6 - Painéis dos regimes de chuvas mensais de 9 estações selecionadas da BHAT.



Fonte: Elaborado pelo autor.

Figura 7 - Regimes de Vazão (m^3/s) mensais para as estações com vazões médias mensais máxima abaixo de $600 m^3/s$ (A) a próximos de $15000 m^3/s$ (B) da BHAT.



Fonte: Elaborado pelo autor.

Para a visualização (mapeamento) do padrão geral de chuva e vazão em toda a área de estudo foram consideradas, com base nas curvas dos regimes de chuva e vazão, os valores médios mensais em cada estação para o período estudado. As estimativas dos valores de chuvas e vazões em localizações não amostradas foram calculadas com o uso do método geostatístico da krigagem. Neste caso, deve-se, inicialmente, construir um modelo da variação ou dependência espacial, representado pelo variograma. Os resultados obtidos no variograma são utilizados para a

interpolação dos valores não amostrados pelo método da krigagem, cujos resultados são apresentados em forma de mapas. A Tabela 2 apresenta os parâmetros dos semivariogramas ajustados para os meses de janeiro, abril e agosto e as Figuras 8 e 9 mostram, respectivamente, os mapas de chuvas e vazões mensais. Observa-se que os alcances, relacionados ao raio de correlação espacial entre as observações, apresentam magnitudes semelhantes para chuva e vazão. Entretanto, o patamar (*sill*), relacionado à variabilidade espacial, é muito maior no caso da vazão relativo à chuva. Isso pode ser observado nas Figuras 5, 6 e 7 dos regimes anuais de chuva e vazão, respectivamente, onde se pode verificar visualmente a maior variabilidade das vazões comparadas às variabilidades das chuvas.

Tabela 2 - Parâmetros ajustados por modelos esféricos para os variogramas das chuvas (mm) e vazões (m³/s).

	Mês	C ₀	Sill (b ₁)	a ₁ (alcance)	Sill (b ₂)	a ₂ (alcance)
Chuvas	Janeiro	0	1000	2,0	1200	4,5
	Abril	0	400	1,0	1700	4,0
	Agosto	0	4,0	1,0	170	4,0
Vazão	Janeiro	0	1000000	2,0	5000000	4,0
	Abril	0	2500000	1,0	800000	4,0
	Agosto	0	120000	1,0	150000	4,0

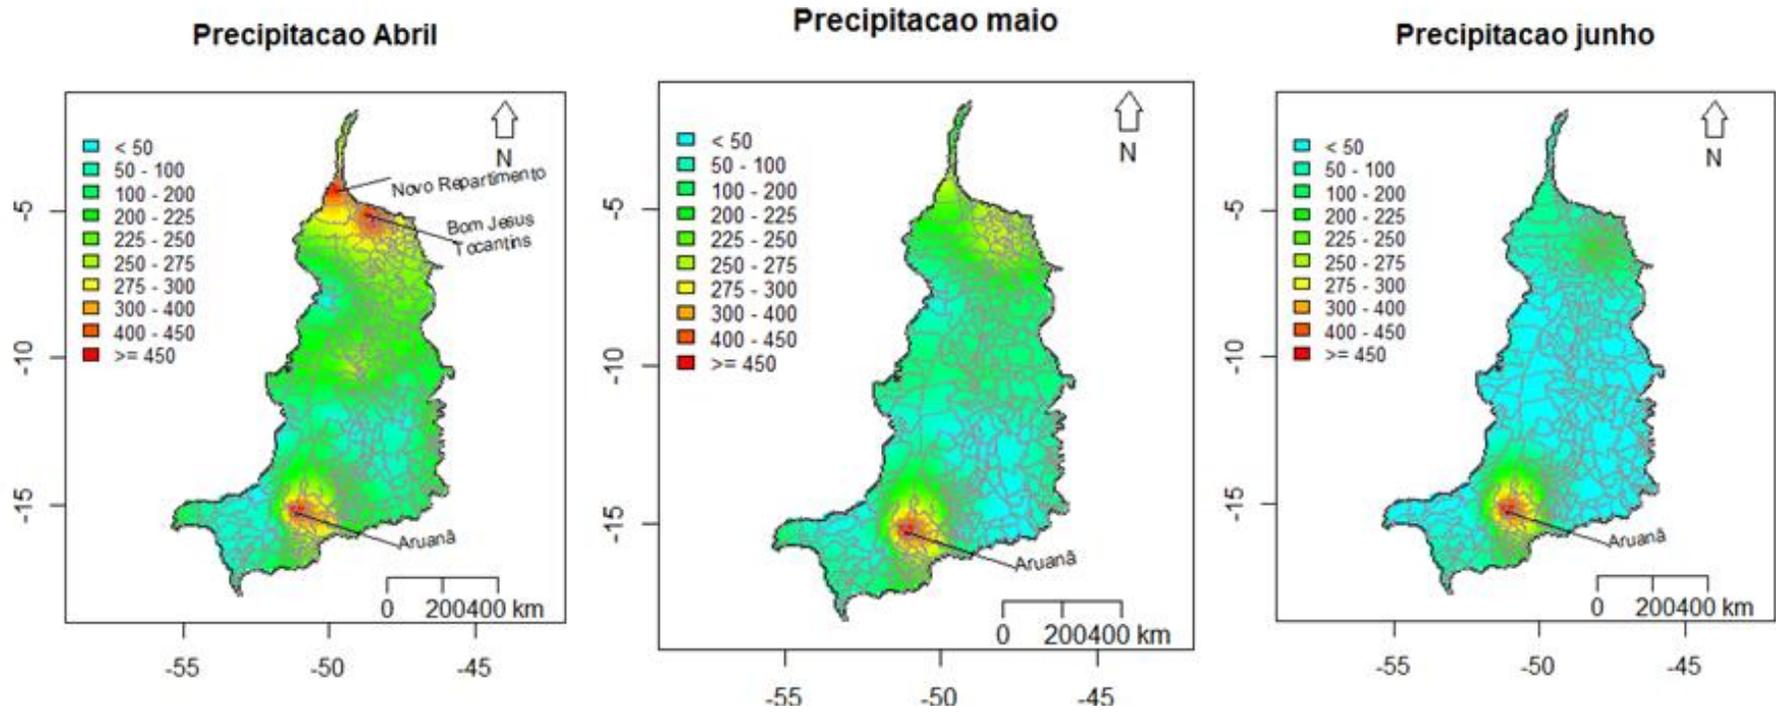
Fonte: Elaborado pelo autor.

Os mapas da Figura 8 mostram que, nos meses de outubro, novembro e dezembro (em janeiro com menor intensidade) episódios de chuvas em níveis acima de 400 mm ocorrem na maior parte da bacia. Nos meses de fevereiro, março e abril as chuvas de maior intensidade (acima de 400 mm) se concentram ao norte da bacia. De abril a agosto observa-se uma região de maior ocorrência de chuvas ao sul da bacia, em torno dos municípios de Aruanã, Goiás Velho e Carmo do Rio Verde.

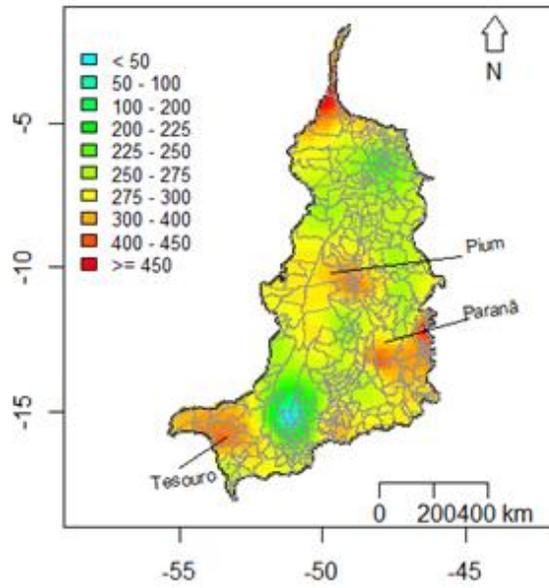
A região central da bacia experimenta mais fortemente a escassez de chuvas, com níveis abaixo de 100 mm, nos meses de maio a agosto. Esses resultados podem ser comparados com os obtidos por Acosta (2007), onde, com base em simulações para um ano de dados da climatologia entre os anos de 1961-1990 da BHAT, identificou, para a precipitação média mensal (em mm/dia) duas estações bem definidas, uma chuvosa (de dezembro a abril) e outra estação seca (entre os meses

de Junho até Setembro). Para as vazões, os mapas da Figura 9 mostram que as maiores vazões (acima de 4000 m³/s) concentram-se mais ao norte e nordeste da bacia, incluindo municípios como Bom Jesus do Tocantins, Dianópolis, São Domingos do Araguaia, Arixá do Tocantins e Carolina. Predomina em grande parte da bacia vazões abaixo de 500 m³/s.

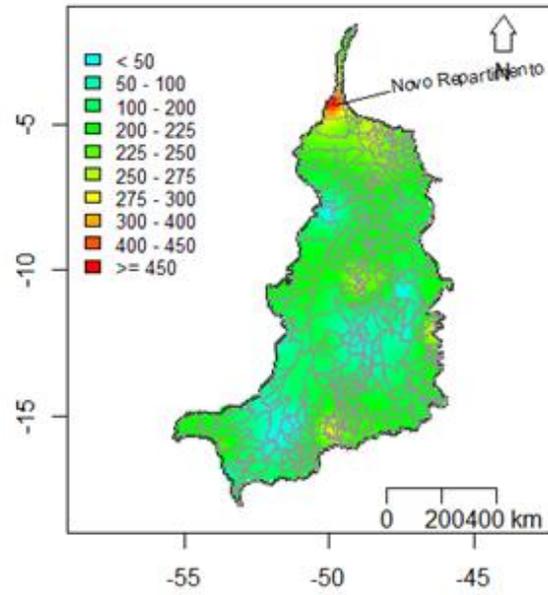
Figura 8 - Chuvas mensais (mm) para a Bacia do Araguaia-Tocantins.



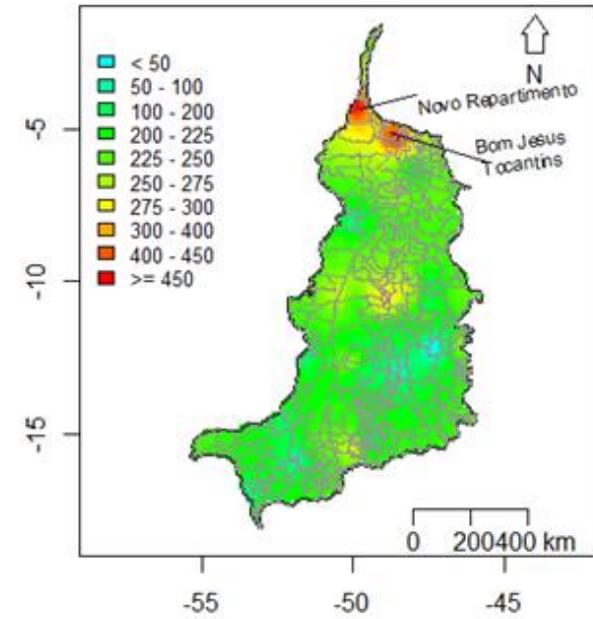
Precipitacao Janeiro



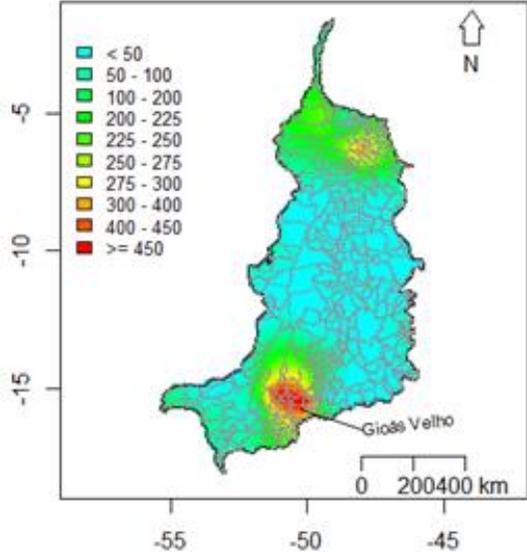
Precipitacao Fevereiro



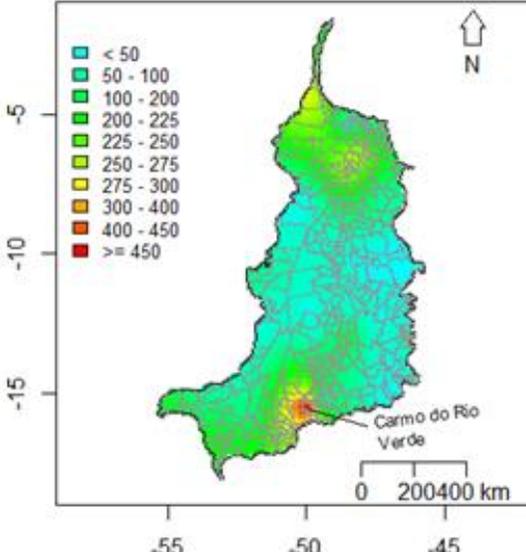
Precipitacao Marco



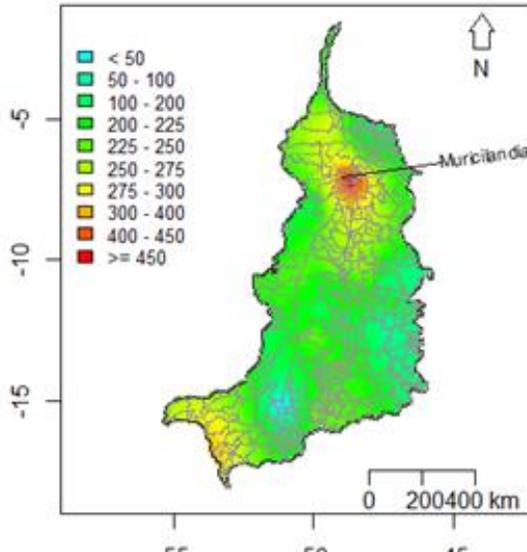
Precipitacao julho

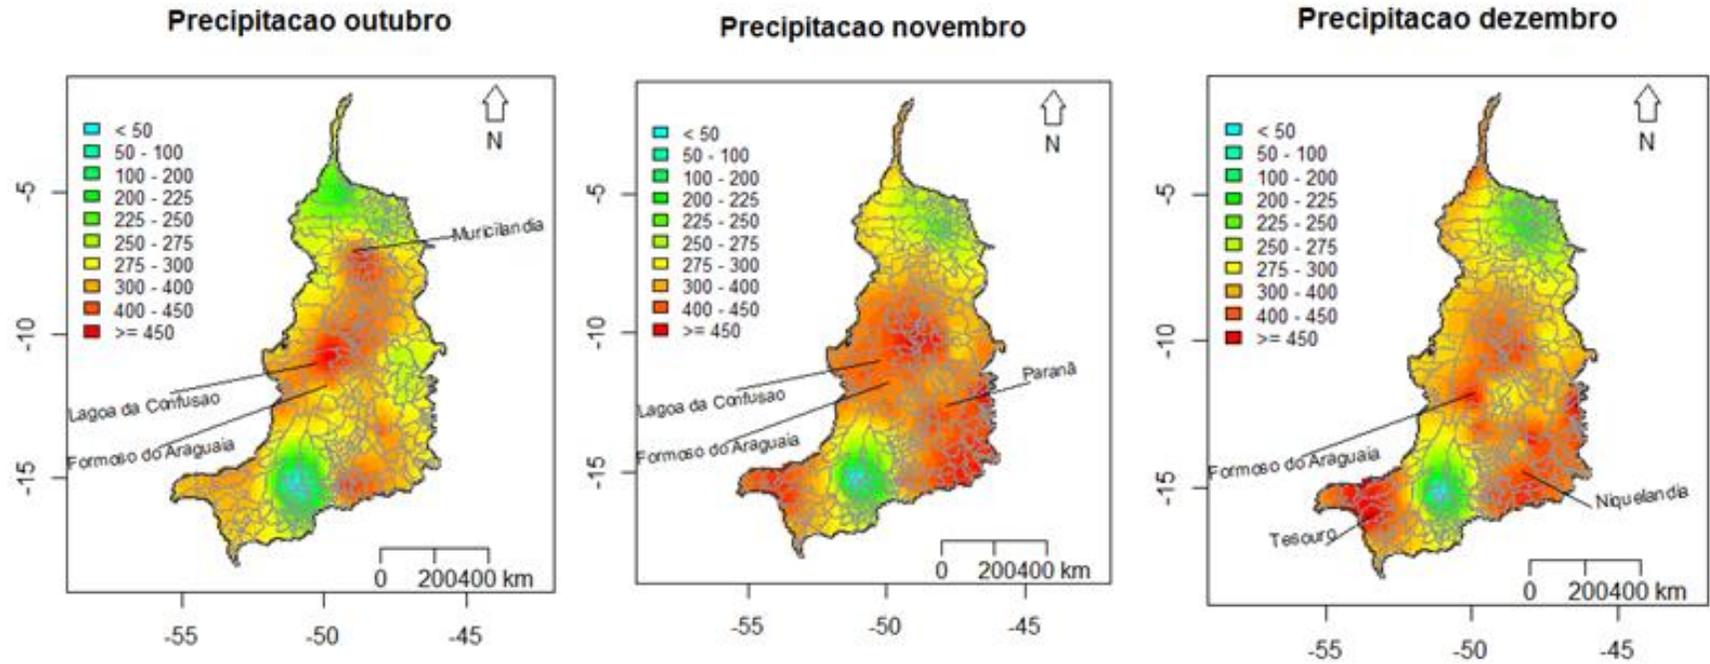


Precipitacao agosto

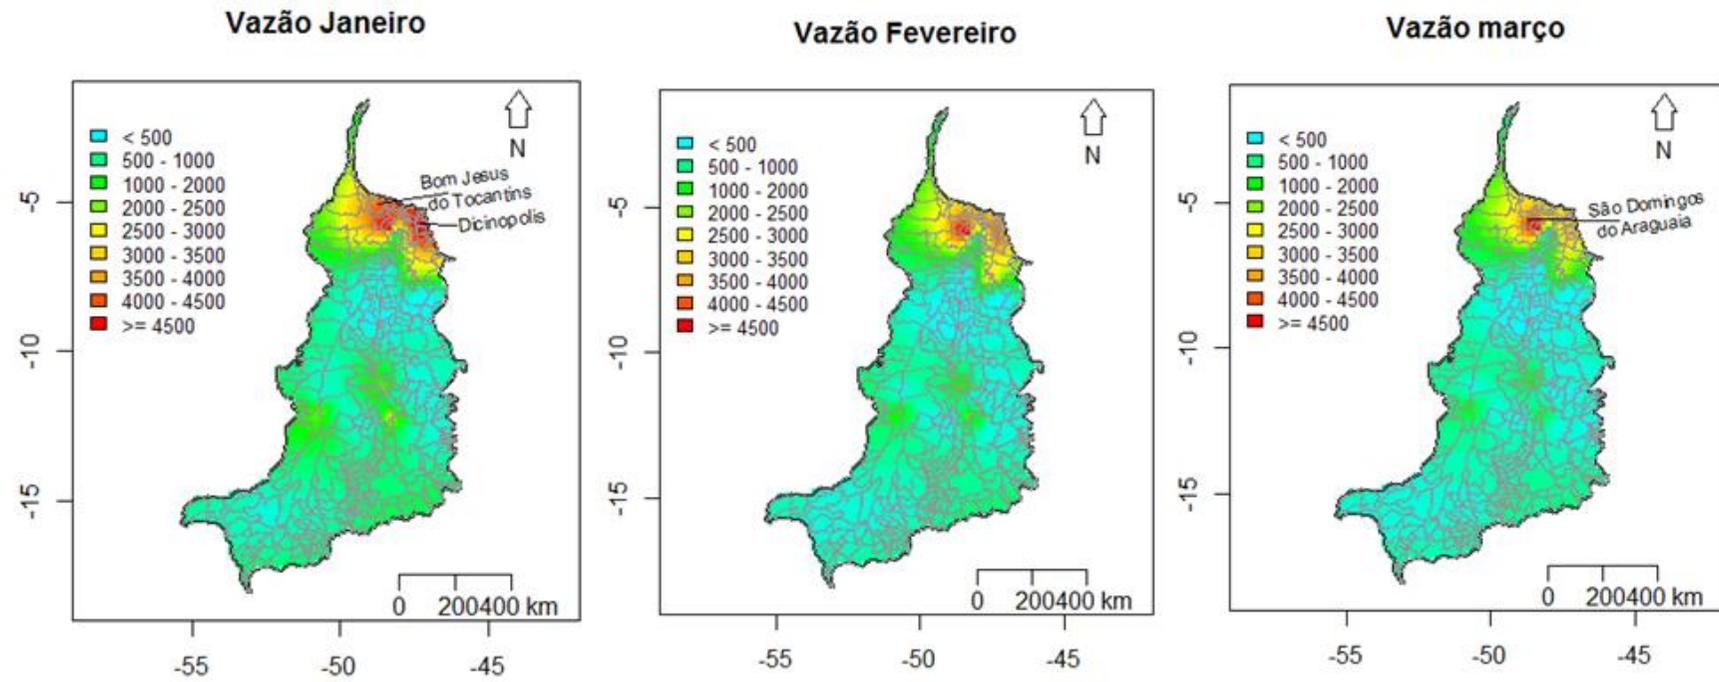


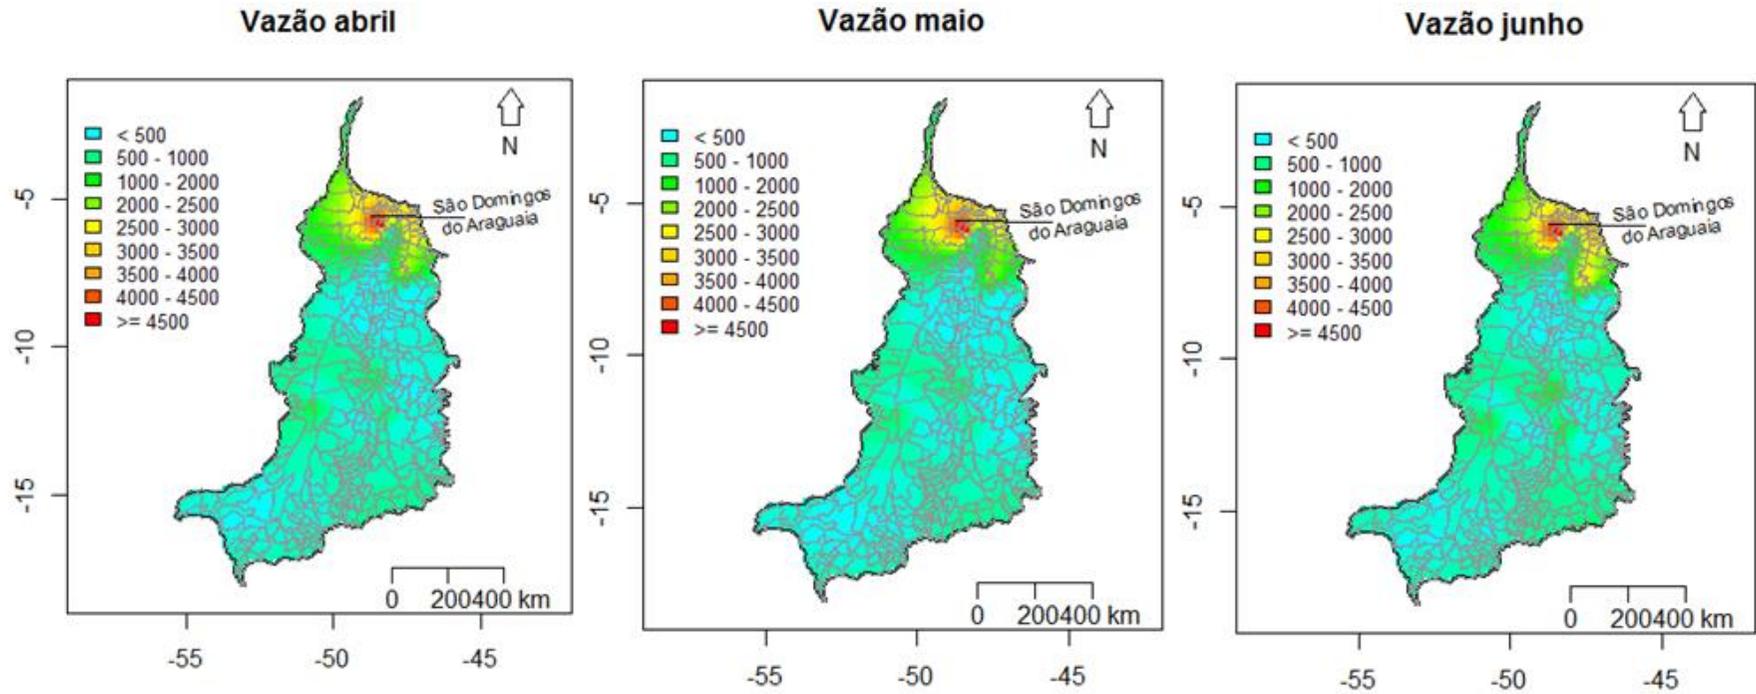
Precipitacao setembro



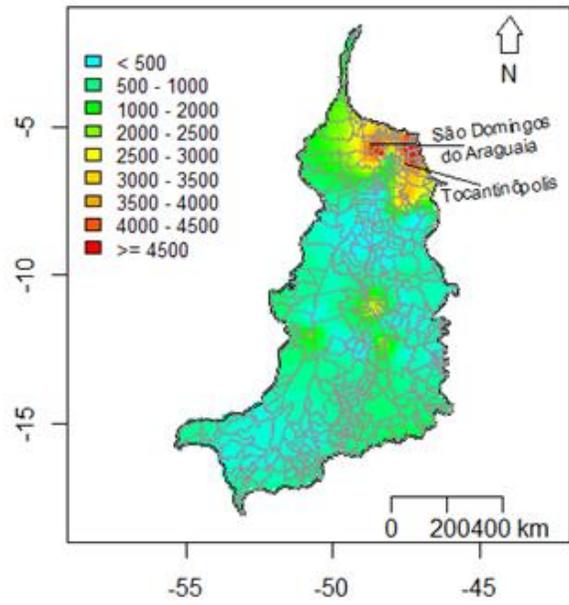


Fonte: Elaborado pelo autor.

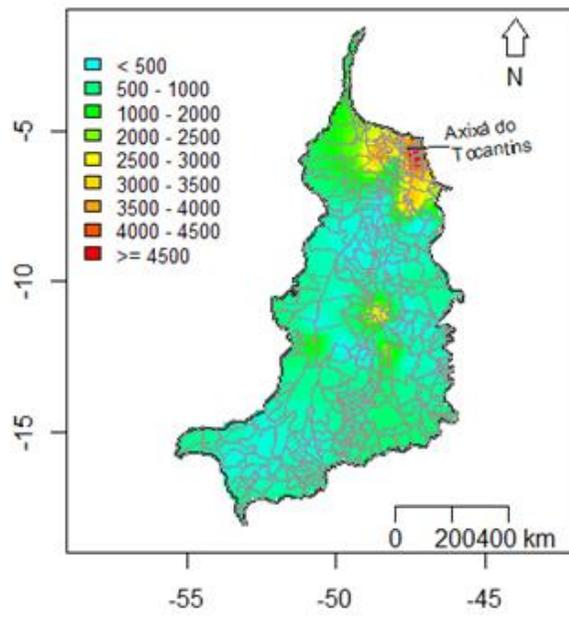
Figura 9 - Vazões mensais (m^3/s) para a Bacia do Araguaia-Tocantins.



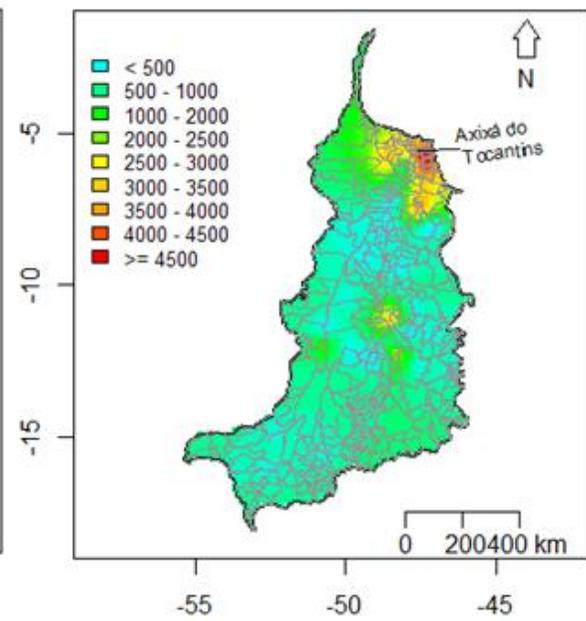
Vazão julho

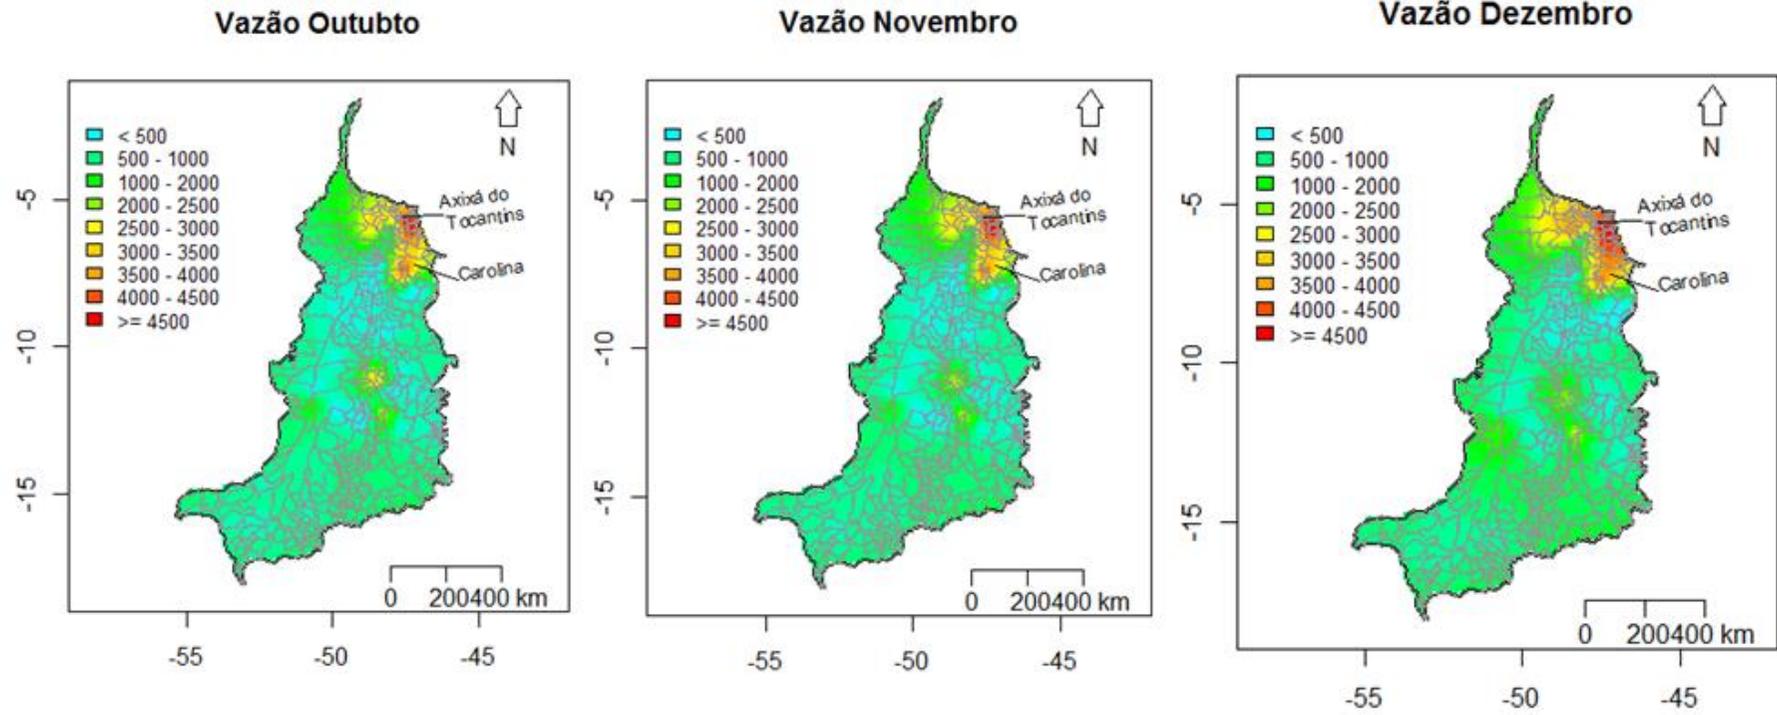


Vazão agosto



Vazão Setembro

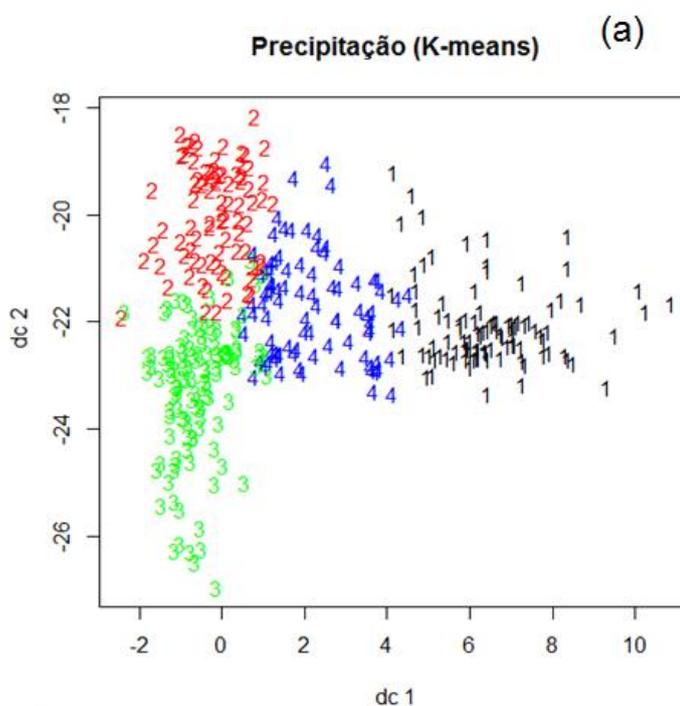


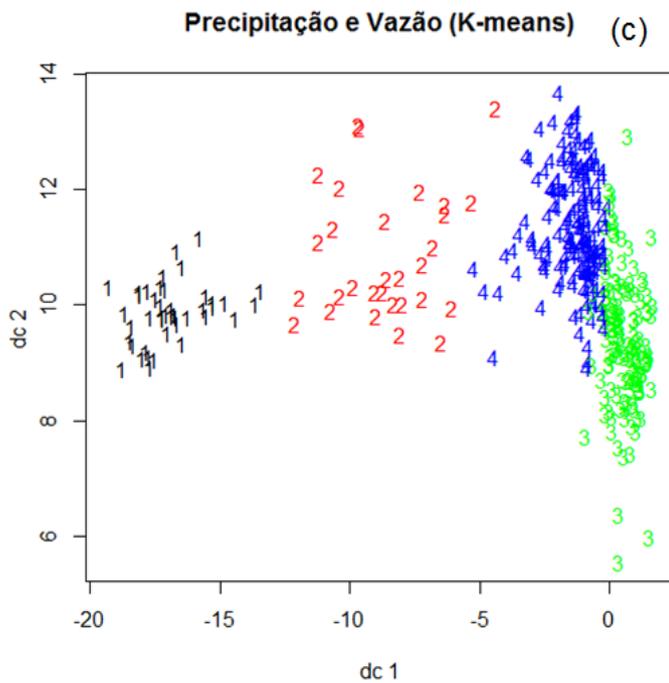
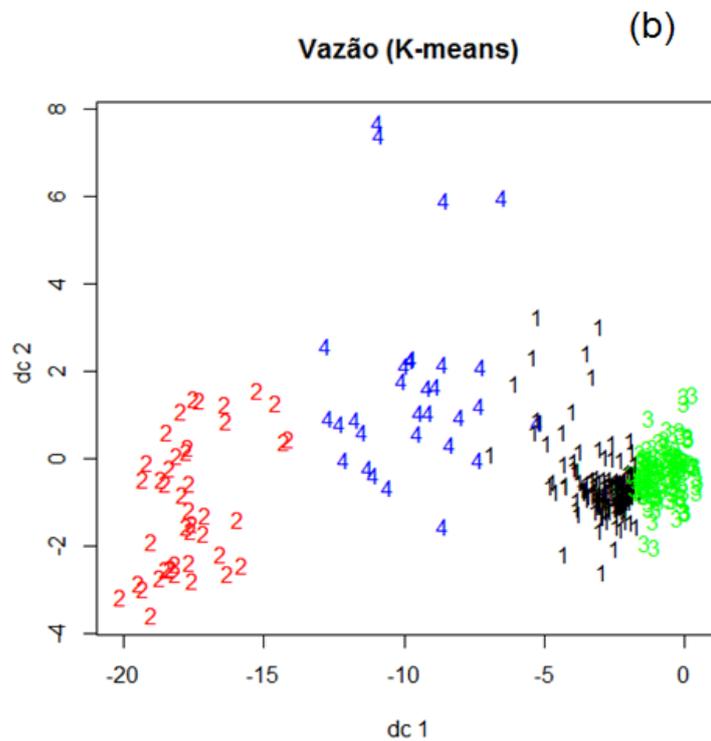


Fonte: Elaborado pelo autor.

Em seguida, foi feita uma caracterização da Bacia do Araguaia-Tocantins com base nos regimes de chuva e vazão observados. Neste caso, como foram estimadas, com base no método geoestatístico da krigagem, as chuvas e vazões médias mensais em toda a área da bacia, foi possível conhecer os regimes de chuva e vazão para cada um dos 393 municípios que compõem a Bacia. Em seguida, com o uso do método *k-means*, pode-se comparar os regimes de chuva e vazão de cada município e, a partir desta análise, a Bacia foi dividida em quatro regiões com regimes de chuvas e vazões característicos. Na Figura 10 são apresentados os resultados do método *k-means* na classificação em 4 grupos homogêneos de chuvas, vazões e chuvas e vazões conjuntamente. Observa-se que os grupos para vazões são mais definidos em relação aos grupos de chuvas, ou seja, as vazões conseguem caracterizar melhor a bacia.

Figura 10 - Classificação de chuvas (a), vazões (b) e chuvas e vazões conjuntamente (c) baseada no método de *k-Means*.





Fonte: Elaborado pelo autor.

As características de cada grupo formado, fornecidas pelas estatísticas descritivas, são apresentadas nas Tabelas 3 e 4. A análise do mapa e dos regimes de chuva da Figura 11 e Tabela 3, mostra que o grupo 3 com 122 municípios concentrados no meio e a sudeste da bacia, apresenta maior média e maior valor máximo. As maiores ocorrências de chuva neste grupo são nos meses de outubro, novembro e dezembro. O grupo 2 (83 municípios), com menor média e menor valor máximo concentra-se no centro e mais ao sul da bacia. As menores médias de chuvas desse grupo ocorrem no primeiro semestre (de janeiro a junho). A principal característica do grupo 1 (100 municípios ao norte e sul da bacia) é apresentar maiores médias de chuvas no primeiro semestre e menores médias no segundo semestre.

Os grupos formados com base nas vazões (Figura 12 e Tabela 3) ficaram bem caracterizados. O grupo 2 (43 municípios ao norte da bacia) com maiores níveis de vazão no ano inteiro (média de 3980 m³/s), seguido pelo grupo 4 com 30 municípios também concentrados ao norte da bacia e vazão média de 2235 m³/s. O grupo 1 aparece em seguida com 176 municípios (o mais numeroso) concentrados mais ao centro da bacia e média de 674 m³/s. Finalmente, o grupo 3, segundo mais numeroso com 144 municípios concentrados ao sul e no centro da bacia com média 208 m³/s.

Tabela 3 - Estatísticas descritivas dos grupos formados por *k-means* para chuva e vazão.

	Grupo	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	N
Chuva	Grupo1	16,54	36,24	127,30	137,70	219,80	274,80	100
	Grupo2	4,29	29,52	124,50	130,70	234,40	272,90	83
	Grupo3	3,44	34,18	143,80	142,30	255,90	287,40	122
	Grupo4	15,03	39,61	146,40	139,80	250,50	274,10	88
Vazão	Grupo1	210,50	270,30	571,30	674,6	1082	1325	176
	Grupo2	1056	1462	3041	3980	6714	8116	43
	Grupo3	74,40	109,90	189,20	208	302,10	393,30	144
	Grupo4	621,90	851,80	1735	2235	3558	4477	30

Fonte: Elaborado pelo autor.

Quando se considerou as duas variáveis (chuva e vazão) conjuntamente (Figura 13 e Tabela 4), predominou na caracterização da bacia, os grupos formados pela vazão, uma vez que, essa variável, discrimina melhor os grupos homogêneos. O grupo1 com 43 municípios localizados ao norte da bacia, apresenta maior média de

vazão no ano inteiro e maior média de chuva no primeiro semestre (de fevereiro a junho) e menor média de chuva no segundo semestre (de setembro a dezembro). A vazão média de vazão e chuva deste grupo é de 3980 m³/s e 140,5 mm, respectivamente. Esse grupo apresenta também os maiores valores máximo de chuva (289,5 mm) e vazão (8116 m³/s).

O grupo 2 (30 municípios ao norte da bacia), com segundo maior nível médio de vazão no ano inteiro e menor média mensal de chuva no primeiro semestre (janeiro a junho). A vazão média de vazão e chuva deste grupo é de 2235 m³/s e 140,5 mm, respectivamente. O grupo 4, o mais numeroso com 176 municípios predominando no centro da bacia, apresenta média de vazão e chuva de 674,6 m³/s e 138,6 mm, respectivamente. O grupo 3, segundo mais numeroso com 144 municípios ao sul e ao centro da bacia, com menores valores médios de vazão e chuva, ou seja, 208 m³/s e 136,3 mm, respectivamente. Esse grupo apresenta os menores valores mínimos de vazão (74,4 m³/s) e chuva (11,66 mm) e menores valores máximos, i.e, 393,3 m³/s para vazão e 272,3 mm para chuva.

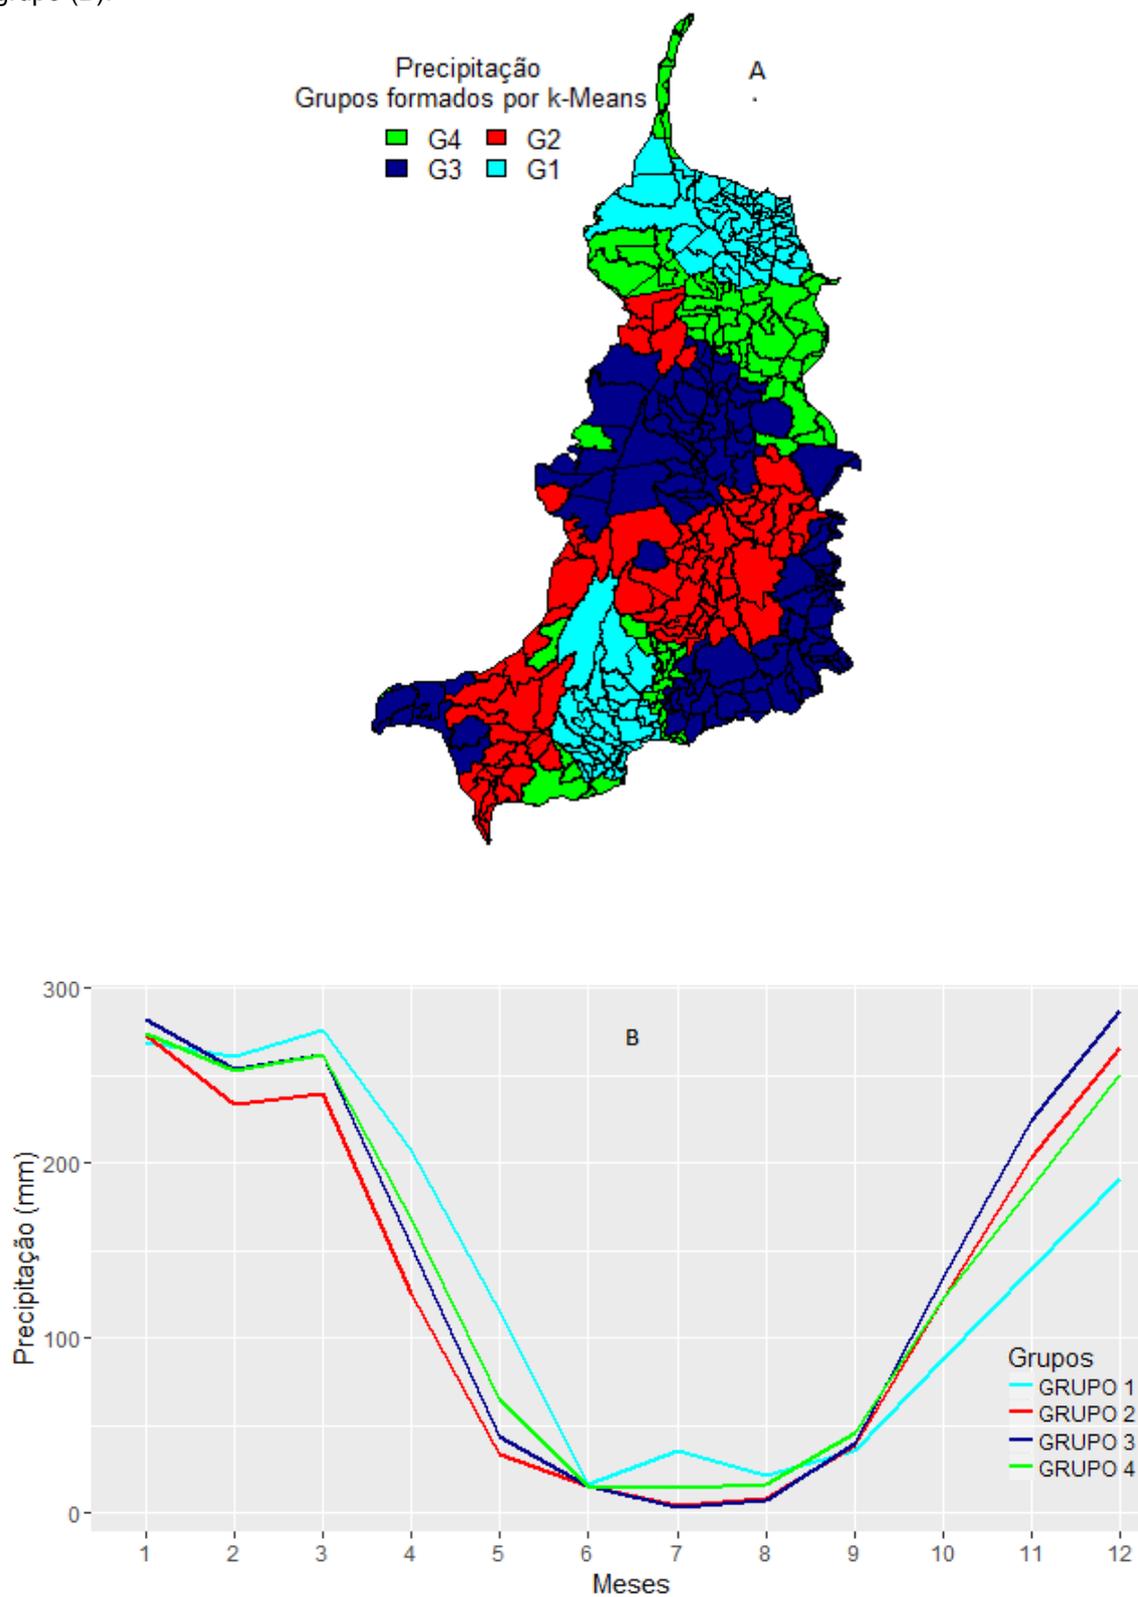
Em resumo, para os grupos formados quando se considerou as duas variáveis conjuntamente (Tabela 4 e Figura 13), podemos observar que a bacia caracteriza-se por apresentar uma área com maior disponibilidade hídrica, formada pelos grupos 1 e 2, ao norte da bacia, com menos de 20% dos municípios (73 municípios), e outra área com menor disponibilidade hídrica, formada pelos grupos 3 e 4, localizados no centro e ao sul da bacia, com mais de 80% dos municípios (cerca de 320 municípios).

Tabela 4 - Descritivas dos grupos formados por *k-means* para chuva e vazão conjuntamente

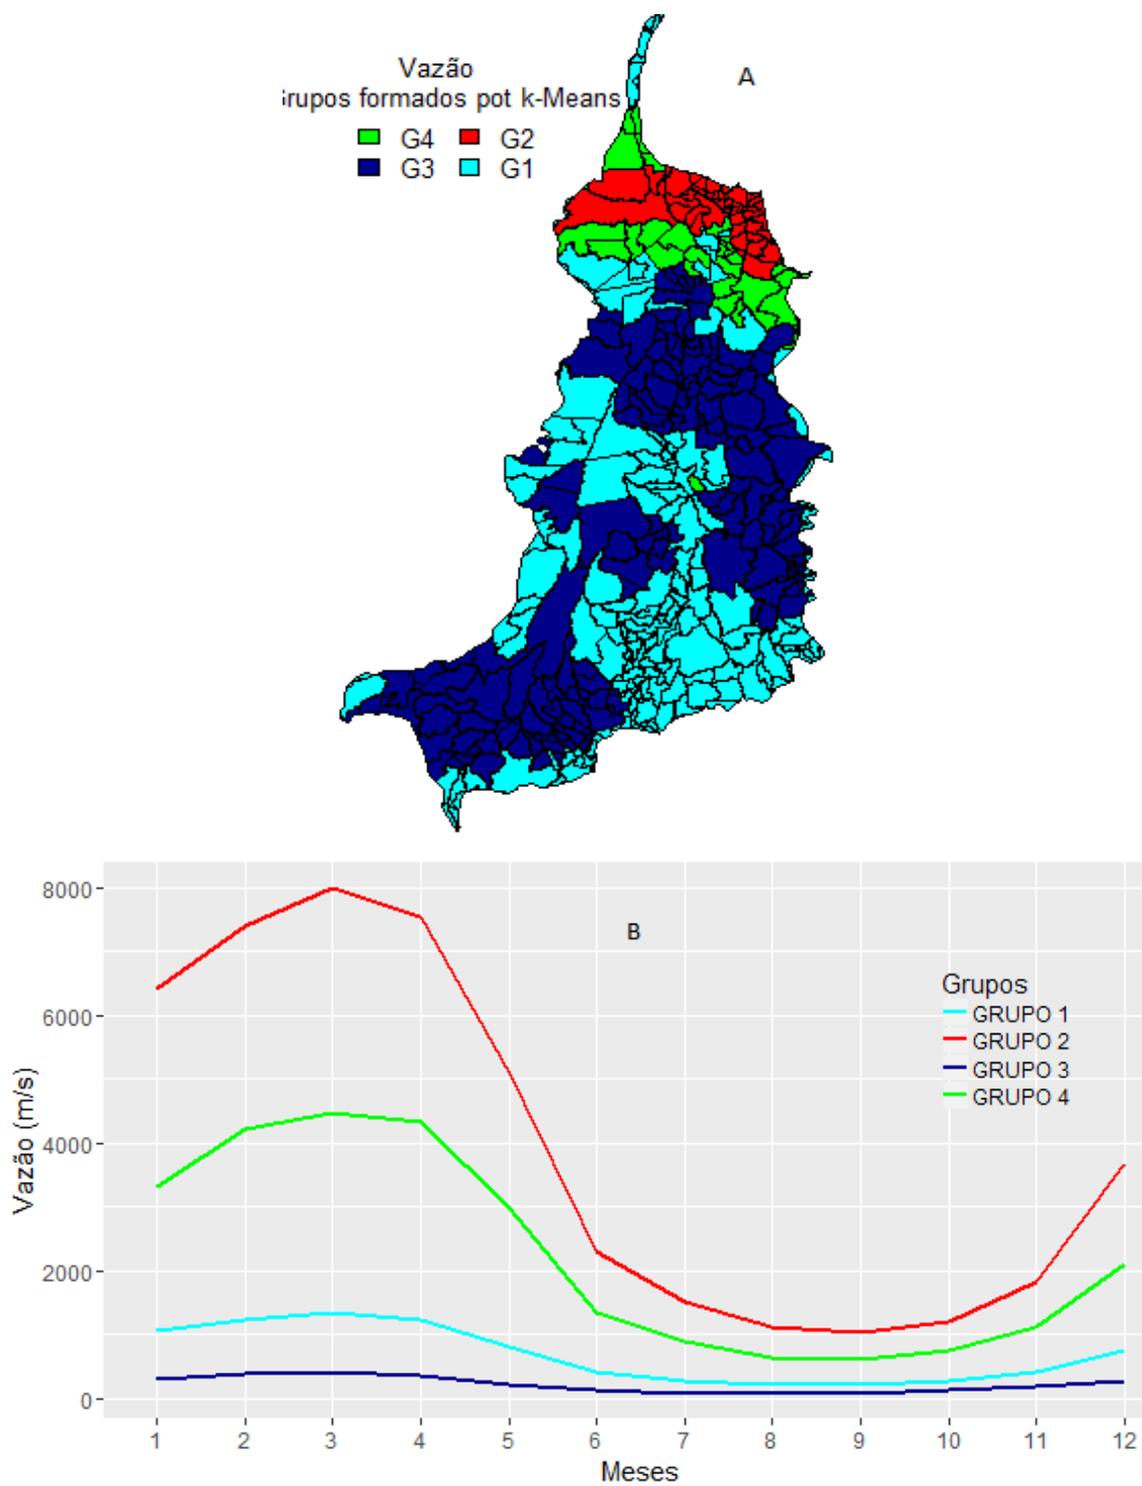
	Grupo	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	N
Chuva	Grupo1	14,13	31,68	13,,20	140,5	229,40	289,50	43
	Grupo2	15,71	40,69	134,60	140,5	22,,60	27,80	30
	Grupo3	11,66	36,14	136,50	136,3	24,,60	272,30	144
	Grupo4	12,51	33,58	13,,20	138,6	252,20	277,90	176
Vazão	Grupo1	1056	1462	3041	3980	6714	8116	43
	Grupo2	621,90	851,80	1735	2235	3558	4477	30
	Grupo3	74,40	109,90	189,20	208	302,10	393,30	144
	Grupo4	210,50	270,30	571,30	674,60	1082	1325	176

Fonte: Elaborado pelo autor.

Figura 11 - Grupos formados por *k-means* com base na chuva (A) e médias mensais (regimes) de cada grupo (B).

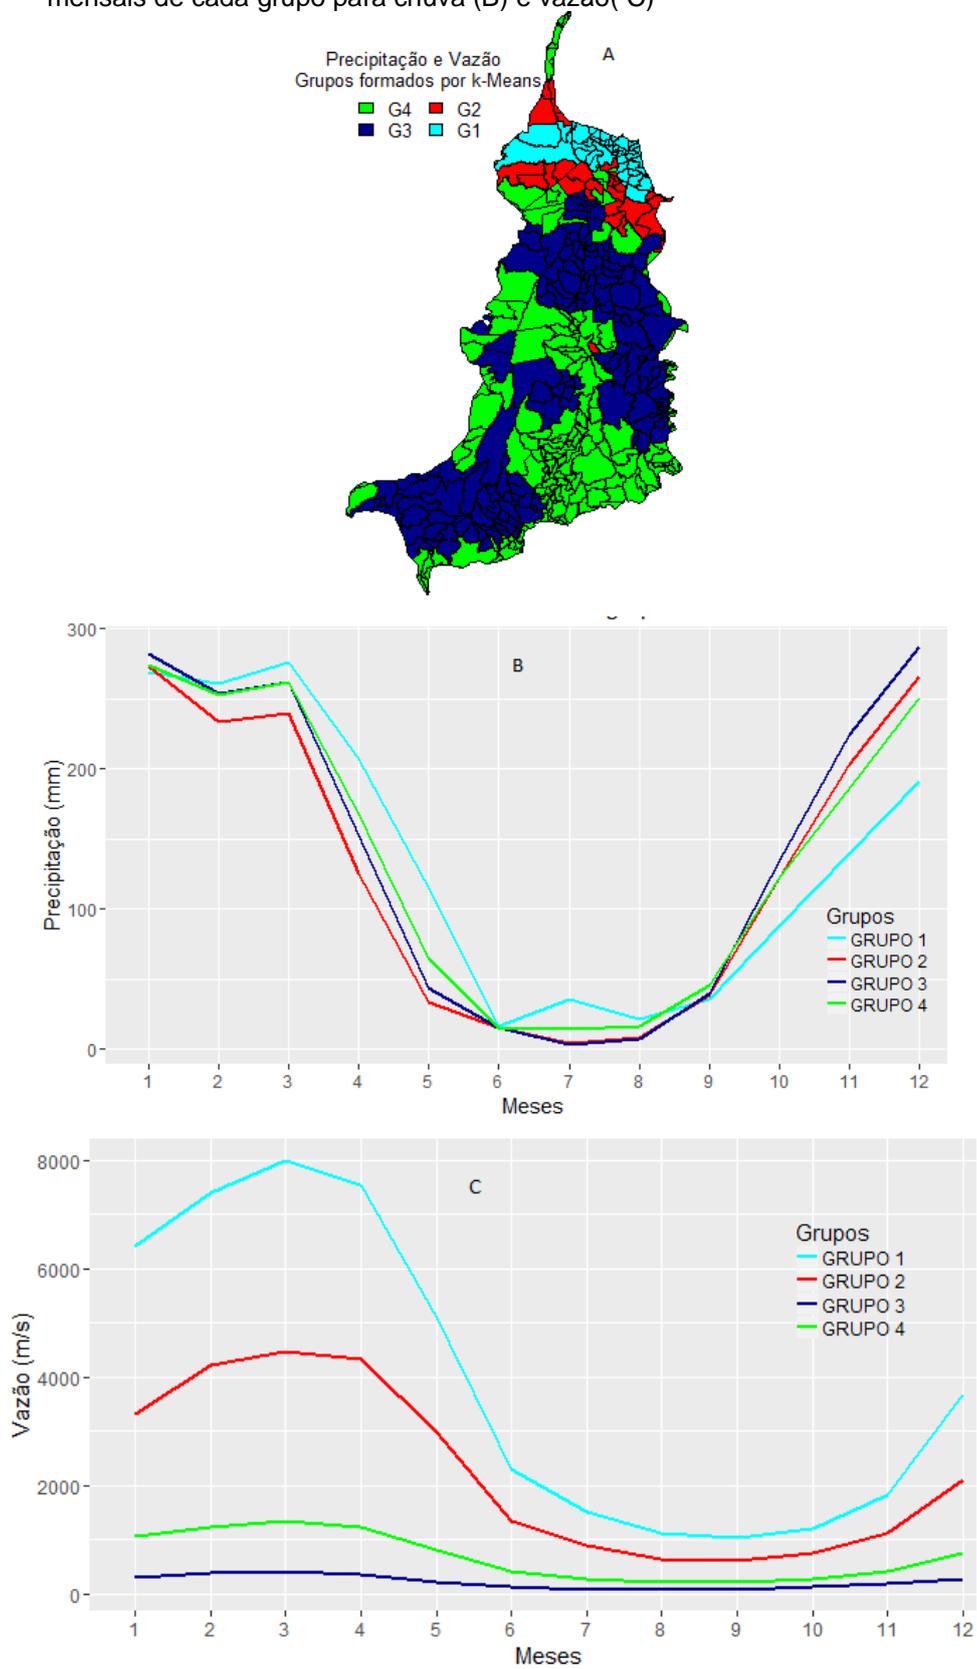


Fonte: Elaborado pelo autor.

Figura 12 - Grupos formados por *k-means* com base na vazão (A) e médias mensais de cada grupo (B)

Fonte: Elaborado pelo autor.

Figura 13 - Grupos formados por *k-means* com base na vazão e chuva conjuntamente (A) e médias mensais de cada grupo para chuva (B) e vazão (C)



A irrigação de culturas agrícolas é uma prática utilizada para complementar a disponibilidade da água provida naturalmente pela chuva, proporcionando ao solo teor de umidade suficiente para suprir as necessidades hídricas das plantas (SETTI et al., 2001). Esta favorece a obtenção de aumentos significativos de produtividade de diversas culturas agrícolas, contribuindo para reduzir a expansão de plantios em áreas com cobertura vegetal natural, aumentar a duração do período anual de plantios e a produção agrícola. Nos casos do milho e da soja, por exemplo, estima-se que a adoção de sistemas de irrigação pode proporcionar um aumento de produtividade de 57% e 60%, respectivamente (PIVOT, 2013). Dependendo das condições de temperatura, em muitas regiões a irrigação por pivôs centrais possibilita a sucessão de até três cultivos irrigados ao longo do ano agrícola, como plantio de milho, feijão e olerícolas (SILVEIRA, 2011).

No caso das culturas irrigadas de soja, milho, café, feijão e outras, o sistema de irrigação mais utilizado é o pivô central, em que a área é irrigada por um sistema móvel, constituído por uma barra com aspersores que se movimenta em torno de um ponto central fixo. A barra pode movimentar-se em torno do eixo, tanto no sentido horário quanto no anti-horário, formando uma área irrigada com formato circular. Além de água, a estrutura também é usada para a aplicação de fertilizantes, inseticidas e fungicidas (BRAGA; OLIVEIRA, 2005; IBGE, 2007).

O sistema chegou ao Brasil na década de 1970, tendo se consagrado como sistema de irrigação nas décadas seguintes, impulsionado, principalmente, por programas governamentais como o PROINE (Programa de Irrigação do Nordeste), PROFIR (Programa de Financiamento de Equipamentos de Irrigação) e o PRONI (Programa Nacional de Irrigação), dado o custo relativamente baixo, a facilidade de operação e a eficiência entre 70 e 90% no uso da água (CHRISTOFIDIS, 2002; SCHMIDT et al., 2004).

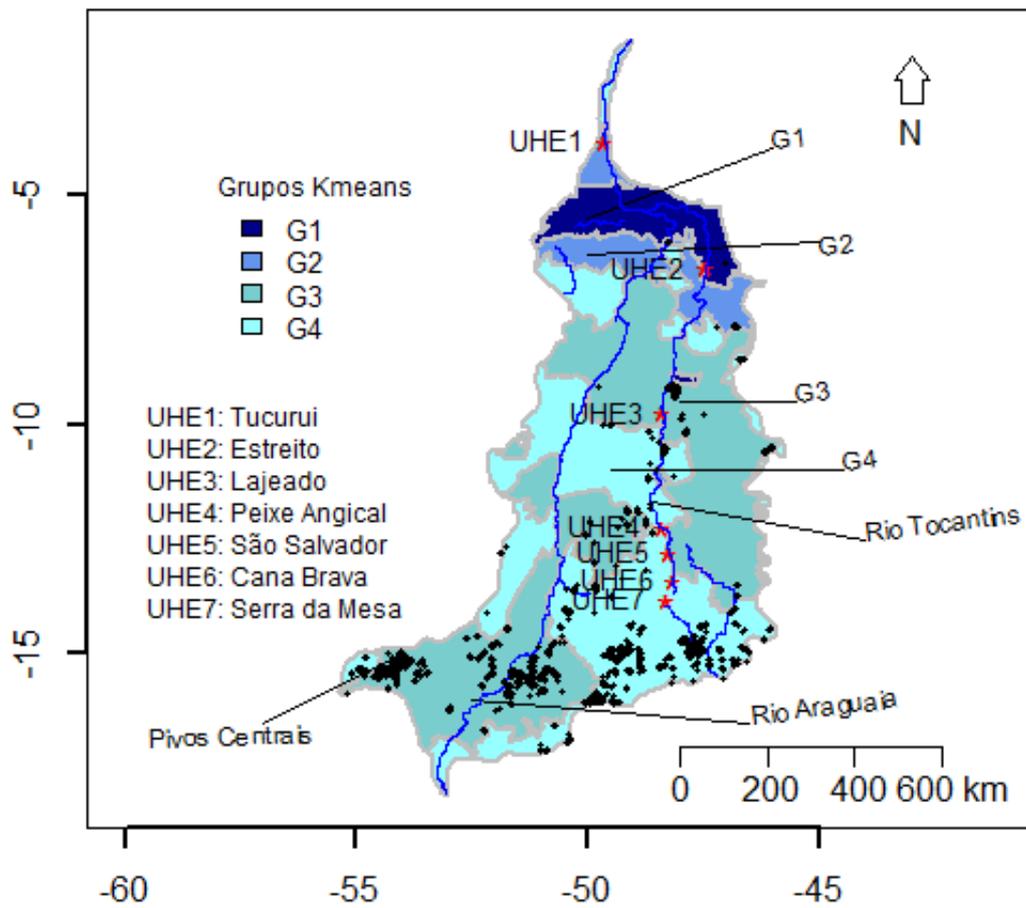
Conforme Christofidis (2005), a área ocupada pela agricultura irrigada no Brasil responde por aproximadamente 42% da produção total de alimentos. De acordo com Sandri e Cortez (2009), no final da primeira década de 2000 ocorreu uma acentuada expansão da irrigação por pivôs centrais no Brasil, principalmente nos Estados de São Paulo, Goiás, Minas Gerais 10 Variação da Área Irrigada por Pivôs Centrais no Brasil entre 2013 e 2014 e Bahia, motivada pelas facilidades operacionais e de controle da lâmina de irrigação, com custos competitivos pelo menor dispêndio de mão-de-obra e pela possibilidade de se obter alta eficiência de aplicação e distribuição de água.

Com o crescente interesse no aumento da produção agrícola no país, é provável que o número de pivôs centrais venha aumentando a cada ano, sendo importante a realização de levantamentos atualizados que permitam identificar a localização geográfica e a área irrigada por pivôs centrais, possibilitando conhecer melhor a situação da agricultura irrigada no país, e o gerenciamento de outorgas solicitadas.

Metodologias como as utilizadas por Ferreira et al. (2011), Guimarães e Landau (2011, 2014), Toledo et al. (2011), Guimarães et al. (2012), Landau et al. (2013, 2014), que mapearam os pivôs centrais ocorrentes em diversas épocas e Estados do Brasil, a partir de imagens de satélite de 2008 a 2013, possibilitam o mapeamento de cada pivô central, permitindo a realização de análises relacionadas com a localização geográfica e tamanho de cada um. Este trabalho objetivou analisar a variação da agricultura irrigada entre 2013 e 2014, representando um subsídio para a definição de estratégias envolvendo o uso de agricultura irrigada e políticas para gerenciamento do uso das águas nas respectivas bacias hidrográficas e políticas de gestão do uso da água nas diferentes regiões do Brasil.

A Figura 14 apresenta a distribuição espacial dos pivos na bacia assim com as usinas hidrelétricas instaladas e rios principais. As regiões dos grupos 1 e 2, com cores mais escuras são caracterizadas por maior disponibilidade hídrica enquanto as regiões dos grupos 3 e 4 caracterizam-se por apresentarem menor disponibilidade hídrica. Pode-se observar que os pivos centrais utilizados na agricultura irrigada localizam-se principalmente nas regiões dos grupos 3 e 4, provavelmente por causa da menor disponibilidade hídrica. Das 7 usinas hidrelétricas (UHE) instaladas na BHAT, todas no rio Tocantins, exceto as UHE Tucuruí e Estreito, localizam-se nas regiões de menor disponibilidade hídrica. Essa caracterização pode auxiliar, portanto, na seleção de locais que precisam de mais atenção quanto à irrigação.

Figura 14 - Mapa com os pivos (em pontos) e usinas hidrelétricas nas áreas irrigadas na bacia.



Fonte: Elaborado pelo autor.

2.4 Conclusão

Na elaboração de planos de gestão de recursos hídricos geralmente, um conjunto de ações são estabelecidos. Na questão do uso sustentável de recursos hídricos o conhecimento de suas interfaces com o uso do solo, a proteção ambiental e o conhecimento dos processos hidro-climáticos da região, entre outros, complementam e dão consistência ao conjunto de ações.

O uso adequado de ferramentas de análise, no presente estudo, a integração dos métodos estatísticos *k-means* e geoestatística, podem contribuir de forma significativa no entendimento dos padrões de chuvas e vazões predominantes em determinadas regiões. Neste caso, a geoestatística foi usada no mapeamento de chuvas e vazões e o método *k-means* permitiu definir áreas homogêneas, isto é, áreas com características próprias, dentro da BHAT, com base nos regimes de chuvas e vazão.

A maior variabilidade nos regimes de vazão sugere que esta variável define melhor áreas homogêneas do que as chuvas. Quatro regiões dentro da BHAT podem ser consideradas na caracterização da bacia com base nos regimes de chuva e vazão, duas com grande disponibilidade hídrica predominando ao norte da bacia e duas, mais extensas, com menor disponibilidade hídrica, ocupando a maior parte da bacia. A grande maioria dos pivos centrais, usados em irrigação e usinas hidroelétricas (UHE) localizam-se em regiões com menor disponibilidade hídrica.

Estudos adicionais são necessários para verificar a relação dessas regiões com variáveis físicas, bióticas e até mesmo socioeconômicas, incluindo variáveis da agricultura e pecuária.

Referências

- ACOSTA, Ricardo. **Um modelo biosfera-hidrosfera para a bacia do Tocantins-Araguaia**. 2007. 70f. Dissertação (Mestrado) - Instituto de Astronomia, Geofísica e Ciências Atmosféricas, USP, 2007.
- BATISTA, André Luiz França. **Modelos de séries temporais e redes neurais artificiais na previsão de vazão**. 2009. 79f. Dissertação (Mestrado em Engenharia de Sistemas) - Universidade Federal de Lavras, Lavras, 2009.
- BRAGA, Antônio de Pádua; CARVALHO, André Carlos Ponce de Leon Ferreira; LUDERMIR, Teresa Bernarda. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- BERTONI, Juan C.; TUCCI, Carlos E.M. **Chuva**. In: TUCCI, Carlos E.M. (org). **Hidrologia: ciência e aplicação**. 2. ed. Universidade UFRGS; ABRH, 2001.
- COLLISCHONN, Walter; TASSI, Rutinéia. **Introduzindo hidrologia**. 6 ed. Porto Alegre: IPH UFRGS, 2008.
- DEITEL, Harvey M.; DEITEL, Paul J. **Java como programar**. Trad. Edson Furmankiewicz. 8. ed. São Paulo: Pearson Prentice Hall, 2010.
- DUARTE, Alejandro Fonseca. As chuvas e as vazões na bacia hidrográfica do rio Acre, Amazônia ocidental: caracterização e implicações socioeconômicas e ambientais. **Amazônia: Ci & Desenv**. Belém, v.6, n.12, p.161-183, 2011.
- GIL, Antonio Carlos. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002.
- HAGAN, Martin T.; MENHAJ, Mohammad B. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions On Neural Networks**. v.5, n.6, p.989-993, 1994.
- HAGAN, Martin T.; DEMUTH, Howard B.; BEALE, Mark. **Neural network design**. China: Thomson Asia Pte Ltd, China Machine Press e CITIC Publishing House, 1996.
- HAYKIN, Simon. **Redes neurais: princípios e práticas**. Trad. Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001.
- HEATON, Jeff. **Introduction to neural networks for java**. 2. ed. St. Louis: Heaton Research, 2008.
- HEATON, Jeff. E-book. **Introduction to the math of neural networks (Beta-1)**. St. Louis: Heaton Research, 2011.
- LIMA, Carlos Henrique Ribeiro; FERREIRA FILHO, Walter Martins. Análise de modelos de redes neurais aplicados ao processo chuva-deflúvio no semi-árido. In:

SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 15, 2003, Curitiba. **Anais[...]**. Curitiba: ABRH, 2003. <https://files.abrhidro.org.br/Eventos/Trabalhos/154/481.pdf>. MACHADO, Fernando Weigert. **Modelagem chuva-vazão mensal utilizando redes neurais artificiais**. 2005. xv, 156f. Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambiental). Universidade Federal do Paraná, Curitiba, 2005.

MENDEL, Jerry M.; McCLAREN, Robert W. Reinforcement-learning control and pattern recognition. *In*: MENDEL, Jerry M.; FU, King Sun. **Adaptive, learning, and pattern recognition; theory and applications**. New York: Academic Press, 1970, p.287-318.

MINISTÉRIO DO MEIO AMBIENTE - MMA. Secretaria de Recursos Hídricos. **Caderno da região hidrográfica do Tocantins-Araguaia**. Brasília, DF, 2006

MORETTIN, Pedro A.; TOLOI, Clélia M. C. **Análise de séries temporais**. 2. ed. São Paulo: Egard Blucher, 2006.

ROSENBLATT, Frank. **On the convergence of reinforcement procedures in simple perceptrons**. Buffalo: Cornell Aeronautical Laboratory Report, 1960,

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by backpropagation errors. **Nature**, London, v.323, p.533-536, 1986.

SAJIKUMAR, N.; THANDAVESWARA, B.S. A non-linear rainfall-runoff model using an artificial network. **Journal of Hydrology**, v. 216, p.32-35, 1999.

SECRETARIA DE ESTADO DE PLANEJAMENTO-SEPLAN. **Acre em números**. Rio Branco, 2011.

SILVA, Edna Lúcia da; MENEZES, Estera Muszkat. **Metodologia da pesquisa e elaboração de dissertação**. 4. ed. Florianópolis: UFSC, 2005.

SILVEIRA, André L.L. da. Ciclo hidrológico e bacia hidrográfica. *In*: TUCCI, Carlos E.M. (org). **Hidrologia: ciência e aplicação**. 2 ed. Universidade UFRGS; ABRH, 2001.

SOUSA, Wanderson dos S.; SOUSA, Francisco de A. S. de. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio Piancó. **R. Bras. Eng. Agríc. Ambiental**, Campina Grande, v.14, n.2, p.173-180, 2010.

VALENÇA, Mêuser. **Fundamentos das redes neurais: exemplos em java**. 2.ed. Olinda: Livro Rápido, 2010.

3 MAPEAMENTOS DE PREVISÕES DE CHUVAS NA BACIA ARAGUAIA-TOCANTINS

Resumo

Estudos sobre a variabilidade dos parâmetros hidroclimáticos locais em bacias hidrográficas são importantes para analisar o comportamento dos vários sistemas hídricos ao longo dos anos. Esse tipo de ação possibilita ter uma melhor compreensão desses sistemas, abrindo a possibilidade de realizar previsões visando um melhor planejamento dos recursos hídricos. Foram realizadas previsões de chuvas e vazões da bacia hidrográfica do Araguaia-Tocantins (BHAT), em séries temporais mensais com variações nos períodos de 1969 a 2017 (vazões) e 1974 a 2017 (chuvas). Dois métodos foram utilizados: redes neurais e modelos de Box-Jenkins. Uma comparação das previsões obtidas para séries de chuvas e vazões mostrou que, não houve, entre os dois métodos, diferenças estatisticamente significativas nas previsões individuais tanto de chuvas como de vazões. Entretanto, se for utilizado, para a comparação dos métodos, o RSME (erro quadrático medio) o método de Box-Jenkins apresentou melhores resultados nas previsões, ou seja, previsões de chuvas e vazões têm menores erros em relação à Redes Neurais. Com os resultados das previsões de chuvas obtidos pelos métodos acima mencionados, foi construído um modelo considerando as dimensões de tempo e espaço, com auxílio da geoestatística, para o mapeamento de previsões de chuvas na BHAT. Confirmado os resultados obtidos nas séries temporais, os mapas de previsão de chuvas construídos com o método de Box-Jenkins apresentaram, visualmente, melhores resultados, ou seja, previsões de chuvas com menores erros, observados na comparação do RSME.

Palavras-chave: Bacia Araguaia-Tocantins; Redes Neurais, Modelo Box-Jenkins, Geoestatística, modelo espaço-temporal. Mapas de previsão.

3.1 Introdução

Variáveis ambientais e socioeconômicas são afetadas por chuvas em muitas partes do mundo. Características de florestas, níveis de produção agrícola, temperaturas e muitas outras variáveis são influenciadas por regimes de chuva. A intensificação do regime de chuvas na região, afeta o nível e vazão das bacias, pelo fato da chuva ser a principal moduladora da variação das vazões nas bacias hidrográficas. Observações de campo mostram que as chuvas apresentam considerável variação espacial, causada, entre outros, por fenômenos meteorológicos como El Niño, La Niña, temperaturas de superfície do mar -TSM.

Na prática é impossível medir e descrever todos os fatores que influenciam na variação espacial e temporal observada nas ocorrências de chuvas isso pode complicar o modelamento quantitativo da chuva. Há uma extensa literatura que apresenta diversos estudos sobre chuvas, inclusive estudos que consideram os componentes espaciais e temporais relacionados às ocorrências de chuvas (ref). Muitos mapeamentos de chuvas são construídos com base em observações meteorológicas obtidas de satélites (www.aeb.gov.br). Esses mapas, entretanto, em geral não avaliam a existência da dependência espacial e; ou temporal em eventos de chuvas.

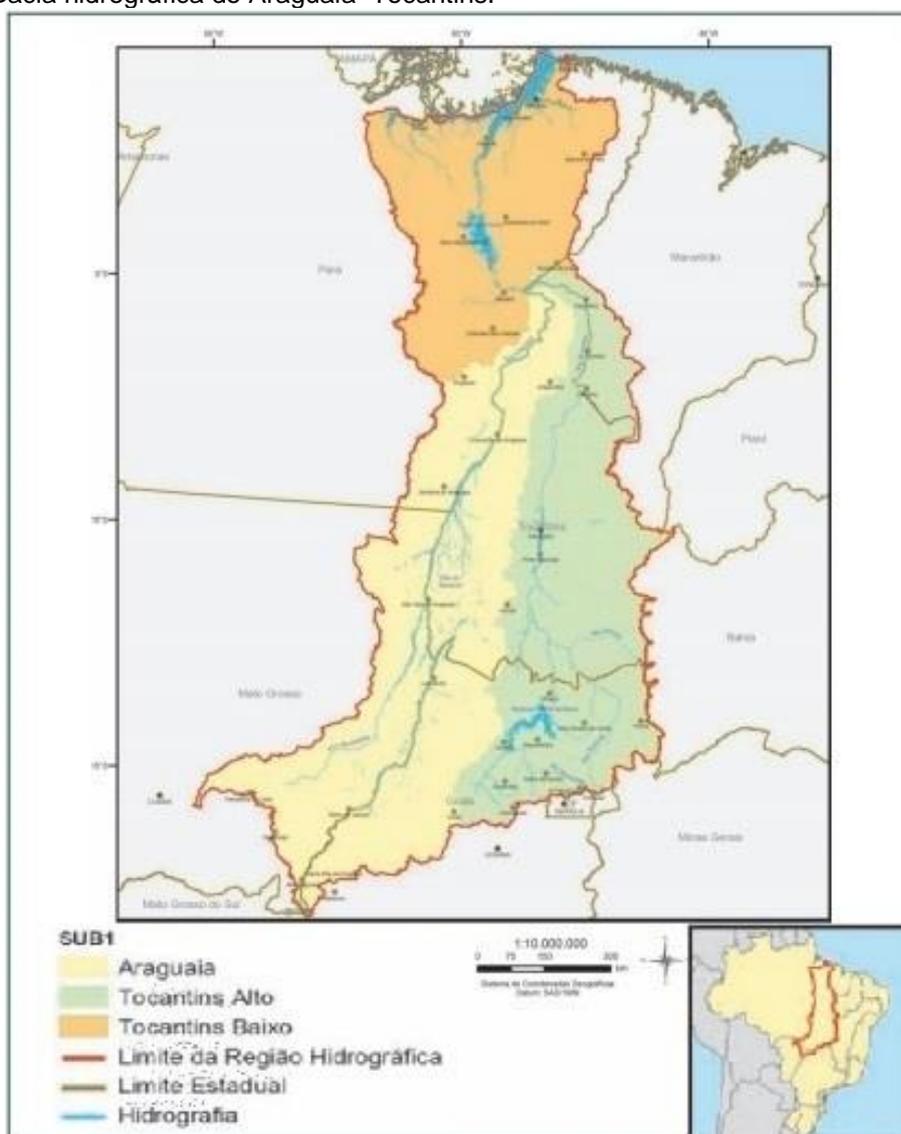
Este capítulo é direcionado a mapeamento de previsões de chuvas com o uso de modelo espaço-temporal. Modelos de previsão de séries temporais com uso da metodologia de Box-Jenkins têm sido amplamente utilizados na previsão de valores futuros. No entanto, o uso da rede neural artificial também está aumentando devido à sua flexibilidade e precisão nas previsões. Deste modo, foi realizada uma comparação das previsões obtidas por modelo de rede neural, o MLP (*Multi-Layers Perceptron*) e modelos temporais com a metodologia de Box-Jenkins. Foram comparados os resultados obtidos por cada método de modo que, se pôde ter uma avaliação do desempenho de cada método para realização de previsões de valores futuros. Foi realizado também um estudo para avaliação dos níveis de chuva e vazões ao longo do tempo na bacia Araguaia-Tocantins. Pôde-se observar que, há uma tendência decrescente tanto nos níveis de chuva quanto de vazões na bacia.

3.2 Material e método

3.2.1 Área de Estudo

A região hidrográfica do Araguaia–Tocantins, mostrada na Figura 15, possui uma área de 921.921 km², equivalendo a aproximadamente 10,8% do território brasileiro. De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), em 2010 a referida região apresentava uma população de 8.610.721 habitantes, sendo 76% ocupando áreas urbanas, caracterizando uma densidade demográfica de 9,3 hab./km², portanto, inferior à do país que era de 22,4 hab./km² (IBGE, 2010).

Figura 15 - Bacia hidrográfica do Araguaia–Tocantins.



Fonte: (MMA, 2006).

3.2.2 Redes Neurais Artificial

Uma rede neural artificial (RNA) é um paradigma de processamento de informação semelhante à arquitetura do cérebro. É composta de um grande número de elementos interconectadas chamadas neurônios trabalhando em uníssono para resolver tarefas específicas. Um neurônio biológico pode receber até 10.000 insumos diferentes, e pode enviar sua saída para muitos outros neurônios (LESLIE, 1996). Os neurônios em uma RNA também recebem informações como entrada de outros neurônios e os enviam como saída para outros neurônios, exatamente como os neurônios biológicos fazem.

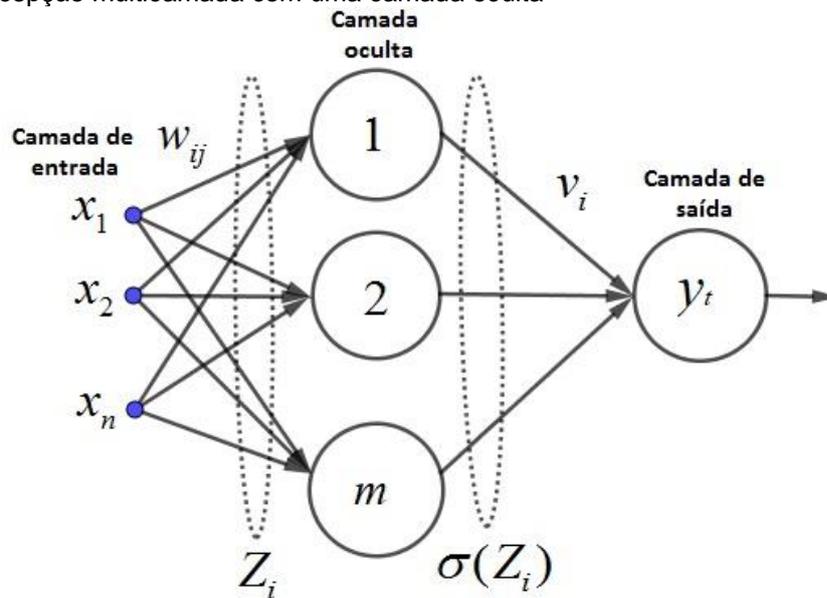
Considerado como um método alternativo ao modelo ARIMA na previsão de séries temporais, as RNAs possuem variada característica destacável (HAYKIN, 2001, LESLIE, 1996). Uma das principais é como um aproximador universal, ou seja, uma RNA pode estimar qualquer função contínua não linear com um bom grau de precisão (LAGARIS et al., 1998; ZHANG, 2003). A Figura 16 mostra um perceptron multicamada (MLP) feedforward com n entradas, uma camada oculta com m neurônios e um neurônia na camada de saída, tal topologia de RNA é a mais comum na previsão de séries temporais (KHANDELWAL; ADHIKARI; VERMA, 2015; ZHANG, 2003; ABHISHEK et al., 2012), para essa situação temos o seguinte modelo matemático:

$$\begin{cases} Z = b_{0j} + WX & j = 1, 2, \dots, n \\ y_t = b_0 + V\sigma(Z) + \varepsilon_t \end{cases} \quad (4)$$

sendo, $W = [w_{ij}]$ e $V = [v_{j1}]$ ($i = 1, 2, \dots, m; j = 1, 2, \dots, n$) são matrizes contendo os pesos sinápticos; $X = (x_1, x_2, \dots, x_n)^T$ é o vetor contendo os dados de entrada (neste caso, são os elementos da série temporal); b_0 e b_{0j} são os bias; ε_t é o ruído branco em cada amostra; e $\sigma(\cdot)$ é a função de ativação, que para problemas envolvendo séries temporais é adotada a função logística (KHANDELWAL; ADHIKARI; VERMA 2015; ZHANG, 2003).

Função logística:
$$y(x) = \frac{1}{1 + e^{-kx}} \quad (5)$$

Figura 16 - Percepção multicamada com uma camada oculta



Fonte: Elaborado pelo autor.

3.2.3 Modelos de Box-Jenkins para séries temporais

De acordo com Morettin e Tolo (2004), uma série temporal (ST) pode ser definida como um conjunto de observações, Y_t em função do tempo. As principais ferramentas utilizadas para análise de séries temporais são: as funções de auto-correlação e auto-correlação parcial. A função auto-correlação (FAC) representa a correlação simples entre Y_t e Y_{t-k} em função da defasagem k . A função de auto-correlação de uma ST $\{Y_t\}$ pode ser definida como:

$$\rho = \frac{\sum_{t=0}^{N-k-1} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=0}^{N-1} (Y_t - \bar{Y})^2} \quad (6)$$

onde, N representa o comprimento da ST e \bar{Y} é o valor esperado das observações, calculada para a variação temporal (*atraso*) k . O coeficiente de auto-correlação (ρ) de uma ST varia entre -1 e 1 . Se ρ assume o valor 1 , então, diz-se que as duas variáveis medidas possuem uma auto-correlação positiva absoluta, caso contrário, se $\rho = -1$, diz-se que a auto-correlação negativa é absoluta. Quando ρ assume valor 0 , não existe auto-correlação entre as variáveis, ou seja, considera-se que as observações são independentes.

A função auto-correlação parcial (FACP) representa a correlação entre Y_t e Y_{t-k} como uma função da defasagem k , filtrado o efeito de todas as outras defasagens

sobre Y_t e Y_{t-k} . A função de autocorrelação parcial é definida como a seqüência de correlações entre $(Y_t$ e $Y_{t-1})$, $(Y_t$ e $Y_{t-2})$, $(Y_t$ e $Y_{t-3})$ e assim por diante, desde que os efeitos de defasagens anteriores sobre t permanecem constantes. A FACP é calculada como o valor do coeficiente ϕ_{kk} na equação:

$$Y_t = \phi_{k1}Y_{t-1} + \phi_{k2}Y_{t-2} + \phi_{k3}Y_{t-3} + \dots + \phi_{kk}Y_{t-k} + u_t \quad (7)$$

O modelo desenvolvido pela metodologia de Box-Jenkins, conhecido como ARIMA (Auto Regressivo Integrado Médias Móveis), consiste basicamente de uma função de regressão populacional para Y_t em que há apenas 2 tipos de “variáveis explicativas”: a parte “auto-regressiva”, que representa os valores passados de Y_t e a parte “médias móveis”, que representa valores presente e passado do distúrbio normal u_t (ou “inovação”). A forma geral da equação segue a notação de Box e Jenkins (1976) é:

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} \quad (8)$$

onde p é a defasagem máxima de Y_t presente na equação, q é a defasagem máxima de u_t (médias móveis) presente na equação e ϕ_p e θ_q são os parâmetros (autoregressivos e médias móveis, respectivamente) do modelo a determinar.

O tipo (autoregressivo ou médias móveis) e a quantidade de parâmetros a serem usados nos modelos são determinados pela análise das FAC e FACP. Livros texto como Moretin e Tolo (2004), mostram como é feita a escolha dos parâmetros por meio da análise das FAC e FACP. A classe de modelos ARIMA é extremamente flexível. Ela é capaz de produzir, com pouquíssimos parâmetros, séries temporais com os comportamentos mais variados. Em geral, os modelos são apresentados na forma de equações que incluem os operadores B que são operadores diferença, $B^k Y_t = Y_{t-k}$, ou seja,

$$\phi(B)\Delta^d Z_t = \theta(B)a_t \quad (9)$$

em que ϕ e θ são os parâmetros auto-regressivos e médias móveis a serem estimados e $\Delta^d = (1 - B)^d$ é o operador diferença, utilizado para tornar a série estacionária se for necessário.

3.2.4 Geoestatística

A Teoria das variáveis regionalizadas é aplicada no modelamento da estrutura de correlação com uso do variograma (JOURNEL; HUIJBREGTS, 1978). Cada observação é considerada a realização de uma variável regionalizada $Y(s)$, que depende das medidas em localizações, s , determinadas. A variabilidade entre quaisquer duas quantidades $Y(s)$ e $Y(s + h)$, em dois pontos s e $s + h$ separados por o vetor h , pode ser caracterizado pelo variograma. O variograma $\gamma(h)$ em função do vetor de separação h , mas independente de s , é definido como metade da esperança matemática das diferenças quadradas de $Y(s)$ e $Y(s + h)$:

$$\gamma(h) = \frac{1}{2}E[Y(s)-Y(s+h)]^2 \quad (10)$$

onde E representa a esperança matemática. O variograma pode ser estimado substituindo-se a esperança pelo valor médio, tomado para todos os pares de diferentes observações (y_i, y_{i+h})

$$\hat{\gamma}(h) = \frac{1}{2n(h)} \sum_I^{n(h)} (y_i - y_{i+h})^2 \quad (11)$$

onde $n(h)$ é o numero de pares (y_i, y_{i+h}) separados pelo vetor h e o índice i indica as diferentes localizações espaciais das observações.

Os principais modelos de variograma são caracterizados por dois parâmetros (JOURNEL; HUIJBREGTS, 1978): o patamar (*sill*) e o alcance. O patamar é o valor limite do modelo de variograma $g(h)$ conforme h aumenta. O alcance indica a distância em que devem existir dependências espaciais e é medido pela distância em que o variograma atinge o seu valor do patamar. Além do alcance, as observações não são mais correlacionadas espacialmente. No outro extremo do variograma, $y(0) = 0$ por definição. No entanto, em muitos estudos, $g(h)$ não tende a zero quando h se aproxima de zero. Esta descontinuidade do variograma na origem é chamado o efeito de pepita e é causado por variações não espaciais, como erros de medição, e variações espaciais que ocorrem em distâncias muito pequenas. Quando o patamar é igual ao efeito pepita (efeito pepita puro) a indicação é de ausência total de correlação espacial.

Existem vários modelos que podem ser usados para ajustamento de variogramas experimentais. Um dos mais utilizados é o modelo de variograma esférico, definido como:

$$g(h) = \begin{cases} C_0 h = 0 \\ C_0 + C \left(\frac{3a}{2h} - \frac{a^3}{2h^3} \right) & 0 < h \leq a \\ C_0 + C & h > a \end{cases} \quad (12)$$

onde C_0 é o efeito pepita, a é o alcance e C é o patamar. Os parâmetros do modelo são determinados iterativamente por meio do ajuste do modelo aos resultados da análise do semivariograma amostral. O modelo resultante é uma medida da variabilidade da amostra e, assumindo que as amostras são representativas, uma medida da variabilidade da variável regionalizada.

Para que a técnica geoestatística de mapeamento (krigagem) seja aplicada é necessário que a variável regionalizada seja estacionária (média constante) e que o variograma exista. Essa condição é chamada de hipótese intrínseca. A krigagem usa uma combinação linear das observações na estimativa de valores não amostrados e com erro com variância mínima. Deste modo, fornece o chamado melhor preditor linear não-viesado (BLUP) da variável regionalizada (STEIN; CORSTEN, 1991). A krigagem estima uma variável estocástica, em vez de um parâmetro, como a esperança de uma observação. A estimativa é geralmente associada a uma incerteza. A informação utilizada para a estimativa considera as observações e o modelo de variograma.

A análise pode ser estendida para o domínio espaço-tempo usando observações (chuvas previstas por modelos de series temporais) em diferentes meses do ano. O principal pressuposto para justificar este passo é que as chuvas apresentam uma correlação serial, que foi utilizada nas previsões mensais em todas as estações para determinado ano. Além disso, as chuvas também podem ser caracterizadas por uma estrutura de correlação espacial semelhante para cada mês no ano considerado. Desta forma, a variabilidade espacial da chuva pode ser caracterizada pela mesma estrutura de modelo de variograma. Isso não significa, porém, que a distribuição das precipitações foi a mesma para cada mês.

São feitas previsões de chuvas para 12 meses de determinado ano, indicados por y_{ij} , com $i = 1, \dots, n_i$, sendo n_i o número de amostras (estações em determinada localização espacial) e $j = 1, \dots, 12$, o número de cada mês do ano. Deste modo, a falta de observações para estimar o variograma é contornado usando a seguinte equação (STERK; STEIN, 1997):

$$\hat{\gamma}(h) = \frac{1}{2n(h)} \sum_{j=1}^{12} \sum_t^{n_i(h)} (y_{ij} - y_{i+h,j})^2 \quad (13)$$

onde y_{ij} e $y_{i+h,j}$ indicam o i -ésimo par de observações (previsões) no tempo j (mês), separados pelo vetor h , dos quais existem $n_i(h)$ estações. O número total de pares de pontos para cada vetor h é igual a $n(h)$. A unidade básica de classe de distância é a defasagem, h_{lag} . Para um número finito (p) de múltiplos de h_{lags} , p valores de variograma são obtidos. Um gráfico com todos os pares $(x, \hat{\gamma}(h))$, para $x = \alpha h_{lag}$, $\alpha = 1, \dots, p$ (denominado de variograma experimental) é obtido e utilizado no ajuste de um modelo variográfico $g(h)$ para facilitar a interpretação (caracterização do padrão espacial) e permitir a interpolação espacial (krigagem).

Com uso do *software* R (versão 3.1.1) foram feitas estimativas de previsões de chuva com base nas series históricas e os respectivos mapas de previsões, que foram produzidos com auxílio da krigagem. Para krigagem, foi utilizada a rotina *geoR* a qual utiliza um algoritmo de krigagem ordinária. É estimado um valor da variável regionalizada (Y) num determinado local não amostrado (s_0) com base num número (p) de observações ao redor ou na vizinhança. O preditor T para o valor $Y(s_0)$ é uma combinação linear das p observações y_1, \dots, y_p :

$$T = \sum_{i=1}^p \lambda_i Y_i \quad (14)$$

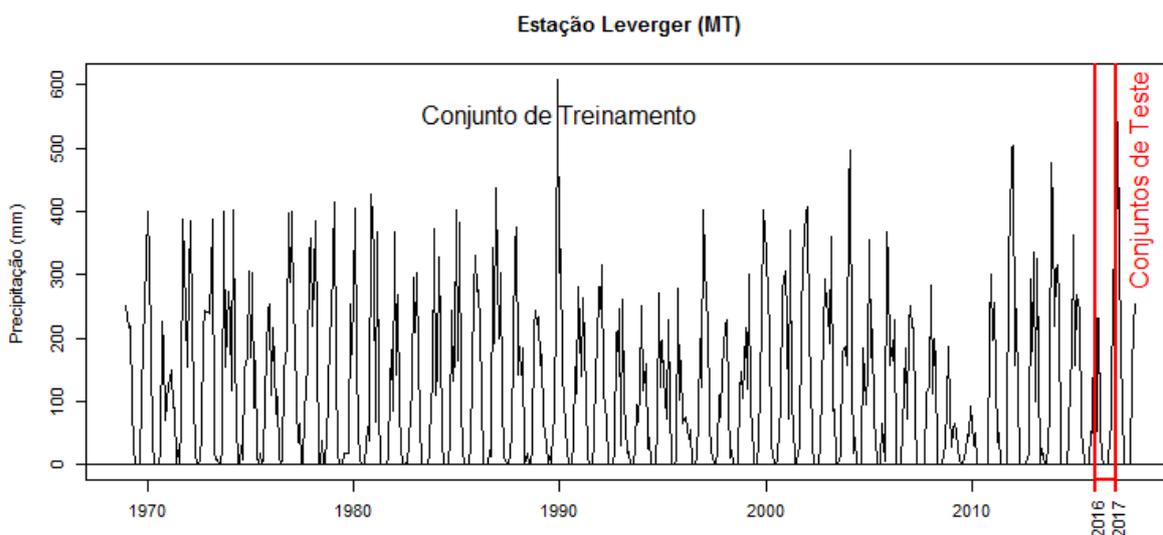
Os p pesos λ , são calculados de tal forma que T é não tendencioso e que a variância do erro de previsão é mínima. Este procedimento requer informações sobre o variograma da variável regionalizada. Uma descrição detalhada do procedimento de cálculo pode ser encontrada em manuais geoestatísticos (JOURNAL; HUIJBREGTS, 1978; CRESSIE, 1991).

3.3 Resultados e Discussão

Inicialmente foi realizada uma avaliação dos dois métodos utilizados em previsões de series temporais: método de Box-Jenkins e Redes Neurais. Na comparação das previsões nos dois métodos, foram utilizadas observações de médias mensais de duas estações meteorológicas da bacia do Araguaia-Tocantins (Brasil), uma de vazões mensais (m^3/s) e outra de chuvas mensais (mm), da Agência Nacional de Águas (ANA) com registros contínuos nos períodos de 1969 a 2017 e 1974 a 2017, respectivamente.

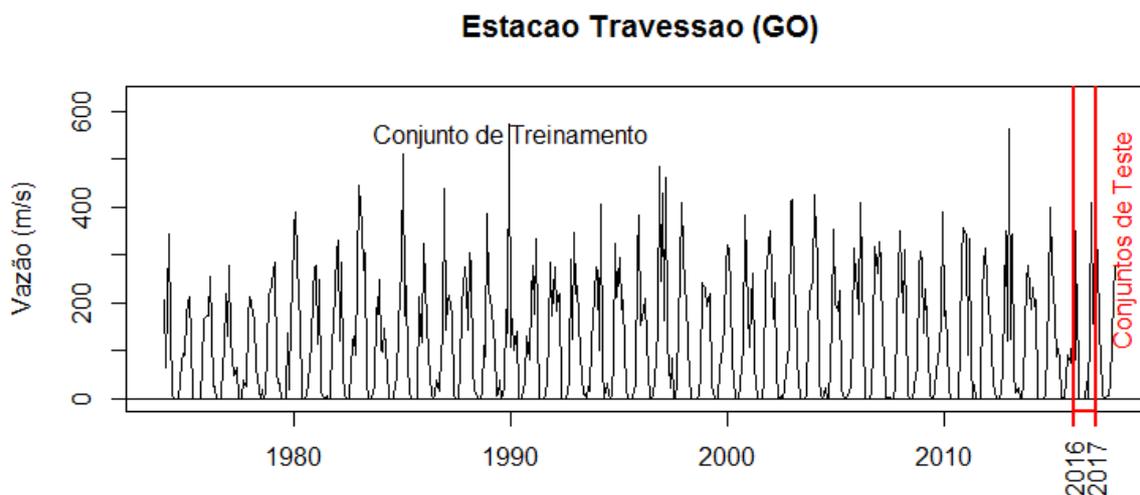
A série de chuvas foi representada pelos dados da estação Leverger no Mato Grosso (MT) e a série de vazão pelos dados da estação Travessão em Goiás (GO) (Figuras 16 e 17, respectivamente) A técnica da imputação múltipla - IM (NUNES et al., 2009; CAMARGOS et al., 2011), foi utilizada para a estimativa de valores faltantes observados nas duas séries. As séries foram divididas em duas partes: uma para o conjunto de treinamento e outra para o teste de validação (comparação) das previsões obtidas nos dois métodos (Figuras 16 e 17). Foram utilizados dois conjuntos de teste, um com 12 observações (ano de 2017) e outro com 24 observações (anos de 2016 e 2017).

Figura 17 - Série de chuvas mensais na estação Leverger (MT) de 1969 a 2017.



Fonte: Elaborado pelo autor.

Figura 18 - Série de vazões mensais (m/s) na estação Travessão (GO) de 1974 a 2017.

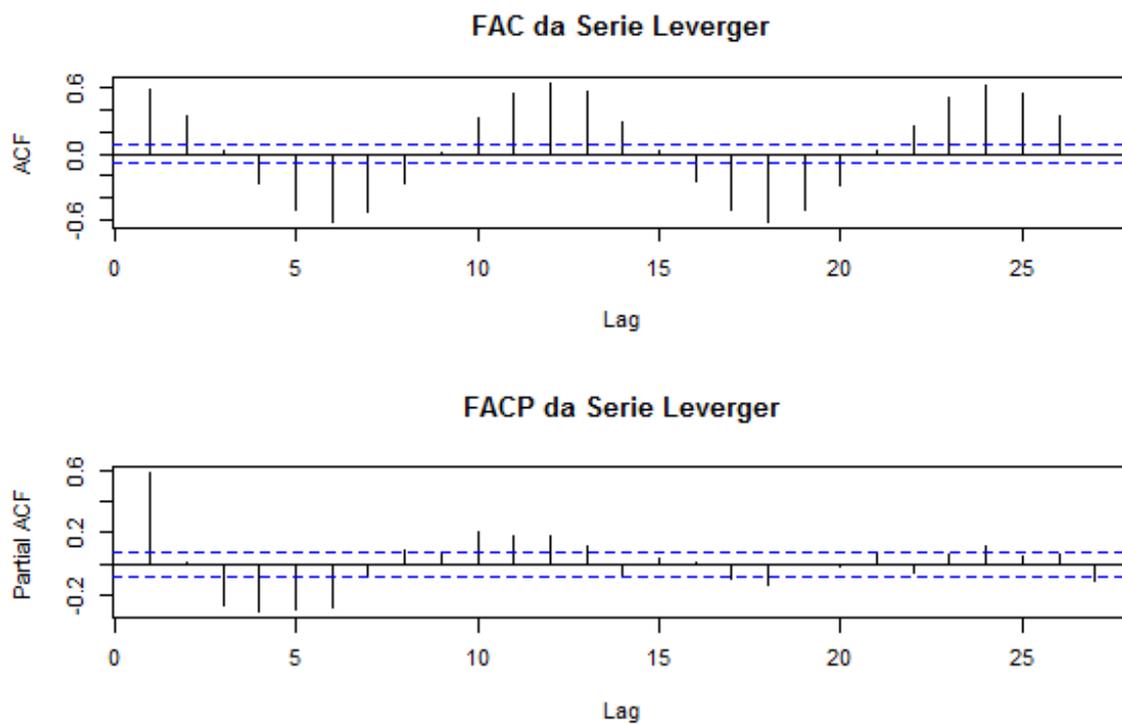


Fonte: Elaborado pelo autor.

Primeiramente, foram considerados os conjuntos de treinamento até dezembro de 2016. Neste caso, as observações de chuvas e vazão do ano de 2017 foram utilizadas para as comparações das previsões geradas pelos métodos de Box-Jenkins e RNA. Em seguida, foram utilizados os conjuntos de treinamento até dezembro de 2015 ficando as observações dos anos de 2016 e 2017 para as comparações das previsões.

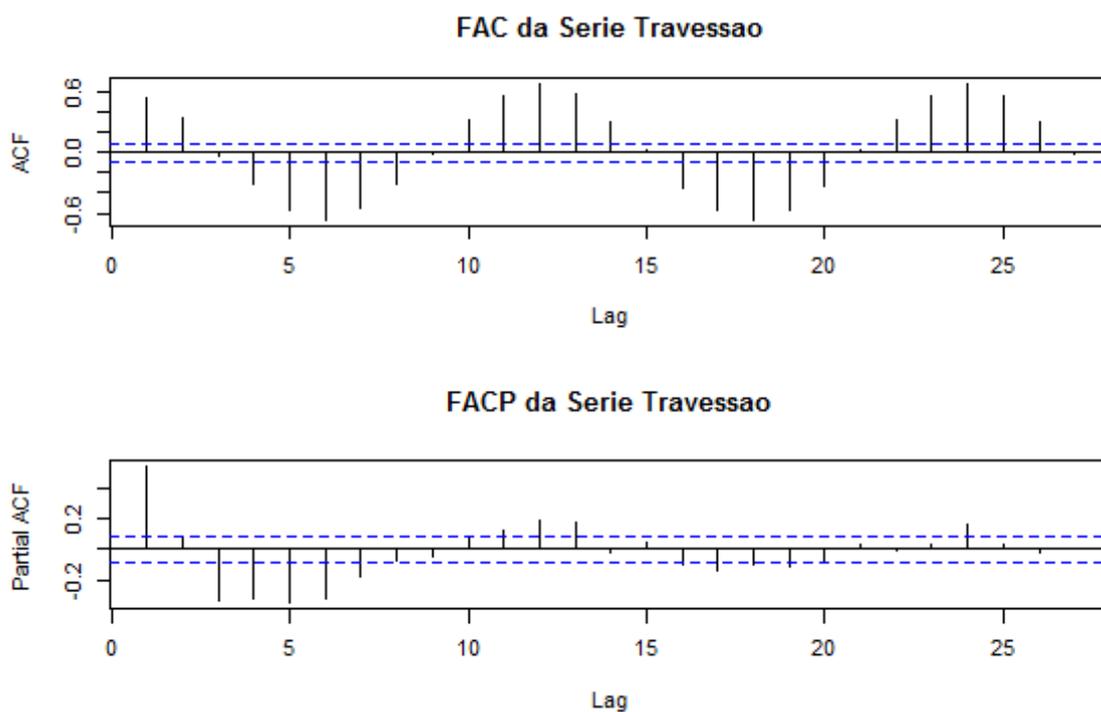
Em geral, o tipo e os parâmetros do modelo Box-Jenkins são identificados pela análise das funções autocorrelação (FAC) e autocorrelação parcial (FACP). Pode ser observado nas Figuras 3 e 4 a presença de uma sazonalidade nas séries, também observadas nas FAC e FACP. As FAC nas duas séries mostram a existencia de um componente sazonal provavelmente no *lag* 12 (Figuras 19 e 20).

Figura 19 - FAC e FACP para as chuvas mensais. Serie Leverger



Fonte: Elaborado pelo autor.

Figura 20 - FAC e FACP para as vazões mensais. Serie Travessão



Fonte: Elaborado pelo autor.

Com base nas análises das FAC e FACP foram ajustados dois modelos para série de chuvas da estação Leverger (MT) no período de 1969 a 2016 (eq. 15), em que foram realizadas 12 previsões mensais para o ano de 2017 e outro no período de 1969 a 2015 (eq. 16) em que foram realizadas 24 previsões mensais para os anos de 2016 e 2017. Do mesmo modo, para a série de vazões da estação Travessão (GO) foram ajustados 2 modelos, um no período de 1974 a 2016 (eq. 17), em que foram realizadas 12 previsões mensais para o ano de 2017 e outro no período de 1974 a 2015 (eq. 18) em que foram realizadas 24 previsões mensais para os anos de 2016 e 2017. Nesses modelos, Y_t indica a série (chuva ou vazão), a_t o ruído, B é o operador diferença, $B^k Y_t = Y_{t-k}$, e o nível descritivo, p , é fornecido abaixo de cada estimativa dos parâmetros do modelo. Todos os parâmetros estimados foram significativos com probabilidades de erro abaixo de 5%, exceto na equação 3, para a estimativa no *lag* 2 do parâmetro de médias móveis, que apresentou significância abaixo de 10%.

$$(1 - \underset{p<0,002}{0,128 B} - \underset{p<0,022}{0,096 B^2} - \underset{p<0,031}{0,0907 B^{10}} - \underset{p<0,067}{0,1005 B^{13}}) Y_t = (1 - \underset{p<0,0001}{0,982 B^{12}}) a_t \quad (15)$$

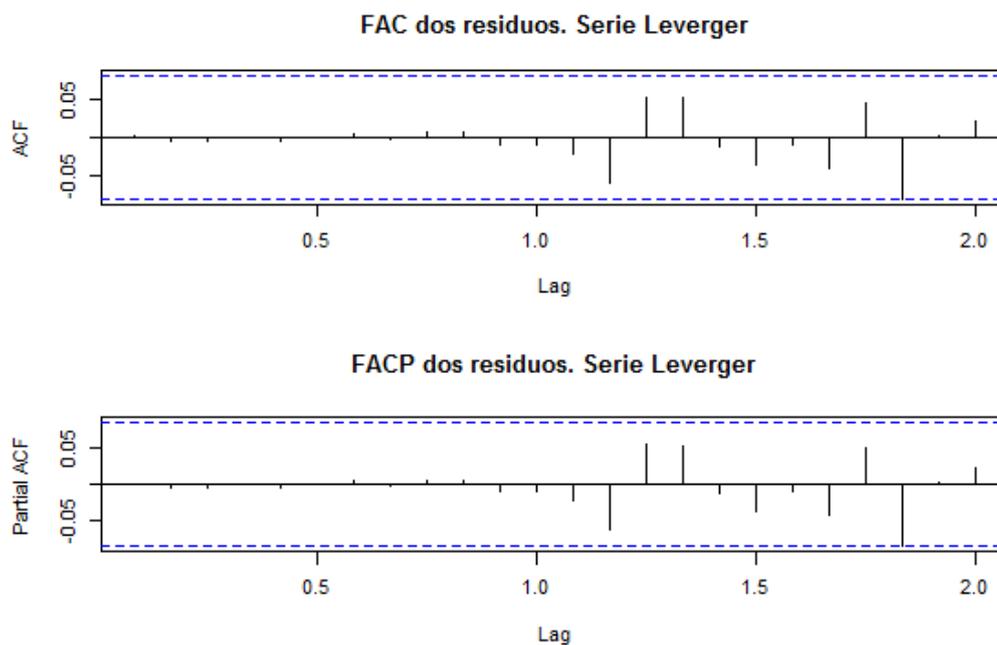
$$(1 - \underset{p<0,0001}{0,141 B} - \underset{p<0,0205}{0,0992 B^2} - \underset{p<0,029}{0,0931 B^{10}} - \underset{p<0,0304}{0,0921 B^{13}}) Y_t = (1 + \underset{p<0,0001}{0,999 B^{12}}) a_t \quad (16)$$

$$(1 - \underset{p<0,0001}{0,9982 B^{12}}) Y_t = \underset{p<0,0001}{119,35} + (1 - \underset{p<0,0589}{0,0815 B^2}) (1 + \underset{p<0,0001}{0,9097 B^{12}}) a_t \quad (17)$$

$$(1 - \underset{p<0,0001}{0,9987 B^{12}}) Y_t = \underset{p<0,0001}{116,3847} + (1 - \underset{p<0,0135}{0,1077 B^2}) (1 + \underset{p<0,0001}{0,92655 B^{12}}) a_t \quad (18)$$

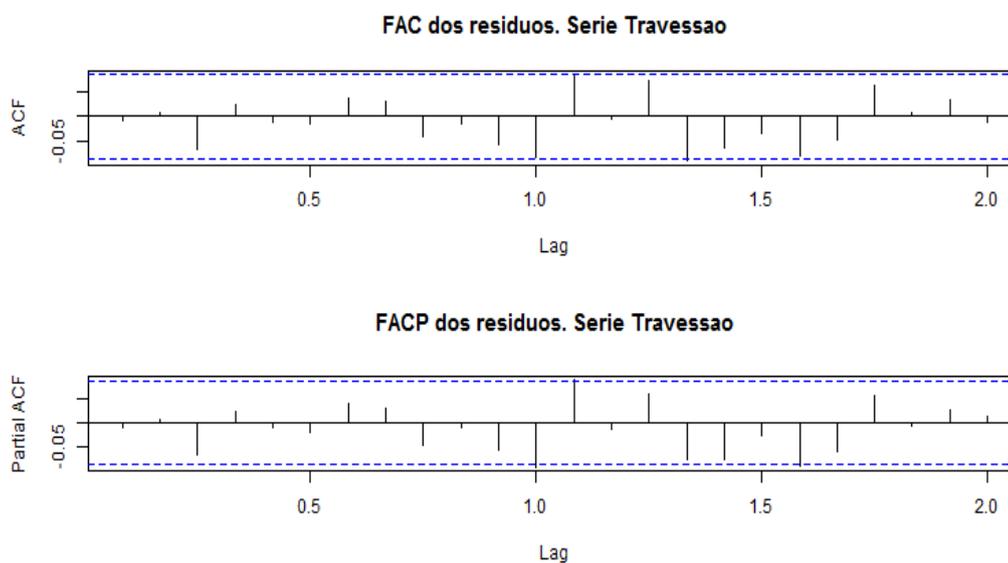
Depois de identificados os modelos e os parâmetros estimados, a verificação diagnóstica deve ser feita para garantir se os modelos são adequados. Isso pode ser feito usando o teste Box-Pierce ou Ljung-Box. Para verificação de diagnóstico, a hipótese nula é que os resíduos são independentes e o modelo é adequado. O teste de Box-Pierce para todos os apresentou valores de p (nível descritivo) para os *lags* 24, 36, 48 maiores que 0,05. Portanto, aceitamos a hipótese nula de que os resíduos são independentes e os modelos podem ser considerados adequados. Isso pode ser confirmado nos gráficos dos resíduos apresentados nas Figuras 21 e 22.

Figura 21 - FAC e FACP dos resíduos para as chuvas mensais. Serie Leverger



Fonte: Elaborado pelo autor.

Figura 22 - FAC e FACP dos resíduos para as vazões mensais. Serie Travessão

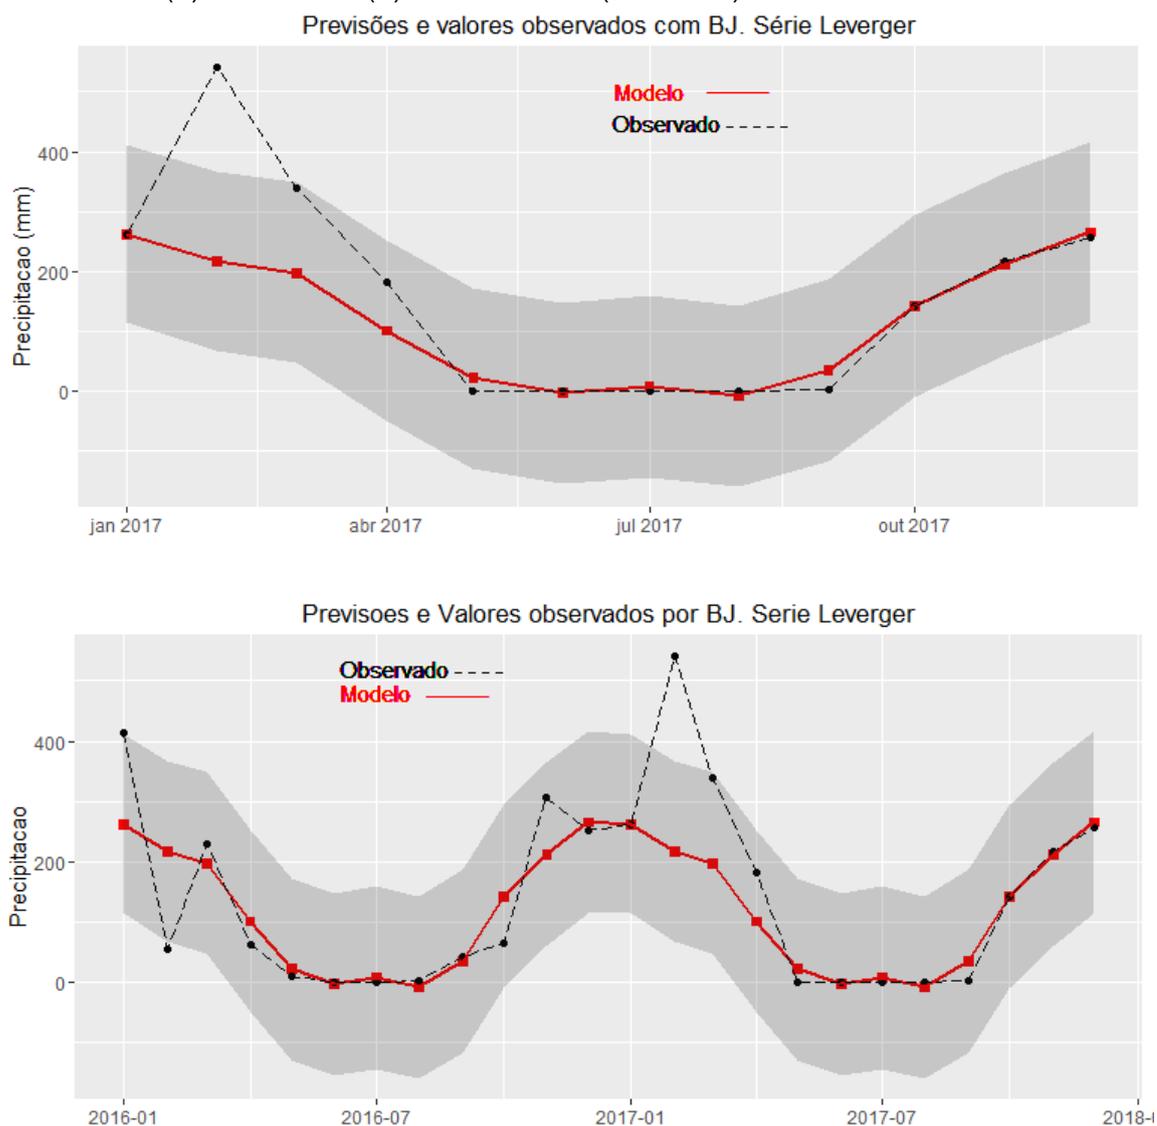


Fonte: Elaborado pelo autor.

Para a avaliação da qualidade do ajuste dos modelos foram realizadas previsões para 12 e 24 meses, respectivamente (2017 e 2016 a 2017) com intervalo de confiança (IC) de 95%, que foram comparadas com os valores observados nos respectivos periodos. As previsões são apresentadas nas Figuras 23 e 24 para as

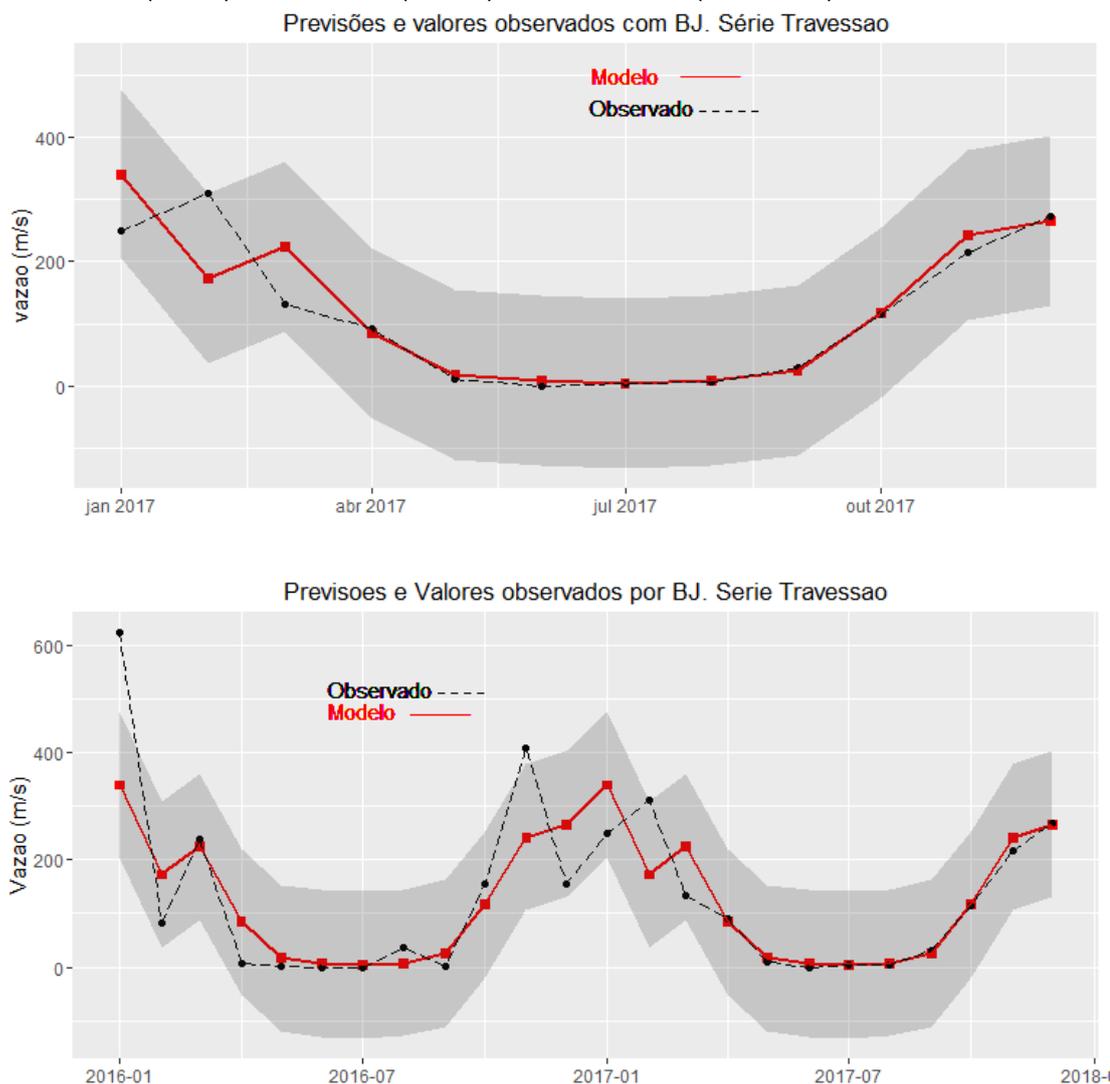
séries Leverger e Travessão, respectivamente. Pode-se observar nas duas estações que todos os valores previstos e observados são estatisticamente iguais, pois todos se encontram dentro do IC de 95%, exceto para fevereiro de 2016 e 2017 na estação Leverger e janeiro e novembro de 2016 para a estação Travessão.

Figura 23 - Previsões com modelo BJ e valores observados para chuvas na estação Leverger para 2017 (A) e 2016-2017 (B) com IC de 95% (área cinza)



Fonte: Elaborado pelo autor.

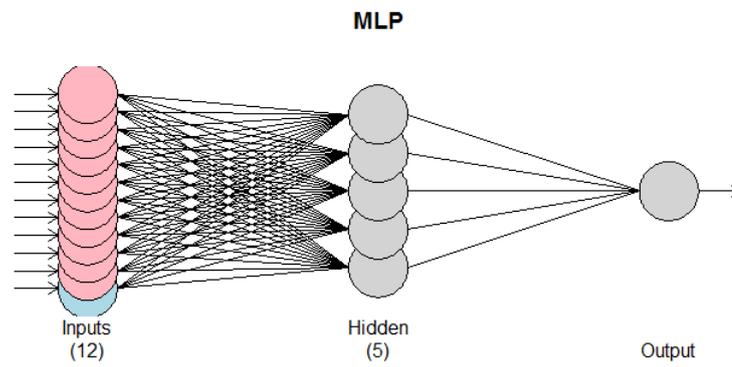
Figura 24 - Previsões com modelo BJ e valores observados para vazões na estação Travessão para 2017 (acima) e 2016-2017 (abaixo) com IC de 95% (área cinza)



Fonte: Elaborado pelo autor.

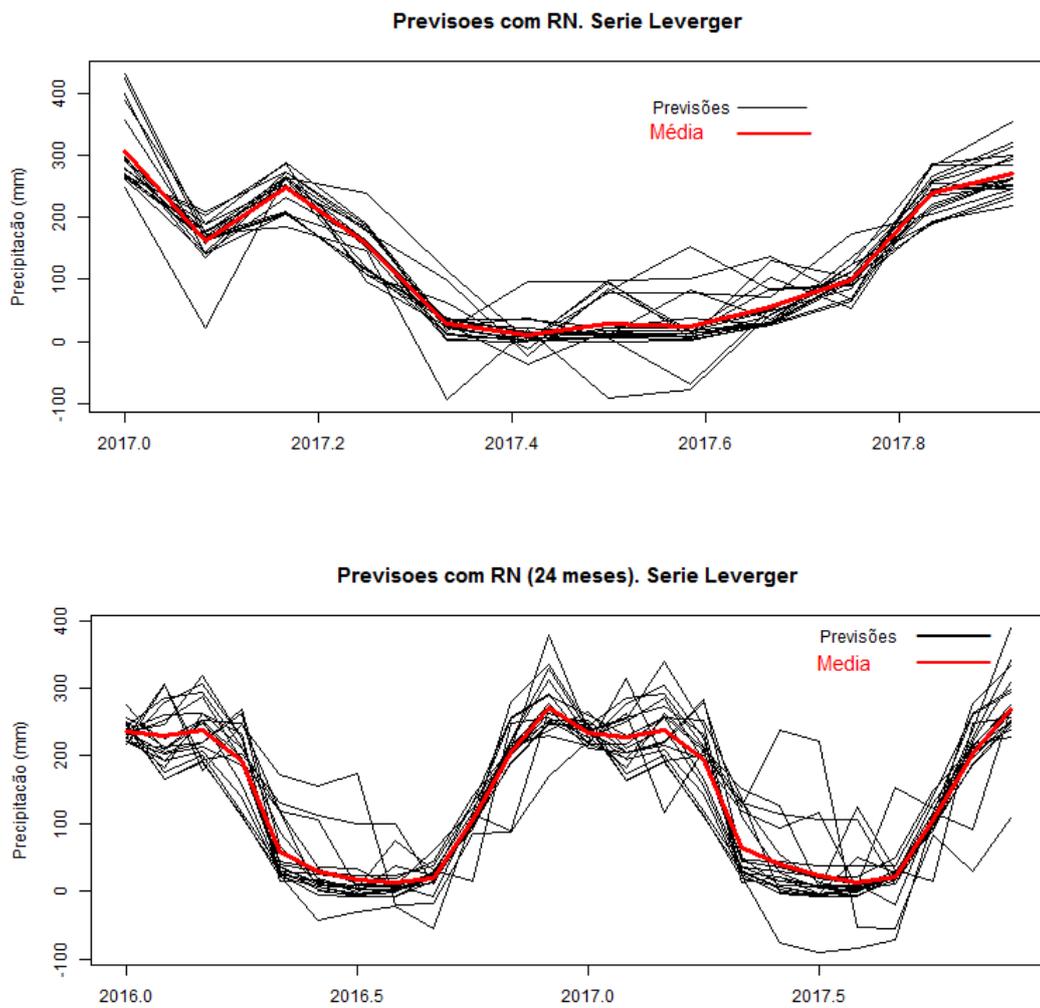
As mesmas séries foram utilizadas na aplicação de redes neurais (RN). Os resultados obtidos para os mesmos conjuntos de treinamento e conjunto de testes são apresentados a seguir. A Figura 25 mostra o desenho do modelo MLP da rede neural utilizada, com 12 entradas, referentes aos meses de cada ano, 5 camadas ocultas e 20 repetições ou simulações (previsões) para cada série, para os anos de 2017 e 2016-2017. Os resultados são mostrados nas Figuras 26 para série Leverger e Figura 27 para a série Travessão.

Figura 25 - Diagrama do modelo MLP da RNI utilizada, com 12 entradas e 5 camadas ocultas



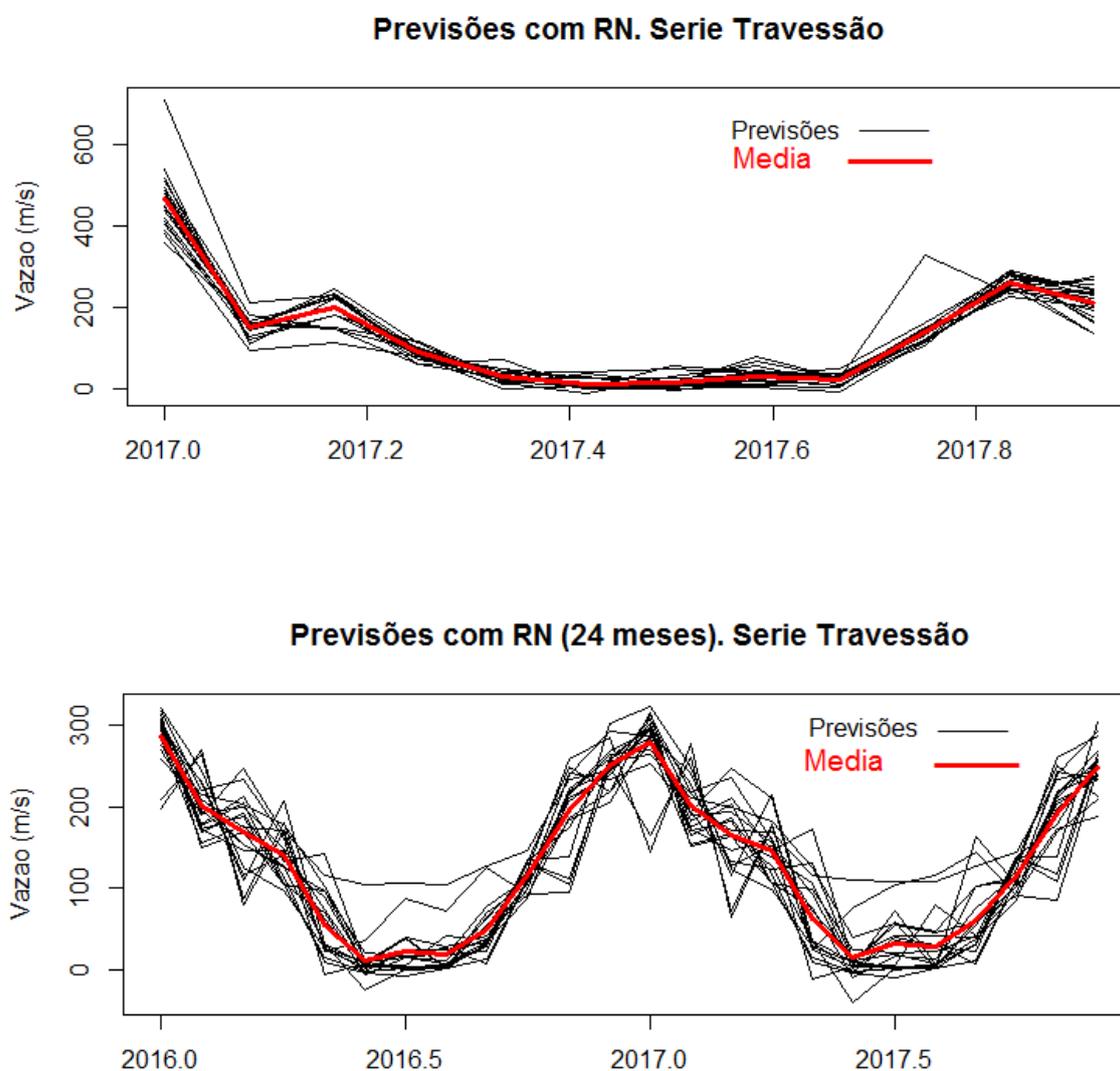
Fonte: Elaborado pelo autor.

Figura 26 - Previsões com RN para chuvas. Estação Leverger para 2017 e 2016-2017.



Fonte: Elaborado pelo autor.

Figura 27 - Previsões com RN para vazões. Estação Travessão para 2017 e 2016-2017



Fonte: Elaborado pelo autor.

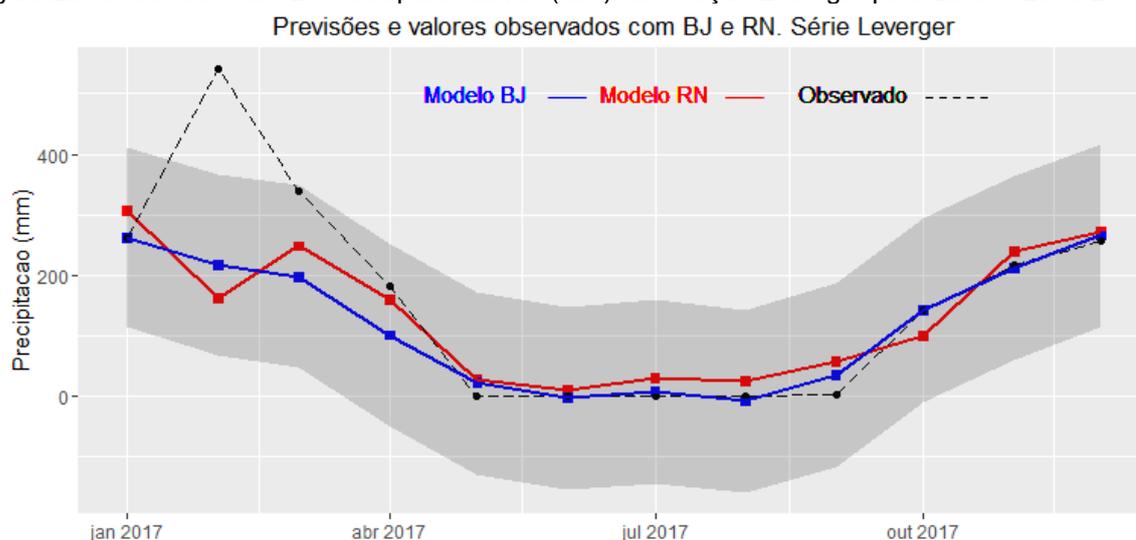
A comparação entre os dois métodos foi feita com base no erro quadrático médio (RMSE), mostrado na Tabela 5, e visualmente nas Figuras 28 e 29, que mostram as estimativas de BJ e de RN. As estimativas de RN foram representadas pela média das 20 simulações e foram considerados os IC de 95% dos modelos de BJ. Visualmente pode observar que, estatisticamente, não há diferença nas previsões geradas pelos dois métodos, uma vez que todos os valores previstos estão inseridos dentro do IC de 95%. Ou seja, pode-se considerar, com risco de erro de menos de

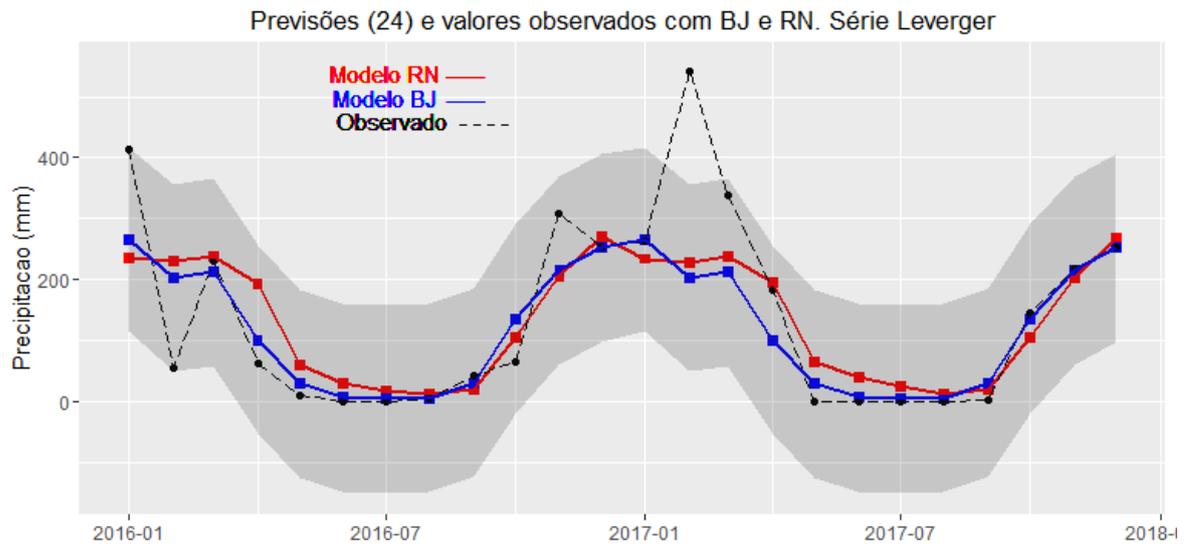
5%, que as previsões individuais obtidas por redes neurais e modelos de Box-Jenkins não apresentam diferenças estatisticamente significativas.

Se forem considerados os resultados do RMSE, pode-se observar pela Tabela 5 que, em todos os casos o modelo baseado na metodologia de BJ apresentou erros médios de previsões menores do que a RN. A estação Travessão apresentou menores erros médios de previsões nos dois métodos. Previsões para 12 meses apresentou menores erros médios na estação Travessão. Entretanto, na estação Leverger as previsões de 24 meses tiveram menores erros médios. Khandelwal, Adhikari e Verma (2015), comparou previsões de BJ e RN em 4 séries temporais (*Lynx*, *Exchange rate*, *Indian mining* e *US temperature*).

Em duas dessas séries (*Indian mining* e *US temperature*, com 30 e 60 previsões, respectivamente) o modelo BJ apresentou EQM menor do que o método RN. As séries *Lynx* e *Exchange rate*, com 14 e 52 previsões, respectivamente, o método EQM da RN foi menor. Safee e Ahmad (2014), utilizou série de índices climáticos em Sitiawan, Perak, Malasia, na comparação de previsões obtidas com vários métodos estatísticos, incluindo modelos de Bok-Jenkins, e redes neurais. Os modelos BJ apresentaram menores EQM e MAPE tanto na parte de treinamento da série quanto no conjunto de teste ou avaliação.

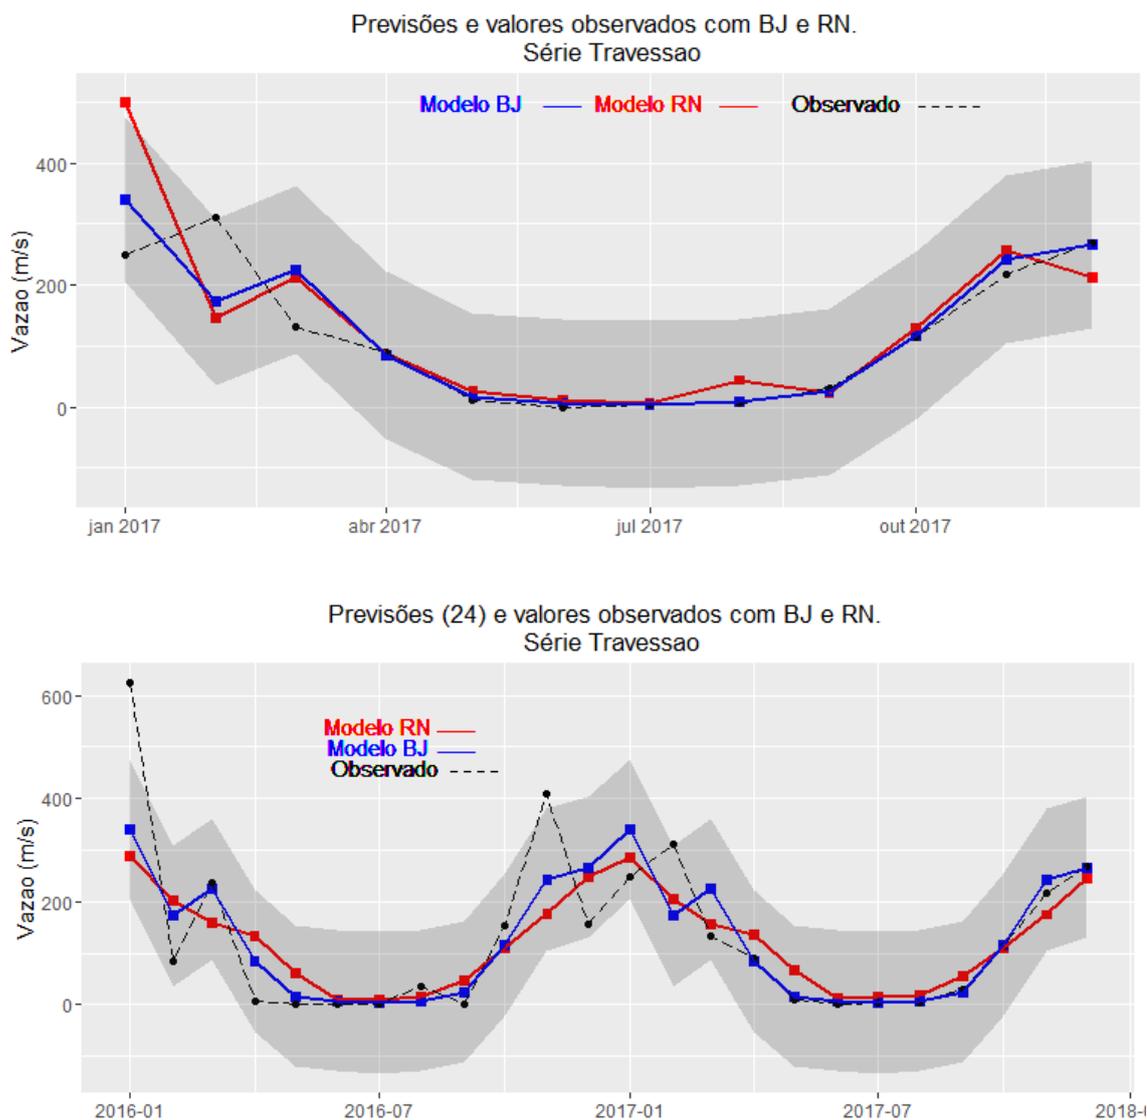
Figura 28 - Previsões com BJ e RN para chuvas (mm) na estação Leverger para 2017 e 2016-2017.





Fonte: Elaborado pelo autor.

Figura 29 - Previsões com BJ e RN para vazões (m³/s) na estação Travessão para 2017 e 2016-2017.



Fonte: Elaborado pelo autor.

Tabela 5 - Medidas dos erros (RSME) nas previsões para cada modelo

Estação	Tipo de Modelo	Nº de previsões	Erro (RMSE)
Leverger	Box-Jenkins (equação 1)	12 (2017)	105,5486
	Redes Neurais (MLP)		116,5135
	Box-Jenkins (equação 2)	24 (2016 e 1017)	91,7132
	Redes Neurais (MLP)		94,7158
Travessão	Box-Jenkins (equação 3)	12 (2017)	55,3284
	Redes Neurais (MLP)		93,1440
	Box-Jenkins (equação 4)	24 (2016 e 1017)	85,4241
	Redes Neurais (MLP)		94,1989

Fonte: Elaborado pelo autor.

Em geral, os trabalhos que se propõem a comparar a performance de previsões e ajuste de modelos com uso de redes neurais e modelos de Box-Jenkins utilizam medidas como RMSE (raiz do erro quadrático médio) e MAPE (erro absoluto médio percentual) e MAE (Erro absoluto médio). Todas essas medidas são baseadas em valores médios, ou seja, consideram um único valor para representar cada conjunto de resultados. Sabe-se que médias são influenciadas por valores extremos. Neste sentido, a média só representa adequadamente conjuntos com distribuições simétricas, ou seja, sem a presença de valores extremos. O RMSE por exemplo, apresenta a tendência de penalizar grandes erros de previsão em detrimento de outras medidas. Por isso se considera a medida mais apropriada para determinar os métodos que apresentam grandes erros.

O ideal, entretanto, seria comparar cada valor de previsão dos dois métodos. Isso pode ser feito por meio de teste de hipóteses ou intervalos de confiança. Neste sentido, os resultados obtidos mostram que, previsões obtidas por redes neurais, com o método MLP, e modelos de Box-Jenkins não apresentam diferenças estatisticamente significativas.

Para a elaboração de mapas de previsões de chuvas foram analisadas séries históricas de trinta e uma estações da bacia Araguaia-Tocantins. Para cada estação foram aplicados os métodos de BJ e RN, nas séries até o ano de 2016, configurando o conjunto de treinamento para o método RN e conjunto para construção de modelos no método BJ. Foram realizadas previsões para um horizonte de doze meses, correspondendo ao ano de 2017. Com os resultados das previsões e valores observados no ano de 2017, foram construídos os mapas de previsões com uso da geoestatística. De forma a considerar as dimensões de tempo e espaço nos mapas, foi utilizado o modelo de variograma dado pela equação 10, no estabelecimento dos pesos para o modelo de predição de valores de chuvas em locais não amostrados (*grid* ou malha). Na construção dos mapas, foi utilizado o modelo dado pela equação (19), para a interpolação (estimação) de valores em locais amostrados. Os resultados são apresentados a seguir.

Na Figura 30 são apresentados os mapas considerando os resultados para os modelos BJ, RN e mapa para os valores observados no ano de 2017, construído para efeito de comparação entre os métodos. Na Tabela 6, são mostradas as principais estatísticas (média e mediana) e o RMSE. Valores de média e mediana próximos indicam que a distribuição tem baixa assimetria. Deste modo, a média pode

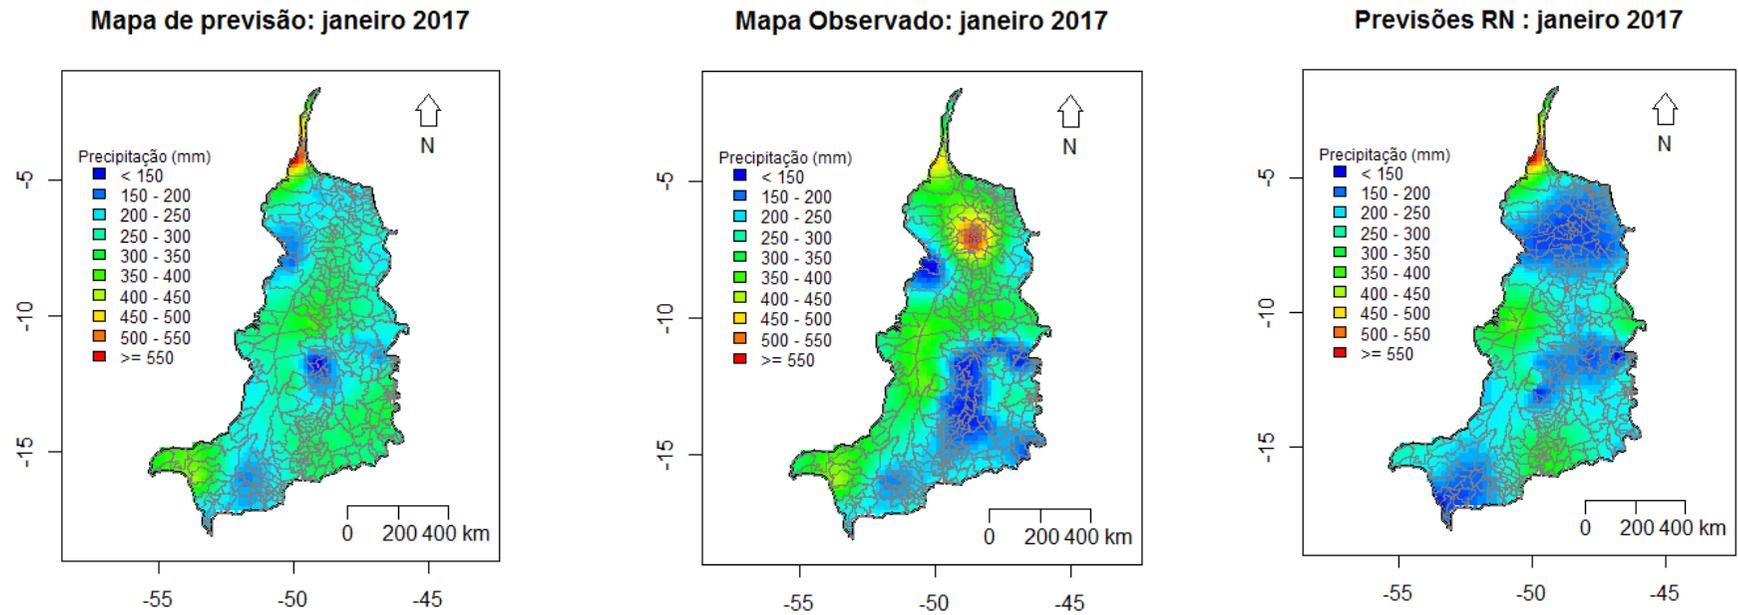
representar adequadamente os dados e as medidas de variabilidades serem mais confiáveis.

As amostras dos meses de junho e agosto foram as mais assimétricas (em negrito na Tabela 6). Nos meses de janeiro, maio e julho, houve uma superestimação na média pelo modelo BJ. No método RN houve superestimativa nas médias, além dos meses de janeiro, maio e julho, dos meses de agosto, setembro e novembro (Tabela 6). Uma comparação visual nos resultados obtidos pelos dois métodos e a análise dos valores do RMSE da Tabela 6, mostra que melhores resultados de previsões foram obtidos com a metodologia de Box-Jenkins, que apresentou menores RMSE. Os maiores erros no método de Box-Jenkins ocorreram nos meses mais chuvosos, como janeiro (60,92), fevereiro (52,68), março (23,27), setembro (21,54), outubro (19,59) e dezembro (18,33).

Com o método RN os maiores erros ocorreram de forma parecida. A alta variabilidade dos dados de chuva, mostrados nas séries históricas, torna as previsões menos precisas. Ainda assim, pode-se observar que se conseguiu, na maioria dos meses, padrões de distribuição das previsões de chuvas compatíveis com padrões de distribuição de chuvas dos valores observados. Sterk e Stein (1997) utilizaram, com resultados satisfatórios, essa mesma metodologia (modelo variográfico espaço-temporal) no modelamento de transporte de partículas de sedimentos transportadas pelo vento, dados com considerável variação espacial. Eles consideraram, entretanto, apenas 4 períodos próximos (13, 27, 30 de junho e 1 de julho e 1993) e usaram krigagem e simulação condicional estocástica. Talvez separando os períodos de chuva e seca (menos chuva) se possa ter resultados mais favoráveis, uma vez que, desse modo, se pode diminuir consideravelmente a variabilidade nos dados de chuva.

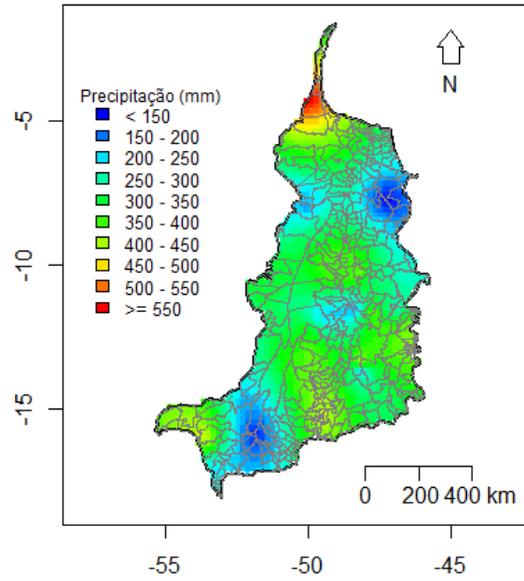
Subyani (2004) utilizou a informação sazonal na construção de variogramas para o modelamento da correlação espaço-temporal no campo de precipitação. Os resultados do gráfico Distância-Tempo do deram uma visão geral da variação estrutural da precipitação no tempo e na distância. O método mostrou os fatores climáticos que afetaram a ocorrência de precipitação na área de estudo. As linhas de contorno do gráfico revelam o padrão e o grau de continuidade estrutural da precipitação nas dimensões espacial e temporal. Não houve, entretanto, neste trabalho, uma aplicação dos resultados do variograma na interpolação (krigagem) de dados.

Figura 30 - Valores observados e previsões mensais de chuva para o ano de 2017 pelos métodos RN e BJ:
 Box-Jenkins (BJ) Observados

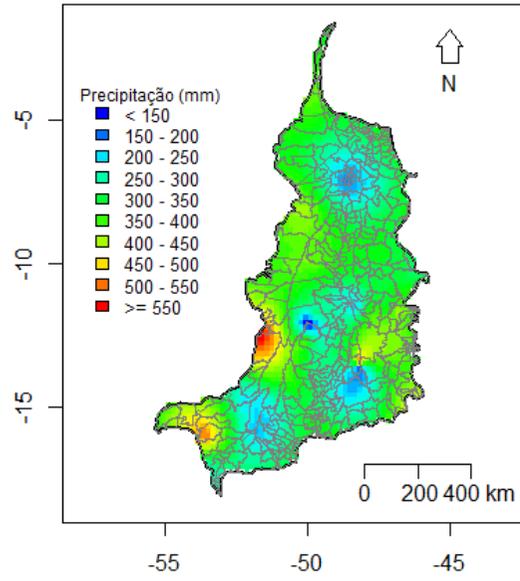


Redes neurais (RN)

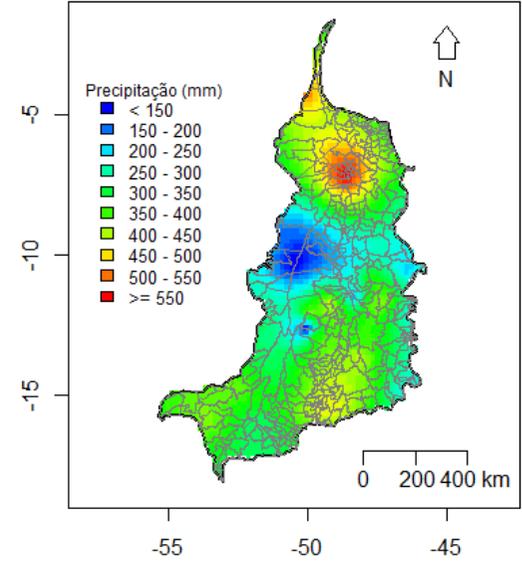
Mapa de previsão: fevereiro 2017



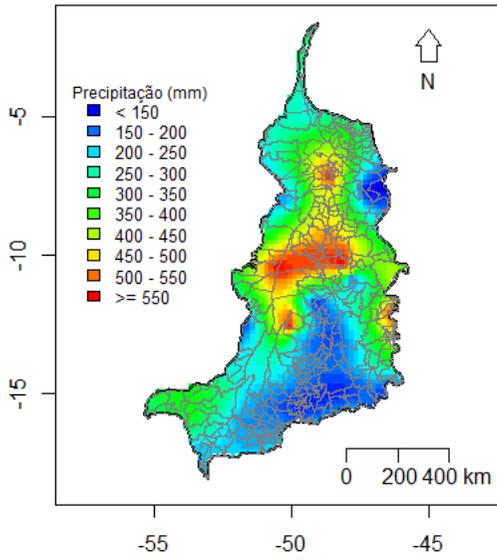
Mapa Observado: fevereiro 2017



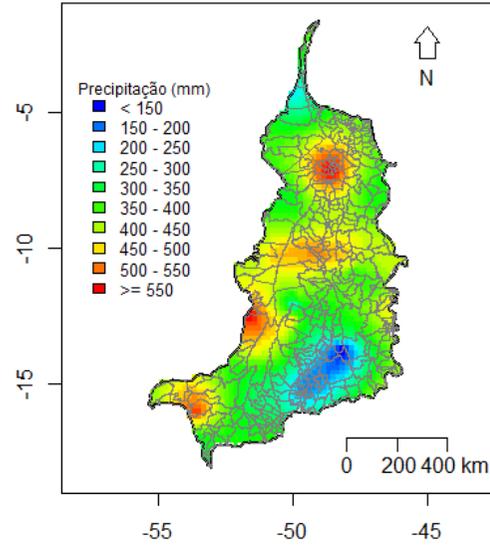
Previsões RN : fevereiro 2017



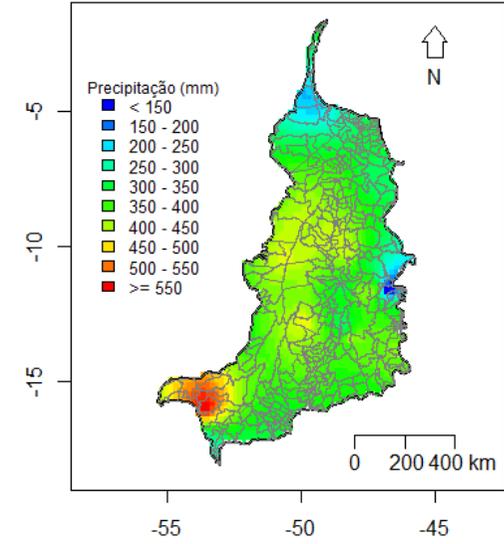
Mapa de previsão: Março 2017



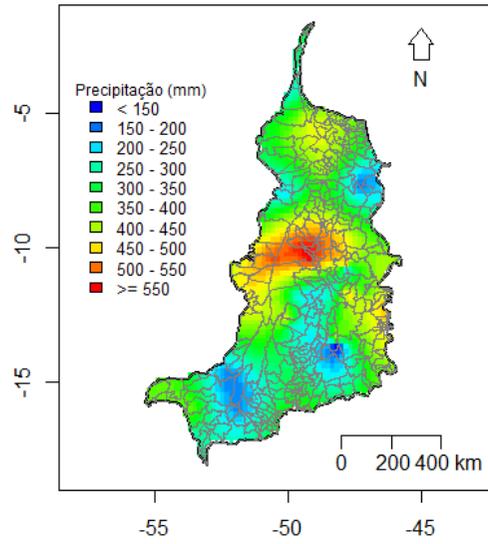
Mapa Observado: Março 2017



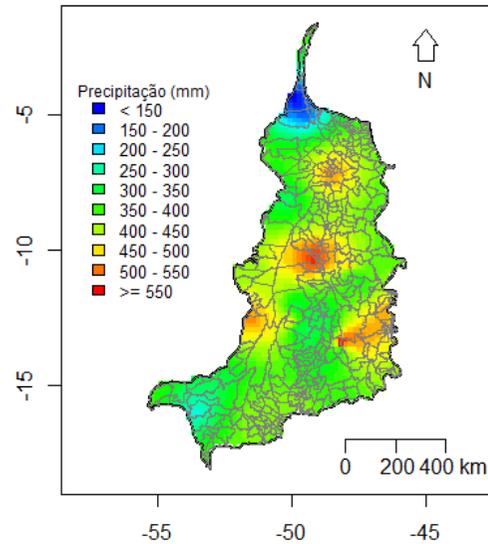
Previsões RN: Março 2017



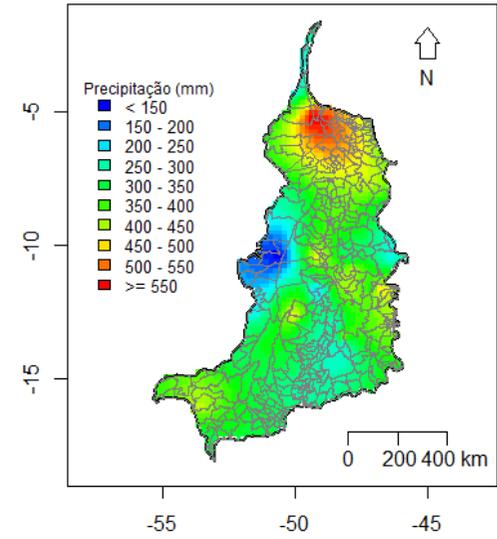
Mapa de previsão: Abril 2017



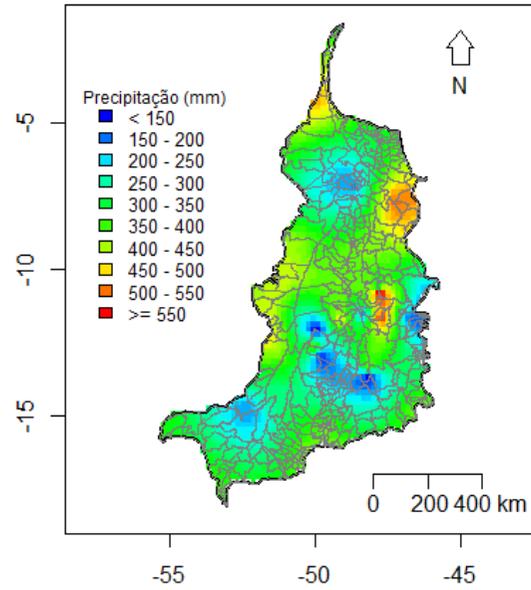
Mapa Observado: Abril 2017



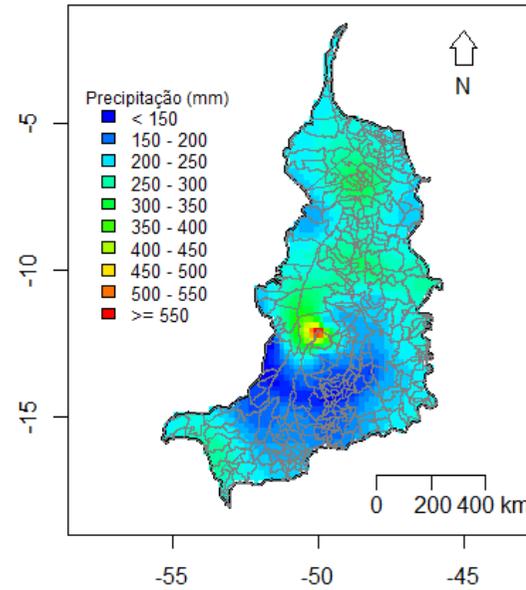
Previsões RN: Abril 2017



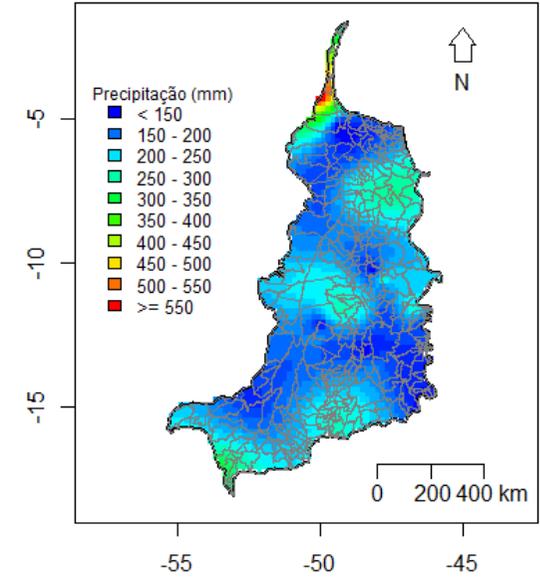
Mapa de previsão: Maio 2017



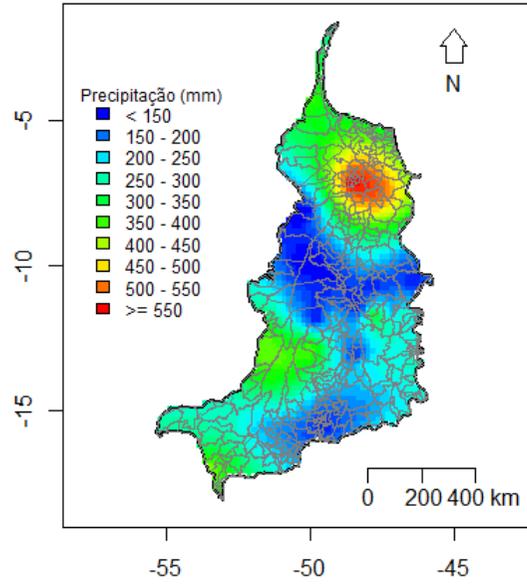
Mapa Observado: Maio 2017



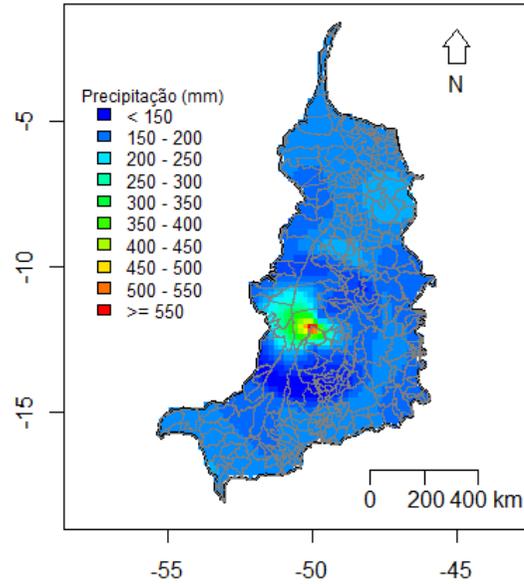
Previsões RN: Maio 2017



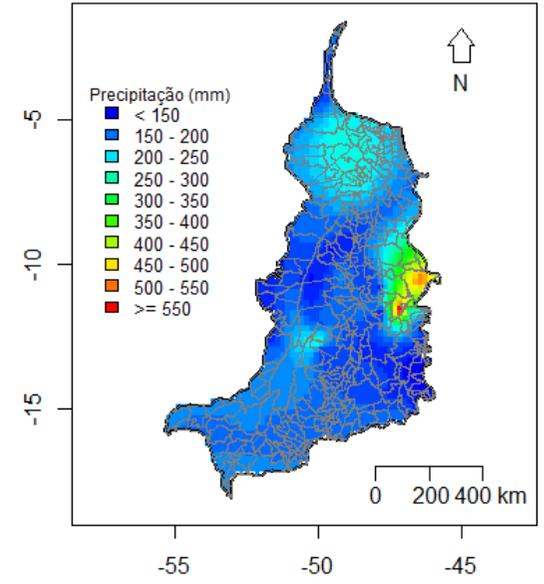
Mapa de previsão: Junho 2017



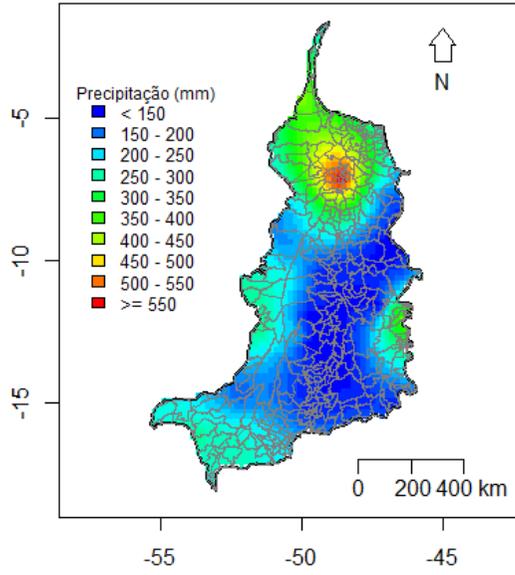
Mapa Observado: Junho 2017



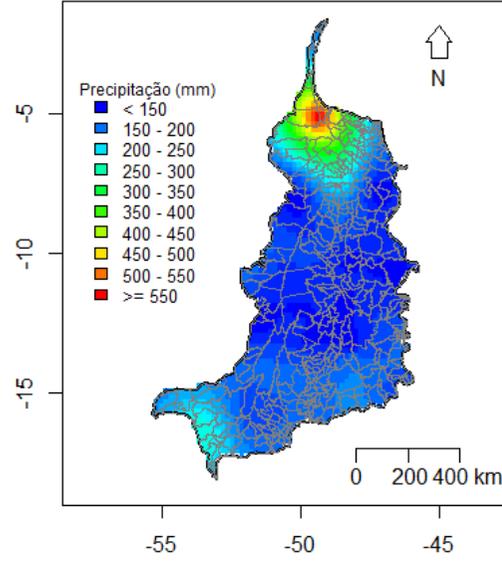
Previsões RN: Junho 2017



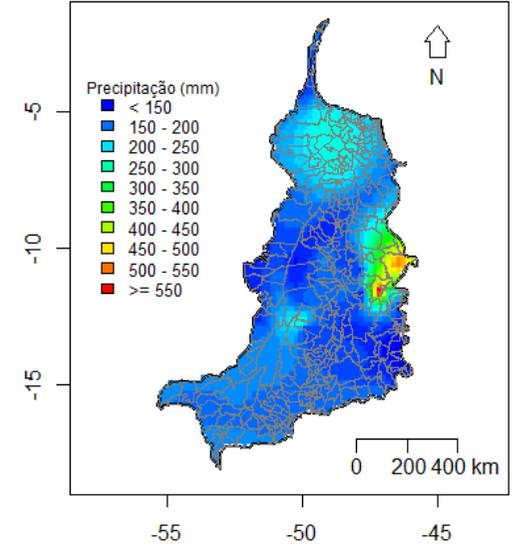
Mapa de previsão: Julho 2017



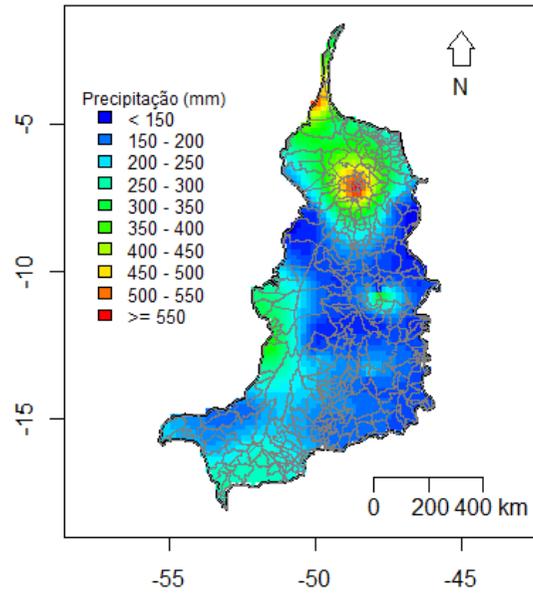
Mapa Observado: Julho 2017



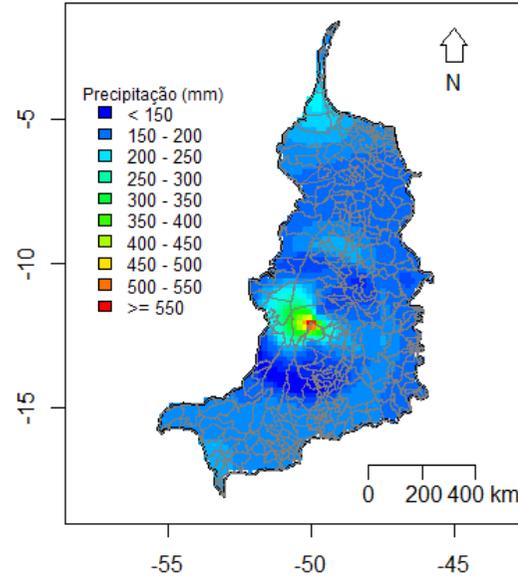
Previsões RN: Junho 2017



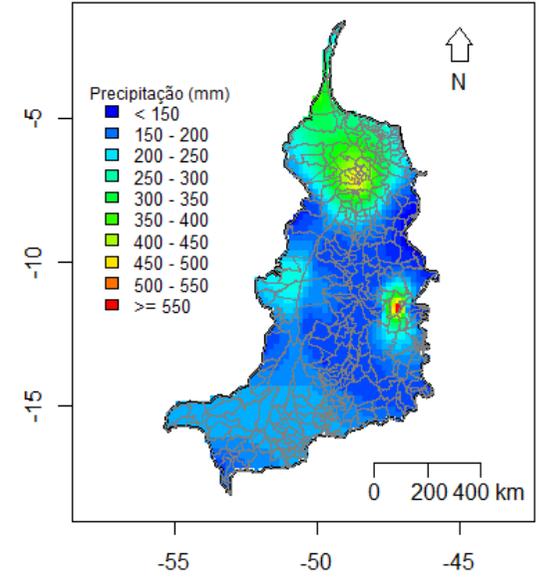
Mapa de previsão: Agosto 2017



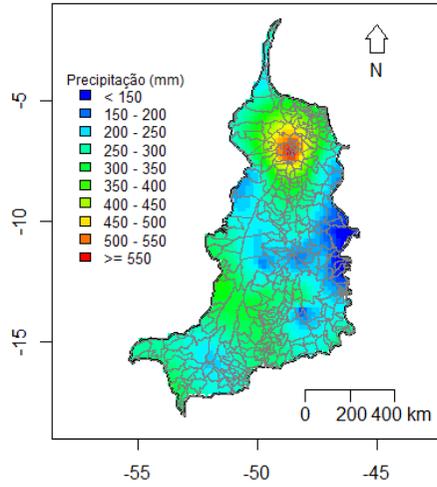
Mapa Observado: Agosto 2017



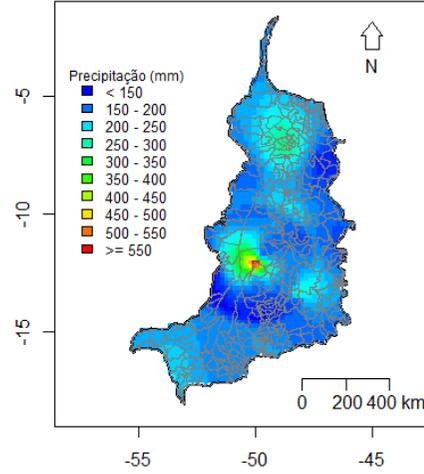
Previsões RN: Agosto 2017



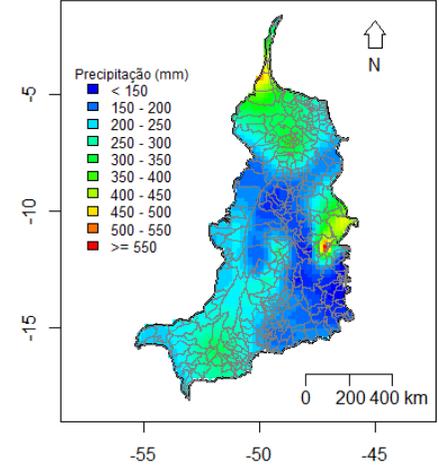
Mapa de previsão: Setembro 2017



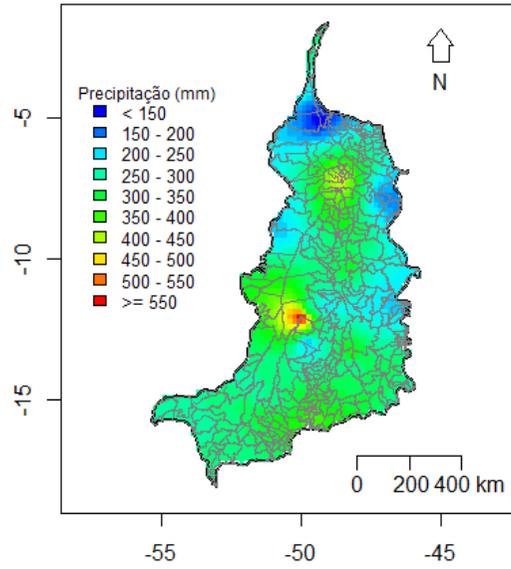
Mapa Observado: Setembro 2017



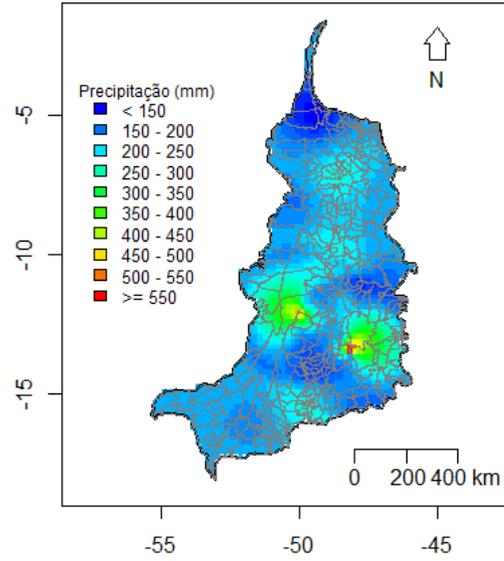
Previsõwa RN: Setembro 2017



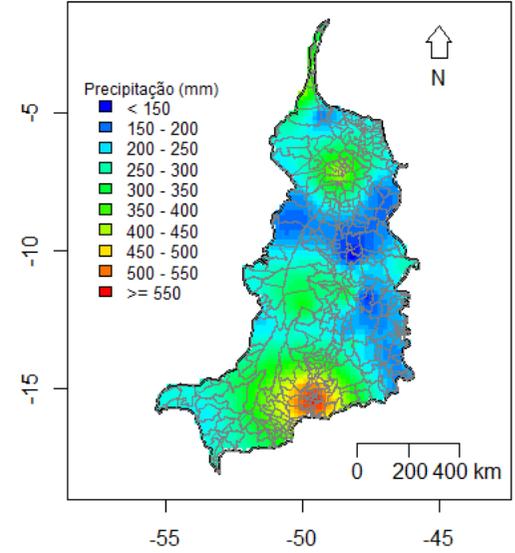
Mapa de previsão: Outubro 2017



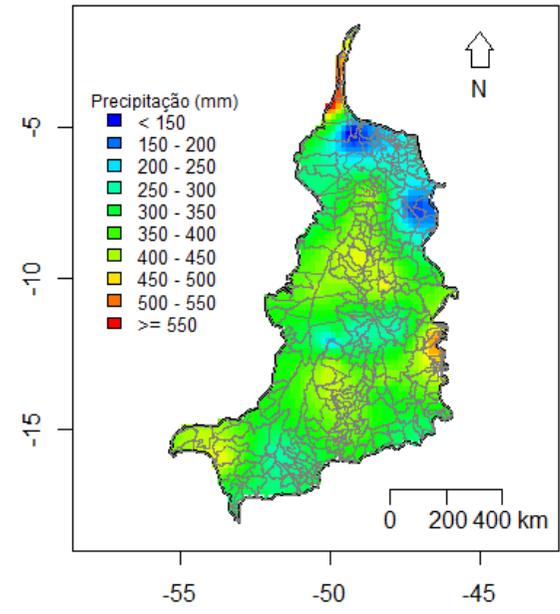
Mapa Observado: Outubro 2017



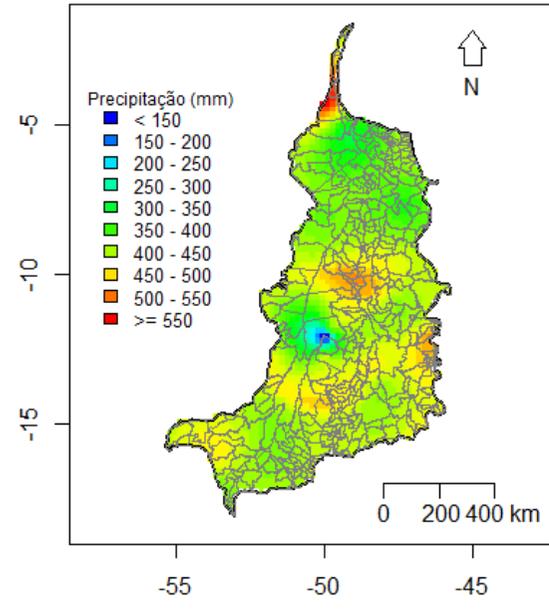
Previsões RN: Outubro 2017



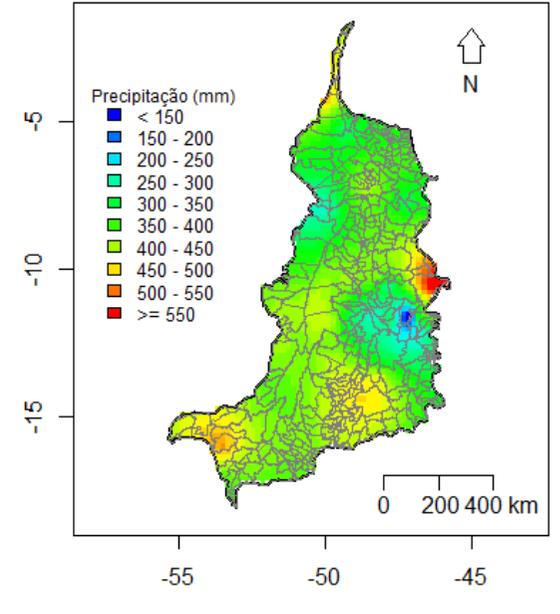
Mapa de previsão: Novembro 2017



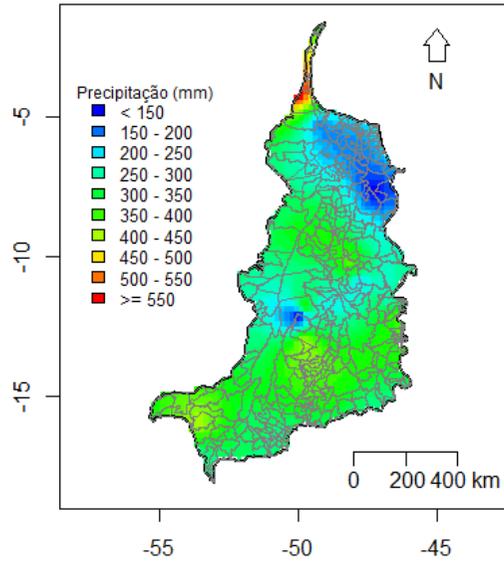
Mapa Observado: Novembro 2017



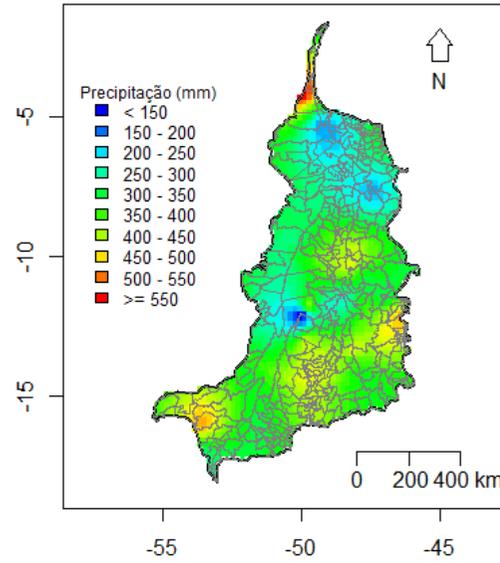
Previsões RN: Novembro 2017



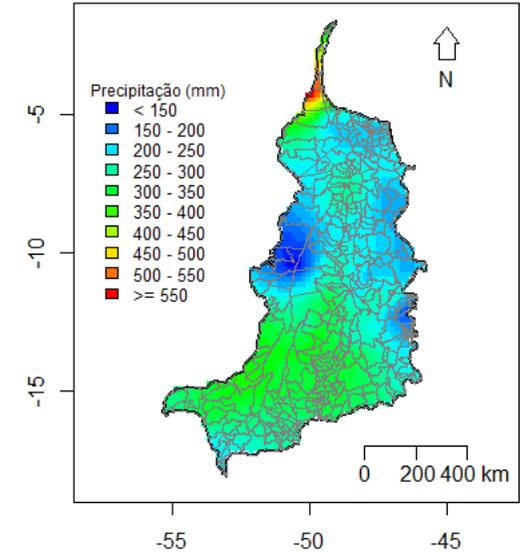
Mapa de previsão: Dezembro 2017



Mapa Observado: Dezembro 2017



Previsões RN: Dezembro 2017



Fonte: Elaborado pelo autor.

Tabela 6 - Resultados para previsões com métodos BJ e RN. Ano de 2017

Mes	Box-Jenkins (BJ)			Redes Neurais (RN)			Observados	
	Mediana	Media	RMSE	Mediana	Media	RMSE	Mediana	Media
JAN	288.6	288.7	60.92	328.4	328.3	101.85	223.2	234.7
FEV	247.7	247.8	52.68	181.50	183.10	115.38	270.3	271.0
MAR	230.0	229.9	23.27	205.80	206.90	48.41	234.5	238.1
ABR	128.60	128.20	16.37	98.49	98.56	50.41	134.9	136.2
MAI	46.820	46.920	17.92	46.02	46.33	27.57	37.20	39.57
<i>JUN</i>	12.740	12.800	17.54	19.33	20.30	25.96	5.50	20.06
JUL	8.159	8.145	4.53	25.75	26.38	27.78	2.00	4.294
AGO	13.520	13.830	14.38	17.41	18.45	21.36	3.80	14.52
SET	51.070	51.530	21.54	58.290	58.790	35.16	37.50	54.14
OUT	122.00	122.40	19.59	121.60	122.10	38.12	128.6	144.7
NOV	209.4	209.2	14.23	212.10	211.20	29.05	214.0	209.9
DEZ	268.6	268.7	18.33	238.30	239.90	56.28	270.4	274.2

Fonte: Elaborado pelo autor.

3.4 Conclusão

Previsões com uso de séries temporais são obtidas com muita frequência com uso de modelos de Box-Jenkins e, mais recentemente tem-se ampliado com utilização de redes neurais nesta tarefa. Boas previsões de uma série temporal, principalmente para séries com alta variabilidade, como nas séries analisadas, não é uma tarefa fácil.

Os métodos estatísticos de séries temporais, entre eles o de Box-jenkins, são limitados pelos pressupostos subjacentes do modelo, como a estacionariedade, sazonalidade ou duração da série temporal. Modelos de redes neurais, ao contrário, não tem as limitações dos modelos estatísticos incluindo o ruído, amostragem irregular ou tamanho da série temporal, mas podem apresentar outras desvantagens como o tempo computacional e dificuldade de fornecer explicações sobre os dados.

Em geral, os trabalhos que se propõe a comparar a performance de previsões e ajuste de modelos com uso de redes neurais e modelos de Box-Jenkins utilizam medidas como RMSE e MAPE e MAE. Todas essas medidas são baseadas em valores médios, ou seja, consideram um único valor para representar cada conjunto de resultados. Sabe-se que médias são influenciadas por valores extremos. Neste sentido, a média so representa adequadamente conjuntos com distribuições simétricas, ou seja, sem a presença de valores extremos.

O RMSE por exemplo, apresenta a tendência de penalizar grandes erros de previsão mais do que outras medidas. Por isso se considera a medida mais apropriada para determinar os métodos que apresentam grandes erros. O ideal, entretanto, seria comparar cada valor de previsão dos dois métodos. Isso pode ser feito por meio de teste de hipóteses ou intervalos de confiança. Neste sentido, este trabalho mostra que, previsões obtidas por redes neurais, com o método MLP, e modelos de Box-Jenkins não apresentam diferenças estatisticamente significativas.

A grande variabilidade nos dados torna as previsões uma tarefa mais difícil. Os resultados mostraram mapas de previsão com padrão aproximado de mapas de valores observados, entretanto, com erros relativamente grandes. Entre as sugestões para melhorar os mapas de previsões, isto é, mapas com menores erros, incluem a consideração da sazonalidade, ou seja, a realização de mapas em períodos diferentes de chuvas (chuvoso e menos chuvoso) e a inclusão de co-variáveis que sejam correlacionadas com as ocorrências de chuvas, como temperatura, umidade e outras. Neste caso, seria necessária a utilização de modelos de séries temporais multivariados e redes neurais com múltiplas entradas.

4 TENDÊNCIAS HIDROCLIMÁTICAS E IMPLICAÇÕES NA AGRICULTURA IRRIGADA E PECUÁRIA

Resumo

As variações climáticas e hidrológicas influenciam as condições da qualidade de vida das pessoas, na geração de energia, no uso dos recursos hídricos, além das atividades agropecuárias, industriais, turísticas dentre outras. Espera-se que, com os estudos voltados às alterações dos parâmetros climáticos e hidrológicos ocorridos no passado seja possível compreender melhor as modificações que estão sendo registradas no presente, além de servir de elementos fundamentais para pesquisas que visem uma melhor averiguação do futuro comportamento da hidrologia numa determinada região. Neste trabalho foi estudado o comportamento de tendências das variáveis chuva e vazão na Bacia Hidrográfica Araguaia-Tocantins (BHAT) e relações com variáveis agropecuárias, mais precisamente as relacionadas a cultura temporária, que englobam milho e soja, por exemplo, e rebanhos bovinos. Pôde-se observar que, há uma tendência decrescente tanto nos níveis de chuva quanto de vazões na bacia sendo que, as taxas de decrescimento das vazões são maiores em relação às chuvas. Em geral, regiões da BHAT com baixa disponibilidade hídrica, apresentaram correlação espacial com cultura temporária e rebanho bovino. Houve ainda uma correlação espacial significativa entre o número de pivos centrais usados em regiões com baixa disponibilidade hídrica e as culturas temporárias (áreas plantadas). O Uso de mapas do *Índice Bivariado Local de Moran (Mapas LISA)* permitiu identificar locais em que ocorrem correlações positivas e negativas entre as variáveis hidroclimáticas e variáveis agropecuárias além de permitirem a identificação de regiões de transição.

Palavras-chave: Bacia Araguaia-Tocantins. Tendências. Análise exploratória de dados espaciais. Índice Bivariado de Moran Global e Local.

4.1 Introdução

O crescimento demográfico brasileiro, associado com as mudanças no agronegócio reflete de maneira notável sobre o uso dos recursos hídricos.

A migração da população do campo para a cidade e a industrialização, além de exercerem significativa demanda das águas dos mananciais, também exigiram o crescimento do parque gerador de energia elétrica, que, por sua vez, implicou na necessidade de aproveitamentos hidrelétrico.

Com o aumento da população, maior produção de alimentos, o que veio encontrar na agricultura irrigada a técnica apropriado para satisfazer a essa demanda. Denomina-se irrigação o conjunto de técnicas destinadas a deslocar a água no tempo ou no espaço para modificar as possibilidades agrícolas de cada região. A irrigação visa a corrigir a distribuição natural das chuvas (CHRISTOFIDIS, 1999).

O aumento do custo da terra, aliado ao considerável capital necessário à exploração agrícola, não permite mais que a produção final dependa da ocorrência ou não de um regime de precipitação adequado. Assim sendo, a nova tendência do meio empresarial agrícola tem sido a de aumento do interesse pela prática da irrigação, que, além de reduzir riscos, proporciona outras vantagens significativas ao produtor.

A intensificação da prática da irrigação é uma opção estratégica de grande alcance para aumentar a oferta de produtos destinados ao mercado interno, consolidar a afirmação comercial do Brasil num mercado internacional altamente competitivo e melhorar os níveis de produtividade, renda e emprego no meio rural.

A ênfase neste trabalho é direcionada ao estudo de tendências de variáveis hidroclimáticas (chuvas e vazões) e suas relações com variáveis agropecuárias (cultura temporária e rebanho bovino) na BHAT considerando o aspecto espacial.

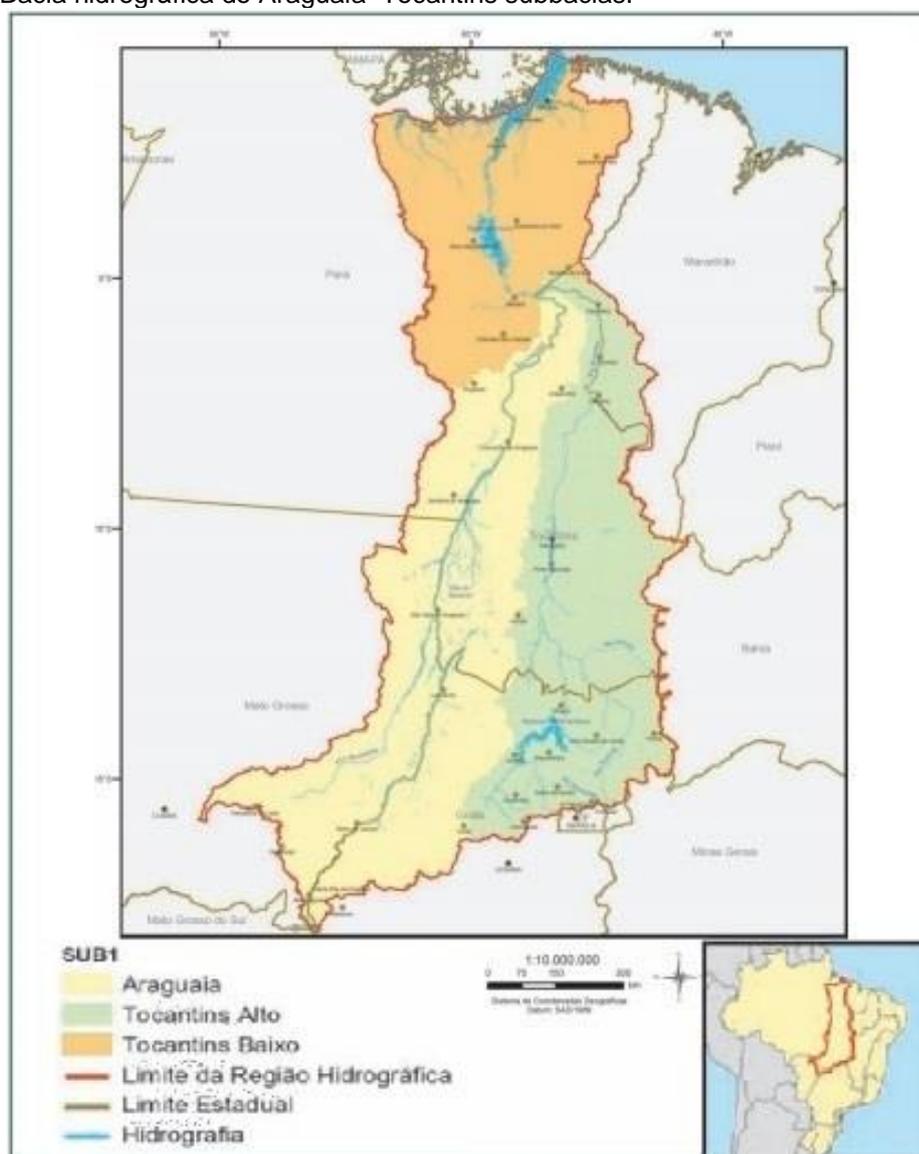
Foram utilizadas ferramentas da geoestatística na construção de mapas e da estatística exploratória de dados espaciais (AEDE) no estudo de relações espaciais das variáveis.

4.2 Material e Métodos

4.2.1 Área de estudo

A região hidrográfica do Araguaia–Tocantins, mostrada na Figura 31, possui uma área de 921.921 km², equivalendo a aproximadamente 10,8% do território brasileiro. De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), em 2010 a referida região apresentava uma população de 8.610.721 habitantes, sendo 76% ocupando áreas urbanas, caracterizando uma densidade demográfica de 9,3 hab./km², portanto, inferior à do país que era de 22,4 hab./km² (IBGE, 2010).

Figura 31 - Bacia hidrográfica do Araguaia–Tocantins subbacias.



Fonte: (MMA, 2006).

4.2.2 Geoestatística

A Teoria das variáveis regionalizadas é aplicada no modelamento da estrutura de correlação com uso do variograma (JOURNEL; HUIJBREGTS, 1978). Cada observação é considerada a realização de uma variável regionalizada $Y(s)$, que depende das medidas em localizações, s , determinadas. A variabilidade entre quaisquer duas quantidades $Y(s)$ e $Y(s + h)$, em dois pontos s e $s + h$ separados por o vetor h , pode ser caracterizado pelo variograma. O variograma $\gamma(h)$ em função do vetor de separação h , mas independente de s , é definido como metade da esperança matemática das diferenças quadradas de $Y(s)$ e $Y(s + h)$:

$$\gamma(h) = \frac{1}{2}E[Y(s)-Y(s+h)]^2 \quad (20)$$

onde E representa a esperança matemática. O variograma pode ser estimado substituindo-se a esperança pelo valor médio, tomado para todos os pares de diferentes observações (y_i, y_{i+h})

$$\hat{\gamma}(h) = \frac{1}{2n(h)} \sum_i^{n(h)} (y_i - y_{i+h})^2 \quad (21)$$

onde $n(h)$ é o numero de pares (y_i, y_{i+h}) separados pelo vetor h e o índice i indica as diferentes localizações espaciais das observações.

Os principais modelos de variograma são caracterizados por dois parâmetros (JOURNEL; HUIJBREGTS, 1978): o patamar (*sill*) e o alcance. O patamar é o valor limite do modelo de variograma $g(h)$ conforme h aumenta. O alcance indica a distância em que devem existir dependências espaciais e é medido pela distância em que o variograma atinge o seu valor do patamar. Além do alcance, as observações não são mais correlacionadas espacialmente. No outro extremo do variograma, $\gamma(0) = 0$ por definição.

No entanto, em muitos estudos, $g(h)$ não tende a zero quando h se aproxima de zero. Esta descontinuidade do variograma na origem é chamado o efeito de pepita e é causado por variações não espaciais, como erros de medição, e variações

espaciais que ocorrem em distâncias muito pequenas. Quando o patamar é igual ao efeito pepita (efeito pepita puro) a indicação é de ausência total de correlação espacial.

Existem vários modelos que podem ser usados para ajustamento de variogramas experimentais. Um dos mais utilizados é o modelo de variograma esférico, definido como:

$$g(h) = \begin{cases} C_0 h = 0 \\ C_0 + C \left(\frac{3a}{2h} - \frac{a^3}{2h^3} \right) & 0 < h \leq a \\ C_0 + C & h > a \end{cases} \quad (22)$$

onde C_0 é o efeito pepita, a é o alcance e C é o patamar. Os parâmetros do modelo são determinados iterativamente por meio do ajuste do modelo aos resultados da análise do semivariograma amostral. O modelo resultante é uma medida da variabilidade da amostra e, assumindo que as amostras são representativas, uma medida da variabilidade da variável regionalizada.

Para que a técnica geoestatística de mapeamento (krigagem) seja aplicada é necessário que a variável regionalizada seja estacionária (média constante) e que o variograma exista. Essa condição é chamada de hipótese intrínseca. A krigagem usa uma combinação linear das observações na estimativa de valores não amostrados e com erro com variância mínima. Desse modo, fornece o chamado melhor preditor linear não-viesado (BLUP) da variável regionalizada (STEIN; CORSTEN, 1991). A krigagem estima uma variável estocástica, em vez de um parâmetro, como a esperança de uma observação. A estimativa é geralmente associada a uma incerteza. A informação utilizada para a estimativa considera as observações e o modelo de variograma.

Com uso do *software* R (versão 3.1.1) foram criados mapas das distribuições espaciais de chuvas e vazões. Para a krigagem (interpolação), foi utilizada a rotina *geoR* a qual utiliza um algoritmo de krigagem ordinária. É estimado um valor da variável regionalizada (Y) num determinado local não amostrado (s_0) com base num número (p) de observações ao redor ou na vizinhança. O preditor T para o valor $Y(s_0)$ é uma combinação linear das p observações y_1, \dots, y_p :

$$T = \sum_{i=1}^p \lambda_i Y_i \quad (23)$$

Os p pesos λ , são calculados de tal forma que T é não tendencioso e que a variância do erro de previsão é mínima. Este procedimento requer informações sobre o variograma da variável regionalizada. Uma descrição do procedimento de cálculo pode ser encontrada em (JOURNAL; HUIJBREGTS, 1978; CRESSIE, 1991).

4.2.3 Modelos de tendência

O comportamento médio de variáveis ao longo do tempo pode ser modelado por modelos de tendência linear do tipo

$$y = \beta_0 + \beta_1 t + \varepsilon, \quad (24)$$

onde y é a variável resposta (nível de chuva ou vazão, por exemplo), t , o tempo (anos, meses, dias), β_0 é o intercepto da reta, β_1 é a inclinação da reta (coeficiente angular), que pode indicar a taxa de crescimento (ou decrescimento) da variável resposta e ε , o erro do modelo.

4.2.4 Análise exploratória de dados espaciais (AEDE)

A análise Exploratória de Dados Espaciais pode ser utilizada sempre que as informações estiverem espacialmente localizadas e quando for preciso levar em conta, explicitamente, a importância do arranjo espacial dos fenômenos na análise ou na interpretação de resultados desejados (BAILEY; GATTREL, 1995).

A AEDE avalia se há alguma forma de associação espacial entre variáveis dentro de determinadas áreas geográficas. Segundo Almeida (2012), o primeiro passo no estudo de AEDE é testar a hipótese de que os dados espaciais sejam distribuídos aleatoriamente. Intuitivamente, aleatoriedade espacial significa que, os valores de um atributo numa região não dependem dos valores deste ou de outros atributos nas regiões vizinhas.

A dependência espacial pode ser analisada em termos globais, utilizando-se o índice Global de Moran, ou em termos locais, empregando-se o índice de Moran local.

Na análise global, ter-se-á um resultado da associação espacial dos dados de uma região como um todo. Na análise local, serão obtidas estatísticas que indicam a dependência de cada localidade em relação à situação média de uma vizinhança definida a priori (ANSELIN, 1995).

A estatística mais difundida para medida de dependência espacial é o *Índice Global de Moran*, que mede a autocorrelação espacial a partir do produto dos desvios em relação a média. É uma medida global da autocorrelação espacial, pois indica o grau de associação espacial presente no conjunto de dados. Para um processo estocástico e estacionário de segunda ordem, o índice global (univariado) de Moran é formalmente definido como:

$$I_{kl} = \frac{z_k' W z_l'}{z_k' z_k} \quad \text{Ou} \quad I_{kl} = \frac{z_k' W z_l'}{n} \quad (25)$$

onde $z_k = [Y_k - \mu_k] / \sigma_k$ é a variável em estudo padronizada (com média, $\mu = 0$ e desvio padrão, $\sigma_k = 1$) em uma localização particular k . $z_l = [Y_l - \mu_l] / \sigma_l$ é, da mesma forma, a variável em outra localização l (onde $k \neq l$).

A variável de ponderação W é uma matriz de continuidade. Se a zona k é adjacente (toca) à zona l , a interação recebe um peso igual a 1. Caso contrário, a interação recebe um peso igual a zero. E n é o número de observações. No presente trabalho, as análises são referentes à precipitação pluviométrica e ao rendimento médio da mandioca a nível municipal, tem-se que Z (chuva ou rendimento médio) é um vetor de n (municípios) observações da variável de interesse. Segundo Anselin (1995), a matriz W conterá as informações referentes à dependência espacial entre as regiões.

De uma forma geral, o índice de Moran presta-se a um teste cuja hipótese nula é de independência espacial. Nesse caso, seu valor seria zero ou próximo de zero. Significaria que os valores de I variam aleatoriamente no espaço, sem nenhuma estruturação espacial. Valores de I maiores (ou menores) do que o valor esperado $E(I) = -1/(n-1)$ demonstram a existência de autocorrelação positiva (ou negativa). Se I for positivo significa que, em relação aos valores de determinada região, os valores de regiões vizinhas tendem ser semelhantes (altos ou baixos), enquanto se I for negativo

os valores de regiões vizinhas tendem a ser diferentes. Quanto mais próximo de 1 (ou de - 1), mais forte é a autocorrelação espacial (UPTON et al., 1985; WALLER et al., 2004).

Sua generalização multivariada (Índice Bivariado de Moran) pode ser definida como:

$$I_{kl}^i = z_k^i W_{ij} z_l^j \quad (26)$$

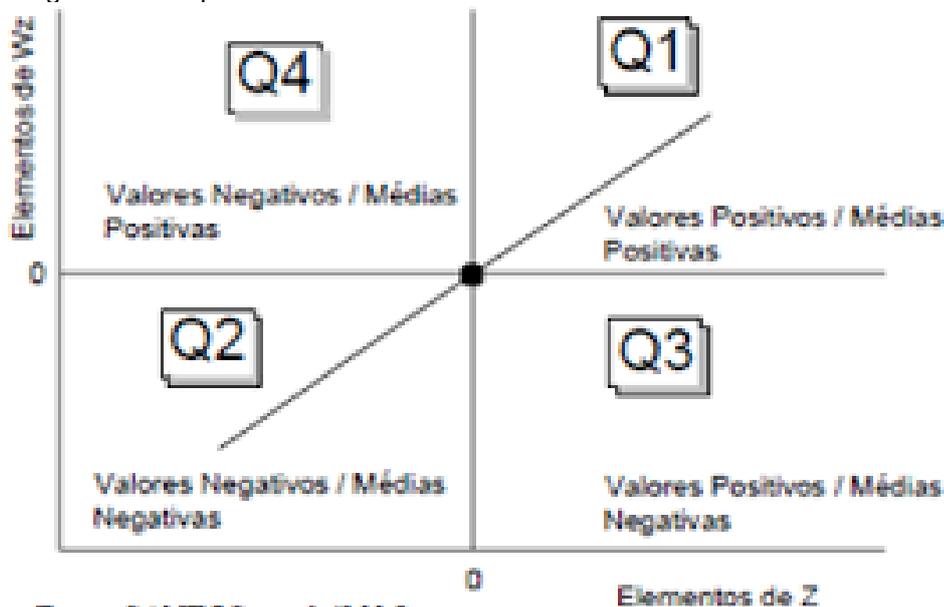
Com as mesmas notações usadas anteriormente. Esta estatística fornece uma indicação do grau de associação linear (positiva ou negativa) entre o valor de uma variável em dada localidade i e a média de uma outra variável nas localidades vizinhas, l .

Depois de calculado o índice de Moran, é importante estabelecer sua validade estatística. Ou seja, é necessário medir se os valores aferidos possuem uma correlação espacial significativa. Para tanto, é preciso associar ao índice uma distribuição estatística, sendo comum relacionar a estatística do teste à distribuição normal.

Uma das formas de interpretar a estatística I de Moran é por meio do diagrama de dispersão de Moran. No eixo abscissas (x) são colocados os valores da variável padronizada observados em determinadas regiões. No eixo das ordenadas são os valores das médias dos valores padronizados das localidades vizinhas (Wz) a cada variável, no caso univariado ou os valores de outras variáveis padronizadas observadas nas regiões vizinhas, no caso bivariado. Em outras palavras, é uma representação do coeficiente de regressão e permite visualizar a correlação linear entre z e Wz através do gráfico de duas variáveis.

No caso específico da estatística I de Moran tem-se o gráfico de Wz e z . Portanto, o coeficiente I de Moran será a inclinação da curva de regressão de Wz contra z e esta inclinação indicará o grau de ajustamento. A autocorrelação positiva é reforçada com a inclinação crescente da reta de regressão e o agrupamento das unidades no primeiro e terceiro quadrante, por outro lado, quando existe autocorrelação espacial negativa a reta é decrescente e as unidades tendem a se agrupar em sua grande maioria no segundo e quarto quadrante na Figura 32 (ALMEIDA, 2012).

Figura 32 - Diagrama de dispersão de Moran bivariado.



Fonte: Elaborado pelo autor.

No primeiro quadrante encontra-se o agrupamento alto-alto (AA), ou seja, as unidades espaciais pertencentes a essa aglomeração exibem regiões com valores altos da variável de interesse plotada no eixo das abscissas, rodeados regiões que apresentam valores também altos na outra variável de interesse, plotados no eixo das ordenadas. O agrupamento baixo-alto (BA) representa uma unidade espacial qualquer com um baixo valor da variável de interesse, mas é circundada por unidades espaciais com alto valor de outra variável, essa situação é demonstrada no segundo quadrante.

O agrupamento baixo-baixo (BB) refere-se às unidades espaciais onde são observados valores baixos da variável de interesse circundados por unidades espaciais que ostentam valores também baixos na outra variável, representado pelo terceiro quadrante. Um agrupamento alto-baixo (AB) diz respeito a um cluster no qual uma unidade espacial qualquer com um alto valor da variável de interesse são vizinhos de unidades espaciais com um baixo valor, estando situado no quarto quadrante (Figura 32).

As regiões que estão localizadas nos quadrantes AA e BB apresentam autocorrelação espacial positiva, ou seja, estas regiões formam *clusters* de valores similares. Por outro lado, os quadrantes BA e AB apresentam autocorrelação espacial

negativa, ou seja, estas regiões formam clusters com valores diferentes, conhecidas como regiões de transição.

Os indicadores globais de autocorrelação espacial fornecem um único valor como medida da associação espacial para todo o conjunto de dados. A hipótese testada é a de que não existe correlação espacial. Esse índice é útil na caracterização da região de estudo como um todo, mas, quando se trata de um grande número de áreas, é possível que ocorram vários regimes de associação espacial e que apareçam máximos locais de autocorrelação espacial, em que a dependência espacial é ainda mais pronunciada. Ou seja, a estatística global do *I de Moran*, segundo Perobelli *et al.* (2005), pode esconder padrões locais de autocorrelação espacial. Por isso é importante avaliar o padrão local de autocorrelação espacial a fim de se obter um maior detalhamento dos resultados. Uma maneira de fazê-lo é utilizar indicadores locais de associação espacial (LISA) que possam ser associados a diferentes localizações de uma variável distribuída espacialmente (DRUCK *et al.*, 2004).

Um dos LISA mais difundidos é o índice Local de Moran, onde as contribuições individuais de cada observação podem ser estimadas através da equação abaixo:

$$I_i = Z_i \frac{\sum_{j=1}^n W_{ij} Z_j}{\sum_{j=1}^n Z_j^2} \quad (27)$$

Onde $z_i = [Y_i - \mu_i] / \sigma_i$ é a variável em estudo padronizada (com média, $\mu = 0$ e desvio padrão, $\sigma_k = 1$) em uma localização particular i . $z_j = [Y_j - \mu_j] / \sigma_j$ é, da mesma forma, a variável em outra localização j (onde $i \neq j$).

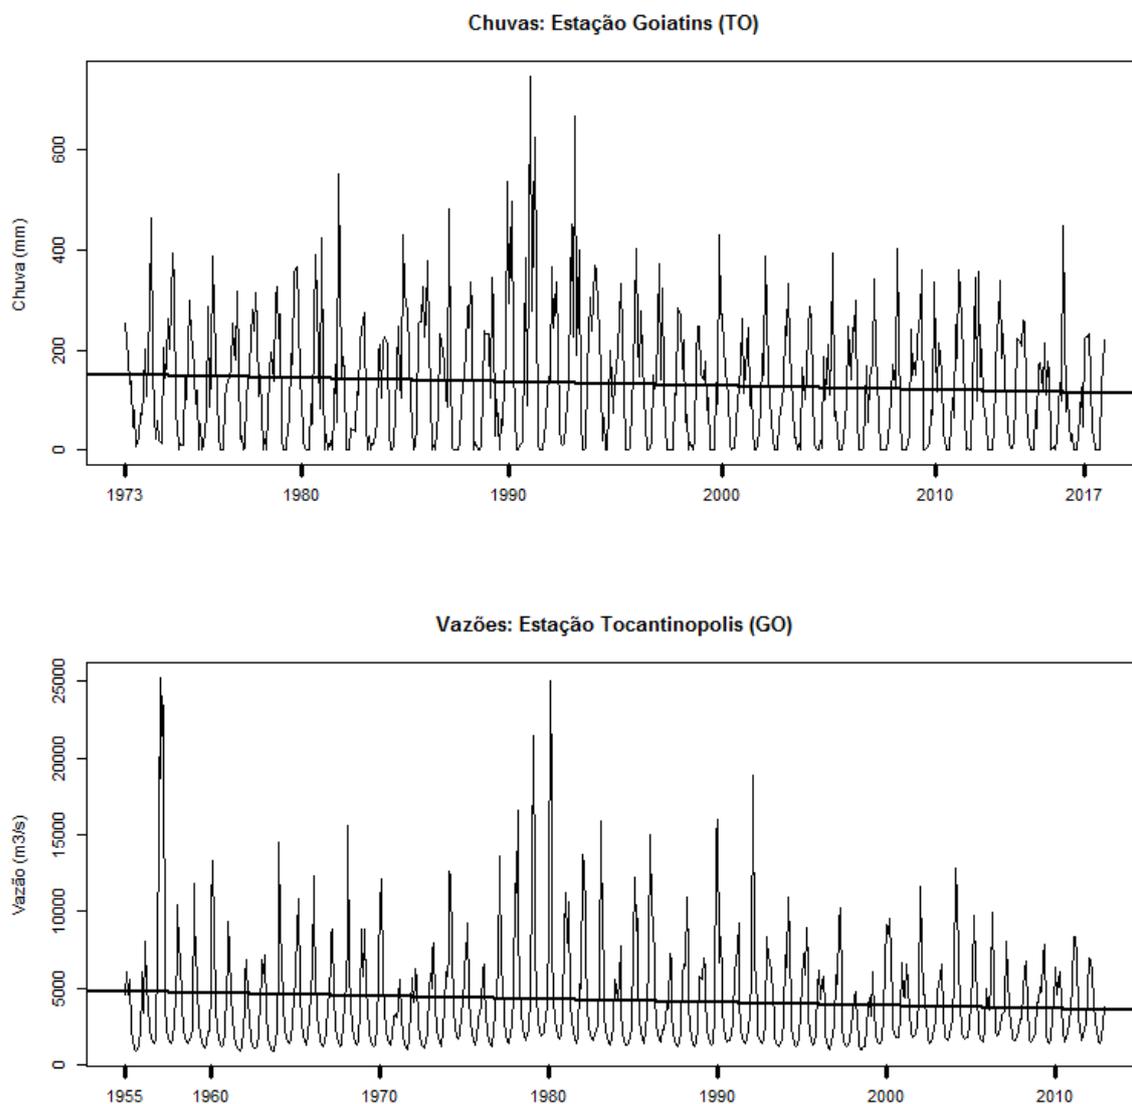
Uma vez determinada a significância estatística do índice local de Moran, é útil gerar um mapa, conhecido como mapa LISA, que indique as regiões que apresentam correlação local significativamente diferente daquela do resto dos dados. Essas regiões podem ser vistas como “bolsões” de não estacionariedade, pois são áreas com dinâmica espacial própria e que merecem análise detalhada.

4.3 Resultados e Discussão

Foi feito um estudo nas séries históricas de vazão e chuvas na Bacia Hidrográfica Araguaia-Tocantins, para avaliação dos níveis de vazão e chuva ao longo do tempo. Observou-se uma tendência de decréscimo na grande maioria das séries de chuva e vazão. Na identificação das tendências foi utilizado um modelo de tendência linear (eq. 5). São apresentados os resultados para duas séries mais longas no tempo, mostradas na Figura 33 e Tabela 7: a) série de chuvas da estação Goiatins (TO) no período de 1972 a 2017 (46 anos) e b) série de vazões da estação Tocantinópolis (TO) de 1955 a 2010 (58 anos).

Observa-se que as tendências para a série de chuvas (estação Goiatins) e vazões (estação Tocantinópolis), apresentaram um decréscimo significativo ($p < 0,0465$ e $p < 0,0114$) respectivamente. Neste caso, pode-se concluir que as chuvas, nesta estação, sofrem, em média, uma diminuição de 0,07 mm por mês, enquanto na estação de Tocantinópolis o decréscimo é de 1,69 mm por mês, em média (Tabela 7).

Figura 33 - Série de chuvas (Goiatins) e vazões (Tocantinópolis) com linhas de tendência



Fonte: Elaborado pelo autor.

Tabela 7 - Modelos de tendência linear ($y = \beta_0 + \beta_1 X + \varepsilon$)

Série	β_0	β_1	$t(\beta_1)$	$Prob(\beta_1) > t$
Goiatins	150.62	-0.07	-1.995	0.0465 *
Tocantinópolis	4823.41	-1.69	-2.536	0.0114 *

Fonte: Elaborado pelo autor.

β_0 : constante; β_1 : coeficiente angular; ε : erro

* : Significativo a 5%

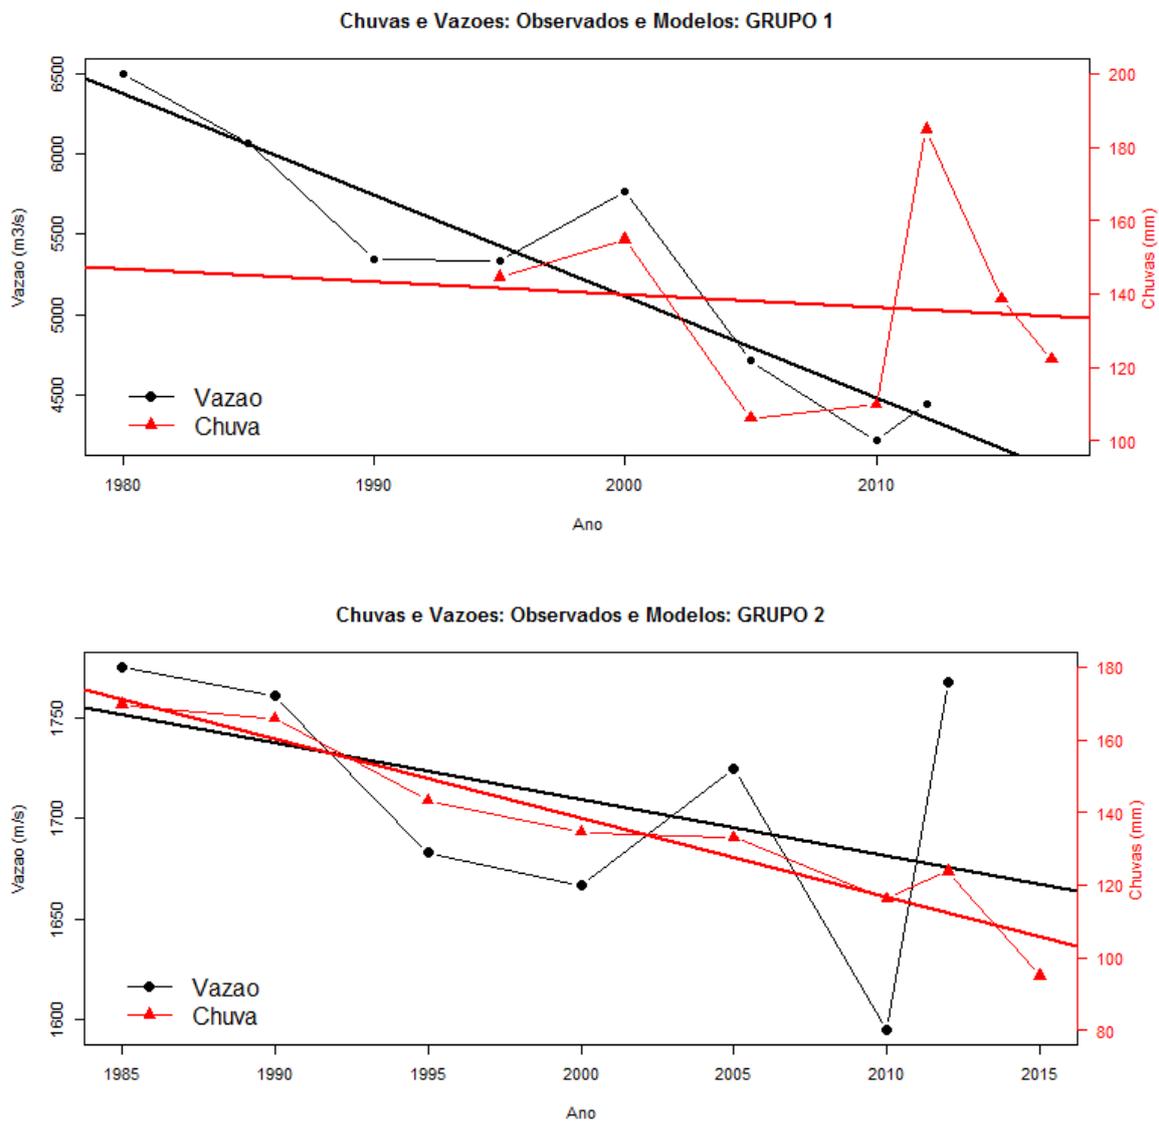
Na avaliação dos níveis de chuva e vazão em toda a bacia, foram consideradas inicialmente, as estações localizadas nas regiões dos 4 grupos que foram definidos na caracterização da bacia quando se usou os resultados de chuva e vazão conjuntamente, no estudo realizado neste trabalho, no capítulo 2.

Para as regiões pertencentes aos grupos 1 e 2, com maior disponibilidade hídrica, foram utilizadas as estações de chuva de Itupiranga no período de 1995 a 2017 (Grupo 1) e estações de Goiantins e Ananás no período de 1975 a 2015 (Grupo 2) e as estações de vazão de Descarreto e Tocantinópolis no período de 1975 a 2012 (Grupo 1) e estações de Monte Lindo no período de 1985 a 2012 e Pedra Cherosa no período de 1975 a 2012 (Grupo 2).

Para as regiões dos grupos 3 e 4, com menor disponibilidade hídrica foram utilizadas para chuva 16 estações (Anexo 1) no período de 1975 a 2015 (Grupo 3) e 11 estações (Anexo 1) no período de 1975 a 2015 (Grupo 4). Para vazão foram utilizadas sete estações (Anexo 2) no período de 1975 a 2012 (Grupo 3) e 3 estações (Anexo 2) de vazão no período de 1975 a 2012 (Grupo 4). Em seguida, foram consideradas todas as estações de chuvas e vazões no período de 1975 a 2012, onde se avaliou o comportamento médio de chuvas e vazões para toda a bacia do Araguaia-Tocantins.

Na Figura 34 e Tabelas 8 e 9, para o Grupo 1, observa-se boa correlação entre chuva e vazão no período de 1995 a 2012, em que há informações de ambas as variáveis. A taxa de decréscimo ao longo do tempo é bem maior para as vazões ($63,16 \text{ m}^3/\text{s}$, em média ao ano) em relação as chuvas ($0,34 \text{ mm}$, em média ao ano). Ressalta-se, entretanto, que o período considerado para as chuvas (1995 a 2017) foi menor em relação ao período das vazões (1980 a 2015). O ano de 2005 apresentou a maior variação negativa, tanto para chuva como para vazão ($-31,47\%$ e $-22,39\%$, respectivamente) em relação à 2000. No Grupo 2, as vazões e correlações apresentam uma razoável correlação e as taxas de decréscimo entre vazão e chuva são muito próximas ($2,81 \text{ m}^3/\text{s}$, em média ao ano e $2,19 \text{ mm}$, em média ao ano, respectivamente). A maior variação negativa ocorreu, para a chuva, em 2015 ($30,43\%$) em relação à 2012 e, para a vazão, em 2010 ($9,15\%$) em relação a 2005.

Figura 34 - Médias anuais de chuvas (vermelho) e vazões (preto) e linhas de tendência. Bacia Araguaia-Tocantins. Grupos 1 e Grupo 2.



Fonte: Elaborado pelo autor.

Tabela 8 - Medias anuais (Grupo 1)

Ano	Chuva (mm)	Δ (%)	Vazão (m ³ /s)	Δ (%)
1980	NA		6498,77	
1985	NA		6066,33	-7,13
1990	NA		5348,4	-13,42
1995	144,53		5332	0,31
2000	154,8	7,11	5770,11	7,59
2005	106,08	-31,47	4714,44	-22,39
2010	109,8	3,5	4217,12	-11,79
2012	184,77	68,28	4442,74	5,08
2015	138,54	-25,02	NA	
2017	122,03	-11,92	NA	

Tabela 9 - Medias anuais (Grupo 2)

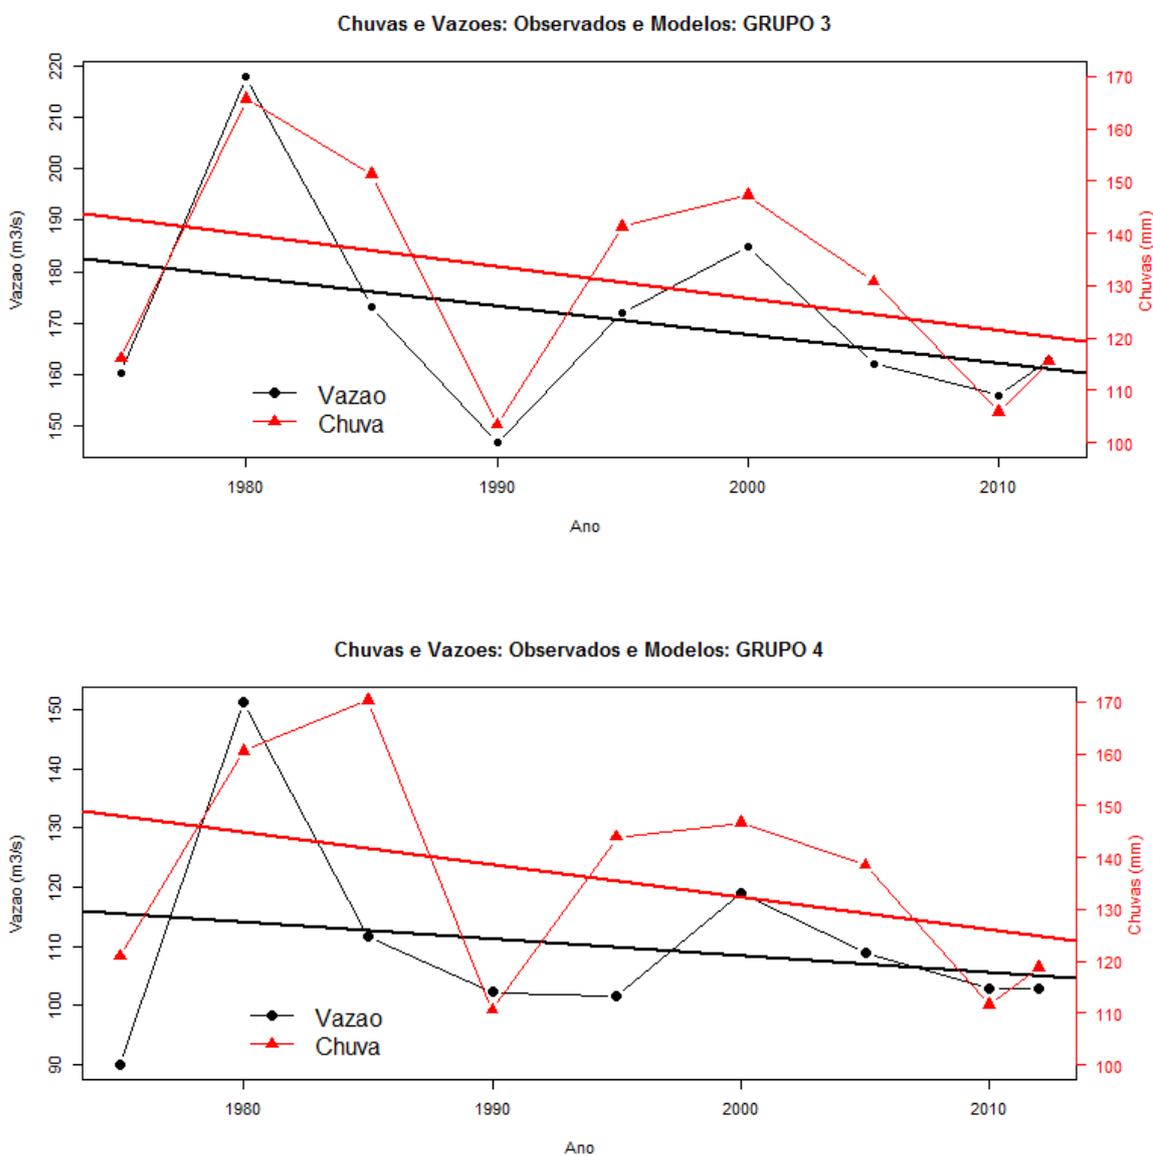
Ano	Chuva	Δ (%)	Vazao	Δ (%)
1985	169,7		1774,91	
1990	165,83	-2,33	1760,64	0,81
1995	143,18	-15,82	1682,86	-4,62
2000	134,57	-6,39	1666,84	0,96
2005	133,07	-1,13	1724,43	3,34
2010	116,22	-14,51	1594,74	-8,13
2012	123,72	6,07	1767,5	9,77
2015	94,85	-30,43	NA	

Fonte: Elaborado pelo autor.

*NA : sem informação. Em vermelho variações negativas

A Figura 35 e Tabelas 10 e 11 mostram os resultados para os grupos 3 e 4, de menor disponibilidade hídrica. O comportamento de chuvas e vazões no período de 1975 a 2012 são bem parecidos, tanto no grupo 3 quanto no grupo 4, indicando boa correlação. No Grupo 3, as taxas de decaimento de chuvas e vazões são bem próximas (em média, 0,61 mm ao ano e 0,56 m³/s ao ano, respectivamente). Nesse grupo, a maior variação negativa ocorreu, para a chuva, em 1990 (- 31,64%) em relação a 1985 e, para a vazão, em 1985 (- 20,51%) em relação a 1980. As chuvas e vazões nas regiões de maior disponibilidade hídrica (Grupos 1 e 2) apresentam maiores taxas de decréscimo em relação às regiões de menor disponibilidade hídrica (Grupos 3 e 4)

Figura 35 - Médias anuais de chuvas (vermelho) e vazões (preto) e linhas de tendência. Bacia Araguaia-Tocantins. Grupos 3 e 4.



Fonte: Elaborado pelo autor.

Tabela 10 - Medias anuais (Grupo 3)

Ano	Chuva	Δ (%)	Vazão	Δ (%)
1975	115,99		160,21	
1980	165,74	42,9	217,88	35,99
1985	151,29	-8,72	173,19	-20,51
1990	103,43	-31,64	146,82	-15,23
1995	141,23	36,55	172,06	17,19
2000	147,3	4,3	184,72	7,36
2005	130,82	-11,19	162,14	-12,22

Tabela 11 - Medias anuais (Grupo 4)

Ano	Chuva	Δ (%)	Vazao	Δ (%)
1975	120,96		89,91	
1980	160,58	32,76	151,24	68,21
1985	170,3	6,05	111,56	-26,24
1990	110,58	-35,07	102,21	-8,38
1995	143,97	30,2	101,48	0,72
2000	146,66	1,87	118,89	17,16
2005	138,57	-5,52	108,86	-8,43

Fonte: Elaborado pelo autor.

Na Figura 36 e tabelas 12 e 13 são apresentados os resultados para toda a bacia. Foram calculadas as médias anuais de todas as estações de chuva e vazões no período de 1975 a 2012. O comportamento, ao longo do período, bem parecido entre chuvas e vazões sugerem uma boa correlação dessas variáveis. A maior variação negativa ocorreu em 1990, tanto para chuva (-31,60%) como para vazão (-13,40%). A taxa de decaimento da vazão é maior em relação à chuva (em média, 3,38 m³/s ao ano e 0,65 mm ao ano, respectivamente). Isso sugere que, além das chuvas, outras variáveis podem estar influenciando na tendência de diminuição dos níveis de vazão na bacia. Observa-se que, na Tabela 13, muitas taxas de decaimento, representadas pelo parâmetro β_1 , apresentaram valores não significativos. Isso pode ter ocorrido em virtude do período considerado, que variou de 1975 a 2017. Para períodos mais longos, como nas séries apresentadas na Figura 35, provavelmente essas taxas tornariam-se significativas.

Figura 36 - Médias anuais de chuvas (vermelho) e vazões (preto) e linhas de tendência. Bacia Araguaia-Tocantins. Todas as estações (Período de 1975 a 2012)

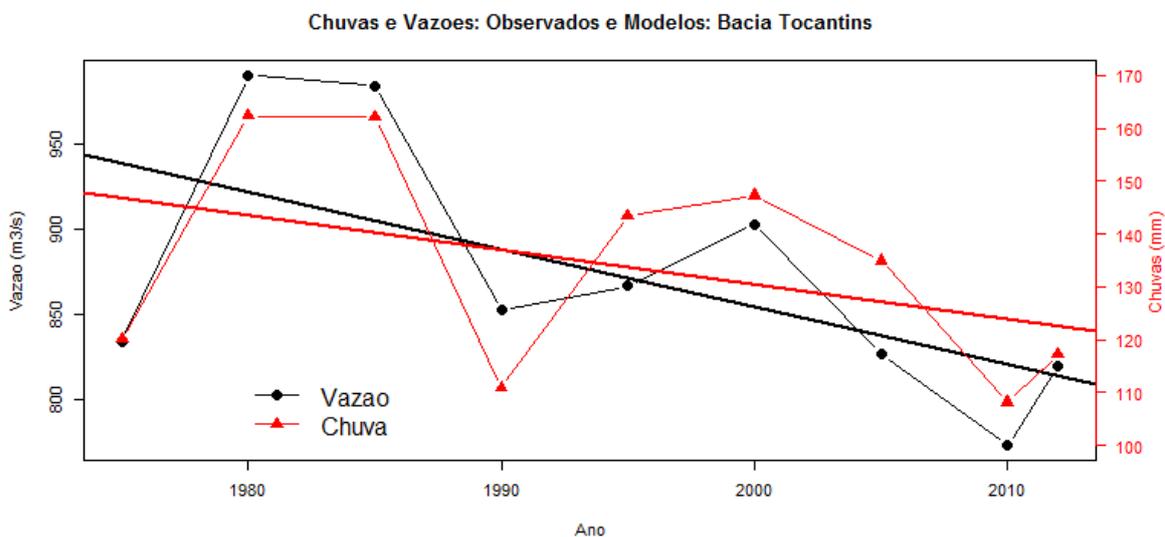


Tabela 12 - Médias anuais (Grupo 4)

Ano	Chuva	Δ (%)	Vazao	Δ (%)
1975	120,04		833,64	
1980	162,37	35,27	989,96	18,75
1985	162,09	0,17	984,12	0,59
1990	110,87	-31,6	852,29	-13,4
1995	143,49	29,42	866,45	1,66
2000	147,24	2,62	902,89	4,21
2005	134,97	-8,34	826,81	-8,43

Fonte: Elaborado pelo autor.

Tabela 13 - Modelos de tendencia linear ($y = \beta_0 + \beta_1 t + \varepsilon$)

Serie	Grupo	β_0	β_1	$t(\beta_1)$	$Prob(\beta_1) > t$
Vazão	G1	131444,30	-63.16	-5.719	0.00124 ***
Chuva	G1	825,94	-0.34	-0.225	0.831
Vazão	G2	7323,17	-2.81	-1.069	0.334
Chuva	G2	4512,41	-2.19	-8.043	0.000197 ***
Vazão	G3	1280,09	-0.56	-0.996	0.352
Chuva	G3	1347,44	-0.61	-1.042	0.332
Vazão	G4	671,86	-0.28	-0.577	0.582
Chuva	G4	1378,21	-0.62	-1.087	0.313
Vazão	Total	7619,27	-3.38	-1.992	0.0867*
Chuva	Total	1439,72	-0.65	-1.189	0.273

Fonte: Elaborado pelo autor.

β_0 : constante; β_1 : coeficiente angular; ε : erro

Significancia: **** 0.01 *** 0.05 ** 0.1 * ' ' 1 (Não Significativo)

Martins e Penereiro (2015) analisaram tendências anuais em variáveis hidroclimáticas, incluindo as chuvas, de 27 estações na BHAT. Utilizaram na detecção de tendências análise de regressão e testes não paramétricos de Mann-Kendall e Pettitt. Em 18 séries de chuvas analisadas “quase não encontraram tendências significativas”. Para as vazões, encontraram 5 series com tendências negativas e sugeriram que isso pode ter influência do possível aumento na tendência da temperatura na região da bacia. Entretanto, este trabalho mostra que, para séries históricas longas, com mais de 40 anos, as curvas de tendência podem ser tornar significativas.

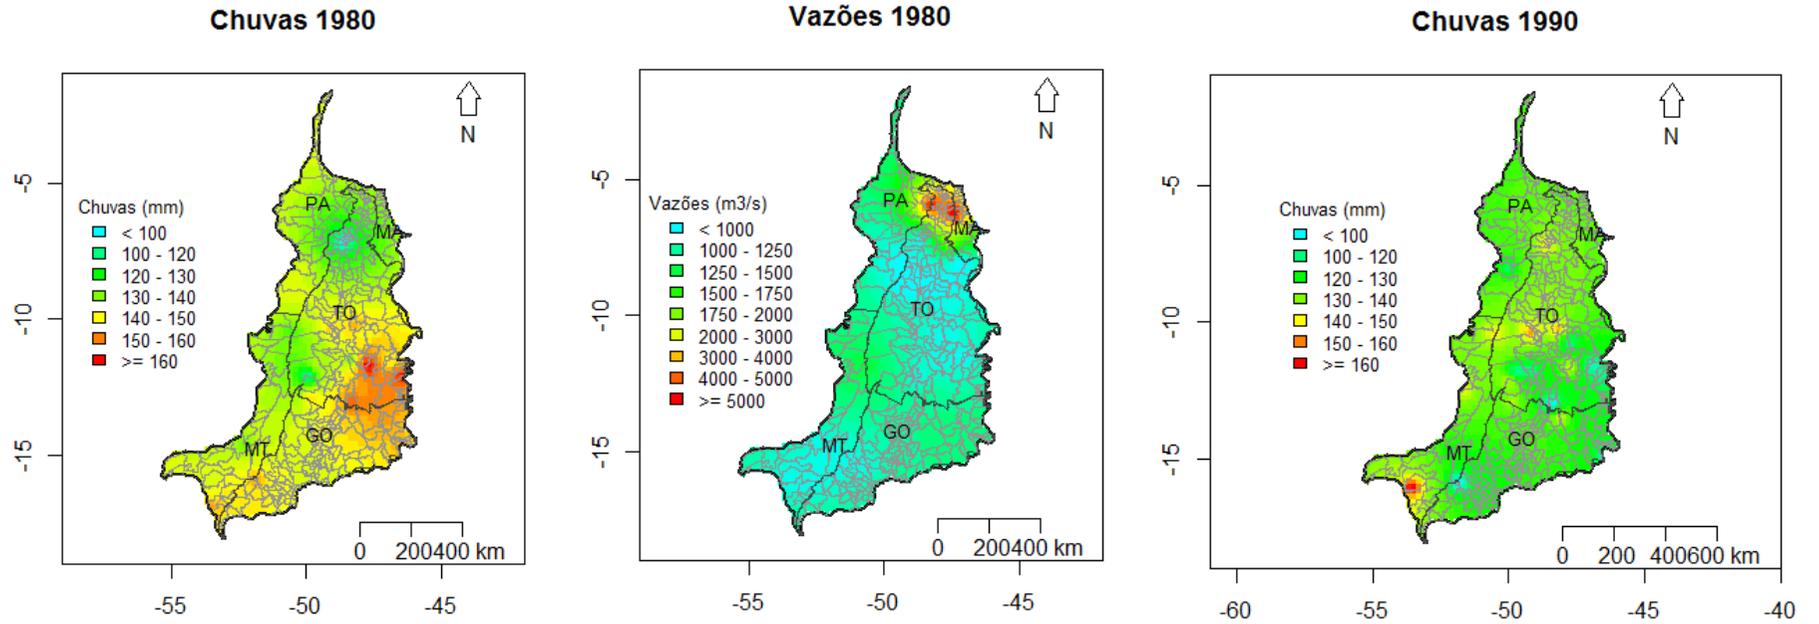
Para visualização dos níveis de chuva e vazão em toda a bacia, foram mapeadas as chuvas e vazões para um periodo de 30 anos, com intervalos de 10 anos, ou seja, de 1980 a 2010 (Figura 37).

Na Figura 37 se observa que, em 1980, a maior ocorrência de chuvas aconteceu na região sudeste da bacia incluindo o estado do Tocantins e Goiás. Em 1990 houve uma diminuição no nível geral de chuvas e as ocorrências ficaram com distribuição aproximadamente homogênea em toda a bacia. Em 2000 houve um aumento nos episodios de chuvas com destaque para uma concentração de aumento no estado do Pará, além do estado do Tocantins. Em 2010, ocorreu um decréscimo

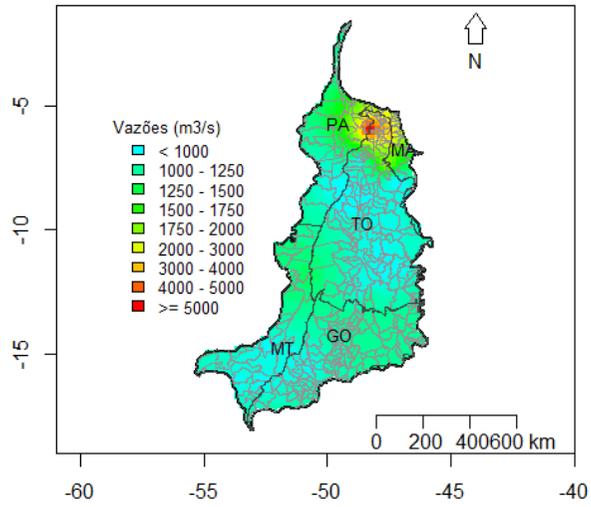
nas chuvas em relação a 2000 com 3 estaques de maiores ocorrências (anomalias) no estado do Tocantins e Maranhão.

A distribuição espacial das vazões no período considerado de 30 anos (1980 a 2010) manteve praticamente o padrão, com destaque para a grande concentração de vazões ao norte da bacia, na divisa dos estados do Pará e Tocantins (Figura 37).

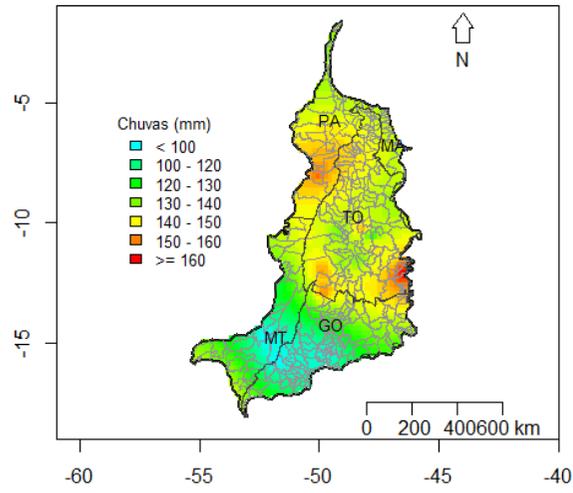
Figura 37 - Chuvas e vazões na Bacia Araguaia-Tocantins. 1980 a 2010



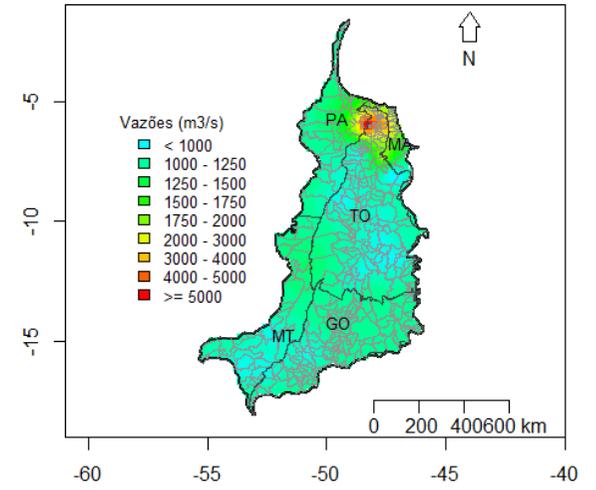
Vazões 1990

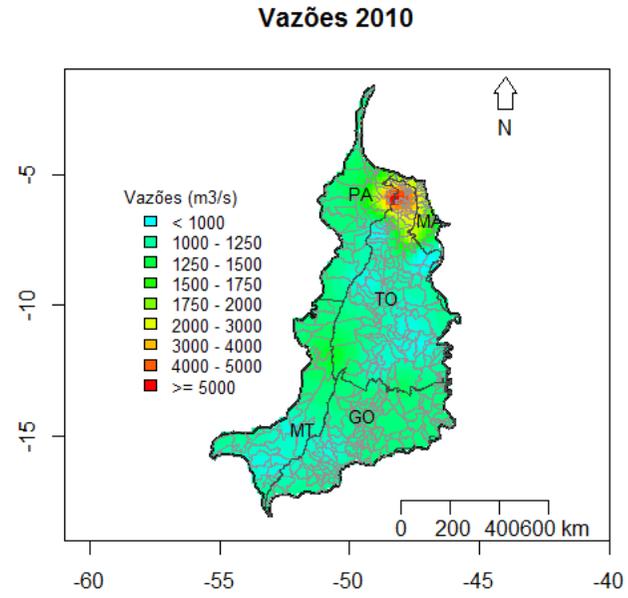
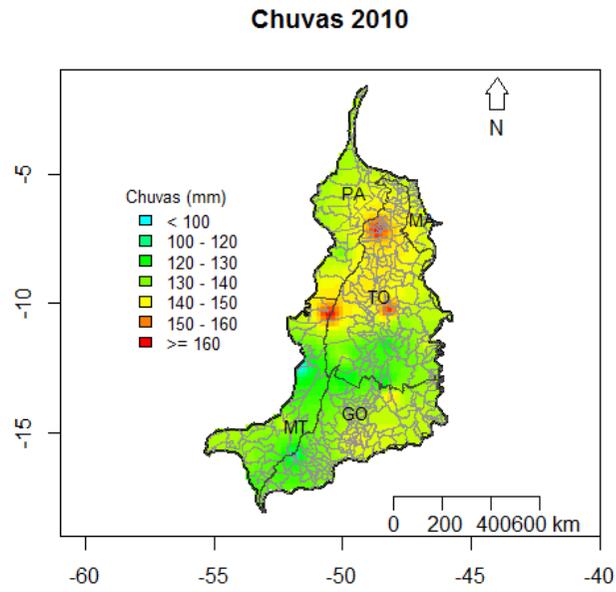


Chuvvas 2000



Vazões 2000



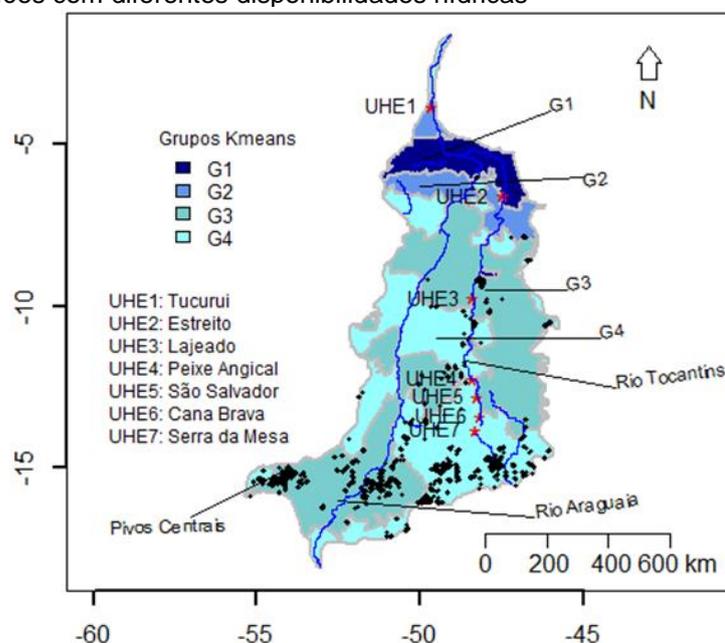


Fonte: Elaborado pelo autor.

Foi feito um estudo para avaliação de possíveis relações das diferentes regiões da BHAT, caracterizadas pela disponibilidade hídrica e as variáveis pivôs centrais, utilizados na irrigação, cultura temporária e rebanho bovino a partir de dados do IBGE no período de 2000 a 2007.

A Figura 38 mostra o mapa da BHAT com destaques dos pivôs centrais (de irrigação) e das regiões com maior (G1 e G2) e menor (G3 e G4) disponibilidade hídrica, respectivamente, além dos principais rios e usinas hidrelétricas instaladas. Observa-se que os pivô centrais localizam-se nas regiões com menor disponibilidade hídrica (G3 e G4).

Figura 38 - Mapa da BHAT com os pivôs centrais (em pontos), principais rios e usinas hidrelétricas nas regiões com diferentes disponibilidades hídricas



Fonte: Elaborado pelo autor.

Na Tabela 14 são mostrados os valores das variáveis para cada grupo da BHAT. Pode-se observar que as regiões dos grupos de maior disponibilidade hídrica (G1 e G2) apresentam valores menores em relação aos grupos de menor disponibilidade hídrica (G3 e G4). A maior quantidade de pivôs centrais nas regiões dos grupos G3 e G4 deve-se principalmente à necessidade de água para produção de culturas temporárias.

Esses resultados foram apresentados em forma de gráficos nas Figuras 39 e 40, para se ter uma melhor visualização das relações entre as variáveis. Essas figuras mostram de forma mais visível, que parece existir uma correlação negativa entre as

variáveis que controlam a disponibilidade hídrica (chuvas e vazões) na BHAT e os pivôs centrais instalados, cultura temporária e rebanho bovino. O gráfico da Figura 8(D), de chuvas e vazões e Tabela 14, mostram uma aparente correlação positiva entre essas variáveis, ou seja, regiões com maior disponibilidade hídrica (G1 e G2) apresentam maiores níveis de chuva e vazão. Ao contrário das regiões 3 e 4, com menor disponibilidade hídrica e menores níveis de chuvas e vazões.

Tabela 14 - Resultados das variáveis por grupos da BHAT

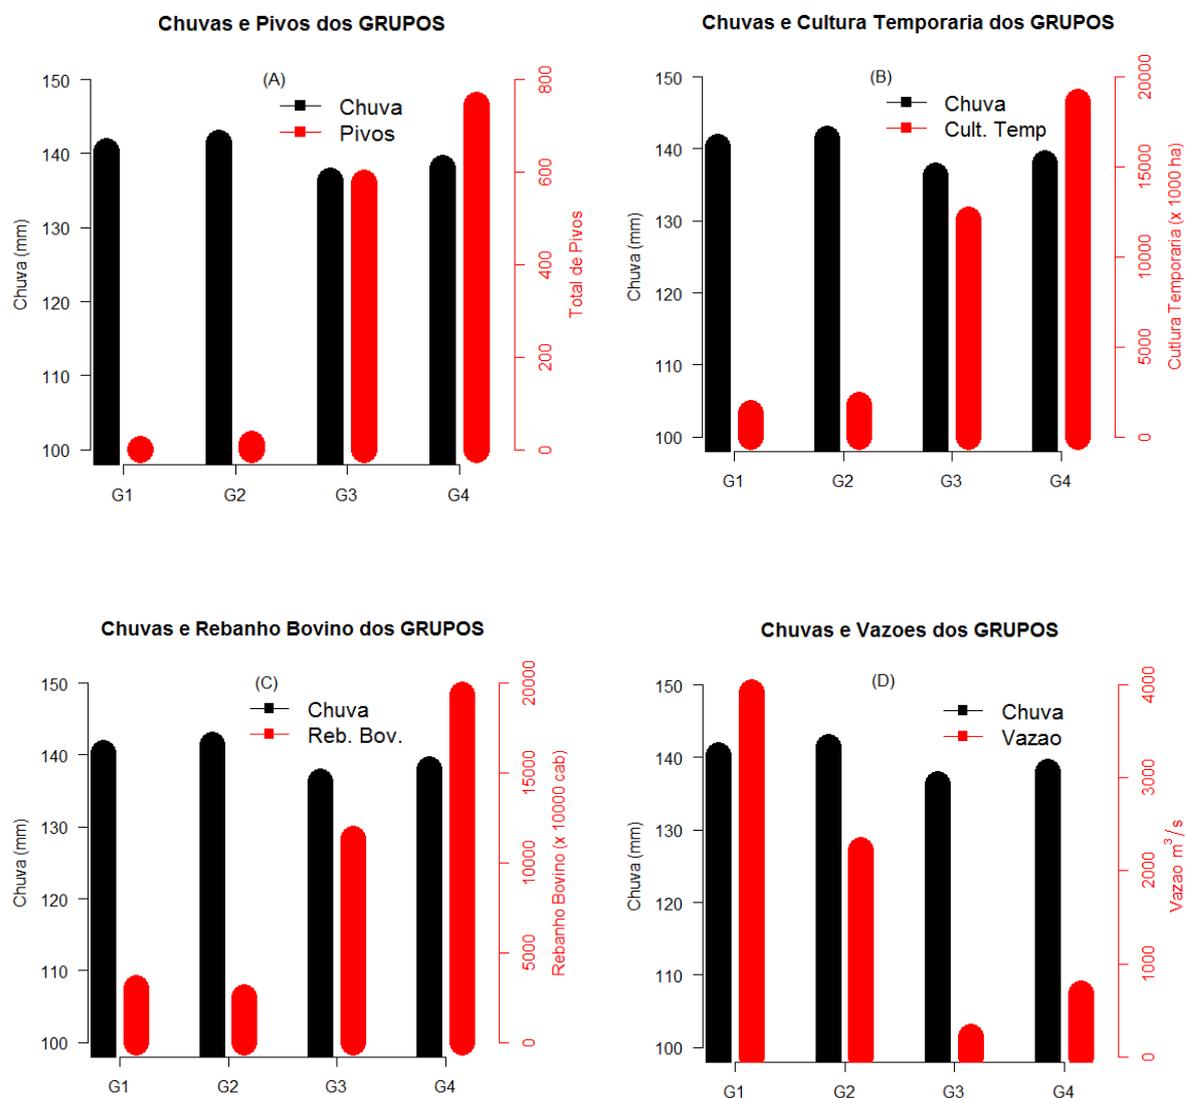
Variáveis	GRUPOS			
	G1	G2	G3	G4
Chuva (mm) *	140.4	141.5	136.4	138.1
Vazao (m ³ /s) *	3926	2229	218.5	684.6
Pivos Centrais (qtde)	1	12	578	745
Cultura Temporária (ha) *	1365035	1773110	11623374	13743429
Rebanho Bovino (cabeças) *	30744909	25290806	82152351	136156226

Fonte: Elaborado pelo autor.

* Chuva e vazão (Média dos regimes)

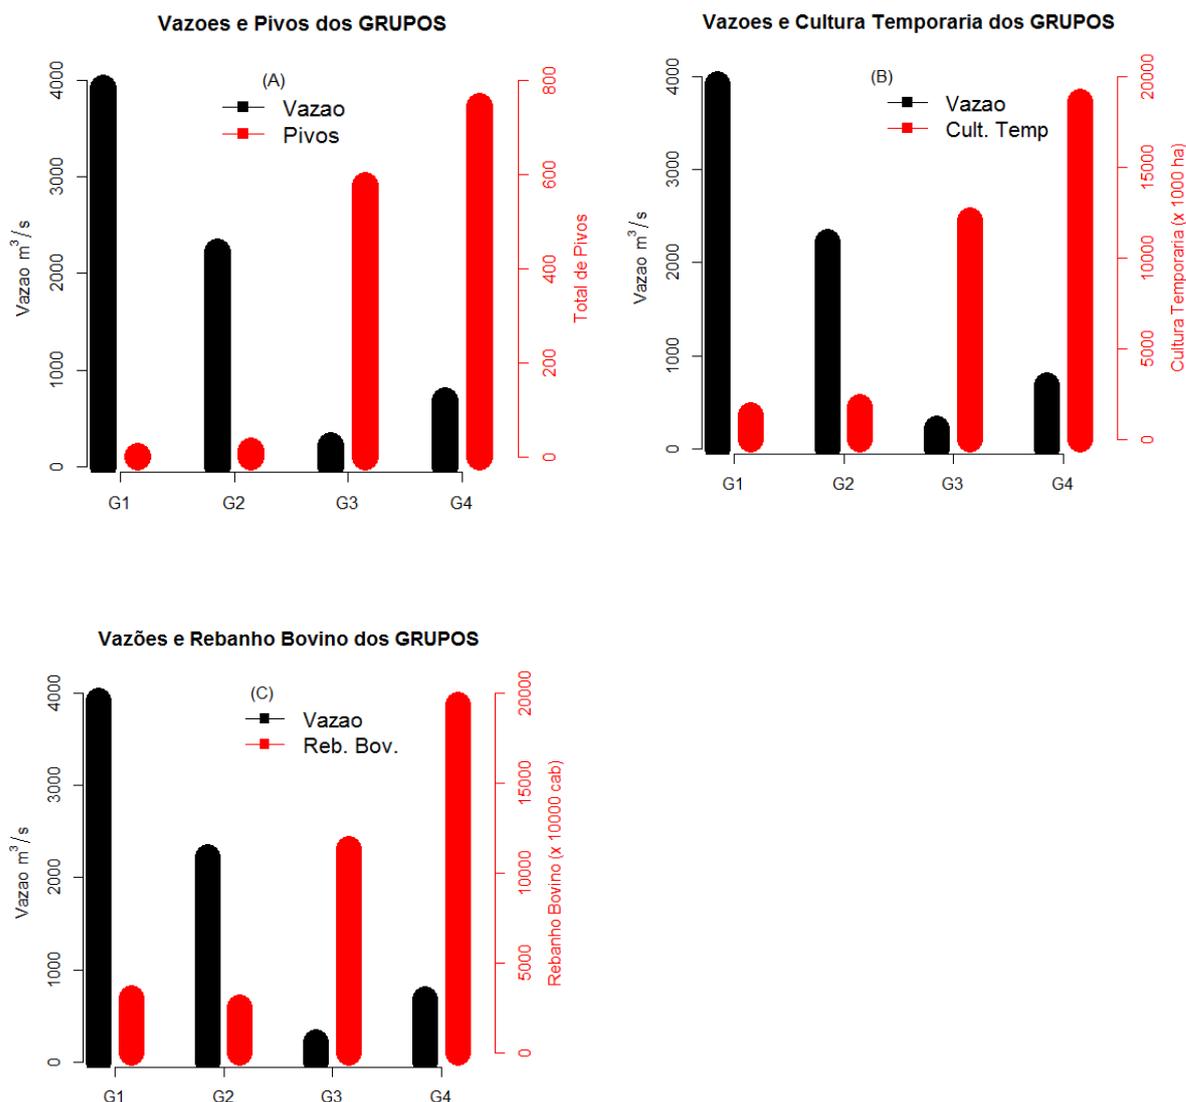
** Cultura Temporária e Rebanho Bovino (total para 2000 a 2007)

Figura 39 - Relação de chuvas com Pivos (A), Cultura Temporária (B), Rebanho Bovino (C) e Vazão (D)



Fonte: Elaborado pelo autor.

Figura 40 - Relação de vazões com Pivos (A), Cultura Temporária (B), Rebanho Bovino (C)

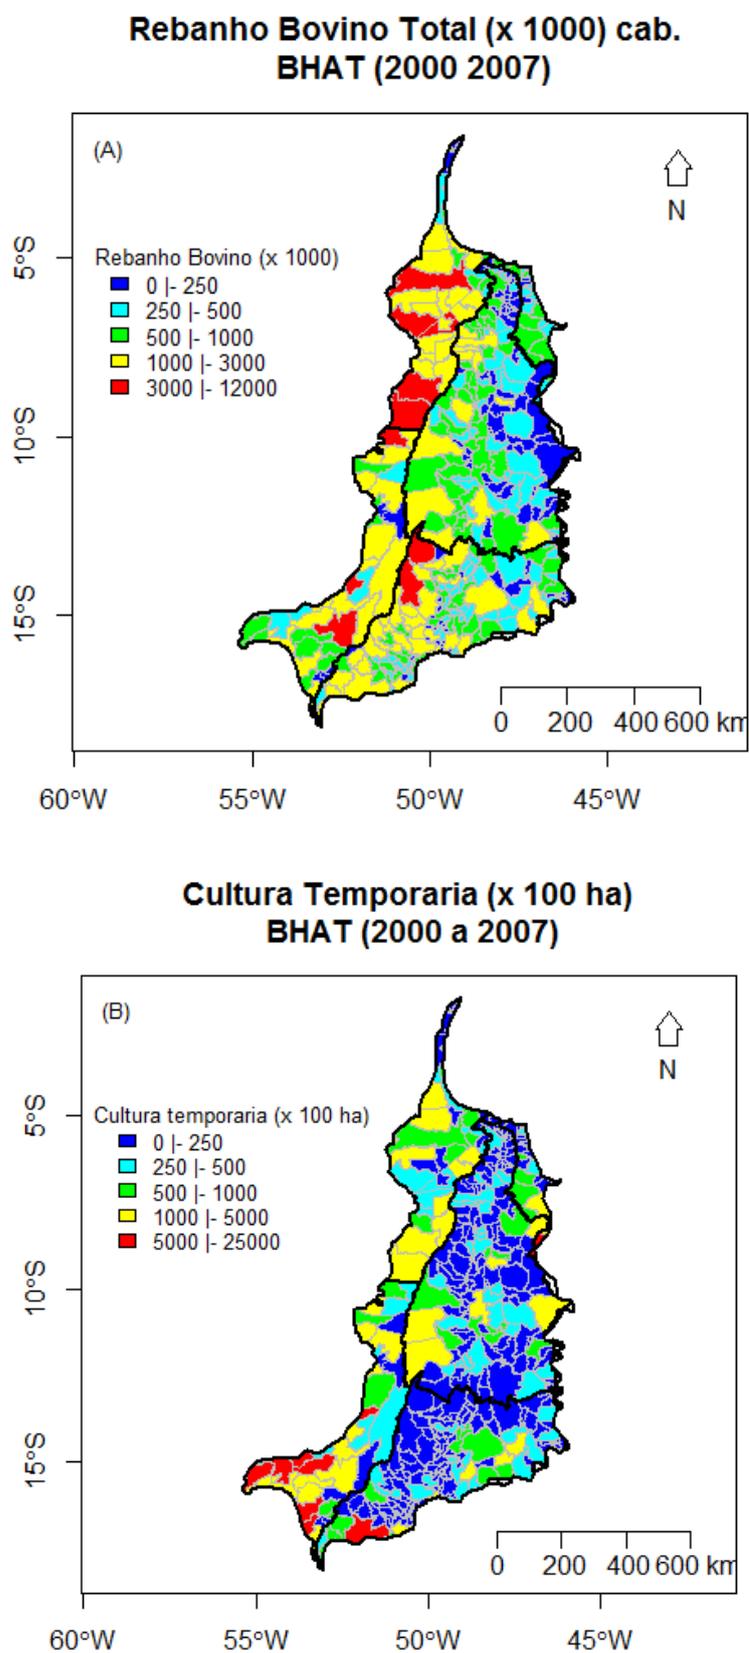


Fonte: Elaborado pelo autor.

A avaliação da significância das diferenças observadas entre as variáveis hidroclimáticas (chuva e vazão) com as outras variáveis (pivôs centrais, cultura temporária e rebanho bovino) foi realizada com auxílio de ferramentas da análise exploratória de dados espaciais (AEDE).

A Figura 41 apresenta os mapas temáticos da cultura temporária e rebanho bovino na BHAT para o período de 2000 a 2007. Maiores criações (acima de 3.000.000 de cabeças) de rebanho bovino no período de 2000 a 2007 aparecem nos estados do Pará, Mato Grosso do Sul e Goiás (Figura 41 A). No Mato Grosso do Sul e Goiás aparecem municípios com maiores áreas plantadas de culturas temporárias (acima de 50000 ha) no período de 2000 a 2007.

Figura 41 - Rebanho Bovino (A) e Cultura Temporária (B) de 2000 a 2007.



Fonte: Elaborado pelo autor.

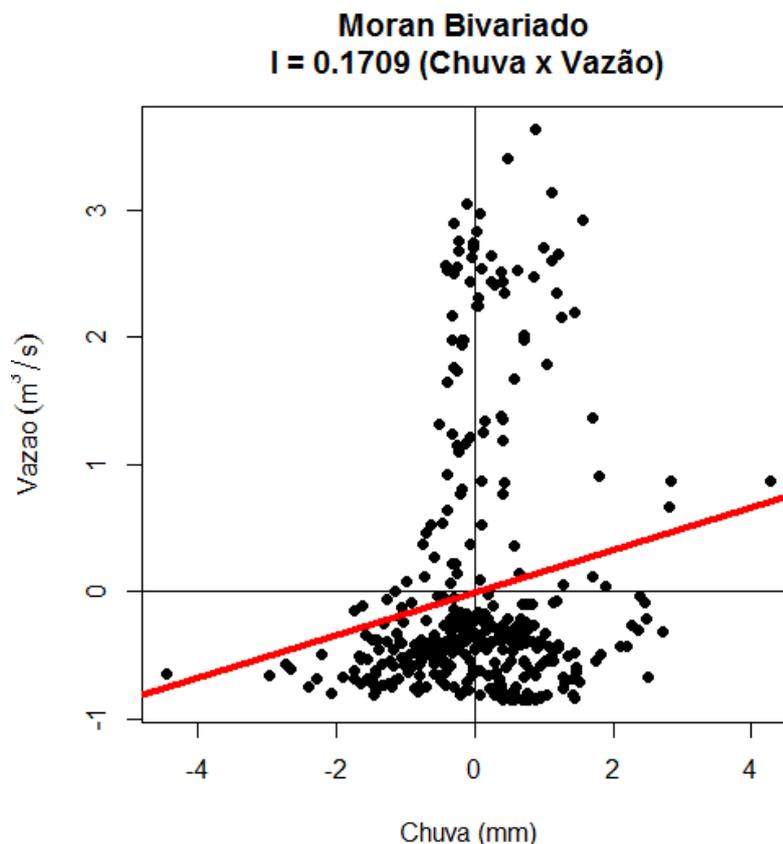
Foi calculado Índice Bivariado de Moran Global e Local na avaliação da correlação espacial entre as variáveis hidroclimáticas e a distribuição dos pivôs centrais, culturas temporárias e rebanho bovino e para as variáveis cultura temporária e pivôs centrais. Na Tabela 15 são apresentados os resultados para o Índice Bivariado de Moran Global. Foram significativas as correlações espaciais para as variáveis, Chuva x Vazão, Chuva x Rebanho Bovino, Vazão x Pivôs, Vazão x Cultura temporária e Pivôs x Cultura Temporária. Não apresentaram significância as variáveis Chuva x Pivôs, Chuva x Cultura Temporária e Vazão x Rebanho Bovino. A Figura 42 mostra o gráfico de dispersão bivariado de Moran para chuva e Vazão.

Tabela 15 - Índice Bivariado de Moran Global

Variáveis	I de Moran	Prob
Chuva x Vazão	0.1709	0.001 ***
Chuva x Pivos	-0.0218	0.586
Chuva x Cult Temp	0.0088	0.838
Chuva x Reb. Bovino	-0.1965	0.001 ***
Vazão x Pivos	-0.1194	0.029 **
Vazão x Cult. Temp.	-0.1079	0.038 **
Vazão x Reb. Bovino	-0.0694	0.163
Pivos x Cult. Temp.	0.0976	0.005 ***

Significância: '***' 0.01 '***' 0.05 '*' 0.1 ' ' 1 (Não Significativo)

Figura 42 - Grafico de dispersão Bivariado de Moran



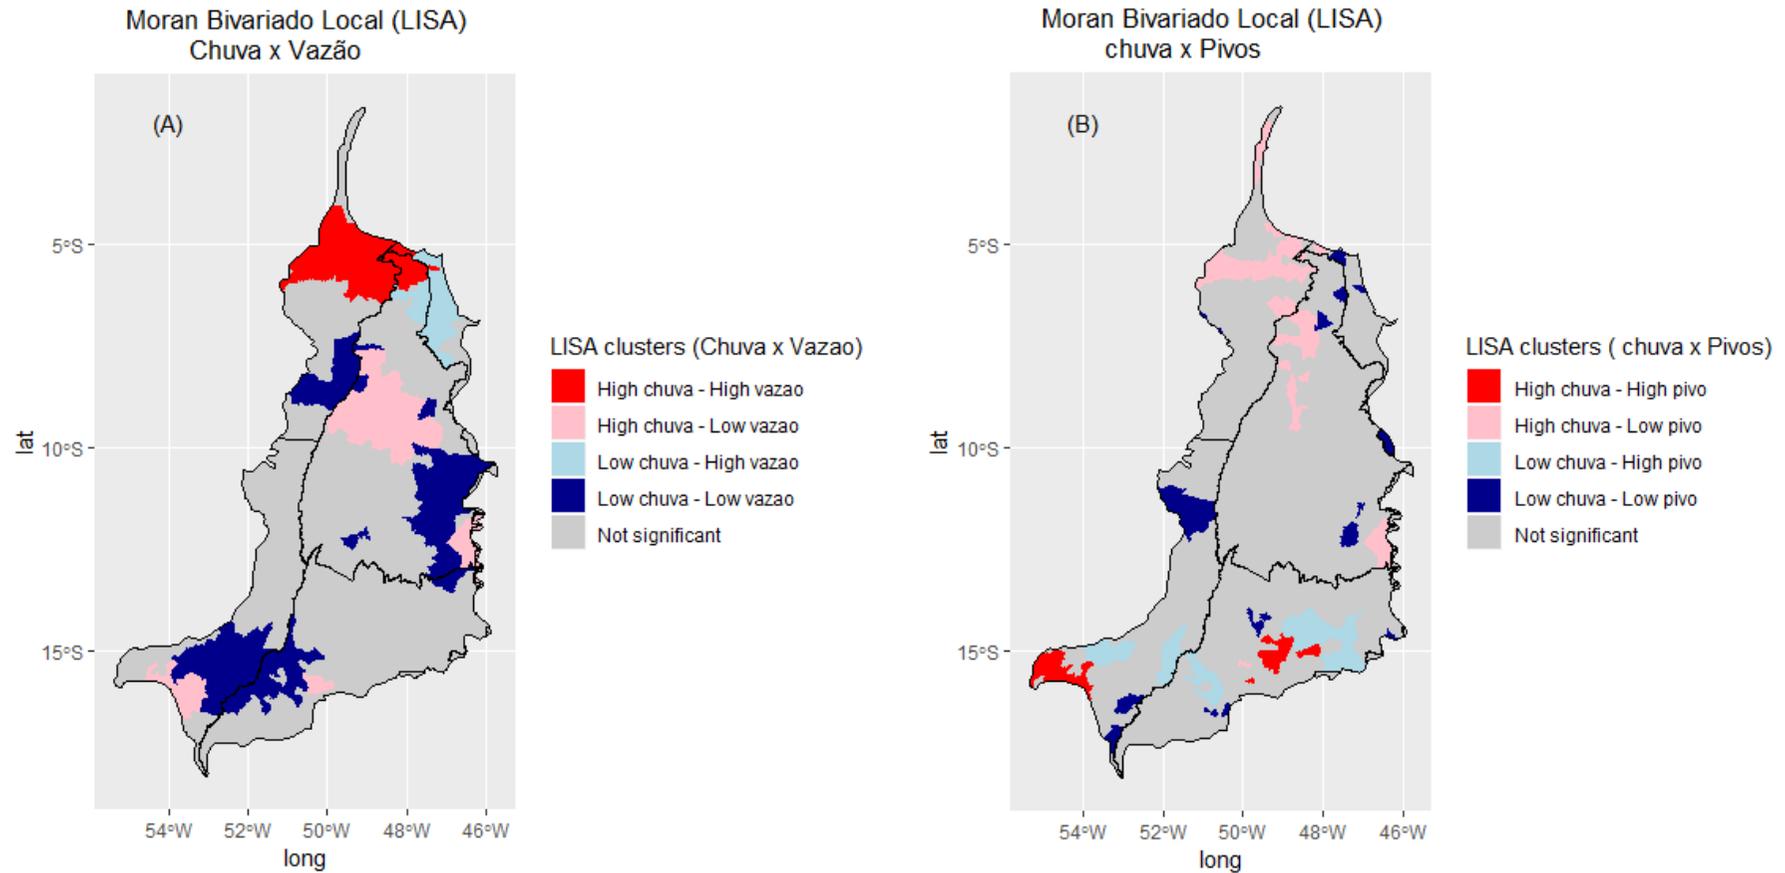
Perobelli et al. (2005) citam 3 situações em que o Índice de Moran Global pode esconder padrões locais de autocorrelação espacial. Neste sentido, foi aplicado Índice Bivariado de Moran Local para identificação dos locais em que ocorrem diferenças significativas entre as variáveis e localizações que possam não ter sido detectadas pelo Índice Bivariado de Moran Global. Os resultados são apresentados em forma de mapas, conhecidos como mapas LISA (*Local Indice Spatial Analyses*). Nas Figuras 43 e 44 são mostrados os resultados dos Índices bivariados de Moran Locais.

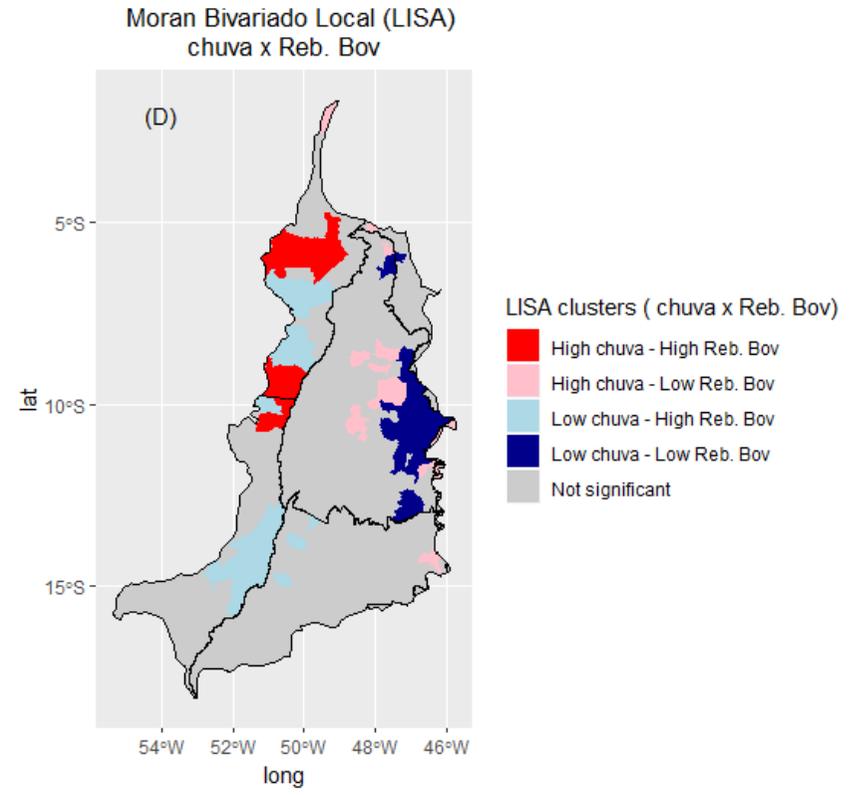
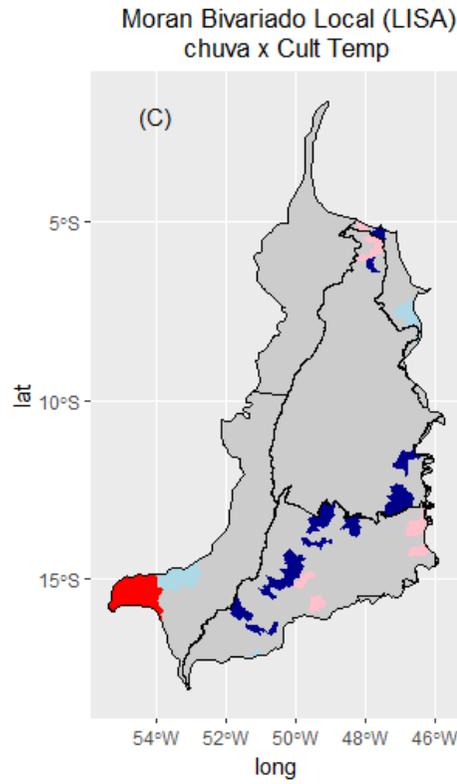
Observa-se na Figura 43(A) uma alta correlação espacial entre chuvas e vazões ao norte da bacia, nas regiões dos grupos 1 e 2, no estado do Pará e norte do estado de Tocantins, caracterizados por alta disponibilidade hídrica e ao sul, no estado do Mato Grosso e leste, no estado do Tocantins (em azul) nas regiões dos grupos 3 e 4, de baixa disponibilidade hídrica. Com relação às variáveis chuvas e pivôs, embora o Índice bivariado de Moran Global não tenha detectado correlação espacial, observa-se pequenos *clusters* localizados, indicando correlação positiva espacial entre chuvas e pivôs, por exemplo, ao sul da bacia, no estado de Mato e no estado de Goiás, em regiões com grande quantidade de pivôs centrais (Figura 43(B)).

As áreas plantadas de cultura temporária aparecem com correlação mais significativas com a chuva, no estado de Mato Grosso e no estado de Goiás, ao sul da BHAT (Figura 43(C)). Um comportamento semelhante ocorre quando se considera a relação espacial de vazões com cultura temporária (Figura 43B). A criação de rebanhos bovinos tem correlação espacial com chuvas destacam principalmente no estado do Para ao norte da bacia e no estado de Mato Grosso ao sudoeste da bacia (Figura 43(D)). Um comportamento semelhante é observado em relação às vazões (Figura 43C) Embora o Índice bivariado de Moran Global tenha apresentado um valor negativo, indicando que áreas com pouca chuva deveriam se associar com rebanho bovino elevado ou áreas com muita chuva se associar a rebanhos bovinos em pouca quantidade, este índice não considera a água disponibilizada pelos pivôs em áreas com baixos níveis de chuvas e vazões. A água fornecida pelos pivôs incrementa as áreas plantadas de cultura temporária que são utilizadas em parte na criação de rebanhos bovinos.

A Figura 43D mostra que a associação positiva entre pivôs e cultura temporária se deve principalmente aos clusters que ocorrem no estado do Mato Grosso, ao sul da bacia e no estado de Goiás em regiões com baixos níveis de chuvas e vazões.

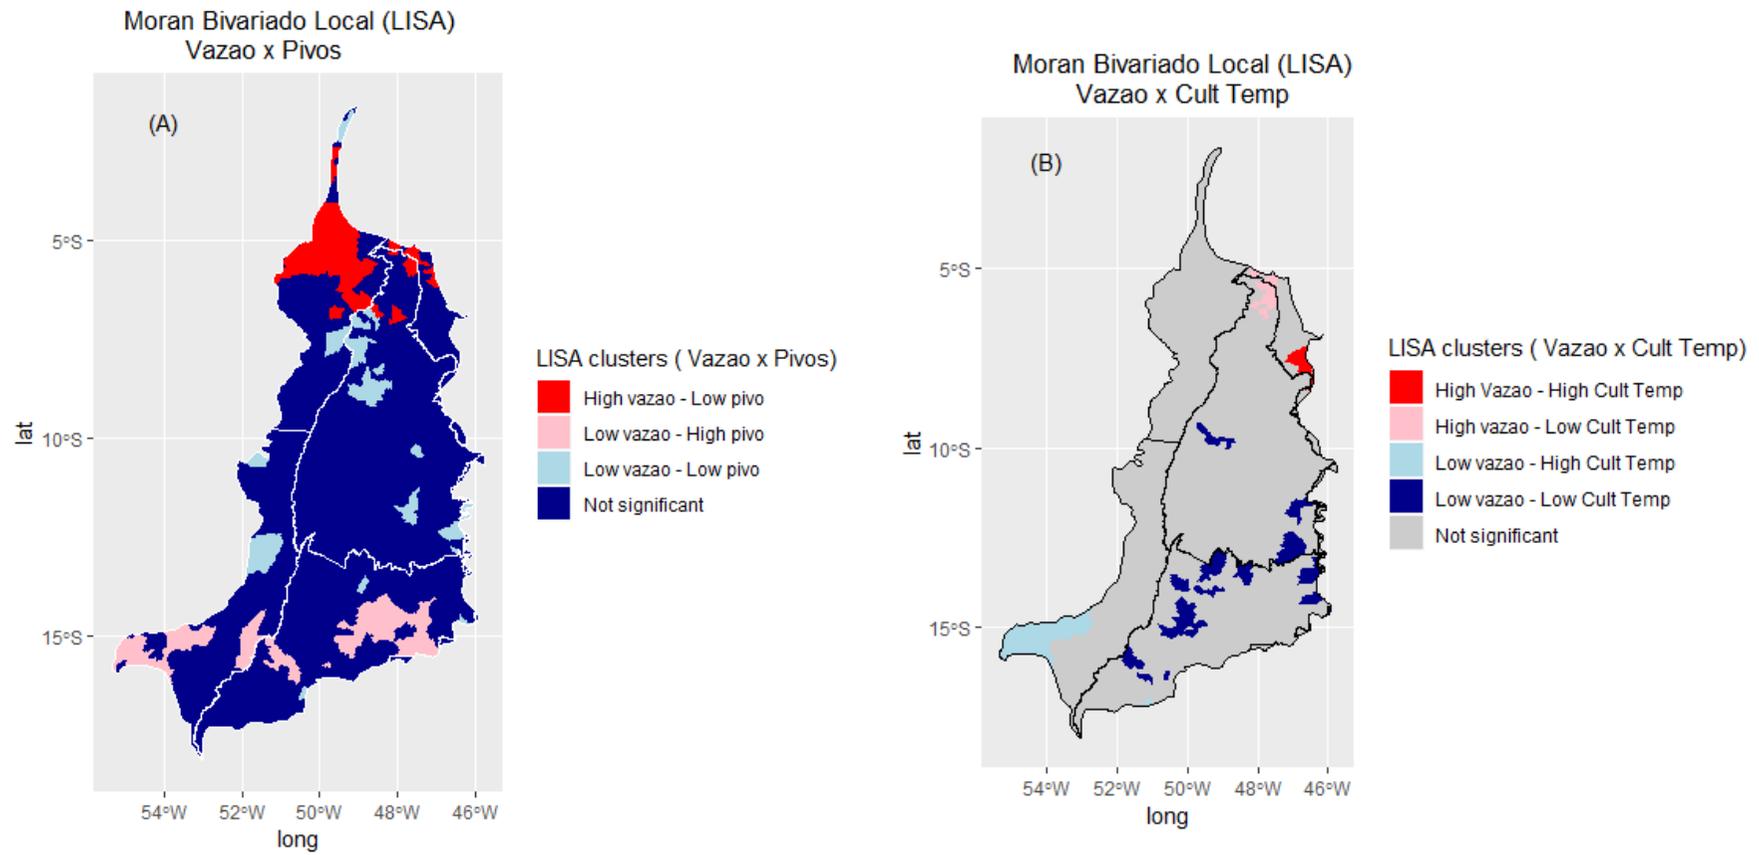
Figura 43 - Mapas LISA para a chuva e vazao (A), pivos (B), Cultura Temporaria (C) e Rebanho Bovino (D)

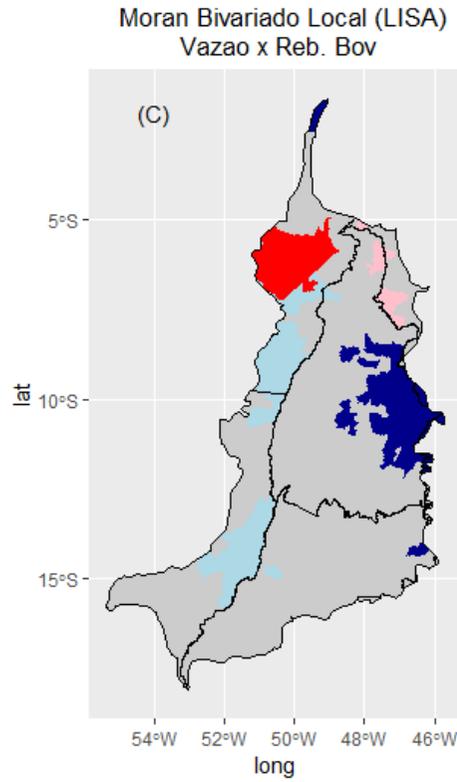




Fonte: Elaborado pelo autor.

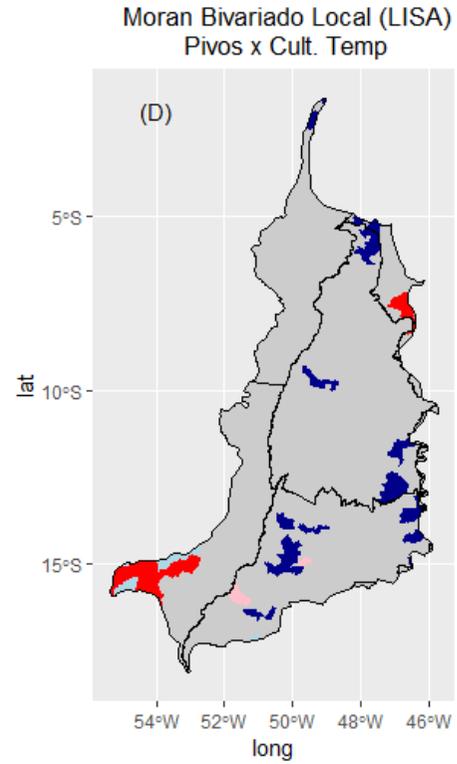
Figura 44 - Mapas LISA para vazão e pivôs (A), Cultura Temporária (B) e Rebanho Bovino (C) e Pivôs x Cultura Temporária (D)





LISA clusters (Vazao x Reb. Bov)

- High Vazao - High Reb. Bov
- High vazao - Low Reb. Bov
- Low vazao - High Reb. Bov
- Low vazao - Low Reb. Bov
- Not significant



LISA clusters (Pivos x Cult. Temp)

- High pivo - High cult temp
- High pivo - Low cult temp
- Low pivo - High cult temp
- Low pivo - Low cult temp
- Not significant

Fonte: Elaborado pelo autor.

Rocha e Parre (2009) utilizaram a análise exploratória de dados espaciais na análise da distribuição espacial da agropecuária no Estado do Rio Grande do Sul no ano de 2004. Com auxílio de Índices bivariados de Moran Global e Local conseguiram identificar relações espaciais do valor bruto da produção agropecuária (variável endógena da função de produção) e variáveis exógenas do modelo (capital, trabalho, área colhida, energia elétrica, temperatura e chuva).

Campolina et al. (2012), relatório do *estudo da dinâmica da cobertura e uso da terra do estado do Tocantins* fizeram uma avaliação e quantificação da dinâmica espacial do território tocantinense no período 1990-2007, por meio de imagens orbitais tm/landsat, da geração da dinâmica da cobertura e uso da terra, e da análise integrada de dados geográficos com apoio de variáveis socioeconômicas. No estudo da **integração da dinâmica da cobertura e uso da terra com os dados socioeconômicos** considerando uma análise mais robusta sobre as áreas mapeadas, buscou-se identificar a existência de padrões espaciais de distribuição, aglomerados e seus respectivos sinais de dependência. para este caso, utilizaram a análise exploratória de dados espaciais que consiste em ferramentas estatísticas descritivas e gráficas que possuem a intenção de detectar padrões e sugerir hipóteses por meio da imposição de um mínimo de estrutura possível.

4.4 Conclusão

A indicação que tanto chuvas como vazões apresentam um decréscimo ao longo do tempo na BHAT apontam para a necessidade de estudos adicionais com vistas a identificar as causas que podem estar afetando os níveis de chuvas e vazões, tendo em vista a complexidade em associar as alterações observadas nas séries com variações naturais do clima e influências antropogênicas. Deste modo, medidas de prevenção e ações podem ser tomadas para que atividades, tanto econômicas, sociais e/ou ambientais, possam ser menos afetadas pela diminuição da disponibilidade hídrica.

A análise exploratória de dados espaciais permitiu a identificação de correlações espaciais significativas entre variáveis hidroclimáticas e variáveis agropecuária. Áreas caracterizadas como de baixa disponibilidade hídrica em relação aos níveis de chuvas e vazões na BHAT apresentam maior quantidade de pivôs centrais que favorecem a produtividade de culturas temporárias e criação de rebanhos bovinos. É alta também a criação de rebanhos bovinos em áreas com alta disponibilidade hídrica, mesmo com pouca existência de pivôs centrais.

5 CONCLUSÃO GERAL

A Bacia Hidrográfica Araguaia-Tocantins (BHAT) é a mais extensa em área de drenagem dentro do território brasileiro, com processos de uso e ocupação cada vez mais crescentes em termos das demandas do agronegócio e exploração mineral. Nesta pesquisa realizou-se um estudo estatístico sobre as tendências hidroclimáticas (precipitação e vazão) na BHAT e suas relações com a agricultura irrigada. O mapeamento hidroclimático baseado na análise de agrupamento identificou quatro regiões homogêneas dentro da BHAT, duas ao norte com predominância de altos valores de chuva/vazão e alta disponibilidade hídrica e duas regiões se estendendo ao longo da bacia, com valores mais baixos de chuva e vazão e menor disponibilidade hídrica. O regime chuvoso da BHAT ocorre entre dezembro e março e o regime seco entre maio e setembro. Os meses de outubro/novembro e abril são de transição com variações pronunciadas no ciclo sazonal. O estudo geoestatístico de previsões chuva/vazão revelou que os resultados usando o modelo de Box-Jenkins é relativamente melhor quando comparado ao modelo de Redes Neurais Artificiais. A abordagem integrada das variáveis hidroclimáticas com os dados agropecuários dentro da BHAT revelaram um padrão significativo de tendências negativas de precipitação e vazões coincidentes espacialmente nas regiões de intensa produtividade de milho e soja e de rebanho bovino. Um resultado relevante foi a detecção de correlação espacial significativa entre o número de pivôs centrais em regiões com baixa disponibilidade hídrica, os quais favorecem a produtividade das culturas temporárias.

REFERÊNCIAS

- AQUINO, S.; Latrubesse, E.M.; SOUZA FILHO, E E. Caracterização hidrológica e geomorfológica dos afluentes da bacia do rio Araguaia. **Revista Brasileira de Geomorfologia**, v. 10, p. 43-54, 2009.
- BEIJO, L.A.; AVELAR, F.G. Distribuição generalizada de valores xxtremos no estudo de dados climáticos: umabreve revisão e aplicação. **Revista da Estatística da UFOP**, v. 1, p. 10-16, 2011. ISSN 2237-8111.
- BOX, G. E. P.; JENKINS, G. **Time series analysis, forecasting and control**. San Francisco: Holden-Day, 1976.
- CARDOSO, M.R.D.; MARCUZZO, F.F.N.; PINTO FILHO, R.F. Caracterização física básica da bacia hidrográfica Araguaia visando determinar susceptibilidade a enchentes. In: SIMPÓSIO BRASILEIRO DE GEOGRAFIA FÍSICA E APLICADA – SBGFA, 14., 2011, Dourados – Mato Grosso do Sul, 2011. **Anais[...]**. Mato Grosso do Sul: [s.n], 2011. p. 1-10. Disponível em: rigeo.cprm.gov.br/jspui/bitstream/doc/.../evento_caracterizacao_bacia_araguaia.pdf. Acesso em: 27 jun. 2015.
- DU, L.M.; HOU, Z.Q.; LI, Q.H. Optimum blockadaptive learning algorithm for error back-propagation networks. **IEEE Transactions on Signal Processing**, v. 40, n.12, p. 3032-3042, 1992.
- EVANGELISTA, J.O.; REIS, K.N.; LOUREIRO, G.E. Distribuição de probabilidade hidrológica de precipitação para sub-região hidrográfica Tocantins 08 no estado do Pará. **Revista Geonorte**, v.9, n.32, p.107-122, 2018. ISSN 2237 - 1419.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Bacias e divisões hidrográficas do Brasil**. 2021. Disponível em: <http://cidades.ibge.gov.br/xtras/home.php>. Acesso em: 8 ago 2022.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Censo demográfico de 2010**. 2010. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101854.pdf>. Acesso em: 10 jan 2022.
- FENG, S.; NADARAJAH, S; HU, Q. Modeling annual extreme precipitation in China using the generalized extreme value distribution. **Journal of the Meteorological Society of Japan**, v.85, n.5.p. 599-613, 2007.
- KHANDELWAL, I.; ADHIKARI, R.; VERMA, G. Time series forecasting using hybrid ARIMA and ANN models based on DWT decomposition. **Procedia Computer Science**, v. 48, p. 173 – 179, 2015. (International Conference On Intelligent Computing, Communication & Convergence. (ICCC-2014), Conferencia Organizada por Interscience Institute of Management and Technology, Bhubaneswar, Odisha, India). Disponível em www.sciencedirect.com. Acesso em: 27 set 2016.
- LESLIE, S. **An introduction to neural network**. 1996. [Online]. Disponível em: <http://www.cs.stir.ac.uk/~lss/NNIntro/InvSlides.html>. Acesso em: 20 Mar. 2017.

MARTINS, L. L. S.; PENEREIRO, J.C. Detecções de tendências em parâmetros hidroclimáticos na bacia hidrográfica Araguaia Tocantins. *In*: ENCONTRO DE INICIAÇÃO CIENTÍFICA, 20 & ENCONTRO DE INICIAÇÃO EM DESENVOLVIMENTO TECNOLÓGICO E INOVAÇÃO – PUC, 5., 2015, Campinas. **Anais**[...]. Campinas: [s.n], 2015. p. 1-6.

SAFEE, Shuhaili; AHMAD, Sabri. Comparing the Univariate Modeling Techniques, Box-Jenkins and Artificial Neural Network (ANN) for Measuring of Climate Index. **Applied Mathematical Sciences**, v. 8, n. 32, p. 1557-1568, 2014. Disponível em: www.m-hikari.com <http://dx.doi.org/10.12988/ams.2014.4150>. Acesso em: 15 mai 2015.

APÊNDICE A1 - Estações pluviométricas utilizadas na avaliação dos níveis de chuva

Estações	Nome	x	y	Período		Grupo
				Início	fim	
E1	Almas	-47.1739	-11.5789	1973	2016	G3
E3	Alvorada	-49.1167	-12.4833	1971	2016	G3
E4	Araguaçu	-49.8167	-12.9167	1973	2017	G3
E5	Aruana	-48.1333	-13.5342	1970	2017	G4
E6	Auroradonorte	-46.401	-14.933	1973	2017	G4
E7	Britania	-51.15	-15.2508	1974	2016	G3
E9	Colonha	-50.0006	-8.04389	1973	2017	G3
E10	Conceição do Tocantins	-47.3167	-12.2167	1973	2017	G3
E11	Dianópolis	-46.8106	-11.6253	1971	2017	G3
E13	Fátima	-48.9019	-10.7633	1971	2016	G4
E14	Fazenda Lobeira	-48.2944	-11.5314	1969	2017	G4
E15	Porto Gilandia	-47.7644	-10.7553	1975	2017	G4
E16	Gurupi	-49.1333	-11.7333	1971	2017	G4
E17	Jaragua	-49.5407	-15.3347	1964	2017	G4
E18	Jatoba	-47.7883	-10.6553	1973	2017	G4
E19	Leverger	-51.61	-12.4936	1969	2017	G4
E21	Natitidade	-47.7281	-11.6967	1973	2017	G3
E22	Novo cordo	-47.4783	-9.99056	1971	2016	G3
E24	Paraíso do Tocantins	-48.8906	-10.1653	1971	2016	G4
E25	Peres	-51.8536	-15.89	1972	2017	G3
E26	Pindorama do Tocantins	-47.5767	-11.1403	1973	2016	G3
E28	Ponte Alta do Bom Jesus	-46.4792	-12.0906	1973	2016	G3
E30	Porto Alegre	-47.045	-11.61	1975	2017	G3
E35	São Félix do Araguaia	-48.1333	-13.5167	1974	2017	G4
E38	Tesouro	-53.5494	-16.0778	1971	2017	G3
E39	Xavantina	-52.2667	-14.6786	1969	2017	G3
E40	Ananas	-48.0667	-6.3675	1975	2015	G2
E41	Muricilandia	-48.6	-7.1675	1975	2017	G3
E42	Goiatins	-47.3	-7.7175	1972	2017	G2
E43	Esperantina	-48.5333	-5.3675	2005	2015	G1
E44	Itupiranga	-49.3167	-5.13417	1994	2017	G1

APÊNDICE A2 - Outras Estações pluviométricas

Estações	Nome	x	y	Período		Grupo
				Início	fim	
E2	Alto garca	-53.5336	-16.9442	1976	2017	G3
E8	Sandolândia (Barreira do pequi)	-49.9333	-12.0833	1984	2017	G3
E12	Engenho Novo São Félix	-48.1381	-13.5331	1970	1999	G4
E20	Mateiros	-46.4183	-10.5453	1998	2017	G3
E23	Palmeirópolis	-48.4	-13.0333	1978	2017	G4
E27	PIUM	-49.1792	-10.3908	1983	2016	G4
E29	Ponte Alta	-47.5361	-10.7508	1984	2016	G4
E31	Praiaalta	-49.9756	-12.6925	1985	2017	G3
E32	Projeto Barreira da Cruz	-49.8564	-10.7342	1999	2016	G4
E33	Projeto Rio Formoso	-49.7717	-11.8392	1980	2017	G3
E34	Santa Teresinha	-50.5125	-10.4608	1985	2017	G4
E36	Serradamesa	-49.9281	-15.4617	1985	2015	G3
E37	Taquarussu	-48.1625	-10.3133	1976	2017	G3
E45	Jacunda	-49.95	-4.25083	1995	2017	G2

APÊNDICE B1 - Estações fluviométricas utilizadas na avaliação dos níveis de vazão

Estações	Nome	x	y	Período		Grupo
				Início	fim	
E7	Colonha	-48.7106	-12.3878	1975	2013	G4
E8	Descarreto	-47.4689	-5.78944	1974	2013	G1
E12	Fazenda Piracicaba	-47.8369	-11.7586	1975	2013	G3
E16	Gilandia	-47.7833	-10.7667	1970	2013	G4
E23	Monte Lindo	-46.965	-8.03444	1984	2012	G2
E24	Muricilândia	-48.6197	-7.15444	1975	2012	G3
E25	Novo Acordo	-47.6747	-9.96333	1972	2012	G3
E27	Pedra Chorosa	-47.6	-7.45	1975	2013	G2
E32	Tesouro	-53.5483	-16.0775	1972	2017	G3
E33	Tocantinópolis	-47.3917	-6.28889	1955	2012	G1
E35	Travessao	-50.7047	-15.5189	1974	2017	G3
E36	Xavantina	-52.355	-14.6725	1969	2017	G3
E37	Fazenda Jatoba	-54.94	-16.1006	1974	2013	G3
E14	Fazenda Telesforo	-50.6667	-11.9167	1970	2013	G4

APÊNDICE B2 - Outras Estações fluviométricas

Estações	Nome	x	y	Período		Grupo
				início	fim	
E13	Fazenda Santa Luciana	-48.3167	-5.98333	1976	2012	G1
E15	Formoso do Araguaia	-50.6625	-11.6181	1981	1994	G3
E17	Ipueiras	-48.4592	-11.2475	2001	2013	G4
E18	Jacaré	-47.2611	-7.96333	1984	2012	G4
E19	Lavandeira	-46.5122	-12.7936	1975	2007	G3
E20	Lobeira	-48.2947	-11.5314	1970	2005	G4
E21	Lontra	-48.2356	-7.2125	2000	2012	G3
E22	Montante Do Rio Ronca	-48.1997	-6.04278	2001	2012	G1
E26	Paraná	-47.8667	-12.5667	1971	2005	G3
E28	Piranhas	-49.3775	-9.18389	1981	2012	G3
E29	Porto Alegre	-47.0447	-11.6114	1976	2013	G3
E30	Praia Alta	-49.5892	-12.4178	1986	2012	G3
E31	Rio Das Balsas	-47.9833	-10	1976	1994	G3
E34	Toxioreu	-52.5497	-16.2006	1976	2017	G3

APÊNDICE C - Códigos do R dos principais programas utilizados na implementação das análises

Programa 1. Cálculo dos regimes de chuvas

```
#### Versão do R: R.3.1.1 ####
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapIII/R_artigo")
### 1.1 Estacao E19: Leverger (CHuvas) ###
lever_miss<- read.table("leverger_corr.txt", head=T)
mlevere<-matrix(lever_miss$chuva,12)# matriz das precipitacoes
mlevere<-t(mlevere) #Transposta
Medl_levere<-apply(mlevere,1,mean, na.rm=TRUE) #médias das linhas (1) (anos)
mlevere<-cbind(mlevere,c(Medl_levere)) # acrescentar a coluna com as Medias dos anos
Medc_levere<-apply(mlevere,2,mean, na.rm=TRUE) #médias das colunas (meses)
mlevere<-rbind(mlevere,c(Medc_levere)) # acrescentar a linha com as Medias dos 12 meses
colnames(mlevere) <- c("jan","fev","mar","abr","mai","jun",
"jul","ago","set","out","nov","dez","Média")
rownames(mlevere) <- c("1969","1970","1971","1972","1973","1974","1975",
"1976","1977","1978","1979","1980","1981","1982","1983",
"1984","1985","1986","1987",
"1988","1989","1990","1991","1992","1993","1994","1995",
"1996","1997","1998","1999","2000","2001","2002","2003",
"2004","2005","2006","2007","2008","2009","2010","2011",
"2012","2013","2014","2015","2016","2017","MEDIA")
# Substituindo os valores faltantes pelas medias mensais respectivas
x1 = sapply(mlevere[,1], function(i){ifelse(is.na(i),mlevere[50,1],i)}) # OK
x2 = sapply(mlevere[,2], function(i){ifelse(is.na(i),mlevere[50,2],i)}) # OK
x3 = sapply(mlevere[,3], function(i){ifelse(is.na(i),mlevere[50,3],i)}) # OK
x4 = sapply(mlevere[,4], function(i){ifelse(is.na(i),mlevere[50,4],i)}) # OK
x5 = sapply(mlevere[,5], function(i){ifelse(is.na(i),mlevere[50,5],i)}) # OK
x6 = sapply(mlevere[,6], function(i){ifelse(is.na(i),mlevere[50,6],i)}) # OK
x7 = sapply(mlevere[,7], function(i){ifelse(is.na(i),mlevere[50,7],i)}) # OK
x8 = sapply(mlevere[,8], function(i){ifelse(is.na(i),mlevere[50,8],i)}) # OK
x9 = sapply(mlevere[,9], function(i){ifelse(is.na(i),mlevere[50,9],i)}) # OK
x10 = sapply(mlevere[,10], function(i){ifelse(is.na(i),mlevere[50,10],i)}) # OK
x11 = sapply(mlevere[,11], function(i){ifelse(is.na(i),mlevere[50,11],i)}) # OK
x12 = sapply(mlevere[,12], function(i){ifelse(is.na(i),mlevere[50,12],i)}) # OK
mlevere<-cbind(x1,x2,x3,x4,x5,x6,x7,x8,x9,x10,x11,x12)
mlevere <-mlevere[-50,] #Removendo a linha das medias
mlevere<-t(mlevere)
# Juntando os dados: vetor com medias no lugar de missing
mlevere_ave<-matrix(mlevere,ncol=1) #ave = average
```

```

# Salvando em forma de tabela
mlevere_var <- as.data.frame(cbind(mlevere_ave,lever_miss$chuva))
lever_imp <- mlevere_var
names(lever_imp)<-c("obs","miss") # obs serie com as medias; miss serie com NA's
# Imputacao ###
library(mice)
md.pattern(lever_imp)
imp <- mice(lever_imp)
res<-complete(imp)
lever_imp$Imp<-res
lever_NA <-ts(lever_miss$chuva,start=c(1969,1),freq=12) #serie original com valores faltantes
lever_med <-ts(res$obs,start=c(1969,1),freq=12) #serie com medias no lugar dos NA's
lever_imp <-ts(res$miss,start=c(1969,1),freq=12) # SERIE IMPUTADA
win.graph(width=8, height=4,pointsize=9)
ts.plot(lever_NA,lever_imp,gpars=list(xlab="", ylab='Precipitação (mm)',
  lty=c(1:2),col=c("red","blue")))
legend(1995,650,legend=c('Precip_NA','Precip_imp'),
  lty=1:2,col=c("red","blue"))

write.table(lever_imp,"C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapIII/R_artigo/E19_lev
er.txt")
win.graph(width=8, height=4,pointsize=9)
ts.plot(lever_NA,lever_imp,gpars=list(xlab="", ylab='Precipitação (mm)',main='Estação
Leverger',
  lty=c(1:2),col=c("red","blue")))
legend(2000,650,legend=c('Precip_NA','Precip_imp'),lty=1:2,col=c("red","blue"))
write.table(lever_imp,"C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapIII/R_artigo/E19_lev
er.txt")
# Medias mensais:
E1_tab<-matrix(res$miss,12)
E1_tab<-t(E1_tab) #Transposta
E1_Mmes<-apply(E1_tab,2,mean) #médias das colunas (meses)
E1_tab<-rbind(E1_tab,c(E1_Mmes)) # acrescentar a coluna Media
E1_Mano<-apply(E1_tab,1,mean) #calculando a médias das linhas (anos)
E1_tab<-cbind(E1_tab,c(E1_Mano)) # acrescentar a coluna Media
colnames(E1_tab) <- c("jan","fev","mar","abr","mai","jun",
  "jul","ago","set","out","nov","dez","Média")
rownames(E1_tab) <- c("1969","1970","1971","1972","1973","1974","1975",
  "1976","1977","1978","1979","1980","1981","1982","1983",
  "1984","1985","1986","1987",

```

```

"1988", "1989", "1990", "1991", "1992", "1993", "1994", "1995",
"1996", "1997", "1998", "1999", "2000", "2001", "2002", "2003",
"2004", "2005", "2006", "2007", "2008", "2009", "2010", "2011",
"2012", "2013", "2014", "2015", "2016", "2017", "MEDIA")
# Grafico das medias mensais no periodo
library(ggplot2)
library(zoo)
E1_mensal<-as.matrix(E1_tab[50,])
E1_mensal<-as.matrix(E1_mensal[-13,])
E1_m <- data.frame(precipitacao = E1_mensal)
E1_m$Regiao <- c("E1","E1","E1","E1","E1","E1","E1","E1","E1","E1","E1","E1")
E1_m$mes <-seq(1:12)
E1_m$nmese <-c("jan","fev","mar","abr","mai","jun",
               "jul","ago","set","out","nov","dez")
write.table(E1_m,file="E19_mensal.txt") # Arquivo do regime de Chuvas (Leverger)
E1 <- ggplot(E1_m, aes(reorder(x=nmese, mes), y=precipitacao, group = 1)) +
  geom_line(colour="red",size = 0.8)+ xlab(" ") + ylab("Precipitação (mm)")+
  ggtitle("Medias mensais Leverger (1969 a 2017)"); E1

```

Programa 2. Graficos dos Regimes

```

##### Versão do R: R.3.1.1 #####
library(ggplot2)
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapII/precip")
### ===== Graficos conjuntos ===== #####
R1_men<-read.table("E1_mensal.txt",header=TRUE) # Arquivo do regime de Chuvas (Almas)
R2_men<-read.table("E2_mensal.txt",header=TRUE) # Arquivo do regime de Chuvas (Alto
Garças)
R3_men<-read.table("E3_mensal.txt", header = TRUE)
R4_men<-read.table("E4_mensal.txt", header =TRUE)
R5_men<-read.table("E5_mensal.txt",header =TRUE)
R6_men<-read.table("E6_mensal.txt",header=TRUE)
R7_men<-read.table("E7_mensal.txt",header=TRUE)
R8_men<-read.table("E8_mensal.txt", header=TRUE)
R9_men<-read.table("E9_mensal.txt", header=TRUE)
R10_men<-read.table("E10_mensal.txt", header=TRUE)
R11_men<-read.table("E11_mensal.txt", header = TRUE)
R12_men<-read.table("E12_mensal.txt", header = TRUE)
R13_men<-read.table("E13_mensal.txt", header = TRUE)
R14_men<-read.table("E14_mensal.txt", header = TRUE)
R15_men<-read.table("E15_mensal.txt", header = TRUE)

```

```

R16_men<-read.table("E16_mensal.txt", header = TRUE)
R17_men<-read.table("E17_mensal.txt", header = TRUE)
R18_men<-read.table("E18_mensal.txt", header = TRUE)
R19_men<-read.table("E19_mensal.txt", header = TRUE)
R20_men<-read.table("E20_mensal.txt", header = TRUE)
R21_men<-read.table("E21_mensal.txt", header=TRUE)
R22_men<-read.table("E22_mensal.txt", header=TRUE)
R23_men<-read.table("E23_mensal.txt", header=TRUE)
R24_men<-read.table("E24_mensal.txt", header=TRUE)
R25_men<-read.table("E25_mensal.txt", header=TRUE)
R26_men<-read.table("E26_mensal.txt", header=TRUE)
R27_men<-read.table("E27_mensal.txt", header=TRUE)
R28_men<-read.table("E28_mensal.txt", header=TRUE)
R29_men<-read.table("E29_mensal.txt", header=TRUE)
R30_men<-read.table("E30_mensal.txt", header=TRUE)
R31_men<-read.table("E31_mensal.txt", header=TRUE)
R32_men<-read.table("E32_mensal.txt", header=TRUE)
R33_men<-read.table("E33_mensal.txt", header=TRUE)
R34_men<-read.table("E34_mensal.txt", header=TRUE)
R35_men<-read.table("E35_mensal.txt", header=TRUE)
R36_men<-read.table("E36_mensal.txt", header=TRUE)
R37_men<-read.table("E37_mensal.txt", header=TRUE)
R38_men<-read.table("E38_mensal.txt", header=TRUE)
R39_men<-read.table("E39_mensal.txt", header=TRUE)
R40_men<-read.table("E40_mensal.txt", header=TRUE)
R41_men<-read.table("E41_mensal.txt", header=TRUE)
R42_men<-read.table("E42_mensal.txt", header=TRUE)
R43_men<-read.table("E43_mensal.txt", header=TRUE)
R44_men<-read.table("E44_mensal.txt", header=TRUE)
R45_men<-read.table("E45_mensal.txt", header=TRUE)
R_mensal<-
rbind(R1_men,R2_men,R3_men,R4_men,R5_men,R6_men,R7_men,R8_men,R9_men,
      R10_men,R11_men,R12_men,R13_men,R14_men,R15_men,R16_men,R17_men,
      R18_men,R19_men,R20_men,R21_men,R22_men,R23_men,R24_men,R25_men,
      R26_men,R27_men,R28_men,R29_men,R30_men,R31_men,R32_men,R33_men,
      R34_men,R35_men,R36_men,R37_men,R38_men,R39_men,R40_men,R41_men,
      R42_men,R43_men,R44_men,R45_men)
# Labels
n1 <- factor(c("ALMA")); l1 <- as.matrix(rep(n1,12))
n2 <- factor(c("ALTOG")); l2 <- as.matrix(rep(n2,12))

```

```
n3 <- factor(c("ALVORADA")); I3 <- as.matrix(rep(n3,12))
n4 <- factor(c("ARAGUAÇU")); I4 <- as.matrix(rep(n4,12))
n5 <- factor(c("ARUANA")); I5 <- as.matrix(rep(n5,12))
n6 <- factor(c("AURORA")); I6 <- as.matrix(rep(n6,12))
n7 <- factor(c("BRITA")); I7 <- as.matrix(rep(n7,12))
n8 <- factor(c("BPEQ")); I8 <- as.matrix(rep(n8,12))
n9 <- factor(c("COL")); I9 <- as.matrix(rep(n9,12))
n10 <- factor(c("CONDTO")); I10 <- as.matrix(rep(n10,12))
n11 <- factor(c("DIAPOLIS")); I11 <- as.matrix(rep(n11,12))
n12 <- factor(c("ENGNOVO")); I12 <- as.matrix(rep(n12,12))
n13 <- factor(c("FAT")); I13 <- as.matrix(rep(n13,12))
n14 <- factor(c("FAZLOB")); I14 <- as.matrix(rep(n14,12))
n15 <- factor(c("GILA")); I15 <- as.matrix(rep(n15,12))
n16 <- factor(c("GUR")); I16 <- as.matrix(rep(n16,12))
n17 <- factor(c("JARAG")); I17 <- as.matrix(rep(n17,12))
n18 <- factor(c("JATO")); I18 <- as.matrix(rep(n18,12))
n19 <- factor(c("LEVER")); I19 <- as.matrix(rep(n19,12))
n20 <- factor(c("MAT")); I20 <- as.matrix(rep(n20,12))
n21 <- factor(c("NAT")); I21 <- as.matrix(rep(n21,12))
n22 <- factor(c("NCORDO")); I22 <- as.matrix(rep(n22,12))
n23 <- factor(c("PALMEI")); I23 <- as.matrix(rep(n23,12))
n24 <- factor(c("PARAISO")); I24 <- as.matrix(rep(n24,12))
n25 <- factor(c("PERES")); I25 <- as.matrix(rep(n25,12))
n26 <- factor(c("PINDORAN")); I26 <- as.matrix(rep(n26,12))
n27 <- factor(c("PIUM")); I27 <- as.matrix(rep(n27,12))
n28 <- factor(c("PALTABJ")); I28 <- as.matrix(rep(n28,12))
n29 <- factor(c("PONTEALTA")); I29 <- as.matrix(rep(n29,12))
n30 <- factor(c("PORTAL")); I30 <- as.matrix(rep(n30,12))
n31 <- factor(c("PRAIA")); I31 <- as.matrix(rep(n31,12))
n32 <- factor(c("PROJBCRUZ")); I32 <- as.matrix(rep(n32,12))
n33 <- factor(c("PROJFORM")); I33 <- as.matrix(rep(n33,12))
n34 <- factor(c("SANTEREZ")); I34 <- as.matrix(rep(n34,12))
n35 <- factor(c("SAOFLX")); I35 <- as.matrix(rep(n35,12))
n36 <- factor(c("SERMESA")); I36 <- as.matrix(rep(n36,12))
n37 <- factor(c("TAQUAR")); I37 <- as.matrix(rep(n37,12))
n38 <- factor(c("TESOU")); I38 <- as.matrix(rep(n38,12))
n39 <- factor(c("XAVANT")); I39 <- as.matrix(rep(n39,12))
n40 <- factor(c("ANAN")); I40 <- as.matrix(rep(n40,12))
n41 <- factor(c("MURICI")); I41 <- as.matrix(rep(n41,12))
n42 <- factor(c("GOIANT")); I42 <- as.matrix(rep(n42,12))
```

```

n43 <- factor(c("ESPERA")); l43 <- as.matrix(rep(n43,12))
n44 <- factor(c("ITUPIR")); l44 <- as.matrix(rep(n44,12))
n45 <- factor(c("JACUND")); l45 <- as.matrix(rep(n45,12))
Municipio <- rbind(l1,l2,l3,l4,l5,l6,l7,l8,l9,l10,l11,l12,l13,l14,l15,l16,
  l17,l18,l19,l20,l21,l22,l23,l24,l25,l26,l27,l28,l29,l30,l31,
  l32,l33,l34,l35,l36,l37,l38,l39,l40,l41,l42,l43,l44,l45)
Municipio <- t(Municipio)
rot<- matrix(Municipio,ncol=1);rot
R_mensal$Municipio <- rot
# Graficos em grupos
### Figura 5 cap 2 ###
win.graph(width=8, height=4,pointsize=8)
p5 <- ggplot(R_mensal, aes(reorder(x=mes, mes), y=precipitacao,group = Municipio))
p5 + geom_line(aes(color = Municipio))+ xlab("Meses") +
  ylab("Chuvas (mm)")+ggtitle("Medias mensais de chuvas")
# Graficos em paineis
(p5 <- p5 + geom_point() + geom_line() + xlab("Meses") + ylab("Chuvas (mm)")+
  facet_wrap(~Municipio, nrow=5)+
  ggtitle("Medias mensais no periodo de 1971 a 2017"))

##### arquivos de todas os regimes #####
alma_reg <- as.matrix(R1_men[,1])
rownames(alma_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
  "jul", "ago", "set", "out", "nov", "dez")
colnames(alma_reg) <- c("alma")
alma_reg <-t(alma_reg)
E1_reg.dat<-alma_reg
altog_reg <- as.matrix(R2_men[,1])
rownames(altog_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
  "jul", "ago", "set", "out", "nov", "dez")
colnames(altog_reg) <- c("altog")
altog_reg <-t(altog_reg)
E2_reg.dat<-altog_reg
alvo_reg <- as.matrix(R3_men[,1])
rownames(alvo_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
  "jul", "ago", "set", "out", "nov", "dez")
colnames(alvo_reg) <- c("alvo")
alvo_reg <-t(alvo_reg)
E3_reg.dat<-alvo_reg
arag_reg <- as.matrix(R4_men[,1])

```

```
rownames(arag_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(arag_reg) <- c("arag")
arag_reg <-t(arag_reg)
E4_reg.dat<-arag_reg
arua_reg <- as.matrix(R5_men[,1])
rownames(arua_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(arua_reg) <- c("arua")
arua_reg <-t(arua_reg)
E5_reg.dat<-arua_reg
auro_reg <- as.matrix(R6_men[,1])
rownames(auro_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(auro_reg) <- c("auro")
auro_reg <-t(auro_reg)
E6_reg.dat<-auro_reg
brita_reg <- as.matrix(R7_men[,1])
rownames(brita_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(brita_reg) <- c("brita")
brita_reg <-t(brita_reg)
E7_reg.dat<-brita_reg
bpeq_reg <- as.matrix(R8_men[,1])
rownames(bpeq_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(bpeq_reg) <- c("bpeq")
bpeq_reg <-t(bpeq_reg)
E8_reg.dat<-bpeq_reg
col_reg <- as.matrix(R9_men[,1])
rownames(col_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(col_reg) <- c("col")
col_reg <-t(col_reg)
E9_reg.dat<-col_reg
conc_reg <- as.matrix(R10_men[,1])
rownames(conc_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(conc_reg) <- c("conc")
conc_reg <-t(conc_reg)
```



```
colnames(jara_reg) <- c("jara")
jara_reg <- t(jara_reg)
E17_reg.dat <- jara_reg
jato_reg <- as.matrix(R18_men[,1])
rownames(jato_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(jato_reg) <- c("jato")
E18_reg.dat <- t(jato_reg)
leve_reg <- as.matrix(R19_men[,1])
rownames(leve_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(leve_reg) <- c("leve")
E19_reg.dat <- t(leve_reg)
mate_reg <- as.matrix(R20_men[,1])
rownames(mate_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(mate_reg) <- c("mate")
E20_reg.dat <- t(mate_reg)
nati_reg <- as.matrix(R21_men[,1])
rownames(nati_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(nati_reg) <- c("nati")
E21_reg.dat <- t(nati_reg)
novo_reg <- as.matrix(R22_men[,1])
rownames(novo_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(novo_reg) <- c("novo")
E22_reg.dat <- t(novo_reg)
palme_reg <- as.matrix(R23_men[,1])
rownames(palme_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(palme_reg) <- c("palme")
E23_reg.dat <- t(palme_reg)
parai_reg <- as.matrix(R24_men[,1])
rownames(parai_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
                        "jul", "ago", "set", "out", "nov", "dez")
colnames(parai_reg) <- c("parai")
E24_reg.dat <- t(parai_reg)
pere_reg <- as.matrix(R25_men[,1])
rownames(pere_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
```

```

      "jul", "ago", "set", "out", "nov", "dez")
colnames(pere_reg) <- c("pere")
E25_reg.dat <- t(pere_reg)
pind_reg <- as.matrix(R26_men[,1])
rownames(pind_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(pind_reg) <- c("pind")
E26_reg.dat <- t(pind_reg)
pium_reg <- as.matrix(R27_men[,1])
rownames(pium_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(pium_reg) <- c("pium")
E27_reg.dat <- t(pium_reg)
pabj_reg <- as.matrix(R28_men[,1])
rownames(pabj_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(pabj_reg) <- c("pabj")
E28_reg.dat <- t(pabj_reg)
palt_reg <- as.matrix(R29_men[,1])
rownames(palt_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(palt_reg) <- c("palt")
E29_reg.dat <- t(palt_reg)
pale_reg <- as.matrix(R30_men[,1])
rownames(pale_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(pale_reg) <- c("pale")
E30_reg.dat <- t(pale_reg)
praia_reg <- as.matrix(R31_men[,1])
rownames(praia_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(praia_reg) <- c("praia")
E31_reg.dat <- t(praia_reg)
prbc_reg <- as.matrix(R32_men[,1])
rownames(prbc_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(prbc_reg) <- c("prbc")
E32_reg.dat <- t(prbc_reg)
prfo_reg <- as.matrix(R33_men[,1])
rownames(prfo_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",

```

```

      "jul", "ago", "set", "out", "nov", "dez")
colnames(prfo_reg) <- c("prfo")
E33_reg.dat <- t(prfo_reg)
sant_reg <- as.matrix(R34_men[,1])
rownames(sant_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(sant_reg) <- c("sant")
E34_reg.dat <- t(sant_reg)
saof_reg <- as.matrix(R35_men[,1])
rownames(saof_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(saof_reg) <- c("saof")
E35_reg.dat <- t(saof_reg)
serr_reg <- as.matrix(R36_men[,1])
rownames(serr_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(serr_reg) <- c("serr")
E36_reg.dat <- t(serr_reg)
taqua_reg <- as.matrix(R37_men[,1])
rownames(taqua_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(taqua_reg) <- c("taqua")
E37_reg.dat <- t(taqua_reg)
tesou_reg <- as.matrix(R38_men[,1])
rownames(tesou_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(tesou_reg) <- c("tesou")
E38_reg.dat <- t(tesou_reg)
xavan_reg <- as.matrix(R39_men[,1])
rownames(xavan_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(xavan_reg) <- c("xavan")
E39_reg.dat <- t(xavan_reg)
anan_reg <- as.matrix(R40_men[,1])
rownames(anan_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(anan_reg) <- c("anan")
E40_reg.dat <- t(anan_reg)
muric_reg <- as.matrix(R41_men[,1])
rownames(muric_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",

```

```

      "jul", "ago", "set", "out", "nov", "dez")
colnames(muric_reg) <- c("muric")
E41_reg.dat <- t(muric_reg)
goiant_reg <- as.matrix(R42_men[,1])
rownames(goiant_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(goiant_reg) <- c("goiant")
E42_reg.dat <- t(goiant_reg)
esperan_reg <- as.matrix(R43_men[,1])
rownames(esperan_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(esperan_reg) <- c("esperan")
E43_reg.dat <- t(esperan_reg)
itupir_reg <- as.matrix(R44_men[,1])
rownames(itupir_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(itupir_reg) <- c("itupir")
E44_reg.dat <- t(itupir_reg)
jacund_reg <- as.matrix(R45_men[,1])
rownames(jacund_reg) <- c("jan", "fev", "mar", "abr", "mai", "jun",
      "jul", "ago", "set", "out", "nov", "dez")
colnames(jacund_reg) <- c("jacund")
E45_reg.dat <- t(jacund_reg)
##### arquivo com os regimes #####
clus_reg <- rbind(E1_reg.dat, E2_reg.dat, E3_reg.dat, E4_reg.dat, E5_reg.dat,
      E6_reg.dat, E7_reg.dat, E8_reg.dat, E9_reg.dat, E10_reg.dat,
      E11_reg.dat, E12_reg.dat, E13_reg.dat, E14_reg.dat, E15_reg.dat,
      E16_reg.dat, E17_reg.dat, E18_reg.dat, E19_reg.dat, E20_reg.dat,
      E21_reg.dat, E22_reg.dat, E23_reg.dat, E24_reg.dat, E25_reg.dat,
      E26_reg.dat, E27_reg.dat, E28_reg.dat, E29_reg.dat, E30_reg.dat,
      E31_reg.dat, E32_reg.dat, E33_reg.dat, E34_reg.dat, E35_reg.dat,
      E36_reg.dat, E37_reg.dat, E38_reg.dat, E39_reg.dat, E40_reg.dat,
      E41_reg.dat, E42_reg.dat, E43_reg.dat, E44_reg.dat, E45_reg.dat) ; clus_reg
write.table(clus_reg, "1.regimes_mes.txt") # regimes da serie de chuvas

```

Programa 3. Mapas geoestatísticos dos regimes de chuvas (janeiro)

```
##### Versão do R: R.3.1.1 #####
```

```
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapII/precip")
```

```
#####===== Shape da bacia do tocantos =====###
```

```
require('rgdal')
```

```

tocant <- readOGR('.', 'Municipios') # Municipios
spols <- polygons(tocant) # Criando um objeto "Spatial Polygon"
mtocant <- data.frame(tocant) # Criando um objeto "Dataframe"
xbor <- read.table("borda1.txt", head=T) # Arquivo de bordas da BHAT
coord <- read.table("amostra_chuva.txt", head=T) # Coordenadas das amostras
munic_laty <- tocant$LATITUDESE # Coordenadas dos municipios
munic_longx <- tocant$LONGITUDES
munic_coord <- cbind(munic_longx, munic_laty);
munic_coord <- as.data.frame(munic_coord)
munic_coord$munic <- munic_name
munic_coord$Estado <- tocant$UF
munic_geo1 <- mtocant$NOME
munic_geo2 <- mtocant$GEOCODIGO
munic_geo <- mtocant

### ===== 2. Mapas dos meses usando Krigagem ===== ###
#### Krigagem Ordinária usando o geoR ####
require(gstat)
require(geoR)
regimes <- read.table("1.regimes_mes.txt", head=T)
est <- cbind(coord, regimes) # amostras georeferenciadas
jan <- as.geodata(est, coords.col = 3:4, data.col = 6) # Precipitacoes janeiro
### 2.1. Analise semivariografica ###
varjan <- variog(jan, uvec = seq(0, 6, length = 25), option = "bin")
plot(varjan, pch=19, xlab = "Distância", ylab = "Semivariância", type="b")
title("Semivariograma Experimental: Prec. Jan")
#Semivariograma unidirecional e modelo ajustado
plot(varjan, pch=19, type="b", xlab = "Distância (Grau decimal)", ylab = "Semivariância")
lines.variomodel(cov.model = "spherical", cov.pars =
  rbind(c(1000,2), c(1200,4.5)), nugget = 0, max.dist = 7, lwd = 2, col = "red")
title("Variograma Experimental e modelo ajustado \n Chuvas Janeiro")
### 2.2 Krigagem e Mapa de krigagem ###
loc <- expand.grid(seq(-55.55, -45.40, l=60), seq(-18.933, -1.044, l=100))
kojan <- kslide(jan, locations=loc, cov.model = "spherical",
  cov.pars = rbind(c(1000,2), c(1200,4.5)), nugget = 0)
# definindo uma palleta de cores
require(maptools)
rgb.pal <- colorRampPalette(c("cyan", "green", "yellow", "red"), space = "rgb")
brks <- c(0, 50, 100, 200, 225, 250, 275, 300, 400) # lim max = 364 (jan) lim min = 54
cols <- rgb.pal(length(brks) - 1)
image(kojan, border=xbor, loc=loc, val=kojan$predict, col

```

```

    = rgb.pal(30),xlab=" ",ylab=" ")
legend(-59,-3, fill = cols, legend = leglabs(brks,"<",
    ">="),bty = "n", cex = 0.8,col=rgb.pal(30))
text(-58.5,-3.3,"Chuvas (mm) ",adj = c(0, 0),cex= 0.8,srt = 0)
library(maps)
map.scale(x=-48, y=-17.5, ratio=F, relwidth=0.20)
library(GISTools)
north.arrow(x=-44, y=-2.5, len=0.3, lab="N")
detach("package:GISTools", unload=TRUE)
title("Chuvas Janeiro")
tocant <-readOGR('.', 'Municipios') # Adicionando os municipios
spols<-polygons(tocant)
plot(spols, add=T,border="grey58", lwd=0.1)
#Labels
segments(-53.378,-15.907,-55.005,-16.953, col= 'black')
text(-56,-17.7,"Tesouro",adj = c(0, 0),cex=0.85,srt = 7)
segments(-47.802,-12.616,-44.898,-11.764, col= 'black')
text(-45.091,-11.764,"Paraná",adj = c(0, 0),cex=0.85,srt = 7)
segments(-49.728,-10.176,-45.169,-9.634, col= 'black')
text(-45,-9.5,"Pium",adj = c(0, 0),cex=0.85,srt = 7)
## 2.3. Valores de precipitacao de janeiro de cada municipio ###
mcoord <- cbind(munic_coord$munic_longx,munic_coord$munic_laty)
mcoord <-as.data.frame(mcoord)
kojanc <- kslide(jan, locations=mcoord, cov.model = "spherical" ,
    cov.pars = rbind(c(20000,0.5),c(4600,2.5)), nugget = 0)
precjan <- as.matrix(kojanc$predict)
prec_jan <- matrix(c(mcoord[,1],mcoord[,2],precjan,tocant$NOME),ncol=4)
prec_jan <- as.data.frame(prec_jan)
prec_jan[1:5,]
prec_jan$V4 <- NULL
prec_jan$mun <- tocant$NOME
colnames(prec_jan) <- c("x","y","prec_jan","mun")
write.table(prec_jan,file="prec_jan.txt")

```

Programa 4. Análise k-means

```

##### Versão do R: R.3.1.1 #####
##### K MEANS #####
rm(list=ls())
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapII/precip")

```

```

gmun<-read.table("clus2.txt", head=T)
# K-Means Cluster Analysis 4 GRUPOS ##
library(fpc)
fit <- kmeans(gmun,4);fit # 2 cluster solution
fit$size
### FIGURA 10.1 ###
plotcluster(gmun, fit$cluster)
title("Precipitação (K-means)")
write.table(fit$cluster,"3.mun_kmeans4.txt")
#Descritivas
gr <-as.data.frame(fit$cluster)
colnames(gr) <- c("grupos")
gr$grupos
muni <- seq(1:393)
grupos <- cbind(muni,gr$grupos)
colnames(grupos) <- c("mun", "grupos")
grupos <-as.data.frame(grupos)
grupos$GR <- ifelse(grupos$grupos==1, "G1",
  ifelse(grupos$grupos==2, "G2",
    ifelse(grupos$grupos==3, "G3", "G4")))
tab1 <- table(grupos$GR);tab1
tba1 <- as.data.frame(tab1)
tba1$Freq
tba1$Freq/nrow(grupos) # cria variavel percentagem
Porc <- round(tba1$Freq/nrow(grupos)*100, dig = 2) # cria variavel percentagem
tab1 <- cbind(tab1,Porc);tab1
colnames(tab1) <- c("Freq", "Porc")
km4 <- cbind(gmun,grupos)
mjan <-round(tapply(km4$jan,km4$GR,mean),dig=2) ;mjan
mfev <-round(tapply(km4$fev,km4$GR,mean),dig=2) ;mfev
mmar <-round(tapply(km4$mar,km4$GR,mean),dig=2) ;mmar
mabr <-round(tapply(km4$abr,km4$GR,mean),dig=2) ;mabr
mmai <-round(tapply(km4$mai,km4$GR,mean),dig=2) ;mmai
mjun <-round(tapply(km4$jun,km4$GR,mean),dig=2) ;mjun
mjul <-round(tapply(km4$jul,km4$GR,mean),dig=2) ;mjul
mago <-round(tapply(km4$ago,km4$GR,mean),dig=2) ;mago
mset <-round(tapply(km4$set,km4$GR,mean),dig=2) ;mset
mout <-round(tapply(km4$out,km4$GR,mean),dig=2) ;mout
mnov <-round(tapply(km4$nov,km4$GR,mean),dig=2) ;mnov
mdez <-round(tapply(km4$dez,km4$GR,mean),dig=2) ;mdez

```

```

mgrupo <- rbind(mjan,mfev,mmar,mabr,mmai,mjun,mjul,mago,mset,mout,mnov,mdez)
mgrupo <-as.data.frame(mgrupo)
summary(mgrupo$G1); summary(mgrupo$G2) ; summary(mgrupo$G3) ; summary(mgrupo$G4)
desc_G1 <- summary(mgrupo$G1); desc_G2 <- summary(mgrupo$G2)
desc_G3 <- summary(mgrupo$G3); desc_G4 <- summary(mgrupo$G4)
desc <- rbind(desc_G1,desc_G2,desc_G3,desc_G4);desc
desc <- cbind(desc,tab1$Freq) ; desc
colnames(desc) <- c("Min.", "1st Qu.", "Median", "Mean", "3rd Qu.", "Max.", "N")
rownames(desc) <- c("Grupo1", "Grupo2", "Grupo3", "Grupo4")
write.table(desc,file="4.Desc_kmprec4.txt")

```

Programa 5. Mapa de grupos formados por k-means

```

##### Versão do R: R.3.1.1 #####
### Mapas dos grupos formados por k-means ###
require(XML)
require(RCurl)
require(maptools)
require(RColorBrewer)
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapII/precip")
mapaUF = readShapePoly("Municipios.shp") # Mapa do Tocantins
mapaUF$GEOCODIGO <- as.factor(mapaUF$GEOCODIGO)
mapaUF$NOME <- as.factor(mapaUF$NOME)
muni <- as.data.frame(mapaUF$NOME); muni
munig <- as.data.frame(mapaUF$GEOCODIGO)
tmuni <- cbind(muni,munig)
### Tabela com os grupos K-MEANS ###
grupo1 <-read.table("5.grupos_geo4.txt", head=T)
grupo1$GEOCODIGO <-as.factor(grupo1$GEOCODIGO)
# Escolhendo as cores do mapa #
a <- c(1:4)
corDegrade <- colorRampPalette(c("cyan","red","darkblue","green"))
corDegrade(4)
barplot(a, col=corDegrade(4))
paletareg = corDegrade(4)
coresreg = data.frame(GRUPO=levels(grupo1$GRUPO),Cores=paletareg)
grupo1 = merge(grupo1,coresreg)
grupo1 = grupo1[order(as.numeric(grupo1$id)),] # reordenando os dados
# Pareamento entre os dados da tabela e o mapa:
mapadat = attr(mapaUF, 'data')
mapadat$Index = row.names(mapadat)

```

```

mapadat = cbind(mapadat, grupo1, by="GEOCODIGO")
mapadat = mapadat[order(as.numeric(mapadat$Index)),] # Reordenação dos dados do mapa
attr(mapadat, 'data') = mapadat
# Configurando tela (reduzindo as margens da figura)
parDefault = par(no.readonly = T)
layout(matrix(c(1,2),nrow=2),widths= c(1,1), heights=c(4,1))
par (mar=c(0,0,0,0))
plot(mapaUF, col=as.character(mapadat$Cores), lwd=1) # ,border="grey85")
plot(1,1,pch=NA, axes=F)
legend(x='center', legend=rev(levels(mapadat$GRUPO)),
      box.lty=0, fill=rev(paletaReg),cex=.8, ncol=2,
      title=' Precipitação \n Grupos formados por k-Means')

```

Programa 6. Previsão de series temporais por Box-Jenkins

```

### Versao do R: R.3.1.1 ###
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapIII/R_artigo")
### 1.1 Estacao E19: Leverger (Chuvas) ###
lever_imp<- read.table("E19_lever.txt", head=T)
### Grafico da serie (FIGURA 3 Capitulo III) ###
E19t <-ts(lever_imp$x,start=c(1969),freq=12)
win.graph(width=8, height=4,pointsize=9)
plot.ts(E19t,main='Estação Leverger (MT)',ylab='Precipitação (mm)',xlab=' ')
  Xtick = c(2016,2017)
  axis(side=1,lwd=2,at=Xtick,labels=Xtick,tick=TRUE,las=2,col="red")
  abline(v = 2016, col="red", lty = 1, lwd=2)
  abline(v = 2017, col="red", lty = 1, lwd=2)
  text(1990,550,"Conjunto de Treinamento",col="black",cex=1.5)
  text(2018.1,450,"Conjuntos de Teste",col="red",cex=1.2,srt = 90)
### 3. Ajuste do modelo por Serie temporal #####
### OBS: modelo ate dez 2016 previsoes e validade do modelo jan a dez de 2017
library(tseries)
library(forecast)
library(stats)
library(lmtest)
R1p <-ts(lever_imp,start=c(1969,1),end=c(2016,12),freq=12)
plot.ts(R1p,main='Estacao Leverger',ylab='Precipitacao (mm)',xlab=' ')
## Funcoes de autocorrelacao ##
library(TSA)
R1p <-ts(lever_imp,start=c(1969,1),end=c(2016,12),freq=12)
model1=lm(R1p~time(R1p))

```

```

#summary(model1)
par(mfrow=c(2,1))
acf(rstudent(model1),main='FAC da Serie Leverger', drop.lag.0 = TRUE,type = c("correlation"))
acf(rstudent(model1),main='FACP da Serie Leverger',ylab='FACP', drop.lag.0 = TRUE,type =
c("partial"))
detach("package:TSA", unload=TRUE)
# MODELO SELECIONADO
R1_fit <- arima(R1p, include.mean = TRUE, order = c(13,0,0),
              seasonal = list(order = c(0,1,1), period =12))
coefstest(arima(R1p, include.mean = TRUE, order = c(13,0,0),
              seasonal = list(order = c(0,1,1), period =12)))
# Auto correlacoes residuais
Box.test(R1_fit$res, lag = 24, type = c("Box-Pierce", "Ljung-Box"))
Box.test(R1_fit$res, lag = 36, type = c("Box-Pierce", "Ljung-Box"))
Box.test(R1_fit$res, lag = 48, type = c("Box-Pierce", "Ljung-Box"))
library(forecast)
R1_fore <- forecast(R1_fit,h=12)
R1_fore <- forecast.Arima(R1_fit,h=12)
R1_serie<-R1_fore$x #time serie
R1_tab<-cbind(R1_serie,R1_fore$fitted);R1_tab
lo<-R1_fore$fitted-1.96*sqrt(R1_fit$sigma2);lo # IC inf
up<-R1_fore$fitted+1.96*sqrt(R1_fit$sigma2);up # IC sup
R1_tab1<-as.data.frame(R1_tab)
R1_tab1$"Point Forecast"<- R1_fore$fitted
R1_tab1$"Lo 95"<-lo
R1_tab1$"Hi 95"<-up
library(ggplot2)
R1c = data.frame(date = as.yearmon(1969 + seq(0, 575)/12), precipitacao = R1_tab1$"Point
Forecast")
R1c$plb = R1_tab1$"Lo 95"
R1c$pub = R1_tab1$"Hi 95"
R1c$serie= R1_serie
R1c$date <- as.Date(R1c$date, format = "%b-%y")
### Grafico do modelo ajustado ###
R1_m1<-ggplot(R1c, aes(x=date)) +
  geom_line(aes(y=precipitacao), colour="red",size = 0.8) +
  geom_line(aes(y=serie), colour="black",size = 0.5,linetype = 5) +
  geom_ribbon(aes(ymin=plb, ymax=pub), alpha=0.2)+
  xlab(" ") +
  ylab("Precipitacao (mm)")+

```

```

geom_text(aes(label = "Modelo",
  x = date[350],
  y = 590),
  colour = "red")+
geom_text(aes(label = "      _____",
  x = date[400],
  y = 610),
  colour = "red")+
geom_text(aes(label = "Observado - - - - -",
  x = date[380],
  y = 540),
  colour = "black")
(R1_m2<-R1_m1+ ggtitle("Modelo BJ ajustado. Serie Leverger"))
### Grafico das Previsoes ###
#tlever <- matrix(lever_imp,ncol=1)
tlever <- lever_imp#x
dlever<-as.data.frame(tlever)
dlever$x[577:588] # chuvas de 2017
R1_2017 <-dlever$x[577:588];R1_2017
tab_fore <-as.data.frame(R1_fore);tab_fore
tab_2017<-cbind(R1_2017,tab_fore);tab_2017
R1p = data.frame(date = as.yearmon(2017 + seq(0, 11)/12), precipitacao = tab_2017$"Point
Forecast")
R1p$plb = tab_2017$"Lo 95"
R1p$pub = tab_2017$"Hi 95"
R1p$serie=R1_2017
R1p$date <- as.Date(R1p$date, format = "%b-%y")
##### Fig 4 Previsoes #####
R1_p1<-ggplot(R1p, aes(x=date)) +
  geom_point(aes(y=precipitacao),colour="red",fill = "red",size = 2,shape=22)+
  geom_point(aes(y=serie))+
  geom_line(aes(y=precipitacao), colour="red",size = 0.8) +
  geom_line(aes(y=serie), colour="black",size = 0.5,linetype = 5) +
  geom_ribbon(aes(ymin=plb, ymax=pub), alpha=0.2)+
  xlab(" ") +
  ylab("Precipitacao (mm)")+
  geom_text(aes(label = "Modelo",
  x = date[7],
  y = 500),
  colour = "red")+

```

```

geom_text(aes(label = " _____ ",
x = date[8],
y = 520),
colour = "red")+
geom_text(aes(label = " Observado - - - - - ",
x = date[7],
y = 450),
colour = "black")
(R1_p2<-R1_p1+ ggtitle("Previsões e valores observados com BJ. Série Leverger"))
# Calculo do erro rmse
# sqrt(mean((d$prediction-d$y)^2))
erro_bj <- sqrt(mean((tab_2017$R1_2017-tab_2017$"Point Forecast")^2))
erro_bj # Modelo 2: erro 105.5486
#### Fig 7 Diagnostico FAC e FACP (residuos)#####
library(TSA)
par(mfrow=c(2,1))
acf(R1_fit$residuals,lag.max = 24,main='FAC dos residuos. Serie Leverger', drop.lag.0 = TRUE)
pacf(R1_fit$residuals,lag.max = 24,main='FACP dos residuos. Serie Leverger')

```

Programa 7. Previsao de series temporais por redes Neurais

```

### Versão do R: R.3.5.1 ###
library(nnfor)
library(ggplot2)
library(zoo)
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapIII")
ty <- read.table("tslever.txt", header=T) # Dados de entrada
colnames(ty) <- c("chuva")
lever <- ts(ty,start=c(1969,1),freq=12) # Serie Imputada
### Ajuste do modelo por RN #####
### OBS: modelo ate dez 2016 previsoes e validade do modelo jan a dez de 2017
# Grafico da serie
win.graph(width=8, height=4,pointsize=12)
y <- ts(lever,start=c(1969,1),end=c(2016,12),freq=12)
plot.ts(y,main='Estacao Leverger',ylab='Precipitacao',xlab=' ')
h <- frequency(y);h # previsoes
tt <- cbind(c(1:(length(y)+h),rep(0,h))) # 1 ano
fit1 <- mlp(y,difforder=0,lags=0,xreg=tt,xreg.lags=list(0),xreg.keep=TRUE)
print(fit1); plot(fit1)
ts.plot(y,fit1$fitted,gpars=list(xlab="", ylab='Precipitação (mm)',
lty=c(1:2),lwd=c(1,2),col=c("red","blue")))

```

```

legend(1967.1,640,legend=c('Chuvas_obs','Chuvas_fit'),
      lty=1:2,col=c("red","blue"))
prev <- forecast(fit1,h=h,xreg=tt)
prev$all.mean # previsoes rn
plot(forecast(fit1,h=h,xreg=tt))
## editando as previsoes ##
fore <- as.data.frame(prev$all.mean)
write.table(fore,"fore_rn.txt") # salvando os resultados
fore$Mfore <- apply(fore,1,mean, na.rm=TRUE) #médias das linhas (1) (anos)
rn1 <- ts(fore$NN.1,start=c(2017,1),freq=12)
rn2 <- ts(fore$NN.2,start=c(2017,1),freq=12)
rn3 <- ts(fore$NN.3,start=c(2017,1),freq=12)
rn4 <- ts(fore$NN.4,start=c(2017,1),freq=12)
rn5 <- ts(fore$NN.5,start=c(2017,1),freq=12)
rn6 <- ts(fore$NN.6,start=c(2017,1),freq=12)
rn7 <- ts(fore$NN.7,start=c(2017,1),freq=12)
rn8 <- ts(fore$NN.8,start=c(2017,1),freq=12)
rn9 <- ts(fore$NN.9,start=c(2017,1),freq=12)
rn10 <- ts(fore$NN.10,start=c(2017,1),freq=12)
rn11 <- ts(fore$NN.11,start=c(2017,1),freq=12)
rn12 <- ts(fore$NN.12,start=c(2017,1),freq=12)
rn13 <- ts(fore$NN.12,start=c(2017,1),freq=12)
rn14 <- ts(fore$NN.14,start=c(2017,1),freq=12)
rn15 <- ts(fore$NN.15,start=c(2017,1),freq=12)
rn16 <- ts(fore$NN.16,start=c(2017,1),freq=12)
rn17 <- ts(fore$NN.17,start=c(2017,1),freq=12)
rn18 <- ts(fore$NN.18,start=c(2017,1),freq=12)
rn19 <- ts(fore$NN.19,start=c(2017,1),freq=12)
rn20 <- ts(fore$NN.20,start=c(2017,1),freq=12)
rnmed <- ts(fore$Mfore,start=c(2017,1),freq=12)
#class(lever)
lever <- as.data.frame(lever)
#dim(lever)
#lever[577:588,]
y2017 <- ts(lever[577:588,],start=c(2017,1),freq=12)
#plot.ts(y2017,main='Estacao Leverger',ylab='Precipitacao',xlab=' ')
ts.plot(rn1,rn2,rn3,rn4,rn5,rn6,rn7,rn8,rn9,rn10,
       rn11,rn12,rn13,rn14,rn15,rn16,rn17,rn18,rn19,rn20,rnmed,y2017,
       gpars=list(xlab="", ylab='Precipitação (mm)'),
       lwd=c(1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,3,3),

```



```

### Versao do R: R.3.1.1. ###
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapIII/BJ")
library(geoR)
library(gstat)
library(lattice)
library(sp)
# Arquivos com os dados de previsao (modelo BJ) no ano de 2017 #
est <- read.table("est_bj.txt", head=T) # previsoes
coord <- read.table("coord.txt", head=T) # refazer
##### MODELO VARIOGRAFICO ESPACO TEMPORAL #####
prec_est <- as.data.frame(cbind(coord$x,coord$y,est$jan,est$fev,est$mar,
                                est$abr,est$mai,est$jun,est$jul,est$ago,
                                est$set,est$out,est$nov,est$dez))
colnames(prec_est) <- c("x","y","jan","fev","mar","abr","mai",
                        "jun","jul","ago","set","out","nov","dez")
prec_est$mar <- ifelse(prec_est$mar<0,0,prec_est$mar)
prec_est$mai <- ifelse(prec_est$mai<0,0,prec_est$mai)
prec_est$jun <- ifelse(prec_est$jun<0,0,prec_est$jun)
prec_est$jul <- ifelse(prec_est$jul<0,0,prec_est$jul)
prec_est$ago <- ifelse(prec_est$ago<0,0,prec_est$ago)
prec_est$set <- ifelse(prec_est$set<0,0,prec_est$set)
### 2. Analise semivariografica (gstat) ###
### 2.1 Precipitacoes estimadas #####
# Semivariograma Experimental #
gdados <- gstat(NULL, "JAN", jan~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "FEV", fev~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "MAR", mar~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "ABR", abr~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "MAI", mai~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "JUN", jun~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "JUL", jul~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "AGO", ago~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "SET", set~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "OUT", out~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "NOV", nov~1, locations=~x+y, prec_est)
gdados <- gstat(gdados, "DEZ", dez~1, locations=~x+y, prec_est)
vario <- variogram(gdados,cross=FALSE)
plot(vario,xlab = "Distância", ylab = "Semivariância", layout=c(3,6), type = "o",pch=19)
vario[1:15,1] # np *numero de pontos)
vario[1:15,2] # distancia

```

```

vario[1:15,3] # gamma (variograma) jan
vario1 <- vario[1:15,] # variograma de jan
vario <- cbind(vario[1:15,1],vario[1:15,2],
              vario[1:15,3],vario[16:30,3],vario[31:45,3],vario[46:60,3],
              vario[61:75,3],vario[76:90,3],vario[91:105,3],vario[106:120,3],
              vario[121:135,3],vario[136:150,3],vario[151:165,3],vario[166:180,3])
colnames(vario) <-c("n","dist","g1","g2","g3","g4",
                  "g5","g6","g7","g8",
                  "g9","g10","g11","g12")
vario <-as.data.frame(vario)
attach(vario)
# Arquivos com as somatorias ao quadrado de cada campanha
vario$sum1 <- 2*n*g1;vario$sum2 <- 2*n*g2;vario$sum3 <- 2*n*g3
vario$sum4 <- 2*n*g4;vario$sum5 <- 2*n*g5;vario$sum6 <- 2*n*g6
vario$sum7 <- 2*n*g7;vario$sum8 <- 2*n*g8;vario$sum9 <- 2*n*g9
vario$sum10 <- 2*n*g10;vario$sum11 <- 2*n*g11;vario$sum12 <- 2*n*g12
# Arquivo com a somatoria total
vario$sum <- vario$sum1+vario$sum2+vario$sum3+vario$sum4+
              vario$sum5+vario$sum6+vario$sum7+vario$sum8+
              vario$sum9+vario$sum10+vario$sum11+vario$sum12
# variograma conjunto dos 12 meses
vario$gamma <- vario$sum/2*n
# Substituindo o variograma conjunto em um arquivo "gstatVariogram" (vario1) para plotar
vario1$gamma <- vario$gamma
varioge <- vario1
plot(varioge, pch=20,lty=2,lwd=2,type="b",col="black",main="Variograma ST")
#1. modelo ajustado pelo gstat
fvest <- fit.variogram(vario1, mvario, fit.sills = F, fit.ranges = T)
plot(vario1, pch = 20,cex=1.2,lty=1,lwd=2, col="black",fvest,type="b",
      xlab="Distancia (graus decimais)",main = " ")
mvario <-vgm(7000000, "Sph",3.47651, nugget = 0) # Modelo ajustado (fvest)
plot(varioge, pch = 20,cex=1.2,lty=1,lwd=2, col="black",fvest,type="b",
      xlab="Distancia (graus decimais)",ylab="Semivariancia",main = "Modelo ST ajustado")
## 3.1.1 Precipitacoes ESTIMADAS (Previsoes) para janeiro de 2017
#### Mapa de Krigagem (GeoR) ####
## 1.2 Arquivo de bordas
xbor <- read.table("borda1.txt", head=T)
loc <- expand.grid(seq(-55.55,-45.40,l=60),seq(-18.933, -1.044,l=100))
jan <- as.geodata(prec_est,coords.col = 1:2, data.col = 3)
kojane <- kslide(jan, locations=loc, cov.model = "spherical" ,

```

```

cov.pars = c(7000000,3.47651), nugget = 0)
# definindo uma palleta de cores
require(maptools)
rgb.pal <- colorRampPalette(c("blue","cyan","green","yellow","red"), space = "rgb")
brks <- c(0,150,200,250,300,350,400,450,500,550,600)
cols <- rgb.pal(length(brks) - 1)
nf <- layout(matrix(1), widths = lcm(12), heights = lcm(14.5))
image(kojane, border=xbor, loc=loc, val=kojane$predict, col
      = rgb.pal(30),ylab=" ",xlab=" ")
legend(-58,-4, fill = cols, legend = leglabs(brks,"<",
      ">="),bty = "n", cex = 0.8,col=rgb.pal(30))
text(-58,-4.3,"Precipitação (mm)",adj = c(0, 0), srt = 0,cex=0.75)
library(maps)
map.scale(x=-48, y=-17, ratio=F, relwidth=0.20)
library(GISTools)
north.arrow(x=-45, y=-3, len=0.3, lab="N")
detach("package:GISTools", unload=TRUE)
title("Mapa de previsão (BJ): janeiro 2017")
# Adicionando os municipios
require('rgdal')
tocant <-readOGR('.', 'Municipios')
spols<-polygons(tocant)
plot (spols, add=T,border="grey50", lwd=0.5) # municipios

```

Programa 9. Análise Exploratoria de Dados Espaciais

```
### Versao do R: R.3.5.1. ###
```

```

library(raster)
library(rgdal)
library(ggplot2)
library(broom)
library(RColorBrewer)
library(rgeos)
library(dplyr)
library(maptools)
library(ggsn)
#===== 1. Carregar arquivo de dados =====#
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapIV")
dados <- read.csv2("capivcorr.csv", header = TRUE,
      sep = ";", quote = "\"",dec = ".",fill = TRUE)
#===== 2. Mapas Tematicos : Reb. Bov. e Culttemp =====#

```

```

library(rgdal)
library(GISTools)
library(maps)
mapaUF <- readOGR("Municipios.shp")
plot(mapaUF,axes=T)
setwd("C:/Agenda2017/Camil/AFINAL/3.Tese/4.Analises/CapII/precip")
estados = readShapePoly("Estados.shp") #ok
plot(estados, add=T,border="grey28", lwd=3) # estados
### 2.1. Variavel Rebanho Bovino (boi): Figura 10(A) (Tese) ###
# incluir a variavel reb no arquivo shape #
mapaUF$boi <- dados$boi/1000
mapaUF$boi <- cut(mapaUF$boi,
  breaks = c(-1,250,500,1000,3000,12000),
  labels=c("0 |- 250", "250 |- 500", "500 |- 1000", "1000 |- 3000", "3000 |- 12000"))
levels(mapaUF$boi)
breaks <- seq(1, 5, 1)
np <- findInterval(mapaUF$boi, breaks)
table(np)
colors <- c("blue", "cyan", "green", "yellow", "red")
plot(mapaUF, col = colors[np],axes=TRUE,border="grey")
title("Rebanho Bovino Total (x 1000) cab. \n BHAT (2000 2007)")
legend(-59.5, -5.0,cex=0.8, bty = "n", fill = colors,
legend = levels(mapaUF$boi)[1:5])
text(x=-56, y=-5, "Rebanho Bovino (x 1000)", cex=0.8)
text(x=-59, y=-2, "(A)", cex=0.8)
map.scale(x=-48, y=-17, ratio=FALSE, relwidth=0.2)
north.arrow(x=-43, y=-3, len=0.25, lab="N")
plot(estados, add=T,border="black", lwd=2) # estados
### 2.2 Cutura Temporaria (cultt) : Figura 10(B) (Tese)###
mapaUF$cultt <- dados$cultt/100
mapaUF$cultt <- cut(mapaUF$cultt,
  breaks = c(-1,250,500,1000,5000,25000),
  labels=c("0 |- 250", "250 |- 500", "500 |- 1000", "1000 |- 5000", "5000 |- 25000"))
levels(mapaUF$cultt)
breaks <- seq(1, 5, 1)
nc <- findInterval(mapaUF$cultt, breaks)
table(nc)
colors <- c("blue", "cyan", "green", "yellow", "red")
plot(mapaUF, col = colors[nc],axes=TRUE,border="grey")
title("Cultura Temporaria (x 100 ha)\n BHAT (2000 a 2007)")

```

```

legend(-59.5, -5.0,cex=0.8, bty = "n", fill = colors,
legend = levels(mapaUF$culitt)[1:5])
text(x=-56, y=-5,"  Cultura temporaria (x 100 ha)",cex=0.8)
text(x=-59, y=-2,"(B)",cex=0.8)
map.scale(x=-48, y=-17, ratio=FALSE, relwidth=0.2)
north.arrow(x=-43, y=-3, len=0.25, lab="N")
plot (estados, add=T,border="black", lwd=2) # estados
#===== 3. Correlacao Espacial: Chuva, vazao =====#
### 3.1. Chuvas e vazoes por municipio ###
mc1 <- dados[,8:19] # dados de Chuva
# médias das linhas (1): municipios
Mc1m <-apply(mc1,1,mean, na.rm=TRUE) ; Mc1m
mc1med <-cbind(mc1,c(Mc1m),dados$Grupo) # acrescentar a coluna com as Medias dos anos
colnames(mc1med) <- c("janp","fevp","marp","abrp","maip","junp",
"julp","agop","setp","outp","novp","dezp","medch","Grupo")
med_chuvg <- tapply(mc1med$medch,mc1med$Grupo,mean,na.rm = TRUE) ;med_chuvg
mv1 <- dados[,20:31] # dados de Vazoes
# médias das linhas (1) municipios
Mv1m <-apply(mv1,1,mean, na.rm=TRUE) ; Mv1m
mv1med <-cbind(mv1,c(Mv1m),dados$Grupo) # acrescentar a coluna com as Medias dos anos
colnames(mv1med) <- c("jan","fev","mar","abr","mai","jun",
"jul","ago","set","out","nov","dez","medvz","Grupo")
med_vazg <- tapply(mv1med$medvz,mv1med$Grupo,mean,na.rm = TRUE) ;med_vazg
chmed <- mc1med[,13] # chuvas medias
vzmed <- mv1med[,13] # vazoes medias
vzmed <- ifelse(vzmed<0,0,vzmed)
# Incluir as variaveis no arquivo shape "mapaUF"
mapaUF$chuva <- chmed
mapaUF$vazao <- vzmed
mapaUF$pivo <- dados$pivo
mapaUF$culitt <- dados$culitt/100 ##### x 100 ha
mapaUF$boi <- dados$boi/1000 ##### x 1000 cab
### 3.2. Correlacao entre vazao e chuva ###
x <- mapaUF$chuva ;x
y <- mapaUF$vazao ;y
# Bivariate Moran's I
moran_I <- function(x, y = NULL, W){
if(is.null(y)) y = x
xp <- scale(x)[, 1]
yp <- scale(y)[, 1]

```

```

W[which(is.na(W))] <- 0
n <- nrow(W)
global <- (xp%*%W%*%yp)/(n - 1)
local <- (xp*W%*%yp)
list(global = global, local = as.numeric(local))
}
# Permutations for the Bivariate Moran's I
simula_moran <- function(x, y = NULL, W, nsims = 2000){
  if(is.null(y)) y = x
  n = nrow(W)
  IDs = 1:n
  xp <- scale(x)[, 1]
  W[which(is.na(W))] <- 0
  global_sims = NULL
  local_sims = matrix(NA, nrow = n, ncol=nsims)
  ID_sample = sample(IDs, size = n*nsims, replace = T)
  y_s = y[ID_sample]
  y_s = matrix(y_s, nrow = n, ncol = nsims)
  y_s <- (y_s - apply(y_s, 1, mean))/apply(y_s, 1, sd)
  global_sims <- as.numeric( (xp%*%W%*%y_s)/(n - 1) )
  local_sims <- (xp*W%*%y_s)
  list(global_sims = global_sims,
       local_sims = local_sims)
}
# Adjacency Matrix (Queen)
library(spdep)
nb <- poly2nb(mapaUF)
lw <- nb2listw(nb, style = "B", zero.policy = T)
W <- as(lw, "symmetricMatrix")
W <- as.matrix(W/rowSums(W))
W[which(is.na(W))] <- 0
# Calculating the index and its simulated distribution
# for global and local values
m <- moran_I(x, y, W)
# Global Moran
global_moran <- m[[1]][1] ;global_moran
IMchxvz <- global_moran
# Local values
m_i <- m[[2]]
# local simulations

```

```

local_sims <- simula_moran(x, y, W)$local_sims
# global pseudo p-value
# get all simulated global moran
global_sims <- simula_moran(x, y, W)$global_sims
# Proportion of simulated global values taht are higher (in absolute terms) than the actual
index
moran_pvalue <- sum(abs(global_sims) > abs( global_moran )) / length(global_sims)
moran_pvalue
pIMchxvz <- moran_pvalue ; pIMchxvz
# Identifying the significant values
alpha <- .05 # for a 95% confidence interval
probs <- c(alpha/2, 1-alpha/2)
intervals <- t( apply(local_sims, 1, function(x) quantile(x, probs=probs)))
sig <- ( m_i < intervals[,1] ) | ( m_i > intervals[,2] )
# Preparing for plotting
library(stringr)
library(magrittr)
library(ggplot2)
library(sf)
# Convert shape file into sf object
mapaUF_sf <- st_as_sf(mapaUF)
mapaUF_sf$sig <- sig
# Identifying the LISA clusters
xp <- scale(x)[,1]
yp <- scale(y)[,1]
m[1] # Indice Bivariado Global de Moran = 0.1709
# Grafico de Dispaersao : Fig 11 (Tese)
plot(xp, yp,pch=19, xlab=c("Chuva (mm)"),
      ylab = expression(paste("Vazao ", (m^3/s) , sep="")),
      main = "Moran Bivariado \n I = 0.1709 (Chuva x Vazão) ")
abline(h = 0, v = 0)
abline(lm(yp ~ xp), lty = 1, lwd = 4, col = "red")
# LISA Map
patterns <- as.character( interaction(xp > 0, W%*%yp > 0) )
table(patterns)
patterns1 <- as.numeric( interaction(xp > 0, W%*%yp > 0) )
table(patterns1)
patterns <- patterns %>%
  str_replace_all("TRUE", "High") %>%
  str_replace_all("FALSE", "Low")

```

```

patterns[mapaUF_sf$sig==0] <- "Not significant"
mapaUF_sf$patterns <- patterns
mapaUF_sf$patterns2 <- factor(mapaUF_sf$patterns, levels=c("High.High", "High.Low",
"Low.High", "Low.Low", "Not significant"),
      labels=c("High chuva - High vazao", "High chuva - Low vazao",
      "Low chuva - High vazao","Low chuva - Low vazao", "Not significant"))
# GRAFICO DA TESE : Figura 12(A)
mapaUF <- readOGR("Estados.shp")
mapaUF$MSLINK[is.na(mapaUF$MSLINK)] <- "Unknown"
unique(mapaUF$MSLINK)
#Let's convert your spatial object to a data.frame.
# convert spatial object to a ggplot ready data frame
mapaUF_df <- tidy(mapaUF, MSLINK = "id")
# make sure the shapefile attribute table has an id column
mapaUF$id <- rownames(mapaUF@data)
# join the attribute table from the spatial object to the new data frame
mapaUF_df <- left_join(mapaUF_df,
      mapaUF@data,
      by = "id")
ggplot() +
  geom_sf(data=mapaUF_sf, aes(fill=patterns2), color="NA") +
  scale_fill_manual(values = c("red", "pink", "light blue", "dark blue", "grey80")) +
  guides(fill = guide_legend(title="LISA clusters (Chuva x Vazao)")) +
  geom_path(data = mapaUF_df, aes(x = long, y = lat, group = group))+
  labs(title = " Moran Bivariado Local (LISA)\n          Chuva x Vazão") +
  geom_text(aes(label = "(A)",
      x = -54,
      y = -2),
      colour = "black")
theme_minimal()

```