

UNIVERSIDADE FEDERAL DO ABC
CENTRO DE ENGENHARIA, MODELAGEM E CIÊNCIAS SOCIAIS
APLICADAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA
AMBIENTAL

Maria Gabriela Louzada Malfatti

ESTUDO E DESENVOLVIMENTO DE MODELAGEM PARA
PREVISÃO DE VAZÃO DE RIOS NA BACIA DO PARANÁ

Santo André - SP

2016

Maria Gabriela Louzada Malfatti

**ESTUDO E DESENVOLVIMENTO DE MODELAGEM PARA
PREVISÃO DE VAZÃO DE RIOS NA BACIA DO PARANÁ**

Dissertação apresentada ao Programa de Pós-Graduação em
Ciência e Tecnologia Ambiental da Universidade Federal do
ABC, como requisito parcial à obtenção do título de Mestre em
Ciência e Tecnologia Ambiental. Linha de pesquisa: Sistemas
Ambientais

Orientadora: Prof^ª Dr^ª Andréa de Oliveira Cardoso

Coorientadora: Prof^ª Dr^ª Diana Sarita Hamburger

Santo André – SP

2016

Sistema de Bibliotecas da Universidade Federal do ABC
Elaborada pelo Sistema de Geração de Ficha Catalográfica da UFABC
com os dados fornecidos pelo(a) autor(a).

Malfatti, Maria Gabriela Louzada

Estudo e desenvolvimento de modelagem para previsão de vazão de rios na
bacia do Paraná / Maria Gabriela Louzada Malfatti. — 2016.

155 fls. : il.

Orientadora: Andréa de Oliveira Cardoso
Coorientadora: Diana Sarita Hamburger

Dissertação (Mestrado) — Universidade Federal do ABC, Programa de
Pós-Graduação em Ciência e Tecnologia Ambiental, Santo André, 2016.

1. Modelo Empírico. 2. Previsão de Vazão. 3. Padrões Climáticos. I.
Cardoso, Andréa de Oliveira. II. Hamburger, Diana Sarita. III. Programa de
Pós-Graduação em Ciência e Tecnologia Ambiental, 2016. IV. Título.

Este exemplar foi revisado e alterado em relação à versão original, de acordo com as observações levantadas pela banca no dia da defesa, sob responsabilidade única do autor e com a anuência de seu orientador.

Santo André, 30 de maio de 2016.

Assinatura do autor: Mglmalfatti

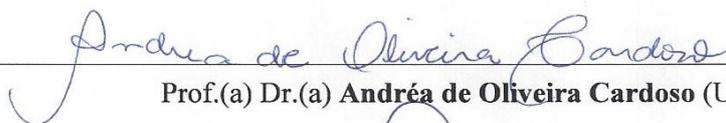
Assinatura do orientador: Andrea de Oliveira Cardoso



MINISTÉRIO DA EDUCAÇÃO
Fundação Universidade Federal do ABC
Programa de Pós-Graduação em Ciência e Tecnologia Ambiental
Avenida dos Estados, 5001 – Bairro Santa Terezinha – Santo André – SP
CEP 09210-580 · Fone: (11) 4996-0017
pgcta@ufabc.edu.br

FOLHA DE ASSINATURAS

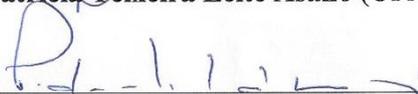
Assinaturas dos membros da Banca Examinadora que avaliou e aprovou a Defesa de Dissertação de Mestrado da candidata Maria Gabriela Louzada Malfatti, realizada em 7 de março de 2016:



Prof.(a) Dr.(a) **Andréa de Oliveira Cardoso** (UFABC) – Presidente



Prof.(a) Dr.(a) **Patrícia Teixeira Leite Asano** (UFABC) – Membro Titular



Prof.(a) Dr.(a) **Pedro Leite da Silva Dias** (USP) – Membro Titular

2

Prof.(a) Dr.(a) **Maria Cleofé Valverde Brambila** (UFABC) – Membro Suplente

Prof.(a) Dr.(a) **Marcio Cataldi** (UFF) – Membro Suplente

AGRADECIMENTOS

Primeiramente, agradeço a Deus por me guiar e estar sempre comigo em todos os momentos de minha vida.

À minha mãe Silvia Helena, pelo apoio e amor incondicional. Ao meu pai que mesmo não estando presente, tenho certeza que lá de cima torce muito pelas minhas conquistas. A todos os meus familiares que me incentivam, principalmente a minha tia e madrinha Maria Cecília. Não posso me esquecer de uma pessoa muito especial, meu amor Bruno, sempre muito paciente e companheiro.

Também em especial agradeço profundamente a minha orientadora Prof.^a Dr.^a Andréa de Oliveira Cardoso, por cada tempo dedicado, por cada correção minuciosa e pela oportunidade de crescer profissionalmente. E a Prof.^a Dr.^a Diana Sarita Hamburger, pela orientação, trazendo perspectivas diferentes para o desenvolvimento desta pesquisa.

Agradeço pelo apoio financeiro da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) a este projeto de mestrado.

Agradeço a todos os professores e técnicos do programa de Pós-graduação de Ciência e Tecnologia Ambiental (CTA), em especial ao técnico do laboratório de Geoprocessamento Diego.

Aos membros da banca, Prof.^o Dr.^o Pedro Leite da Silva Dias e Prof.^a Dr.^a Patrícia Teixeira Leite Asano, por aceitarem o convite e participação da revisão deste trabalho.

E por fim, agradeço aos meus amigos que sempre estiveram me apoiando em minhas decisões acadêmicas e da vida. Agradeço a amizade da Amanda, Emely, Júnia, Ellen e Juliana. Agradeço a todos os meus colegas de pós-graduação, principalmente minhas amigas Maíra e Maryá, muito obrigada pela companhia nos congressos, cursos, palestras, aulas, almoços, jantares e longas conversas...

RESUMO

Devido à importância do conhecimento das variações da vazão de rios para o planejamento dos usos múltiplos da água, este mestrado objetiva explorar as influências remotas do clima, via padrões de variabilidades climáticas, e regionais, via precipitação e vazão em bacias de contribuição. Para tanto, foram desenvolvidos modelos empíricos de previsão de vazões mensais na parte baixa da Bacia Hidrográfica do Rio Paraná (BHRP), mais especificamente onde está localizada a Usina Hidrelétrica (UHE) de Itaipu. Visando garantir séries históricas longas e completas, necessárias para construção de modelos empíricos, os dados de precipitação foram tratados de forma a identificar dados duvidosos e preencher dados faltantes. Além disso, os dados de precipitação foram interpolados, pelo método de Krigagem ordinária, e posteriormente, regionalizados, através de Análise de *Cluster*, visando diminuir o número de séries inseridas no modelo, mantendo regiões com padrões distintos. O modelo empírico utilizado foi o de Regressão Linear Múltipla, sendo aplicado para estimativas de vazão em Itaipu com defasagens variando de 1 a 4 meses, considerando todos os meses consecutivos (modelo geral). Também foram desenvolvidos modelos mensais, para cada mês do ano, separadamente, com defasagens variando de 1 a 12 meses. Para o desenvolvimento dos modelos, considerou-se o período de 1980 a 2000 para calibração e o período de 2001 a 2010, para validação. Estes modelos foram testados com diferentes grupos de preditores, tais como: índices climáticos; precipitação em regiões pluviométricas homogêneas; vazão em pontos a montante e na UHE Itaipu; e o conjunto de todos os preditores anteriores. Por meio do método *stepwise* foram selecionados os preditores mais significativos, sendo destacados os seguintes preditores: índices do El Niño Oscilação Sul e de anomalias de temperatura da superfície do mar no Atlântico Tropical Sul; precipitação em regiões ao sul da BHRP; e a própria vazão em Itaipu defasada. Os modelos foram validados, indicando de um modo geral maior desempenho nas defasagens mais curtas, quando considerados os preditores de vazão e precipitação, sendo que para os meses de janeiro, julho e agosto, a precipitação tem maior contribuição. Nas defasagens mais longas, verificou-se que o melhor desempenho, ocorre para o modelo considerando somente os índices climáticos, mas na maioria dos casos os extremos não são bem capturados, exceto nos meses de abril, junho e julho. Portanto, os resultados deste estudo demonstram a importância de serem consideradas as influências remotas do clima nas estimativas de vazão, principalmente para previsões de mais longo prazo.

Palavras chaves: Modelo Empírico, Previsão de Vazão e Padrões Climáticos.

ABSTRACT

Given the importance of knowledge of river flow variations to the planning of multiple uses of water, this objective masters explore the remote climate influences, though patterns of climate variability, and regional, though precipitation and flow in contribution of basins. Therefore, were developed empirical models of monthly streamflow in the lower of basin the Parana River (BHRP) at the site Itaipu Dam. In order to ensure long and complete historical series, necessary for building empirical models, the rainfall data were analyzed in order to identify unreliable data and fill out incomplete sets. Furthermore, the precipitation data were interpolated by the method kriging ordinary and subsequently regionalized through the cluster analysis, in order to reduce the number of inserted in series model, keeping regions with different patterns. The empirical model used was of multiple linear regression to estimate streamflow in Itaipu with period lagged by 1 to 4 months considering all consecutive months (general model). Also monthly models were developed for each month of the year, separately, with period lagged by 1 to 12 months. For the development of the models, it was considered the period from 1980-2000 for calibration and the period from 2001-2010, for validation. These models were tested with different groups of predictors as: I) only the lagged climate indices; II) only precipitation in homogeneous rainfall regions; III) only flow at upstream points and even the streamflow of Itaipu; IV) and the set of predictors cited I, II and III. Through stepwise method the most significant predictors were selected, being highlighted the best predictors: the contents of the El Niño Southern Oscillation and temperature anomalies of the sea surface in the tropical South Atlantic; rainfall in areas south of BHRP; and proper streamflow lagged in Itaipu. The models were validated, indicating generally higher performance in shorter lags, when considered predictors of flow and precipitation, except for the months of january, july and august, where precipitation has greater contribution. In the longer lags, it was found that the best performance is for the model considering only the climate indices, but in most extreme cases is not captured, except in april, june and july. Therefore, the results of this study demonstrate the importance of considering the remote climate influences on flow estimates, especially longer-term forecasts.

Key words: Empirical Model, Streamflow Forecasting, Climate Patterns.

LISTA DE ILUSTRAÇÕES

- Figura 2.1:** Fases do El Niño Oscilação Sul (ENOS), El Niño (EN) e La Niña (LN), com indicação da anomalia de TSM, vermelho e azul escuro indicam anomalias de +0,8 e -0,6 de temperatura respectivamente, e os vetores indicam a direção e magnitude dos ventos alísios..... 47
- Figura 2.2:** Regiões do Pacífico Equatorial/Tropical de influência do El Niño Oscilação Sul (ENOS), Niño 4, Niño 3.4, Niño 3 e Niño 1+2..... 51
- Figura 2.3:** Fases da Oscilação Decadal do Pacífico (PDO), fase quente (+) e fase fria (-), com indicação da anomalia de TSM, vermelho e azul escuro indicam anomalias de +0,8 e -0,6 de temperatura respectivamente, e os vetores indicam a direção e magnitude dos ventos alísios..... 52
- Figura 2.4:** Fases da Oscilação Multidecadal do Atlântico (AMO), fase quente (+) e fase fria (-), com indicação da anomalia de TSM, laranja e azul escuro indicam anomalias de +1,0 e -1,0 de temperatura respectivamente..... 54
- Figura 2.5:** Localização dos Oceanos, Pacífico Equatorial (PE), Atlântico Tropical (AT), Atlântico Tropical Norte (ATN), Atlântico Tropical Sul (ATS) e Atlântico Equatorial (AEQ). 57
- Figura 3.1:** Localização da Bacia Hidrográfica do Rio Paraná, seus principais rios, sub-bacias e a Usina Hidrelétrica de Itaipu. 61
- Figura 3.2:** Localização das Estações Fluviométricas na Bacia Hidrográfica do Rio Paraná..... 63
- Figura 3.3:** Localização das Estações Pluviométricas na Bacia Hidrográfica do Rio Paraná..... 64
- Figura 3.4:** Distribuição espaço-temporal das Estações Pluviométricas e Fluviométricas na Bacia do Paraná no período de 1950 a 2010, 1960 a 2010, 1970 a 2010 e 1980 a 2010. 66
- Figura 3.5:** Diagrama de *Box Plot* teórico, retângulo definido através dos valores dos quartis e mediana, com os limites superior e inferior. Os pontos foram do diagrama representam os *outliers*... 68
- Figura 3.6:** Regionalização de precipitação proposta por Cardoso (2005) para o trimestre de DJF (Dezembro, Janeiro e Fevereiro)..... 69
- Figura 3.7:** Estações pluviométricas divididas por grupos, utilizadas no Diagrama de *Box Plot*..... 70
- Figura 3.8:** Diagrama de *Box Plot* com a série de dados de precipitação média do acumulado anual sem preenchimento dos dados faltantes, para os grupos de estações pluviométricas. Os pontos no diagrama representam os *outliers*..... 71
- Figura 3.9:** Parâmetros do semivariograma experimental, alcance (a), contribuição (C_1), Efeito Pepita (C_0) e Patamar (C). 76
- Figura 3.10:** Modelos teóricos de semivariograma principais, esférico (linha preta), exponencial (linha vermelha) e gaussiano (linha azul)..... 77
- Figura 4.1:** Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com as precipitações médias acumuladas. 89
- Figura 4.2:** Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com os quantis 15% de precipitação acumulada. 89

Figura 4.3: Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com os quantis 35% de precipitação acumulada.	89
Figura 4.4: Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com os quantis 65% de precipitação acumulada.	90
Figura 4.5: Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com os quantis 85% de precipitação acumulada.	90
Figura 4.6: EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os dados médios de precipitação acumulada.	91
Figura 4.7: Regionalização da precipitação na bacia do Paraná para todas as estações do ano.	92
Figura 4.8: Valores da precipitação mensal relacionados a média(linha azul escura) e aos quantis de 15% (linha vermelha), 35% (linha verde), 65% (linha roxa) e 85% (linha azul clara), calculados sobre cada região pluviométrica homogênea (REG1 a REG8) no período de 1980 a 2010.	94
Figura 5.1: Resultados da avaliação dos modelos I, II, III e IV para as quatro defasagens para os parâmetros VIES, REQM, EA e ER.	104
Figura 5.2: Comparação dos modelos I, II, III e IV com o observado para as defasagens de uma a quatro meses (lag 1-4 meses).	105
Figura 6.1: Coeficiente de correlação (CC) entre os índices climáticos e a vazão de Itaipu para os doze meses do ano, defasados doze vezes (cada barra corresponde a uma diferente defasagem, conforme a legenda acima do gráfico). A linha tracejada corresponde ao valor limite de significância estabelecido através do teste t de Student, $-0,36 \leq CC \leq 0,36$	110
Figura 6.2: Coeficiente de correlação (CC) entre a precipitação nas regiões pluviométricas homogêneas e a vazão de Itaipu para os doze meses do ano, defasados doze vezes (cada barra corresponde a uma diferente defasagem, conforme a legenda acima do gráfico). A linha tracejada corresponde ao valor limite de significância estabelecido através do teste t de Student, $-0,36 \leq CC \leq 0,36$	112
Figura 6.3: Coeficiente de correlação (CC) entre as vazões a montante e Itaipu defasada e a vazão de Itaipu para os doze meses do ano, defasados doze vezes (cada barra corresponde a uma diferente defasagem, conforme a legenda acima do gráfico). A linha tracejada corresponde ao valor limite de significância estabelecido através do teste t de Student, $-0,36 \leq CC \leq 0,36$	113
Figura 6.4: Coeficiente de Determinação (R^2) para todos os meses do ano e nas diferentes defasagens (lag1-12) para os modelos: modelo I (barra azul), modelo II (barra verde), modelo III (barra roxa) e modelo IV (barra vermelha).	118
Figura 6.5: Comparação da vazão observada (linha contínua preta) com as previstas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de janeiro nas defasagens: lag1, lag3 e lag7. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.	120
Figura 6.6: Comparação da vazão observada (linha contínua preta) com as previstas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de fevereiro nas defasagens: lag1 e lag4. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.	121

- Figura 6.7:** Comparação da vazão observada (linha contínua preta) com as previstas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de março nas defasagens lag1 e lag5. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 121
- Figura 6.8:** Comparação da vazão observada (linha contínua preta) com as previstas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de abril nas defasagens lag1 e lag12. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 122
- Figura 6.9:** Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de maio nas defasagens lag4 e lag5. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 122
- Figura 6.10:** Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de junho nas defasagens lag1, lag5 e lag7. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 123
- Figura 6.11:** Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de julho nas defasagens lag1, lag3 e lag4. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 124
- Figura 6.12:** Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de agosto nas defasagens lag1 e lag6. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 124
- Figura 6.13:** Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de setembro nas defasagens lag1 e lag2. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 125
- Figura 6.14:** Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de outubro e nas defasagens lag1 e lag5. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 125
- Figura 6.15:** Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de novembro e nas defasagens lag1 e lag4. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 126
- Figura 6.16:** Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de dezembro e nas defasagens lag2 e lag5. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC. 127

APÊNDICE

- Figura A.1:** Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Esférico; e b) Gaussiano, com as precipitações médias acumuladas. 149
- Figura A.2:** Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Esférico; e b) Gaussiano, com os quantis 15 de precipitação acumulada. 149
- Figura A.3:** Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Esférico; e b) Gaussiano, com os quantis 35 de precipitação acumulada. 150
- Figura A.4:** Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Esférico; e b) Gaussiano, com os quantis 65 de precipitação acumulada. 150
- Figura A.5:** Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Exponencial; b) Esférico; e c) Gaussiano, com os quantis 85 de precipitação acumulada. 151
- Figura A.6:** EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os quantis 15 de precipitação acumulada..... 151
- Figura A.7:** EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os quantis 35 de precipitação acumulada..... 152
- Figura A.8:** EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os quantis 65 de precipitação acumulada..... 152
- Figura A.9:** EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os quantis 85 de precipitação acumulada..... 152
- Figura A.10:** Distribuição espacial dos coeficientes de correlações entre a vazão de Itaipu e vazões a montante e própria Itaipu defasada para um período de 4 meses de defasagem na Bacia do Paraná. 153

ANEXO

- Figura A.1:** Diagrama Esquemático das Usinas Hidrelétricas do SIN na Bacia do Paraná. 155

LISTA DE TABELAS

Tabela 3.1: Índices Climáticos utilizados e seus respectivos períodos de dados.	62
Tabela 3.2: Intervalos de classe para categorização da precipitação.	67
Tabela 3.3: Grupos utilizados para o desenvolvimento do <i>Box Plot</i>	69
Tabela 3.4: Estações pluviométricas identificadas como <i>outlier</i> pelo Diagrama de <i>Box Plot</i>	72
Tabela 3.5: Número estações com dados faltantes sem e com preenchimento dos dados.	73
Tabela 3.6: Intervalo de classes do índice de dependência espacial.	79
Tabela 4.1: Acurácia dos modelos teóricos (exponencial, esférico e gaussiano) de semivariograma.	88
Tabela 4.2: Valores da precipitação anual relacionados a média, quantil 15%, 35%, 65% e 85% para as regiões pluviométricas homogêneas no período de 1980 a 2010.	93
Tabela 5.1: Coeficientes de correlação entre a vazão de Itaipu e os índices climáticos para um período de doze meses de defasagem.	98
Tabela 5.2: Coeficientes de correlação entre a vazão de Itaipu e as regiões pluviométricas homogêneas para um período de doze meses de defasagem.	98
Tabela 5.3: Coeficientes de correlação entre a vazão de Itaipu e as vazões a montante e a própria Itaipu defasada para um período de doze meses de defasagem.	99
Tabela 5.4: Preditores de índices climáticos selecionados no <i>stepwise</i> para defasagens de um a quatro meses.	100
Tabela 5.5: Preditores de precipitação nas regiões pluviométricas homogêneas selecionados no <i>stepwise</i> para defasagens de um a quatro meses.	100
Tabela 5.6: Preditores de vazões selecionados no <i>stepwise</i> para defasagens de um a quatro meses.	101
Tabela 5.7: Coeficiente de Determinação (R^2) para os modelos I, II, III e IV com defasagem de um a quatro meses.	102
Tabela 5.9: Acurácia dos modelos I, II, III e IV em mm para as defasagens de um a quatro meses.	103
Tabela 6.1: Preditores de índices climáticos selecionados no <i>stepwise</i> para defasagens de um a doze meses (lag1-12) para todos os meses do ano.	115
Tabela 6.2: Preditores de precipitação nas regiões pluviométricas homogêneas selecionados no <i>stepwise</i> para defasagens de um a doze meses (lag1-12) para todos os meses do ano.	116
Tabela 6.3: Preditores de vazão selecionados no <i>stepwise</i> para defasagens de um a doze meses (lag1-12) para todos os meses do ano.	117

APÊNDICE

Tabela A.1: Estações fluviométricas e seu respectivo código de referência..... 147

Tabela A.2: Coeficiente de Correlação (CC) entre a vazão de Itaipu observada e os modelos simulados (I, II, III e IV) para todo os meses do ano nas doze defasagens (lag1-12)..... 154

LISTA DE ABREVIATURA E SIGLAS

AAO	Oscilação Antártica
ABR	Abril
AEQ	Atlântico Equatorial
AGO	Agosto
AIQ	Amplitude Interquartil
AMM	Modo Meridional do Atlântico ou Dipolo Atlântico
AMO	Oscilação Multidecadal do Atlântico
ANA	Agência Nacional de Águas
ANEEL	Agência Nacional de Energia Elétrica
ASAS	Anticiclone Subtropical do Atlântico Sul
AT	Atlântico Tropical
ATSM	Anomalias de Temperatura da Superfície do Mar
BHRP	Bacia Hidrográfica do Rio Paraná
CC	Coefficiente de Correlação
CCM	Complexo Convectivo de Mesoescala
CEPEL	Centro de Pesquisas de Energia Elétrica
CPC	Climate Prediction Center
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
DEZ	Dezembro
EA	Erro Absoluto
EM	Erro Médio
EN	El Niño
ENOS	El Niño-Oscilação Sul

EOF	Empirical Orthogonal Fuction
EPM	Erro Padrão Médio
ER	Erro Relativo
ERSST	Extended reconstructed Sea Surface Temperature
INPE	Instituto Nacional de Pesquisas Espaciais
FEV	Fevereiro
JAN	Janeiro
JUL	Julho
JUN	Junho
LN	La Niña
MAI	Maio
MAR	Março
NAO	Oscilação do Atlântico Norte
NCAR	National Center for Atmospheric Research
NCEP	National Centers for Environmental Prediction
NIÑO 3.4	Anomalias de temperatura da superfície do mar na região Centro-Leste do Oceano Pacífico Tropical
NOAA	National Oceanic and Atmospheric Administration
NOV	Novembro
ONS	Operador Nacional do Sistema Elétrico
OUT	Outubro
PDO	Oscilação Decadal do Pacífico
PE	Pacífico Equatorial
PREVIVAZ	Modelo de Previsões de Vazões Semanais
PREVIVAZH	Modelo de Previsões de Vazões Diárias

PREVIVAZM	Modelo de Previsões de Vazões Mensais
PSA	Pacific South America
PT	Pacífico Tropical
REQM	Raiz do Erro Quadrático Médio
SET	Setembro
SIN	Sistema Integrado Nacional
SOI	Índice Oscilação Sul
TNA	Índice do Atlântico Norte
TSA	Índice do Atlântico Sul
TSM	Temperatura da Superfície do Mar
UHE	Usina Hidrelétrica
VCAN	Vórtice Ciclônico de Altos Níveis
VIES	Erro Bias ou Viés
ZCAS	Zona de Convergência do Atlântico Sul
ZCIT	Zona de Convergência Intertropical

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	37
1.1 Justificativa	41
1.2 Objetivos	42
CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA	43
2.1 Modelagem Hidrológica	43
2.2 Principais mecanismos que influenciam a precipitação	44
2.3 Padrões de variabilidade climática	48
2.3.1 Índice Oscilação Sul (SOI)	50
2.3.2 Anomalias de TSM no Centro-Leste do Oceano Pacífico Tropical (NIÑO 3.4).....	51
2.3.3 Oscilação Decadal do Pacífico (PDO).....	52
2.3.4 Oscilação Multidecadal do Atlântico (AMO).....	53
2.3.5 Modo Meridional do Atlântico (AMM)	55
2.3.6 Anomalias de TSM no Atlântico Tropical Sul (TSA).....	56
2.3.7 Oscilação do Atlântico Norte (NAO)	58
2.3.8 Oscilação Antártica (AAO)	58
CAPÍTULO 3 - MATERIAIS E MÉTODOS	60
3.1 Área de estudo	60
3.1.1 Bacia Hidrográfica do Rio Paraná	60
3.1.2 Usina Hidrelétrica de Itaipu.....	61
3.2 Dados	62
3.2.1 Índices Climáticos	62
3.2.2 Vazão de rios	62
3.2.3 Precipitação.....	64

3.3	Definição do período de estudo.....	65
3.4	Tratamento dos dados de precipitação	67
3.4.1	Remoção dos dados discrepantes (<i>outliers</i>).....	67
3.4.2	Preenchimento dos dados faltantes	72
3.5	Interpolação dos dados de precipitação.....	74
3.6	Identificação de regiões pluviométricas homogêneas	79
3.7	Padronização das séries históricas	80
3.8	Correlação defasada	81
3.9	Modelo empírico de regressão linear múltipla.....	82
3.9.1	Seleção dos preditores – Método <i>Stepwise</i>	84
3.9.2	Validação do modelo	84
 CAPÍTULO 4 - REGIÕES PLUVIOMÉTRICAS HOMOGÊNEAS.....		87
4.1	Interpolação.....	87
4.2	Regionalização.....	91
4.3	Conclusão.....	95
 CAPÍTULO 5 - MODELO GERAL DE REGRESSÃO LINEAR MÚLTIPLA.....		96
5.1	Correlações Itaipu X Preditores	96
5.2	Modelo geral de previsão de vazão em Itaipu	99
5.3	Conclusão.....	105
 CAPÍTULO 6 - MODELO MENSAL DE REGRESSÃO LINEAR MÚLTIPLA		108
6.1	Correlação mensal com preditores	108
6.2	Modelos mensais de previsão de vazão em Itaipu	114
6.3	Conclusão	127
 CAPÍTULO 7 - CONCLUSÕES		130
7.1	Conclusões	130
7.2	Sugestões para trabalhos futuros	133

REFERÊNCIAS BIBLIOGRÁFICAS	134
APÊNDICE	147
ANEXO.....	155

CAPÍTULO 1

1. INTRODUÇÃO

O estudo da vazão de um curso d'água apresenta várias utilidades para as atividades socioeconômicas, visto ser uma informação fundamental para o conhecimento hidrológico associado a cada rio, necessário para fins de planejamento e tomada de decisão. Por exemplo, a previsão de vazões é uma das principais questões no planejamento da operação de usinas hidrelétricas e atividades agrícolas, bem como, auxilia na tomada de decisão, que vise minimizar os efeitos de cheias excepcionais e de escassez hídrica (MINE E TUCCI, 1990; SOARES E BESSA, 2001).

O Operador Nacional do Sistema Elétrico (ONS) elabora periodicamente previsões de vazões naturais para os locais de aproveitamento hidroelétricos do Sistema Interligado Nacional (SIN), com o objetivo de subsidiar a tomada de decisão para o planejamento e a operação do sistema hidrotérmico de potência (ONS, 2014). Para atender melhor a demanda com previsões cada vez mais acuradas, o ONS tem buscado novas melhorias em seus modelos, adotando novas metodologias e sistemas computacionais para a previsão de vazões. Atualmente os modelos utilizados nas previsões foram desenvolvidos pelo Centro de Pesquisas de Energia Elétrica (CEPEL), sendo geradas previsões de vazões diárias (PREVIVAZH), semanais (PREVIVAZ) e mensais (PREVIVAZM) (CEPEL, 2015).

Desta forma, os aperfeiçoamentos metodológicos para a obtenção dos cenários hidrológicos de previsão de vazão contribuem para a melhoria do processo de planejamento e programação da operação do SIN. A inclusão de dados de precipitação observada e prevista pode melhorar as previsões de modelos estatísticos e o ONS tem utilizado, para algumas bacias hidrográficas brasileiras, previsões de precipitação geradas pelo Centro de Previsão de

Tempo e Estudos Climáticos/Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE), a partir do modelo regional ETA (GUILHON et al., 2007).

Vários estudos têm contribuído para o aperfeiçoamento de modelos de previsão de vazão, incorporando novas variáveis que contribuem para as variações na vazão. Tucci et al. (2003) utilizaram um modelo hidrológico distribuído para a estimativa de vazão na bacia do Rio Uruguai. Este modelo representa os processos de geração de escoamento na bacia a partir da chuva observada e prevista, e de propagação deste escoamento ao longo da rede de drenagem da bacia. No estudo foram consideradas informações de previsões de chuvas diárias do modelo do CPTEC corrigidas pelo viés do modelo com relação à chuva diária, proporcionando uma melhoria nas previsões de vazão do Rio Uruguai, em relação às realizadas apenas com a média histórica da precipitação. Bravo et al. (2012) aprimoraram o modelo hidrológico distribuído para estimar a vazão na bacia do Alto Paraguai, incorporando o modelo hidrodinâmico unidimensional, com o objetivo de aperfeiçoar os resultados de propagação do escoamento ao longo da rede de drenagem da bacia.

Collischonn et al. (2007) utilizam o modelo MGB-IPH (modelo hidrológico distribuído) que utiliza informações de precipitação observada em postos pluviométricos e precipitação prevista pelo modelo ETA do CPTEC/INPE, para estimar a vazão na bacia do Rio Paranaíba e Guilhon et al. (2007) verificaram a eficiência da incorporação da precipitação em modelos para previsão de vazão nas bacias dos Rios Paraná e Iguazu, sendo que os modelos utilizados foram de caráter físico conceitual concentrado e distribuído, regressão dinâmica, estocástico e inteligência artificial. Nesses modelos a precipitação incorpora um ganho de qualidade nas previsões de vazões, independente do modelo utilizado. Outro exemplo de ganho de qualidade do emprego de precipitação (observada e prevista) em modelos hidrológicos é apresentado em estudos para a previsão de vazão: no reservatório de Ernestina, Rio Jacuí (BRUN e TUCCI, 2001).

A precipitação é uma variável de difícil previsão, dada uma forte componente aleatória, devido à influência de processos de diferentes escalas e grande variabilidade espacial e temporal. No entanto, com o desenvolvimento dos modelos e dos recursos computacionais, as previsões de curto (dias), médio (semanas) e longo (meses) prazo quantitativas de precipitação e de outras variáveis estão cada vez mais precisas (McBRIDE e EBERT, 2000; COLLISCHONN et al., 2007).

Também é conhecido que a precipitação e, portanto, a vazão de rios, sofrem influências remotas de fenômenos climáticos. Robertson e Mechoso (1998) sugerem que a influência da temperatura da superfície do mar (TSM) sobre as vazões dos rios Uruguai e Paraná ocorre em escala interanual, no caso do Pacífico, e decadal do Atlântico.

Dettinger et al. (2000) mostraram um padrão oposto nas correlações entre vazão de rios sobre as regiões Nordeste e Sul do Brasil e o El Niño-Oscilação Sul (ENOS), no qual a vazão sobre o Nordeste tende a diminuir (aumentar) em anos de El Niño - EN (La Niña - LN), e o contrário sobre a região Sul. Além disso, utilizando componentes principais rotacionados de vazão foi verificado que o segundo modo obtido é semelhante ao primeiro componente principal de precipitação, cuja variabilidade está associada à atuação do ENOS no regime de precipitação da América do Sul.

Berri et al. (2002) identificaram impactos consistentes do ENOS sobre a vazão do Rio Paraná, indicando maiores (menores) fluxos médios nos casos de eventos de EN (LN) durante o ano de início do fenômeno e até a parte do ano seguinte.

Cardoso e Silva Dias (2002) analisaram a eficácia dos componentes principais de TSM nos oceanos Atlântico e Pacífico como preditores de vazão em cinco rios do Estado de São Paulo, sendo sugerida a possibilidade de se utilizar padrões de variabilidade de TSM no Pacífico tropical (PT) e Atlântico sudoeste para o prognóstico de vazão em rios no Estado de São Paulo.

Grimm e Tedeschi (2009) observaram que o ENOS exerce influência sobre os extremos de precipitação afetando os extremos de vazão em diversas bacias brasileiras. A ocorrência de eventos EN (LN) está relacionada com o aumento (diminuição) de extremos de vazão na região das bacias do Paraguai e Uruguai.

Kayano e Andreoli (2009) observaram diferenças nos padrões de precipitação associados ao ENOS que podem estar relacionadas à fase da Oscilação Decadal do Pacífico (PDO), podendo influenciar construtivamente o ENOS, quando estiver na mesma fase, ou seja, a PDO pode intensificar o ENOS quando ambos estão na mesma fase.

Cardoso e Cataldi (2012) destacaram que padrões de teleconexões¹, oriundo de diferentes padrões climáticos e escalas temporais (de interanual a interdecadal) podem influenciar na vazão em rios brasileiros. Na Bacia do Paraná foram encontradas correlações significativas principalmente com padrões de variabilidade Oscilação Antártica (AAO), Oscilação Multidecadal do Atlântico (AMO), Modo Meridional do Atlântico (AMM), PDO, Oscilação do Atlântico Norte (NAO), Índice de Oscilação Sul (SOI), Índice do Atlântico Sul (TSA) e Anomalias de TSM na região Centro Leste do Oceano Pacífico Tropical (NIÑO 3.4), sendo esses padrões explorados neste trabalho.

A utilização dos índices climáticos é essencial para a previsão de vazão, visto que as informações contidas neles corrigem a simplificação usual de que as observações do passado são equiprováveis de ocorrer no futuro, pois a curva de frequência irá se alterar em função dos indicadores climáticos. Ou seja, neste caso as previsões não são somente realizadas a partir dos padrões observados do passado e sim utilizando a frequência dos fenômenos climáticos através dos índices climáticos (PINTO et al., 2006a).

Pinto et al. (2006b) utilizam os índices climáticos para previsão de precipitação na bacia do Alto São Francisco, aplicando um modelo de combinação linear ótima de previsões resultantes da autocorrelação serial ou persistência, e dos indicadores climáticos (SOI e anomalias de TSM) que gera uma previsão consensual (as probabilidades de precipitação estão nos limites das categorias). Souza Filho e Lall (2004) utilizaram técnicas de regressão multivariada para explorar a relação entre vazões anuais (ou sazonais) e um conjunto de potenciais preditores climáticos. Ambos os estudos evidenciam a importância da utilização dos índices climáticos e produzem bons resultados.

Alexandre (2012) realizou uma previsão de vazões mensais para o SIN utilizando informações climáticas, observando que os melhores modelos do tipo Periódico Autorregressivo com variáveis exógenas (PARX) são os que fazem uso de índices climáticos como variáveis exógenas, dentre os quais destacam o índice AMO. Esse índice apresenta melhor desempenho no período seco das bacias do norte do Brasil – Amazonas e Araguaia-Tocantis; centro-leste brasileiro – Atlântico Leste e na maioria dos rios que formam a Bacia do Paraná.

¹ Análises de teleconexões compreendem uma visão geral da circulação atmosférica, onde forçantes locais agem para influenciar regiões remotas. Essas análises têm sido usadas principalmente para estudar as flutuações de grande escala, de baixa frequência, na atmosfera (CAVALCANTI e OLIVEIRA, 1996).

Diante das grandes variações e alterações climáticas que vem sendo observadas ao longo do planeta, é cada vez mais importante e estratégico desenvolver estudos que busquem conhecer as influências das variabilidades climáticas sobre a vazão, visando explorá-las para fins prognósticos de tal variável, sendo esse o principal objetivo dessa pesquisa.

1.1 Justificativa

Dada a importância da água como recurso hídrico, da multiplicidade de seu uso, dos mais variados impactos nas atividades socioeconômicas devido às suas variabilidades, decorrentes da influência de diversos fatores, dentre eles o clima, é importante investigar os principais padrões climáticos que podem afetar a vazão de rios e explorá-los para fins de previsibilidade de vazão.

Vários estudos de previsibilidade de vazão foram desenvolvidos com foco em modelos conceituais que consideram os processos envolvidos na bacia e até mesmo previsão numérica de precipitação. Estudos detalhados com foco nas variabilidades climáticas e suas influências precisam ser aprofundados. Neste sentido, ressalta-se que a abordagem desta pesquisa de mestrado se diferencia em relação ao empregado atualmente, pois incorpora os índices climáticos para fins de previsão de vazão de rios. Este aspecto reforça a influência da precipitação, visando aprimorar e também aumentar horizonte da previsão acurada e deste modo, o fornecimento de subsídios para o planejamento antecipado.

Para o estudo de caso buscou-se explorar técnicas de modelagem empírica, em um ponto da Bacia Hidrográfica do Rio Paraná (BHRP), devido sua grande extensão que lhe confere características e variabilidades climáticas distintas em diferentes sub-bacias, que influenciam o regime de precipitação e vazão de rios, bem como sua importância socioeconômica para o país, destacada por grandes regiões agrícolas, industriais, centros urbanos e pela parcela de geração de energia elétrica entregue ao SIN.

Deste modo esta é uma área de estudo estratégica para a pesquisa, cujo conhecimento das inter-relações climáticas com a vazão poderá dar base para o desenvolvimento de um modelo prognóstico eficaz. Tal estudo pode trazer benefícios para as atividades socioeconômicas da região e do país, bem como motivar o desenvolvimento de pesquisas semelhantes que poderão ser aplicadas a outras bacias.

1.2 Objetivos

Esta pesquisa objetiva analisar os principais mecanismos que afetam a vazão na parte baixa da Bacia Hidrográfica do Rio Paraná, mais especificamente no local onde está localizada a Usina Hidrelétrica de Itaipu, com foco na influência de padrões climáticos sobre a vazão, buscando desenvolver um modelo empírico de estimativa de vazões mensais, explorando padrões climáticos que possam ser utilizados como preditores no modelo, juntamente com a própria vazão no ponto e em pontos a montante e a precipitação em diferentes locais da bacia. Os objetivos específicos deste estudo são:

- Identificar os principais padrões climáticos atuantes na região de estudo, a partir da base bibliográfica;
- Realizar a regionalização de precipitação, aplicando métodos de interpolação de dados (Krigagem ordinária) e de análise de agrupamento, visando verificar a distribuição dos dados de precipitação ao longo da bacia do Rio Paraná e reduzir a dimensão do conjunto inicial através do estabelecimento de regiões homogêneas;
- Identificar os principais preditores a partir de correlações defasadas significativas da vazão em Itaipu com índices climáticos, própria vazão defasada, vazões a montante e precipitação em locais da bacia;
- Desenvolver modelos de Regressão Linear Múltipla para estimativa de vazões mensais, com diferentes prazos, utilizando grupos distintos de preditores identificados;
- Validar os modelos testados e indicar os melhores grupos de preditores para cada período e defasagem.

CAPÍTULO 2

2. REVISÃO BIBLIOGRÁFICA

2.1 Modelagem Hidrológica

O conhecimento de hidrologia é essencial para análise e gerenciamento dos recursos hídricos, como: dimensionamento dos usos múltiplos do recurso, planejamento operacional estratégico dos reservatórios e usinas hidrelétricas, controle de inundações, entre outros.

Estudos hidrológicos utilizam a bacia hidrográfica como unidade territorial, onde são feitas as análises do comportamento do ciclo hidrológico da região em questão. A bacia hidrográfica é um sistema físico complexo, o qual no geral possui diferentes propriedades físicas, heterogêneo e variável no tempo. Este sistema é representado matematicamente através de modelos, a fim de representar a dinâmica física real (TUCCI, 2007).

O modelo mais simples em hidrologia é representado pela equação do balanço hídrico, sobre um determinado intervalo de tempo em uma bacia hidrográfica (TUCCI, 2007). Representado pela equação 2.1 a seguir:

$$P - ET = D + \Delta S \quad (2.1)$$

Onde P é a precipitação, ET é a evaporação, D é o deflúvio e ΔS é a variação do armazenamento no tempo.

Como pode ser observado a partir da equação do balanço hídrico, é necessária a medição de variáveis hidrológicas e meteorológicas para uma estimativa precisa do modelo. Os modelos possuem várias limitações devido a quantidade e qualidades dos dados

hidrológicos, a dificuldade de formular matematicamente alguns processos e simplificação dos mesmos (TUCCI, 2007).

Segundo Tucci (2007), os modelos hidrológicos podem ser classificados em:

- Contínuo e Discreto, dependendo da forma de representação dos dados;
- Concentrado e Distribuído, quanto à variabilidade espacial das variáveis utilizadas;
- Estocástico e Determinístico, se o modelo segue ou não as leis da estatística;
- Conceitual e Empírico, dependendo se as funções utilizadas na sua elaboração levam ou não em consideração os processos físicos.

Existem vários modelos que determinam diferentes variáveis hidrológicas. No caso desta pesquisa, a variável em questão é a vazão de um curso d'água. Os principais fatores que se compõe para a definição da vazão são os de natureza climática, fisiográficos e antrópicos. Os fatores fisiográficos estão ligados com as características físicas da bacia hidrográfica, como a área da bacia de contribuição, sua forma, condições de superfície do solo e constituição geológica do subsolo, e a conformação topográfica. Os fatores antrópicos são as obras hidráulicas construídas na bacia e ocupação humana. Os fatores de natureza climática estão relacionados com as características de distribuição, intensidade e duração da precipitação, bem como a ocorrência de uma precipitação anterior, sazonalidade da precipitação e impacto de fenômenos climáticos e suas variabilidades (VON SPERLING, 2007).

2.2 Principais mecanismos que influenciam a precipitação

A grande extensão do território brasileiro e sua posição global implicam em um clima variado, marcado por mecanismos de origem tropical e subtropical, e de diferentes escalas, além de variações sazonais, expressas principalmente pelas estações do ano e pelos regimes de chuvas associados, que produzem reflexos no ciclo hidrológico médio das diversas regiões do país (SATYAMURTY et al., 1998; GRIMM, 2003).

O clima refere-se ao conjunto das condições atmosféricas que caracterizam uma região e é definido pela combinação de vários fatores, dentre eles: latitude, altitude, distribuição de

terra e oceano, correntes oceânicas, fatores locais, sistemas locais e sistemas móveis (transientes e de grande escala) (CAVALCANTI, 2009).

Vários estudos buscam o conhecimento das variabilidades presentes na precipitação, bem como os fatores causadores de tais variáveis. Este é um grande desafio científico, pois a precipitação possui uma componente aleatória de difícil compreensão e estimativa, provavelmente devido a influência da combinação de diversos fatores.

Condições para a ocorrência de precipitação podem ser favorecidas por sistemas locais como: circulações e ventos locais que ocorrem em resposta a configuração de encostas, sistemas orográficos e topografia (influência do relevo), ao aquecimento diferenciado entre continentes e topografia, ao aquecimento diferenciado entre continentes e oceanos, ou áreas adjacentes (VAREJÃO-SILVA, 2006; VIANA, 2009).

Sistemas transientes móveis (sistemas de escala sinótica) podem alterar também as condições de tempo em determinada região, favorecendo a ocorrência de chuvas. De acordo com Varejão-Silva (2006), os principais sistemas atuantes na área de estudo são: Massas de ar, Frentes (sistemas frontais), Ciclones/Anticiclones, Zona de Convergência do Atlântico Sul (ZCAS), Vórtice Ciclônico de Altos Níveis (VCAN), Bloqueio Atmosférico e Complexo Convectivo de Mesoescala (CCM).

A Zona de Convergência do Atlântico Sul (ZCAS) é caracterizada por uma banda de nebulosidade com orientação noroeste-sudeste estendendo-se do Brasil Central até o Atlântico Sul Central. É um dos principais mecanismos causadores de chuvas sobre o Sudeste, Centro-Oeste e de parte da região Sul porção norte, durante o verão austral, estação chuvosa (VAREJÃO-SILVA, 2006; CARVALHO et al., 2004; REBOITA et al., 2010). Carvalho et al. (2004) verificaram que as fases dos ENOS, altera a variabilidade interanual da ZCAS, mostraram que a fase quente (fria) do ENOS favorece a ocorrência de ZCAS oceânica (continental). Segundo Seluchi e Marengo (2000) as frentes frias podem se fundir com a ZCAS, intensificando as chuvas, principalmente na região Sudeste.

Os ciclones (anticiclones) são centro de baixa (alta) pressão que podem causar chuvas em abundância (inibição) principalmente no Sul e Sudeste, dependendo do seu posicionamento, podem desviar os sistemas para regiões vizinhas, de acordo com a sua circulação (REBOITA et al., 2010). O anticiclone subtropical do Atlântico Sul (ASAS)

diminui as condições de formação de nuvem no Sul e Sudeste, a atmosfera fica mais seca e as nuvens não conseguem se formar inibindo as chuvas (BASTOS, 2000).

Os Vórtices Ciclônicos de Altos Níveis (VCAN) consistem em uma circulação ciclônica fechada, de escala sinótica, cujo núcleo é mais frio que a periferia e que se forma na alta troposfera. Alteram o padrão de chuvas no Sul, Sudeste e Nordeste do Brasil, favorecem a formação de ventos que auxilia na formação de nuvens carregadas, ocorrendo chuvas intensas (VAREJÃO-SILVA, 2006).

Os Complexos Convectivos de Mesoescala (CCM) são aglomerados de nuvens cumulonimbus frias e espessas (convectivas) que apresentam forma circular e crescimento vertical num intervalo de tempo entre 6 a 12 horas e associam-se a eventos com precipitação intensa (enchentes, alagamentos e inundações), geralmente acompanhada de descargas elétricas atmosféricas, nas estações quentes na América do Sul (MADDOX, 1980; LIMA, 2005; SALIO et al., 2007; VIANA, 2009). No Brasil o CCM altera principalmente o regime de precipitação na região Sul (SALIO et al., 2007). VIANA et al. (2009) identificaram desastres naturais associados à atuação do CCM no período de outubro e dezembro de 2003, no estado do Rio Grande do Sul.

O Bloqueio Atmosférico é uma anomalia de alta pressão persistente em altos níveis da atmosfera com duração de alguns dias, desviando corrente de ventos de oeste, impedindo que sistemas transientes atinjam na região de bloqueio. Pode ser responsável por anomalias de precipitação sobre o Sul e Sudeste do Brasil, desviando corrente de ventos de oeste impedindo que os sistemas transientes destacados atuem na região do bloqueio (OLIVEIRA e SARAIVA, 2000).

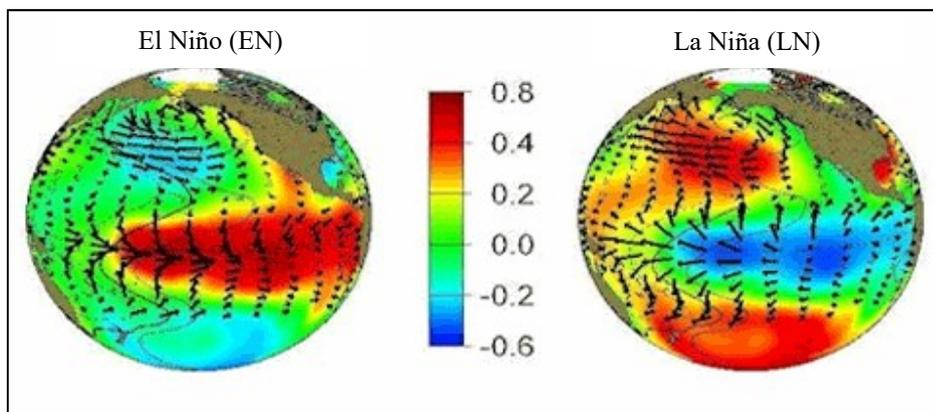
Além dos sistemas transientes, os padrões de chuvas sobre várias regiões do Brasil sofrem influências dos sistemas de grande escala, que ocorrem em escala de tempo e espaço maiores do que os transientes. Os principais sistemas conhecidos atuantes na área de estudo são: Anomalias de TSM no Atlântico e ENOS (VAREJÃO-SILVA, 2006).

As anomalias de TSM no Atlântico Norte e Sul (tropical) podem influenciar no comportamento das ZCAS (CHAVES, 2011). As anomalias do Atlântico Sul podem associar-se a ocorrência de extremos de precipitação sobre o Sul e Sudeste brasileiro (CARDOSO e SILVA DIAS, 2004).

O ENOS representa um fenômeno de interação atmosfera-oceano, associado a alterações dos padrões normais da TSM e dos ventos alísios na região do Pacífico Equatorial (PE), entre a Costa Peruana e no Pacífico Oeste próximo à Austrália (OLIVEIRA, 1999). A variação interanual do sistema atmosfera-oceano que ocorre em torno das condições normais nas componentes oceânicas (El Niño) e atmosféricas (Oscilação Sul) desta região, revela duas fases opostas do fenômeno El Niño (EN) e La Niña (LN) (PSCHEIDT e GRIMM, 2006; MINUZZI et al., 2007).

Segundo o *National Oceanic and Atmospheric Research* (NOAA), o EN é a fase quente (também denominada fase negativa) do ENOS e representa um aquecimento anormal das águas superficiais no Oceano PE. A LN é a fase fria do ENOS (denominada fase positiva) e representa um resfriamento anormal das águas e aumento na pressão atmosférica na região leste do Oceano PE, conforme apresentado na Figura 2.1.

Figura 2.1: Fases do El Niño Oscilação Sul (ENOS), El Niño (EN) e La Niña (LN), com indicação da anomalia de TSM, vermelho e azul escuro indicam anomalias de +0,8 e -0,6 de temperatura, respectivamente, e os vetores indicam a direção e magnitude dos ventos alísios.



Fonte: NOAA.

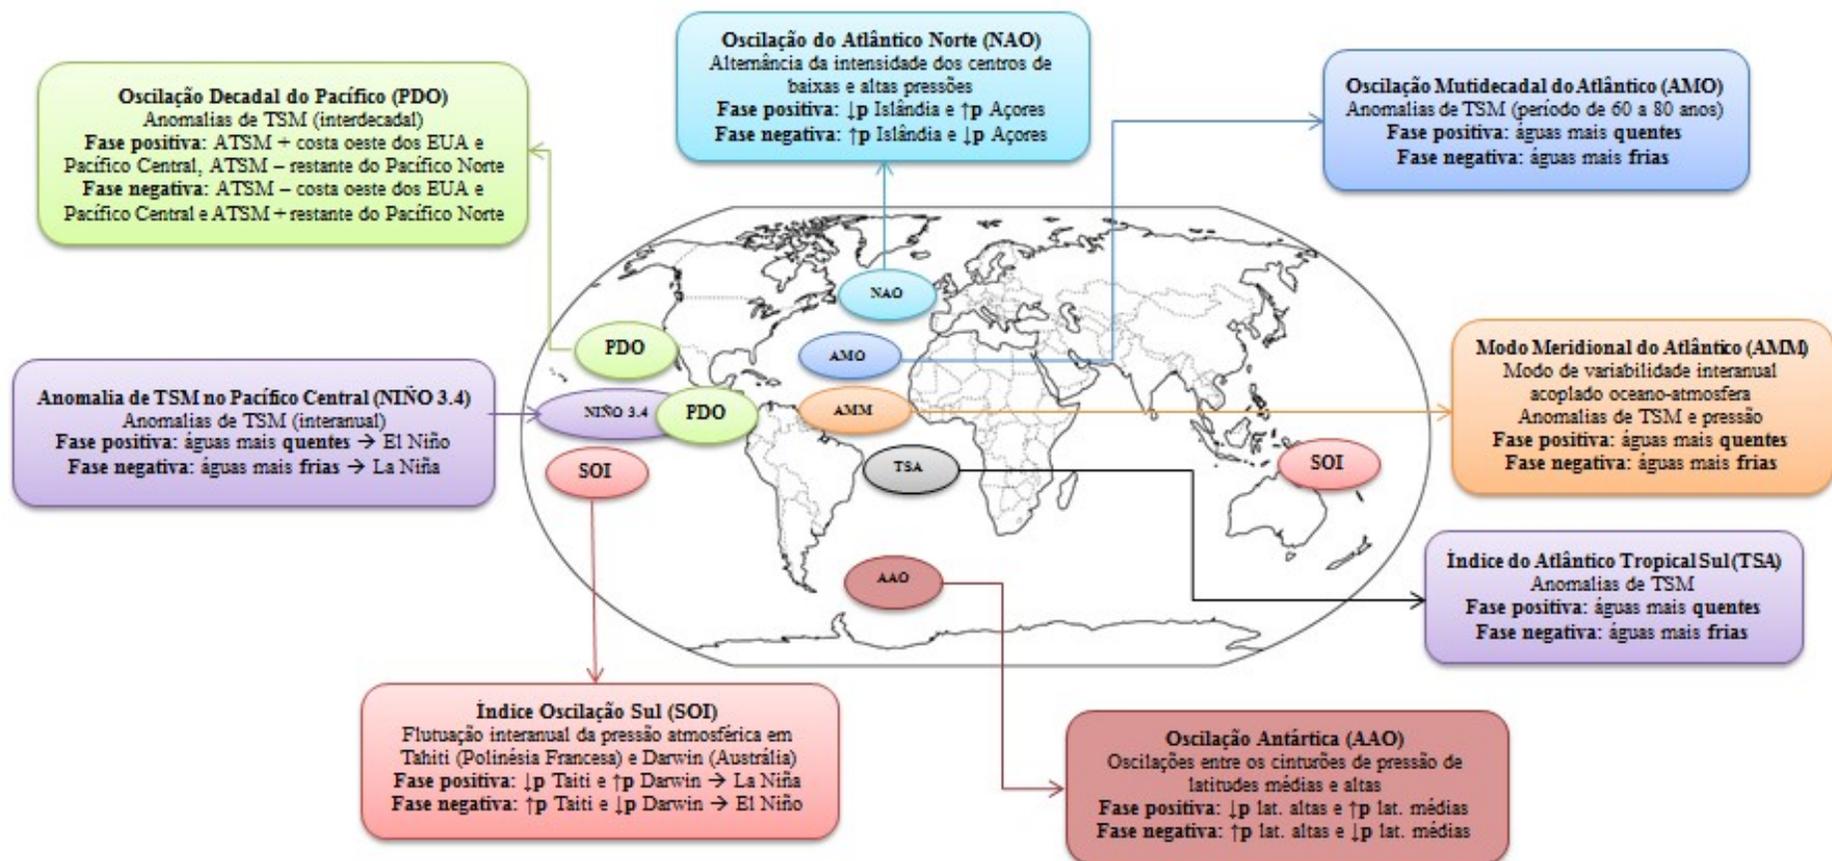
Em condições de EN, os ventos alísios (de leste) no Pacífico Equatorial enfraquecem, podendo até mudar de sentido em alguns casos. As águas mais aquecidas atingem todo o oceano, e o leste do oceano fica mais quente do que o normal. Há um deslocamento da região com maior formação de nuvens para PE Central e a célula de Walker fica bipartida. Já em anos de LN, as condições normais se intensificam. Os ventos alísios ficam mais intensos, deslocando maior quantidade de água superficial de leste para oeste. Desta forma, há maior quantidade de água represada no PE Oeste e o desnível em relação faixa leste aumenta, aumentando também a ressurgência de águas frias junto à costa oeste da América do Sul, a célula de Walker fica mais alongada que o normal (OLIVEIRA, 1999).

De modo geral, o Brasil é afetado pelo fenômeno ENOS de maneira distinta em duas regiões: o Nordeste e a região Sul. Durante a fase quente do ENOS o Nordeste tem sua estação chuvosa inibida (outono), sofrendo secas severas. Por outro lado no mesmo ano, mas em época distinta (primavera), a região Sul tem anomalias positivas de precipitação, causando enchentes. Durante a fase fria, o Sul é afetado com extensivas estiagens. Não há um padrão definido dos impactos nas chuvas do Sudeste e Centro-Oeste, por se tratar de regiões de transição entre impactos opostos desses fenômenos, entretanto a indícios que a região Sudeste experimenta invernos mais amenos em termos de temperatura durante episódios de EN (GRIMM et al., 1998; COELHO et al, 2002; GRIMM, 2003; RODRIGUES et al, 2011).

2.3 Padrões de variabilidade climática

Os padrões de variabilidade climática, representados por índices que foram utilizados neste trabalho, estão descritos a seguir, destacando uma revisão bibliográfica das principais pesquisas realizadas por região de estudo no Brasil em especial na Bacia do Rio Paraná. A Figura 2.2 mostra um resumo dos índices utilizados neste trabalho.

Figura 2.2: Principais padrões de variabilidade climática identificados na Bacia do Paraná.



Fonte: ROPELEWSKI e HALPERT, 1987; ENFIELD et al., 1999; GON e WANG, 1999; TRENBERTH E STEPANIAK, 2001; MAUTA et al., 1997; ENFIELD et al., 2001; CHANG et al., 2007; HURRELL, 2003;

2.3.1 Índice Oscilação Sul (SOI)

A Oscilação Sul é a flutuação interanual da pressão atmosférica ao nível do mar no Oceano Pacífico, devida a variações na circulação atmosférica. O Índice Oscilação Sul (SOI) é caracterizado pela diferença de pressão padronizada em Tahiti (Polinésia Francesa) e Darwin (Austrália), localizados no oceano PT, e está associado ao enfraquecimento ou a intensificação dos ventos alísios sobre o oceano PE (ROPELEWSKI e HALPERT, 1987).

Segundo o *Climate Prediction Center/National Centers for Environmental Prediction* (CPC/NCEP) o índice SOI apresenta uma fase negativa e uma positiva. A fase negativa do índice é representada por anomalias positivas de pressão em Darwin e no setor oeste do PT bem como anomalias negativas no Tahiti e no setor leste do PT. Por outro lado, a fase positiva é caracterizada por anomalias positivas de pressão no Tahiti e no setor leste do PT, assim como anomalias negativas sobre Darwin e setor oeste do PT. Períodos prolongados com valores negativos do índice estão associados com condições anormalmente quentes da TSM ao longo do setor leste do PT, configurando-se um episódio típico de EN. Em contrapartida, longos períodos que apresentam valores positivos do índice coincidem com condições anormalmente frias da TSM ao longo do setor leste do PT e ocorrência de LN.

Vários estudos avaliam o impacto dos ENOS no Brasil: Na região Centro-Oeste não há padrão definido da influencia dos ENOS, bem como a região sudeste (MELO, 2000; MINUZZI et al., 2006). Já para o nordeste quando o SOI é positivo (negativo) tem-se chuva (seca) (SANTOS et al., 2010), enquanto que no sul ocorre ao contrário, quando SOI é positivo (negativo) tem-se seca (chuva). E por fim, na região Norte, as chuvas abundantes podem estar relacionadas com o fenômeno LN (SOI positivo) (Marengo et al., 2013).

Cardoso e Silva Dias (2006) verificaram a relação do ENOS com a vazão do Rio Paraná, sendo sugerido o ENOS como potencial preditor para a modelagem da vazão neste rio. No estudo de Antico (2009) também foi verificada a relação do EN na Bacia do Paraná, indicando que ao sul da bacia os eventos de precipitação intensa estão associados aos eventos de EN.

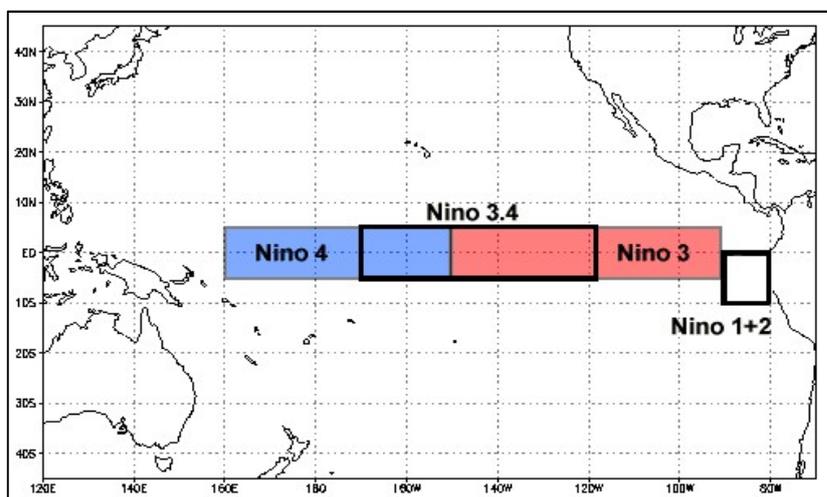
Sahu et al. (2013) analisaram o impacto da LN na vazão do Rio Paranaíba no Brasil (afluente do Rio Paraná, norte da BHRP), os eventos de alta vazão estão associados com anos de LN (acima de 80% dos casos). Sahu et al. (2014) analisaram o impacto da EN na vazão do

Rio Paranaíba no Brasil (afluente do Rio Paraná, norte da BHRP), os eventos de baixa vazão estão associados com anos de EN (acima de 90% dos casos).

2.3.2 Anomalias de TSM no Centro-Leste do Oceano Pacífico Tropical (NIÑO 3.4)

A intensidade do ENOS é verificada com base em anomalias de TSM, sendo a região mais utilizada a faixa do Niño 3.4, região central-leste do oceano PT entre as coordenadas 5°N – 5°S e 170°W – 120°W, conforme mostrado na Figura 2.3. (TRENBERTH, 1997; TRENBERTH e STEPANIAK, 2001).

Figura 2.3:Regiões do Pacífico Equatorial/Tropical de influência do El Niño Oscilação Sul (ENOS), Niño 4, Niño 3.4, Niño 3 e Niño 1+2.



Fonte: NOAA.

A região Niño 3.4 fornece uma boa medida de mudanças importantes na TSM e gradientes de TSM que resultam em mudanças no padrão de convecção tropical profunda e circulação atmosférica. De acordo com Trenberth (1997) a ocorrência do fenômeno EN é definida quando a anomalia de TSM da região 3.4 excede a 0,4°C de magnitude e uma duração superior a 6 meses.

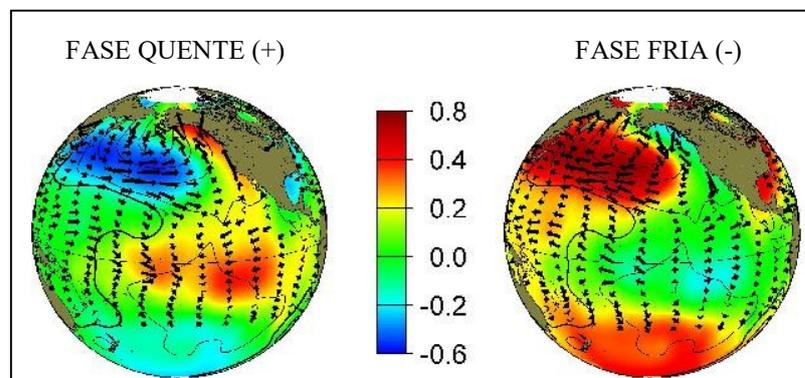
Sansigolo (2000) avaliou a influência dos eventos EN e LN no regime de precipitação em Pelotas (RS) utilizando os critérios estabelecidos por Tenberth (1997), sendo conexões estatisticamente significativas entre eventos LN e precipitações abaixo do normal de abril a dezembro e eventos EN e precipitações acima do normal de abril a junho.

Tedeschi et al. (2013) avaliaram a relação do ENOS com TSM, nas regiões NIÑO 3.4 e 3, para a precipitação na América do Sul, e encontraram que durante EN (LN) tende a aumentar (diminuir) a precipitação na bacia do Prata e uma diminuição (aumento) sobre o norte da América do Sul durante todas as estações.

2.3.3 Oscilação Decadal do Pacífico (PDO)

A Oscilação Decadal do Pacífico (PDO) é uma variabilidade de longo prazo (escala de tempo interdecadal, de 20 a 30 anos) na configuração das TSM no Oceano Pacífico. A PDO apresenta duas fases, conforme a Figura 2.4: *i*) fase positiva ou quente, caracterizada por anomalias de TSM positivas na costa oeste dos Estados Unidos e Pacífico Central, negativas no restante do Pacífico Norte, desde aproximadamente 20°N na direção do pólo; *ii*) fase negativa ou fria, quando o aquecimento/resfriamento nas duas áreas se inverte (MATUA et al., 1997).

Figura 2.4: Fases da Oscilação Decadal do Pacífico (PDO), fase quente (+) e fase fria (-), com indicação da anomalia de TSM, vermelho e azul escuro indicam anomalias de +0,8 e -0,6 de temperatura, respectivamente, e os vetores indicam a direção e magnitude dos ventos alísios.



Fonte: NOAA.

Andreoli e Kayano (2005) avaliaram a relação da PDO com as precipitações da América do Sul ligadas a eventos de ENOS, ou o efeito combinado dos dois eventos, e verificaram que o sinal do EN na precipitação da América do Sul durante os meses de janeiro e fevereiro é mais pronunciado na fase quente da PDO do que na fase fria da PDO. Foi encontrado também um menor número de eventos de LN durante a fase quente de PDO, já na fase fria há maior ocorrência e episódios de LN mais intensos, indicando que a resposta do clima da América do Sul é dependente das fases de PDO. Pode-se dizer, portanto que a PDO pode modular o ENOS (GARCIA e KAYANO, 2008; KAYANO et al, 2009).

Vários estudos verificaram a influência da PDO no Brasil. Rebello (2006) estudou o Estado do Rio Grande do Sul para o período de 1961 a 2005, indicando que na fase positiva (1977 a 1997) ocorreram chuvas em abundância e na fase negativa (1999 a 2005) estiagem. Molion (2008) analisou a variabilidade climática do Brasil e verificou uma forte correlação dos totais pluviométricos e a PDO, em algumas regiões específicas do Brasil (Sudeste da Amazônia, Centro-Oeste e Sul). Sousa et al. (2010) analisaram o Estado de Goiânia, observando que na fase fria (quente) da PDO ocorre uma redução (aumento) de precipitação total anual e frequência de dias com precipitação.

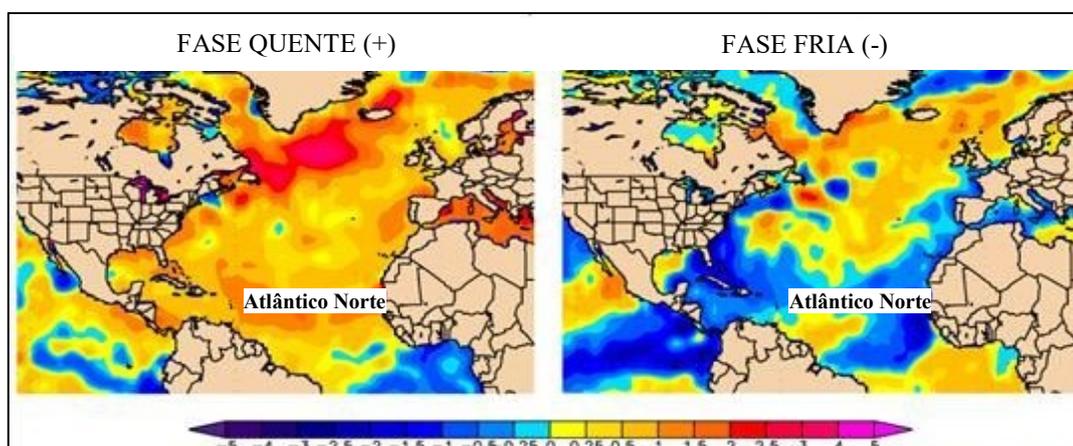
Piccilli (2007) verificou que a PDO tem a maior capacidade de modulação do clima na Bacia do Alto Paraguai (sub-bacia ao norte da Bacia do Paraná), mesmo em grande escala e baixa frequência, tem o poder de modular o clima por muitos anos. Ocorrendo mudanças bruscas nas vazões coincidentes com as mudanças de fase da PDO, e vazões significativamente acima ou abaixo da média durante a duração de cada fase da PDO. Na fase positiva foi verificado o aumento das chuvas e na fase negativa a diminuição das chuvas.

O índice da PDO foi desenvolvido primeiramente por Matua et al. (1997), derivado da primeira componente principal das anomalias da TSM no Pacífico Norte, entre as latitudes 20°N e 90°N. Já o índice PDO do CPC/NCEP é baseado nos dados da ERSST (Extended Reconstructed Sea Surface Temperature) do NOAA, ou seja, a partir dos dados reconstruídos da TSM do Pacífico.

2.3.4 Oscilação Multidecadal do Atlântico (AMO)

A Oscilação Multidecadal do Atlântico (AMO) é um modo natural de variabilidade de TSM que ocorre no Oceano Atlântico Norte, com um período estimado de 60 a 80 anos. A AMO apresenta duas fases, conforme ilustradas pela Figura 2.5, sendo que na fase positiva (fase negativa) ocorrem águas mais quentes (frias) do que o normal no Oceano Atlântico Norte (ENFIELD et al., 2001).

Figura 2.5: Fases da Oscilação Multidecadal do Atlântico (AMO), fase quente (+) e fase fria (-), com indicação da anomalia de TSM, laranja e azul escuro indicam anomalias de +1,0 e -1,0 de temperatura, respectivamente.



Fonte: NOAA.

Como o período de ocorrência desse modo de variabilidade de TSM é representado em uma escala temporal longa (60-80 anos), existem estudos que verificam a ocorrência por registros de espeleotemas², o qual avalia por registro isotópico as variações hidrológicas. Moquet et al. (2013) estudaram a variabilidade multidecadal do sistema de monções de verão durante os últimos 2000 anos na região Centro-oeste do Brasil (Goiás) com base em registros de espeleotemas, onde as variações de escala multidecadais relacionadas à AMO, com frequência aproximada de 63 anos, foram claramente observadas na análise de wavelets da série isotópica dos espeleotemas de Goiás. No curso dos últimos 1550 anos foi observado um aumento (diminuição) de chuva durante as fases de AMO negativas (positivas).

Dantas et al. (2012) verificaram a influência de ambas oscilações de baixa frequência, PDO e AMO, nos extremos de precipitação e temperatura do ar da Amazônia Ocidental. As teleconexões AMO e PDO tiveram influências sobre a precipitação total anual da Amazônia Ocidental, mas não apresentaram influências sobre os dias consecutivos secos.

Silva (2013) avaliou a influência interdecadal (PDO e AMO) no Rio São Francisco e verificou que a bacia hidrográfica se beneficia com a ocorrência simultânea de EN e AMO negativa, sendo que o primeiro promove aumento de chuvas nas cabeceiras do rio e o segundo aumento de chuvas no Nordeste do Brasil. Além disso, a PDO quando se encontra na mesma fase do EN, observa-se um aumento das chuvas no Alto do Rio São Francisco.

² Espeleotema (Do grego, "depósito de caverna") ou concreção é o nome genérico de todas as formações rochosas que ocorrem tipicamente no interior de cavernas como resultado da sedimentação e cristalização de minerais dissolvidos na água (disponível em: <http://www.cprm.gov.br>).

Chiessi et al (2009) sugeriram que a AMO pode influenciar na atividade das ZCAS, fase negativa (fase positiva) AMO aumenta (reduz) a atividade da ZCAS, aumentando a chuva sobre a Bacia do Rio Prata.

Kayano e Capistrano (2014) analisaram a relação entre a AMO e ENOS, e sua influencia na precipitação da América do Sul. O ENOS é intensificado dependente da fase da AMO, o EN é mais pronunciado durante a fase negativa da AMO, enquanto que o LN é mais pronunciado durante a fase positiva da AMO.

O índice AMO, disponibilizado pelo NOAA, é obtido a partir do conjunto de dados *Kaplan SST* (KAPLAN et al., 1998), que possui resolução espacial de 5° x 5°, sobre a região do Atlântico.

2.3.5 Modo Meridional do Atlântico (AMM)

Segundo Chiang e Vimont (2004) o Modo Meridional do Atlântico (ou Dipolo Atlântico) é definido como o modo de variabilidade interanual acoplado oceano-atmosfera "meridional" no Oceano Atlântico tropical, caracterizado por variações em TSM e pressão ao nível do mar ao sul e ao norte da Zona de Convergência Intertropical (ZCIT). O AMM apresentam duas fases, uma fase positiva, AMM (+), apresenta águas mais quentes do que o normal no Atlântico Tropical Norte e águas mais frias no Atlântico Tropical Sul, ocorrendo o oposto na fase negativa, AMM (-) (CHANG et al., 1997).

Wainer e Venegas (2002) observaram que na fase positiva do AMM a ZCIT é impedida de se deslocar para o sul, inibindo as chuvas sobre o norte e nordeste brasileiro e que a fase negativa do AMM o deslocamento da ZCIT para sul é favorecido, trazendo chuvas ao norte e nordeste brasileiro.

Moura et al. (2009) verificaram a relação entre a precipitação do leste do Nordeste do Brasil e a temperatura dos oceanos, no período de 1945 a 1985. A análise mostrou que há influência do Atlântico e Pacífico sobre as chuvas do setor leste, sendo a correlação maior do Atlântico Sul, principalmente na área do Dipolo (AMM), indicando que águas quentes neste oceano afetam negativamente as chuvas, e água mais fria, positivamente.

Bombardi e Carvalho (2011) verificaram a relação entre a precipitação do oeste e sudeste do Brasil e a temperatura dos oceanos, no período de 1979-2007. A análise mostrou que as fases do AMM estão associadas com variações na estação chuvosa. AMM positiva está associada com o atraso na estação chuvosa e término antecipado, diminuindo as chuvas nestas regiões, enquanto que AMM negativa a estação chuvosa é antecipada e prolongada, aumentando as chuvas nestas regiões.

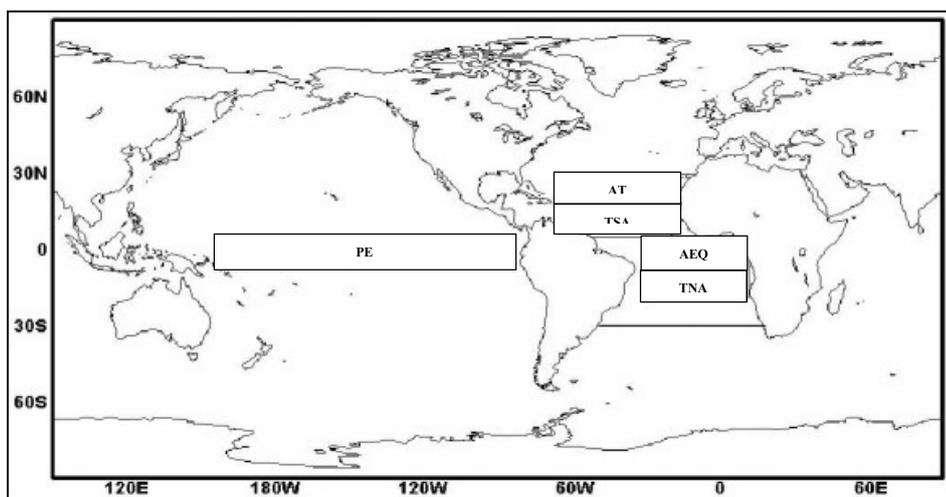
Bombardi et al. (2014) verificaram que durante a fase neutra do ENOS o AMM tem um papel importante na modulação de ciclones (ciclogênese) e nas características da ZCAS. Anomalias negativas estão relacionadas ao aumento de ciclogênese próximo ao sudeste do Brasil próximo a região de influência da ZCAS, alterando sua organização, que aumenta a precipitação sobre todo o leste da América do Sul.

O índice AMM é caracterizado pelo cálculo de duas variáveis: a TSM e os ventos sobre a região do Atlântico tropical ($21^{\circ}\text{S} - 32^{\circ}\text{N}$, $74^{\circ}\text{W} - 15^{\circ}\text{E}$), onde é feito o cálculo do gradiente meridional de TSM e o gradiente meridional dos ventos em superfície, com o objetivo de observar a oscilação da ZCIT, que migra para o hemisfério mais quente. Os dados disponíveis são padronizados e sem tendência (CHIANG e VIMONT, 2004).

2.3.6 Anomalias de TSM no Atlântico Tropical Sul (TSA)

O estudo das influências das anomalias de TSM no Atlântico tropical sobre o clima é facilitado através do uso de índices, tais como: Índice do Atlântico Tropical Norte (TNA), definido pela anomalia de TSM na região do Atlântico Tropical Norte (TNA), faixa $5,5^{\circ}\text{N} - 23,5^{\circ}\text{N}$ e $15^{\circ}\text{W} - 57,5^{\circ}\text{W}$ (Figura 2.6); e Índice do Atlântico Tropical Sul (TSA), caracterizado pela anomalia de TSM na região do Atlântico Tropical Sul (TSA), faixa $0^{\circ} - 20^{\circ}\text{S}$ e $10^{\circ}\text{E} - 30^{\circ}\text{W}$. Durante a fase positiva as águas na faixa do TSA se aquecem e durante a fase negativa se resfriam (ENFIELD et al., 1999).

Figura 2.6: Localização dos Oceanos, Pacífico Equatorial (PE), Atlântico Tropical (AT), Atlântico Tropical Norte (TNA), Atlântico Tropical Sul (TSA) e Atlântico Equatorial (AEQ).



Fonte: Adaptado de ANDREOLI e KAYNO, 2005.

Enfield e Mayer (1997) indicaram que há, no Atlântico tropical norte (principalmente em abril-maio-junho) e no Atlântico subtropical oeste (durante todo o ano, mas mais intenso em junho-julho-agosto), anomalias de TSM associadas com ENSO no Pacífico. Estas anomalias estariam defasadas em relação às do Pacífico em 4-5 meses. Kayno et al (2009) verificaram que está relação pode ser desfavorável, enfraquecendo o ENOS durante a fase positiva quando a TSM negativa.

Andreoli e Kayno (2005) previram anomalias de TSM no Atlântico Tropical (AT) utilizando análises por correlações canônicas e campos de anomalias de TSM do AT e PE, e sugeriram que o ENOS no Pacífico tem maior influência nas anomalias de TSM do ATN e que a variabilidade de TSM no ATS e AEQ está relacionada principalmente às variações atmosféricas locais ou à própria dinâmica oceânica na escala sazonal.

Andreoli e Kayano (2007) verificaram a importância relativa do Atlântico Tropical e Pacífico Leste na variabilidade de precipitação do Nordeste do Brasil, indicando que a influência mais marcante é da TSA.

Chaves (2011) sugere que as anomalias positivas de TSM no TSA podem influenciar no comportamento da ZCAS, aumentando as chuvas na região Sudeste, Centro-Oeste e parte norte da região Sul.

2.3.7 Oscilação do Atlântico Norte (NAO)

A Oscilação do Atlântico Norte (NAO) está relacionada com uma alternância da intensidade dos centros de baixas e altas pressões, que se localizam sobre a baixa polar da Islândia e a Alta Subtropical dos Açores, apresentando variabilidades sazonal e interanual. Na fase positiva da NAO, observam-se pressões mais baixas próximas Islândia e pressões mais altas sobre Açores. Na fase negativa a situação se inverte, pressões mais altas próximas a Islândia e pressões mais altas sobre Açores (HURRELL, 2003).

Segundo Teixeira (2002) o índice NAO positivo pode levar ao resfriamento anômalo (pelo mecanismo vento - evaporação e fluxo de calor latente - TSM) das águas superficiais oceânicas em boa parte da região, no Atlântico Norte, em que se localiza o núcleo norte do Dipolo de TSM do Atlântico tropical e o índice negativo pode levar a um aquecimento dessa área.

Siqueira e Molion (2015) sugerem que as chuvas na região centro-leste do Brasil podem estar relacionadas com a NAO (região ao norte da Bacia do Paraná), podendo influenciar na vazão de Itaipu. Além disso, sugeriram que a NAO se associa ao ENOS.

Piccilli (2007) sugere que a NAO influencia na variabilidade do Atlântico Tropical associado com o ENOS na bacia do Paraguai. Verificaram que durante a fase fria da NAO ocorre a diminuição da precipitação no período seco.

Severo (2008) identificou correlação positiva entre a precipitação do sul do Brasil com a NAO principalmente nas estações de transição (outono e primavera) e com menor intensidade no verão e inverno.

O índice NAO é calculado diariamente pelo CPC/NCEP através das anomalias de altura geopotencial em 500 hPa sobre o modo principal da *Empirical Orthogonal Function* (EOF) derivado de médias mensais de anomalias de altura geopotencial em 500 hPa de 0° N a 90°N.

2.3.8 Oscilação Antártica (AAO)

Segundo Gon e Wang (1999) a Oscilação Antártica (AAO), também chamada de Modo Anular do Hemisfério Sul é definida como a oscilação entre cinturões de pressão de

latitudes médias (40°S) e altas (65°S) no Hemisfério Sul. A AAO apresenta duas fases distintas, uma positiva e uma negativa. Quando a AAO está em sua fase positiva, há uma maior diferença de pressão entre latitudes médias e altas do Hemisfério Sul, uma baixa pressão prevalece em latitudes altas e alta pressão nas latitudes médias. Na fase negativa essa condição se altera, uma alta pressão prevalece em latitudes altas e baixa pressão nas latitudes médias.

Vasconcellos e Cavalcanti (2010) analisaram os extremos de precipitação média na região Sudeste do Brasil e verificaram que os verões muito chuvosos (muitos secos) na região de estudo estão associados à intensificação de trens de ondas do tipo PSA³ (*Pacific South America*) pela fase negativa (positiva) da AAO.

Oliva (2011) verificou a ação combinada entre o ENOS e AAO, onde as fases negativas da AAO predominam durante o EN enquanto que as fases positivas predominam na LN.

Mendes e Cavalcanti (2014) estudaram a relação entre a AAO e aos eventos de bloqueios ao longo do Pacífico Sul e Oceano Atlântico, concluindo que a frequência de dias bloqueados é diferente para cada fase da AAO, apresentando na fase positiva maior duração e maior número de eventos.

O CPC/NCEP computa diariamente o índice AAO através da projeção das anomalias de altura geopotencial em 700 hPa sobre o modo principal da EOF derivado de médias mensais de anomalias de altura geopotencial em 700 hPa de 20°S a 90°S. O EOF captura o máximo da variância explicada. Estes dados são baseados nas reanálises do *National Centers for Environmental Prediction/National Center for Atmospheric Research* (NCEP/NCAR) e foram empregados em uma resolução horizontal de 2,5° por 2,5°, para o período que se iniciou em 1979, e o ciclo sazonal é removido do campo médio mensal do geopotencial. Em seguida a matriz de covariância é usada para a análise da EOF.

³ O padrão atmosférico PSA (América do Sul-Pacífico ou Pacific-South American) é um padrão de multi-escala temporal de variabilidade de baixa frequência, caracterizado por trens de onda emanados da costa leste da Austrália em direção ao Pacífico Sul e sobre a América do Sul (PRANDO, 2010).

CAPÍTULO 3

3. MATERIAIS E MÉTODOS

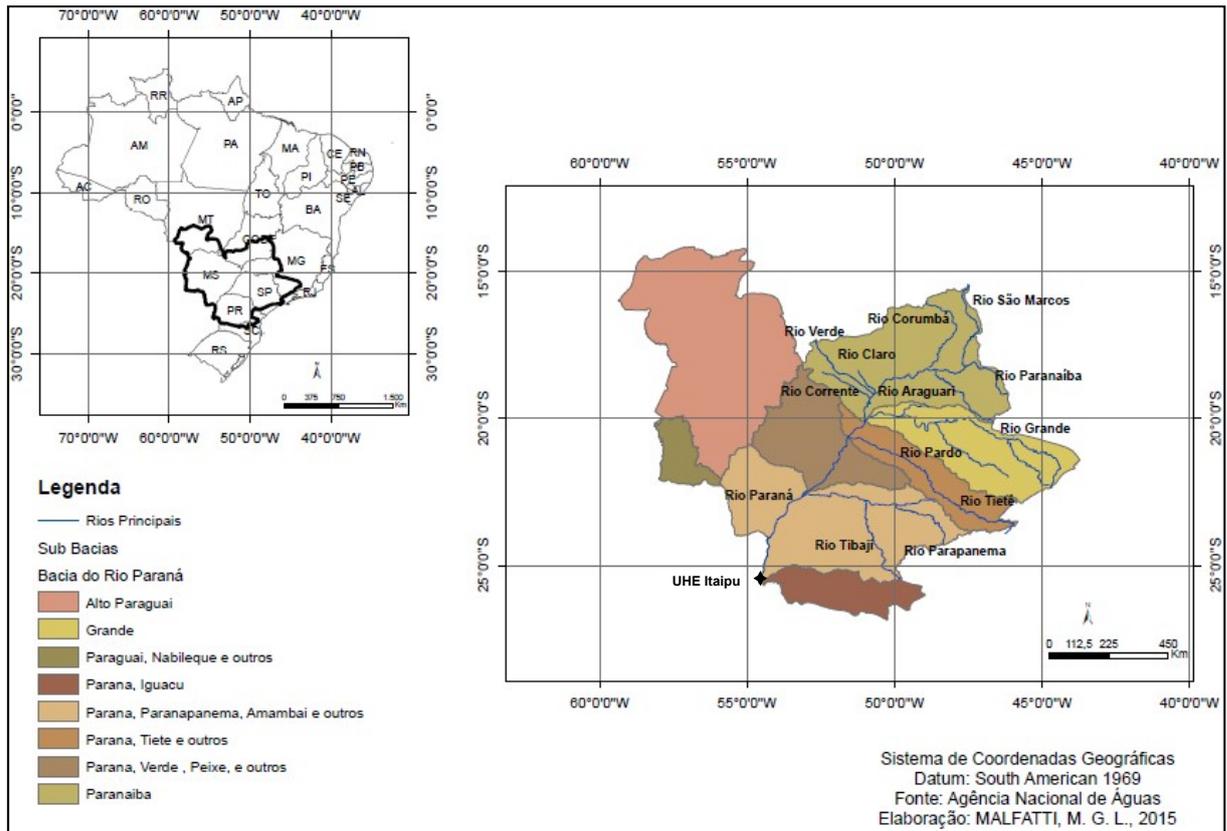
3.1 Área de estudo

3.1.1 Bacia Hidrográfica do Rio Paraná

A Bacia Hidrográfica do Rio Paraná possui uma área de 879.873 Km² (Figura 3.1), que abrange os estados de São Paulo (25% da região), Paraná (21%), Mato Grosso do Sul (20%), Minas Gerais (18%), Goiás (14%), Santa Catarina (1,5%) e Distrito Federal (0,5%). Concentra cerca de um terço da população brasileira (32%), incluindo a região mais industrializada e urbanizada do Brasil e é a bacia hidrográfica com a maior capacidade instalada de geração de energia elétrica do país, correspondendo a 59,3% do total nacional, sendo a de maior demanda, cerca de 75% do consumo nacional (ANA, 2009).

A Agência Nacional de Águas (ANA) subdivide a bacia hidrográfica do Rio Paraná em oito sub-bacias conforme a Figura 3.1, essa divisão é administrativa e não fisiográfica (configuração das sub-bacias). O principal rio desta bacia é o Rio Paraná que nasce da confluência dos rios Paranaíba e Grande, na divisa entre os estados de São Paulo, Minas Gerais e Mato Grosso do Sul, possui uma extensão de 2.570 Km até sua foz no Rio Prata, e seus principais afluentes são os rios Paranaíba, Grande, Tietê, Paranapanema e Iguaçu. Na Figura 3.1 foram destacados os rios principais a montante de Itaipu e os rios que possuem usinas hidrelétricas a monte de Itaipu (Rio São Marcos, Rio Corumbá, Rio Verde, Rio Corrente, Rio Claro, Rio Araguari, Rio Pardo e Rio Tibaji) (ANA, 2009).

Figura 3.1: Localização da Bacia Hidrográfica do Rio Paraná, seus principais rios, sub-bacias e a Usina Hidrelétrica de Itaipu.



Fonte: ANA.

3.1.2 Usina Hidrelétrica de Itaipu

O local da Usina Hidrelétrica (UHE) de Itaipu foi focalizado para a realização de previsão de vazão. Essa usina é de grande importância energética, estando localizada no Rio Paraná, na fronteira entre o Brasil e o Paraguai (Coordenadas - Latitude: -25,40833. Longitude: -54,58889), Figura 3.1. (ANA, 2009; ITAIPU BINACIONAL, 2015).

Construída pelos países Brasil e Paraguai no período de 1975 a 1982, Itaipu Binacional é hoje a segunda maior usina em potencial instalado e a primeira geradora de energia do mundo. Sua maior produção foi no ano de 2013, produzindo 98,60 milhões MWh, fornecendo cerca de 15% da energia consumida no Brasil e 75% do consumo paraguaio (ITAIPU BINACIONAL, 2015).

3.2 Dados

Para o desenvolvimento deste estudo foram utilizados dados mensais das seguintes variáveis: *i)* índices climáticos; *ii)* vazão de rios; e *iii)* precipitação. As informações sobre os dados, como localização e distribuição das estações (fluviométrica e pluviométrica), e período de análise estão representadas a seguir.

3.2.1 Índices Climáticos

Os dados de índices climáticos utilizados estão disponíveis no site “<http://www.esrl.noaa.gov/psd/data/climateindices/list/>” do NOAA, sendo esses índices produzidos pelo CPC/NCEP. Os índices climáticos selecionados e seus respectivos períodos estão especificados na Tabela 3.1.

Tabela 3.1: Índices Climáticos utilizados e seus respectivos períodos de dados.

Sigla	Índice	Período
AAO	Oscilação Antártica	1979 – 2014
AMM	Modo Meridional do Atlântico	1948 – 2014
AMO	Oscilação Multidecadal do Atlântico	1948 – 2014
NAO	Oscilação do Atlântico Norte	1950 – 2014
NIÑO 3.4	TSM na região Central-Leste do Oceano Pacífico Tropical	1950 – 2014
PDO	Oscilação Decadal do Pacífico	1948 – 2013
SOI	Índice Oscilação Sul	1951 – 2014
TSA	Índice do Atlântico Tropical Sul	1948 – 2014

3.2.2 Vazão de rios

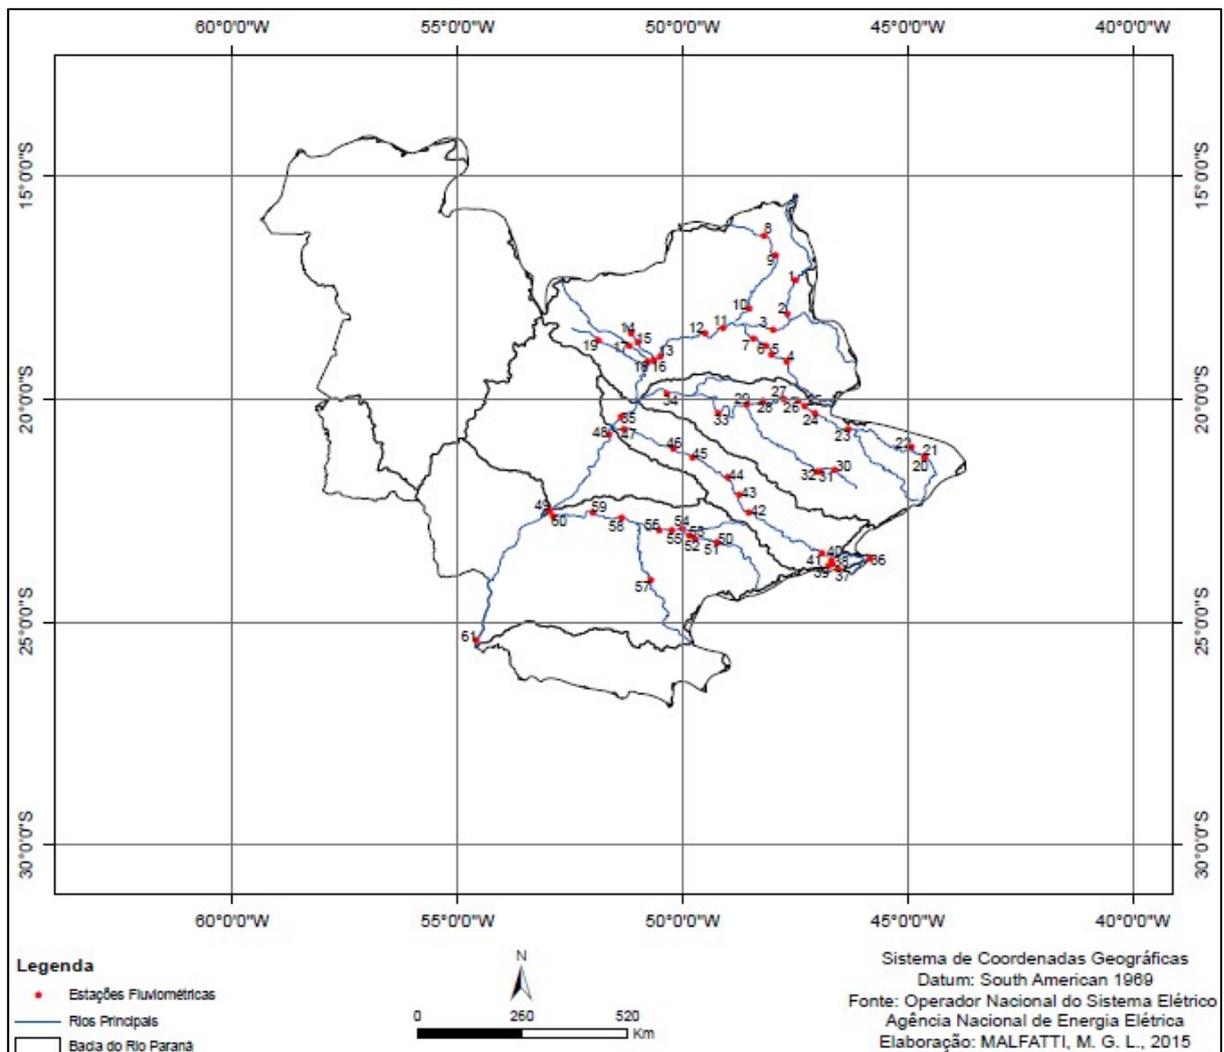
Os dados de vazão utilizados estão disponíveis no site “http://www.ons.org.br/operacao/vazoes_naturais.aspx” do Operador Nacional do Sistema Elétrico (ONS). O conjunto de dados do ONS é composto por informações de vazões naturais⁴ afluentes, diárias e mensais, em aproveitamentos hidroelétricos no Brasil no período

⁴ O termo vazão natural tem sido adotado pelo setor elétrico para identificar a vazão que ocorreria em uma seção do rio, se não houvesse as ações antrópicas na sua bacia contribuinte – tais como regularização de vazões realizadas por reservatórios, desvios de água, evaporações em reservatórios e usos consuntivos (irrigação, criação animal e abastecimento urbano, rural e industrial). Obtida por meio de um processo de reconstituição,

de 1931 a 2013. Neste trabalho foram utilizadas as vazões mensais (m^3/s) distribuídas em pontos sobre a BHRP a montante do posto de Itaipu, o diagrama esquemático das UHE na bacia, encontra-se disponível na Figura A.1 (Anexo).

A Figura 3.2 mostra a localização das 61 estações fluviométricas do ONS, sendo selecionadas todas as estações fluviométricas encontradas na BHRP a montante de Itaipu (60 estações a montante de Itaipu e a própria estação de Itaipu), a Tabela A.1 destacada no Apêndice contém informações adicionais sobre as UHE, seus respectivos códigos de referência estabelecidos, latitudes e longitudes.

Figura 3.2: Localização das Estações Fluviométricas na Bacia Hidrográfica do Rio Paraná.



Fonte: ONS e ANEEL.

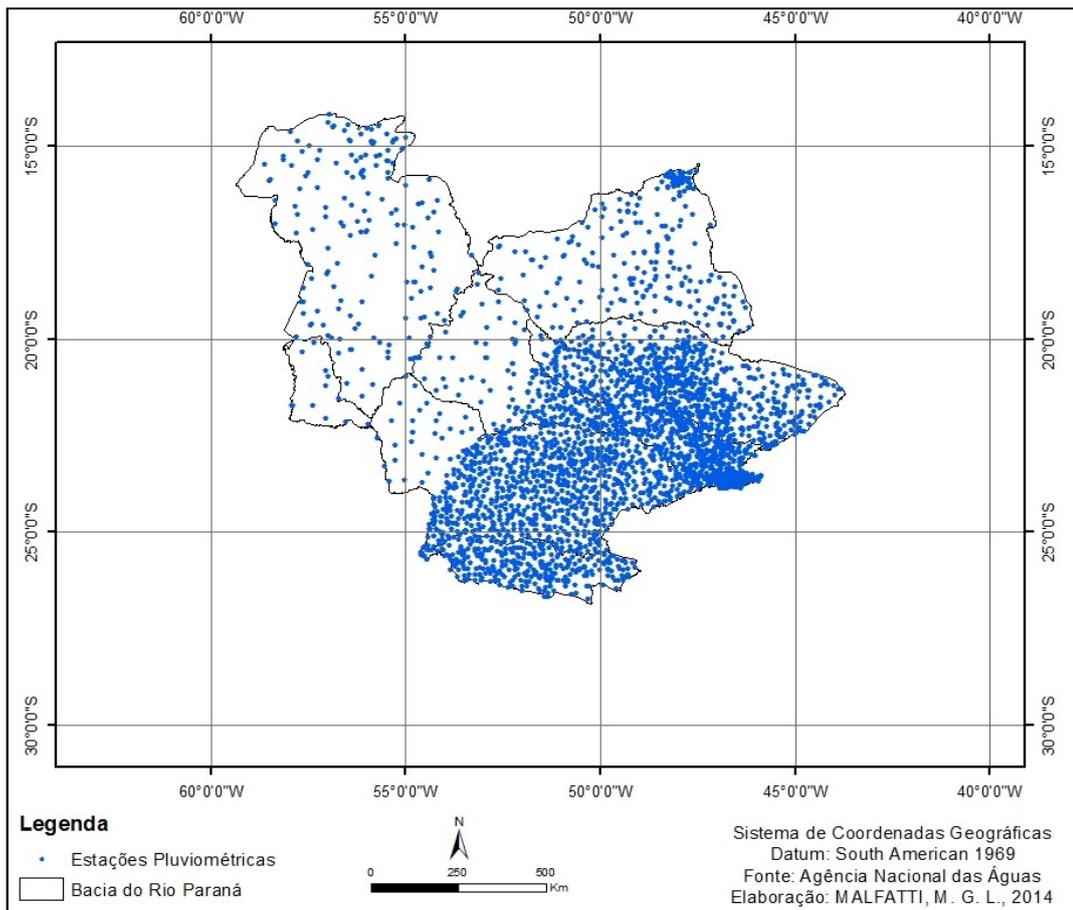
que considera a vazão observada no local e as informações relativas às ações antrópicas na bacia (Definição disponível no site do ONS, "http://www.ons.org.br/operacao/vazoes_naturais.aspx").

Como pode ser observado na Figura 3.2, as estações fluviométricas estão concentradas na região sul e leste da BHRP, onde estão localizados os aproveitamentos hidrelétricos do Brasil, com maior concentração nos rios Grande, Tietê, Paranapanema, Paranaíba e Paraná.

3.2.3 Precipitação

Os dados de precipitação utilizados estão disponíveis na Agência Nacional das Águas (ANA), no site “<http://hidroweb.ana.gov.br/>”. O conjunto de dados é composto por informações de precipitação diária. Neste trabalho foram inicialmente utilizados dados diários de precipitações (mm) distribuídos sobre a BHRP nos locais destacados na Figura 3.3, abrangendo um total de 3.363 estações pluviométricas disponível na ANA em vários períodos, entre 1889 a 2014.

Figura 3.3: Localização das Estações Pluviométricas na Bacia Hidrográfica do Rio Paraná.



Fonte: ANA.

Como pode ser observado na Figura 3.3, as estações pluviométricas apresentam maior densidade na região sul e leste da BHRP, acompanhando a representatividade das estações pluviométricas.

3.3 Definição do período de estudo

Para que o processo de modelagem obtenha maior confiabilidade, considerando uma boa representação climatológica, o período das séries deve ser igual ou superior a 30 anos (séries longas de dados) e também coincidentes para todas as variáveis (TUCCI, 2005). Além disso, a distribuição espacial dos dados deve ser representativa, para que toda a área de estudo seja analisada.

Visto que as vazões de rios e os índices climáticos possuem longas séries completas de dados, superiores a 30 anos, o período de estudo é definido pelo conjunto de dados de precipitação, já que estes dados muitas vezes são incompletos e possuem séries com diferentes períodos.

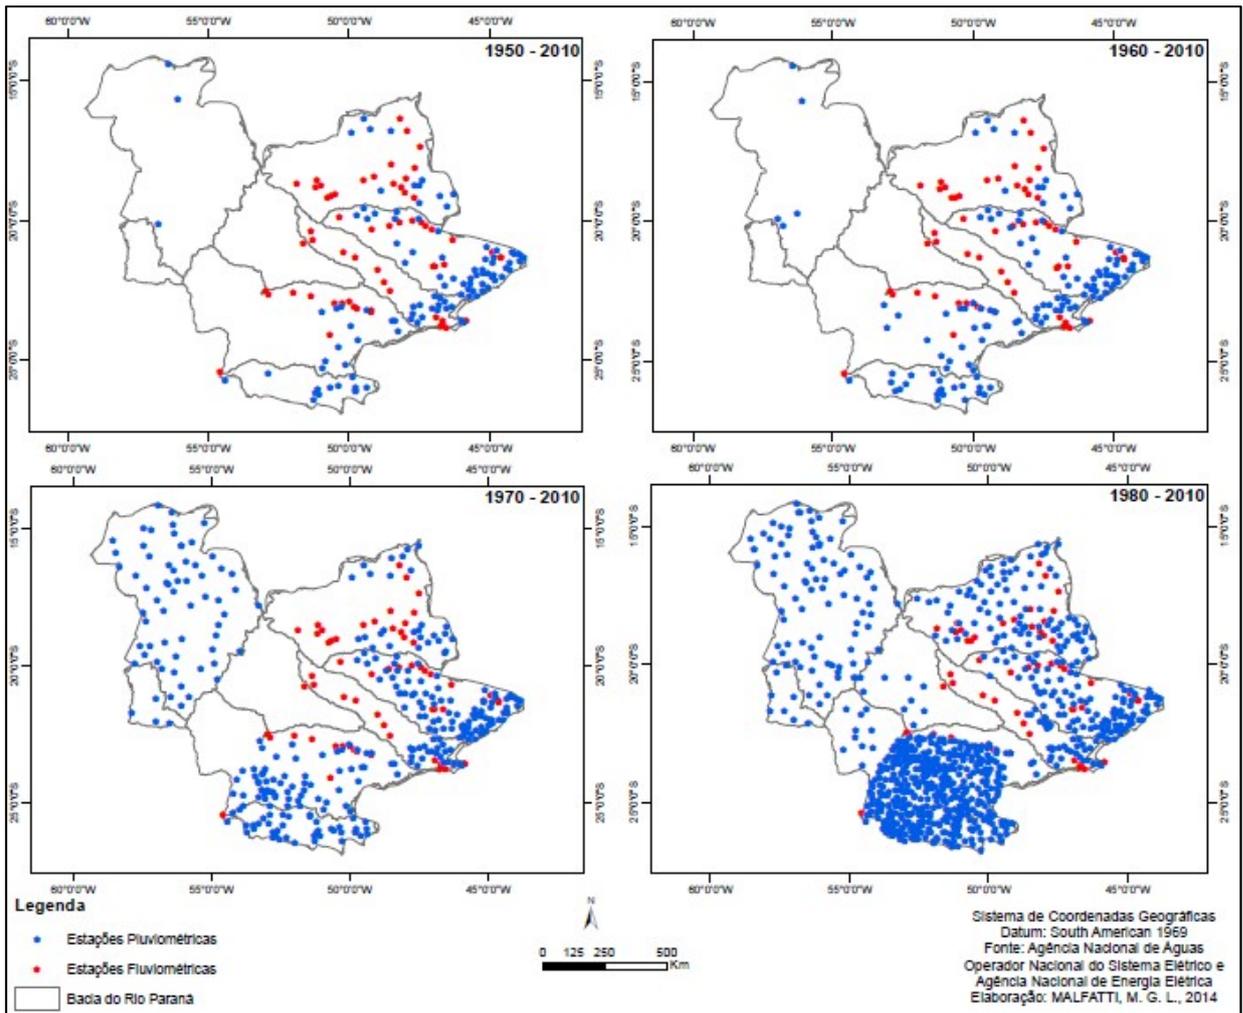
Do universo de 3.363 estações pluviométricas foi aplicado um filtro para selecionar as séries históricas acima de 30 anos. Foram selecionados os intervalos de 1950 a 2010, 1960 a 2010, 1970 a 2010 e 1980 a 2010, contendo séries históricas com 60, 50, 40 e 30 anos de dados respectivamente.

A Figura 3.4 mostra o conjunto de estações pluviométricas e fluviométricas nos intervalos selecionados: *i)* 1950 a 2010; *ii)* 1960 a 2010; *iii)* 1970 a 2010 e *iv)* 1980 a 2010. Os dados contidos no segundo período analisado (*ii*) são estações com séries históricas do primeiro período mais estações que tem dados que se iniciam em 1960. Para o terceiro e quarto período segue a mesma métrica.

Analisando os mapas da Figura 3.4 é possível identificar que no período de 1950 a 2010 os dados pluviométricos estão contidos na região leste da BHRP e apresentam poucas estações do universo inicial de 3.363 estações; para o período de 1960 a 2010 os dados continuaram escassos e contidos na região leste da bacia; para o período de 1970 a 2010 os dados começam a aparecer na região oeste da bacia e com um volume de dados maior que nos períodos anteriores; e para o período de 1980 a 2010 os dados são mais bem distribuídos ao longo da bacia, com exceção da região central, pouco densa, que contém alguns trechos sem

estações pluviométricas com séries de dados superiores a 30 anos. A partir destas considerações o período escolhido para a análise é o de 1980 a 2010, por apresentar o melhor conjunto de dados (798 estações pluviométricas), sendo bem distribuído espacialmente, caracterizado por um período de aproximadamente 30 anos e com um número de estações representativo para realizar as análises.

Figura 3.4: Distribuição espaço-temporal das Estações Pluviométricas e Fluviométricas na Bacia do Paraná no período de 1950 a 2010, 1960 a 2010, 1970 a 2010 e 1980 a 2010.



Fonte: ANA, ONS e ANEEL.

Portanto, o conjunto de dados final a ser utilizados nas análises deste estudo possui registros no período de 1980 a 2010, contendo 798 séries históricas de precipitação, 61 séries históricas de vazão e 8 séries históricas de índices climáticos.

3.4 Tratamento dos dados de precipitação

Os dados de precipitação passaram por um tratamento antes de serem analisados, seguindo as seguintes etapas: *i*) identificação de dados duvidosos (por *outliers*) e *ii*) preenchimentos dos dados faltantes.

Visando reduzir a dimensão dos dados para a identificação de dados duvidosos, foram calculadas as médias e os quantis dos acumulados anuais de precipitação, considerando os limites de 15%, 35%, 65% e 85% (XAVIER e XAVIER, 1987).

Para calcular os quantis de uma determinada série de dados P_i , com i variando de 1 a n observações, é necessário determinar o número de ordem $w(P_i)$ de cada elemento i desta série, supondo que as observações estejam dispostas em ordem crescente. Sendo n o número de observações disponíveis, calculam-se os quantis a partir da equação (3.1).

$$q(P_i) = \frac{1}{2n} + \frac{[w(P_i) - 1]}{n} \quad (3.1)$$

Na Tabela 3.2 são apresentados os intervalos de classes para a categorização da precipitação conforme o critério apresentado por Xavier e Xavier (1987).

Tabela 3.2: Intervalos de classe para categorização da precipitação.

Quantil (P_i)	Classificação
$P_i \leq 0,15$	Muito seco
$0,15 < P_i \leq 0,35$	Seco
$0,35 < P_i \leq 0,65$	Normal
$0,65 < P_i \leq 0,85$	Chuvoso
$0,85 < P_i$	Muito Chuvoso

Fonte: XAVIER e XAVIER, 1987.

3.4.1 Remoção dos dados discrepantes (*outliers*)

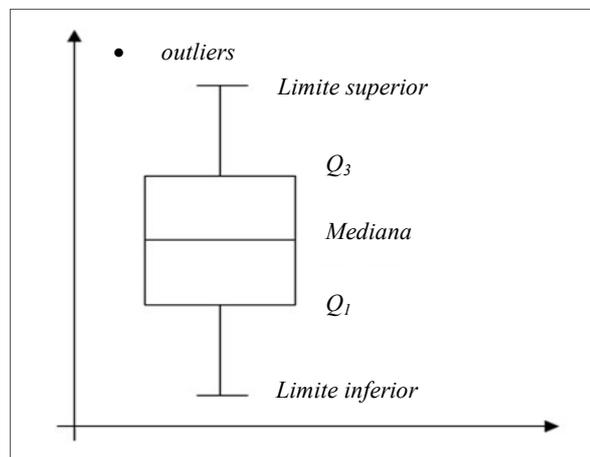
As séries de dados de precipitação podem apresentar dados discrepantes (*outliers*), ou seja, dados que apresentam valores muito diferentes da maioria. O aparecimento desses dados é muitas vezes decorrente de erros de medição, erros de execução (falha no método empregado) e variabilidade inerente dos elementos da amostra (extremos) (NAGHETTINI & PINTO, 2007).

Segundo Ribeiro Júnior e Diggle (2001) na análise geoestatística os *outliers* podem influenciar no comportamento dos semivariogramas experimentais na parte inicial. Assim, pode conduzir à conclusão errada sobre a variância do ruído (efeito pepita) e ou a existência de correlação espacial na interpolação de dados.

Existem vários métodos de identificação dos *outliers*: Diagrama de *Box Plot*, Modelos de Discordância, Teste de Dixon, Teste de Grubbs, Z-score, entre outros (OLIVEIRA et al., 2014). O método utilizado neste estudo foi o de Diagrama de *Box Plot* (Figura 3.5) para a investigação de pontos discrepantes (*outliers*) nas séries históricas de precipitação. Este método consiste em um retângulo definido pelo primeiro e pelo terceiro quartis da amostra ordenada (25% e 75%, respectivamente), contendo a mediana (50%) em seu interior.

Dado que AIQ corresponde a amplitude interquartil ($Q_3 - Q_1 = AIQ$) e que tais quartis limitam o retângulo de dispersão, os limites inferior e superior são estimados em função de AIQ ($Q_3 + 1,5AIQ$ e $Q_1 - 1,5AIQ$, respectivamente). As observações que estiverem acima ou abaixo desses limites são consideradas *outliers* ou valores atípicos, requerendo uma análise cuidadosa para confirmar se não é um erro de medida ou registro.

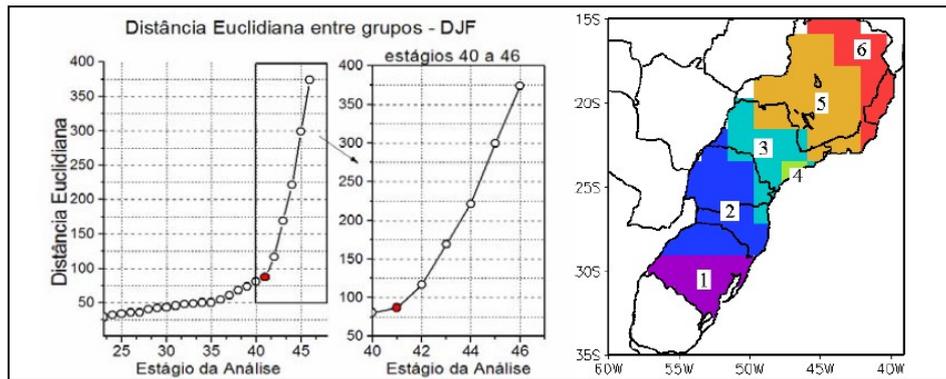
Figura 3.5: Diagrama de *Box Plot* teórico, retângulo definido através dos valores dos quartis e mediana, com os limites superior e inferior. Os pontos fora do diagrama representam os *outliers*.



Neste estudo o Diagrama de *Box Plot* foi desenvolvido no Microsoft Excel 2007[®] para grupos de séries de precipitação média acumulada anual no período de 1980 a 2010, contidas em faixas homogêneas pré-estabelecidas no estudo de Cardoso (2005), indicadas na Figura 3.6, ou seja, o valor médio de precipitação acumulada de cada estação foi calculado. Essas estações foram separadas em grupos pré-estabelecidos e para cada grupo foi desenvolvido o diagrama de *Box plot*. Tal métrica foi aplicada para possibilitar a identificação de dados

duvidosos a partir de comparação com estações pluviométricas consideradas vizinhas por semelhança de padrão climático. Para tanto, escolheu-se a regionalização de Cardoso (2005) para o trimestre de dezembro – janeiro – fevereiro (DJF) por ser o período de classificação que conduziu a uma maior subdivisão de grupos de estações de precipitação distribuídos no Sul e Sudeste, região que abrange a maior parte da BHRP.

Figura 3.6: Regionalização de precipitação proposta por Cardoso (2005) para o trimestre de DJF (Dezembro, Janeiro e Fevereiro).



Fonte: CARDOSO, 2005.

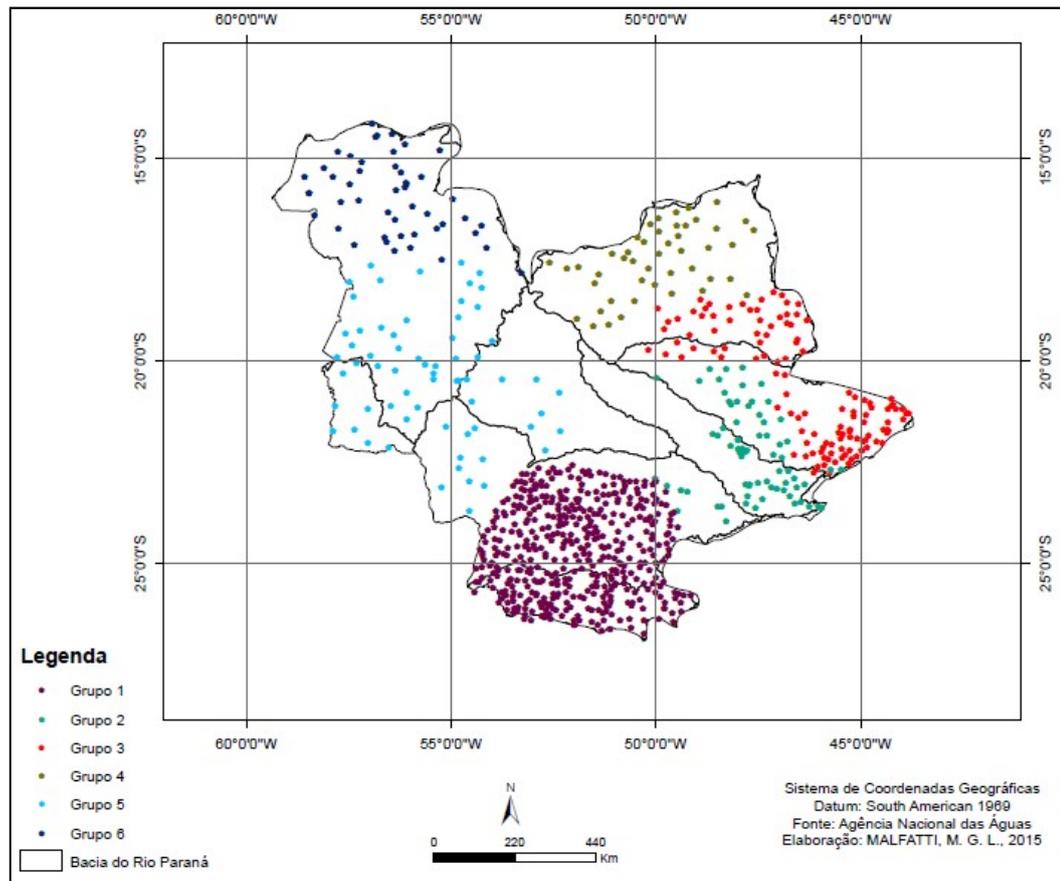
Através da Figura 3.6 observa-se que a faixa regionalizada corresponde à região sul e sudeste do Brasil. Em contrapartida, no presente estudo a área abrange faixas de algumas regiões propostas e mais uma parte da região centro-oeste. Assim, os grupos de estações para o desenvolvimento do Diagrama de *Box Plot* foram adaptados conforme a Tabela 3.3.

Tabela 3.3: Grupos utilizados para o desenvolvimento do *Box Plot*.

Grupo	Regiões consideradas
1	Região 2 definida por Cardoso (2005)
2	Região 3 e 4 definida por Cardoso (2005)
3	Região 5 definida por Cardoso (2005)
4	Faixa sul de Goiás e faixa sul do Distrito Federal
5	Estado do Mato Grosso do Sul

A partir da definição das regiões foram selecionadas as estações pluviométricas contidas nas regiões preliminares indicadas na Figura 3.7.

Figura 3.7: Estações pluviométricas divididas por grupos, utilizadas no Diagrama de *Box Plot*.



Fonte: ANA.

Após a identificação dos possíveis *outliers*, os dados de precipitação foram analisados. As estações que apresentaram *outliers*, dada a métrica anterior, foram reavaliadas individualmente através de um novo Diagrama de *Box Plot*, sendo possível assim identificar o período de *outliers*. Como o dado indicado pode ser um erro ou um extremo de precipitação, foi realizada uma comparação com estações vizinhas.

Nos casos em que foram constatados erros de dados ao longo série, a estação foi removida da base de dados, para que análises posteriores não fossem comprometidas.

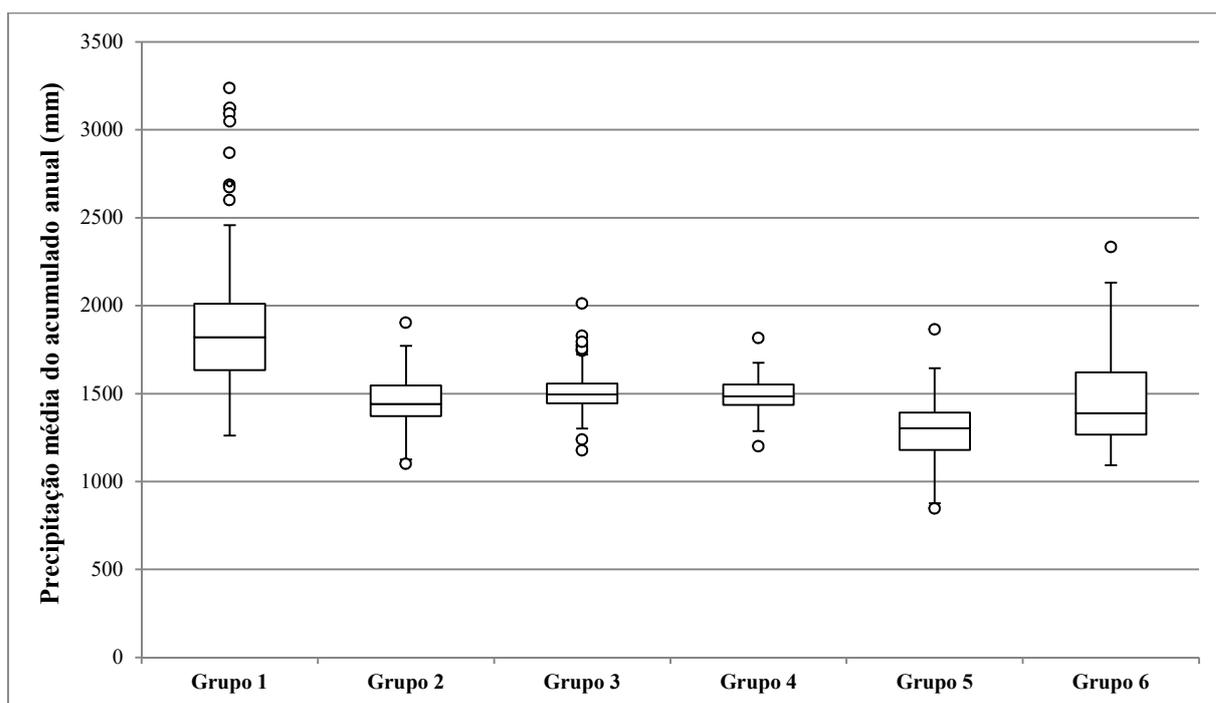
3.4.1.1 Identificação de dados duvidosos de precipitação

Além de identificar os *outliers* o Diagrama de *Box Plot* auxilia no diagnóstico da variabilidade espacial dos dados pluviométricos. O resultado do Diagrama de *Box Plot* para os seis grupos selecionados (Tabela 3.3) está representado na Figura 3.8. Os pontos fora dos

limites representam os *outliers* identificados para cada grupo previamente selecionado, sendo que ao todo foram encontrados vinte e quatro *outliers*.

Conforme destacado pela Figura 3.8, os grupos pré-estabelecidos apresentam padrões climáticos anuais distintos, caracterizados por diferentes faixas da amplitude da precipitação associadas as estações pertencentes a cada grupo (Figura 3.7), com exceção dos grupos 3 (grupo 3 corresponde ao nordeste da BHRP, representada pela faixa norte de MG e norte de SP) e 4 (faixa sul de GO e sul do Distrito Federal) que apresentam distribuições semelhantes. O grupo 5 possui menores acumulados de precipitação (região a oeste da BHRP, MS) enquanto que os grupos 1 (SC, PR e sul de SP) e 6 (sul do MS) apresentam as maiores precipitações e variabilidade espacial.

Figura 3.8: Diagrama de *Box Plot* com a série de dados de precipitação média do acumulado anual sem preenchimento dos dados faltantes, para os grupos de estações pluviométricas. Os pontos no diagrama representam os *outliers*.



Conforme indicado pelo diagrama todos os grupos apresentam outliers, com destaque para os grupos 3 e 1. A Tabela 3.4 indica o código da estação pluviométrica, seu grupo pertencente e o tipo de *outlier* (superior e inferior).

Tabela 3.4: Estações pluviométricas identificadas como *outlier* pelo Diagrama de *Box Plot*.

Grupo	Estação Pluviométrica	Tipo de <i>outlier</i>	Grupo	Estação Pluviométrica	Tipo de <i>outlier</i>
2	02246023	Inferior	1	02553052	Superior
3	02145020	Inferior	1	02651046	Superior
3	02245011	Inferior	2	02345076	Superior
4	01649006	Inferior	3	01847007	Superior
5	01957003	Inferior	3	02047016	Superior
1	02550016	Superior	3	02144018	Superior
1	02550043	Superior	3	02244054	Superior
1	02551022	Superior	3	02245010	Superior
1	02551025	Superior	3	02245080	Superior
1	02552019	Superior	4	01648002	Superior
1	02553046	Superior	5	02355000	Superior
1	02553051	Superior	6	0155500	Superior

Para cada estação indicada na Tabela 3.4, foi realizada uma análise detalhada na série histórica para a procura de dados duvidosos. Em todos os seis casos de *outliers* inferiores verificou-se que a série histórica completa apresenta amplitudes de precipitação inferiores em comparação com as demais estações do grupo, não sendo considerado um dado duvidoso, mas sim um regime climático distinto, sendo mantida tal estação pluviométrica na base de dados. Resultado semelhante foi verificado no caso de dez estações que apresentaram *outliers* superiores. No entanto, nove estações com *outliers* superiores apresentaram dados duvidosos (destacadas em negrito, na Tabela 3.4), possivelmente relacionados a erros de registro, sendo estas excluídas da base de dados original.

3.4.2 Preenchimento dos dados faltantes

Para o desenvolvimento desse estudo foi necessário utilizar um conjunto de dados com séries históricas longas (mínimo 30 anos, como destacado no item 3.3 – Definição do período de estudo), contudo os dados de precipitação raramente possuem séries históricas longas e completas, frequentemente verificam-se falhas ao longo do conjunto de dados.

Para que o conjunto de dados seja mais completo, foi necessário aplicar uma técnica de estimativa de dados faltantes para preenchimento das falhas. O método utilizado é baseado na análise de regressão linear aplicada as estações vizinhas, selecionadas através de

correlação. A curva de regressão é calculada a partir da razão dos desvios, sendo que a estimativa final é a combinação linear obtida por cada vizinha.

As etapas utilizadas para realizar a estimativa foram:

- I. As estações foram separadas inicialmente de acordo com o valor da correlação, (r de Person $\geq 0,80$) com a estação a ser preenchida;
- II. Posteriormente foram selecionadas as estações vizinhas mais próximas (máximo 3 estações vizinhas);
- III. Cada estação vizinha passou a ter um peso dependendo da relação com as estações a serem preenchidas e ao conjunto de estações vizinhas, sendo os pesos determinados pelo modelo de regressão linear múltipla.

A Tabela 3.5 mostra o número de estações com dados faltantes, antes e depois do preenchimento dos dados (sem dados faltantes ou com 1 a 10 meses com dados faltantes).

Tabela 3.5: Número estações com dados faltantes sem e com preenchimento dos dados.

Número de meses com dados faltantes	Sem preenchimento		Com preenchimento	
	Número de Estações	Porcentagem das Estações	Número de Estações	Porcentagem das Estações
Sem dados faltantes	237 estações	30%	640 estações	81,1%
1 mês	116 estações	14,7%	11 estações	1,4%
2 meses	60 estações	7,6%	13 estações	1,6%
3 meses	44 estações	5,6%	5 estações	0,6%
4 meses	29 estações	3,7%	4 estações	0,5%
5 meses	27 estações	3,4%	5 estações	0,6%
6 meses	21 estações	2,7%	5 estações	0,6%
7 meses	15 estações	1,9%	3 estações	0,4%
8 meses	20 estações	2,5%	3 estações	0,4%
9 meses	14 estações	1,8%	2 estações	0,3%
10 meses	14 estações	1,8%	2 estações	0,3%
Mais que 10 meses	191 estações	24,3%	87 estações	12,2%

Vale destacar que, para que o mês seja considerado faltante algum dado diário daquele ano não se encontra disponível (dado diário faltante).

Anteriormente as séries de precipitação sem dados faltantes representavam apenas 30% do total das estações pluviométricas na BHRP para o período de dados de 1980 a 2010, após o preenchimento dos dados as estações pluviométricas que não apresentam dados faltantes representam mais que 80% desses dados, mostrando que o método de preenchimento de dados aplicado foi eficiente.

3.5 Interpolação dos dados de precipitação

A interpolação dos dados de precipitação foi necessária para verificar a distribuição espacial dos dados de precipitação ao longo da bacia do Rio Paraná, principalmente em locais onde não existem estações pluviométricas, e reduzir a dimensão do conjunto inicial através do estabelecimento de regiões homogêneas (metodologia detalhada no item 3.6 – Identificação de regiões pluviométricas homogêneas).

Antes de realizar a interpolação os dados de precipitação foram tratados, visando tornar a elaboração da interpolação mais clara e objetiva, comparando as diferentes estações de precipitação através de limiares representativos desta variável. Para tanto, foram considerados a média e os quantis de 15%, 35%, 65% e 85% dos dados de precipitação acumulada anual das séries pluviométricas preenchidas.

O processo de interpolação de dados consiste em converter dados vetoriais em raster, ou seja, dados pontuais (dados de precipitação nas estações pluviométricas) transformados em campos contínuos. Existem vários métodos de interpolação de dados, alguns deles são: Krigagem (simples, ordinária, universal, indicação, disjunta e Co-krigagem), por Inverso da Distância (IQD), *Thin Plate Spline* (TPS), *Radial Basin*, Inverso da Potência da Distância (IPD), Inverso do Quadrado da *Function Multiquadric* (RBQ) (LOUREIRO e LISBOA, 2011).

Viola et al. (2010) utilizaram métodos de interpolação para o mapeamento da precipitação pluvial em minas gerais, destacando o método da Co-krigagem que obteve o melhor resultado. Léllis e Barroso (2011) interpolaram dados da precipitação na bacia do rio Jacaraípe, Serra (ES) através do método da Krigagem. Loureiro e Lisboa (2011) compararam quatro métodos de interpolação de dados (Thin Plane Spline, Krigagem ordinária, IQD e RBQ) usando observações de precipitação na Bacia do Tocantins-Araguaia, concluíram que o

método mais eficiente foi a Krigagem ordinária. Ávilla et. al (2009) utilizaram o método da Krigagem ordinária para o mapeamento da precipitação mínima provável para o sul de Minas Gerais. Barbosa (2006) também interpolou os dados para análise e espacialização de dados climáticos sobre o estado de São Paulo pelo método da Krigagem ordinária. Mello et al. (2012) analisaram a distribuição de precipitação anual na bacia hidrográfica do rio Cubatão Norte através do método da Krigagem.

O método escolhido para realizar a interpolação dos dados de precipitação média foi a Krigagem ordinária, o método de interpolação geoestatístico mais conhecido e utilizado, principalmente para interpolação de dados de precipitação (LÉLLIS e BARROSO, 2011). A diferença desse método para os demais está na definição dos pesos de ponderação obtidos através dos ajustes dos modelos teóricos para estimar valores pluviométricos em locais não amostrados, obedecendo aos critérios de não-tendenciosidade e mínima variância (VIOLA et al., 2010), e a consideração da dependência espacial que possibilita o controle de uma parcela do erro aleatório e a obtenção de bons resultados. Para isso, utiliza técnicas de regressão que procura minimizar a variância estimada, aplicando um modelo de dependência estocástica entre os dados distribuídos no espaço, cujo valor esperado para o erro seja nula e apresentem variância mínima representada por uma função denominada variograma (CARUSO e QUARTA, 1998). A equação do estimador de Krigagem ordinária é definida a partir da combinação linear dos valores de um subconjunto amostral local (equação 3.2).

$$z(x_j, y_j) = \sum_{i=1}^{n(j)} \lambda_1(x_j, y_j) * z(x_j, y_j) \quad (3.2)$$

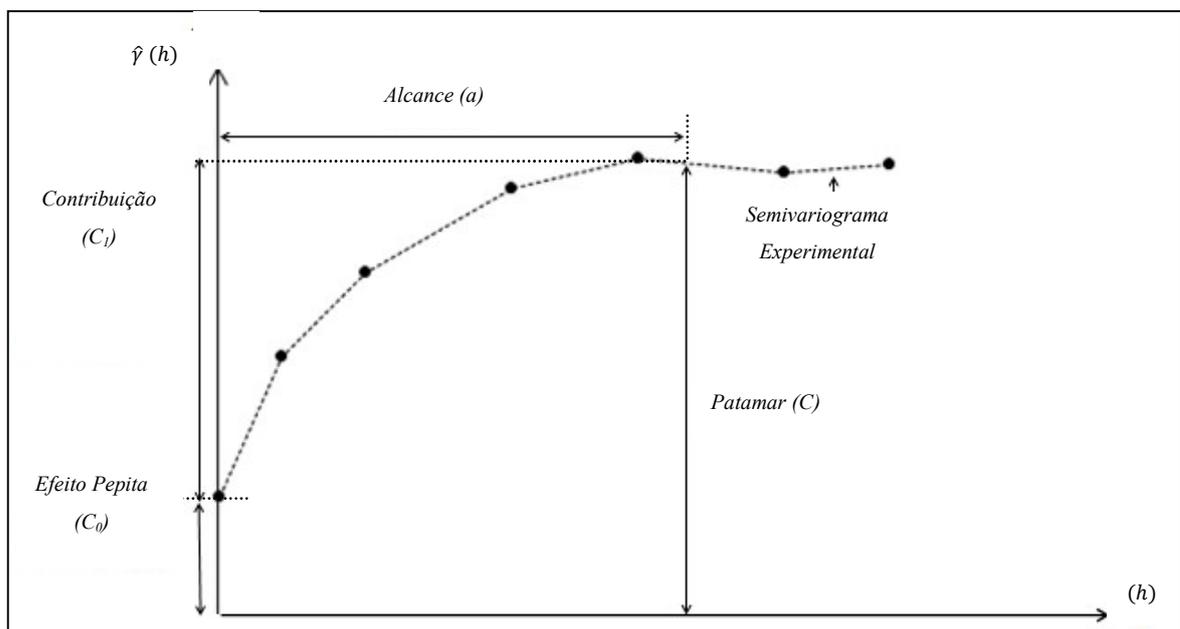
onde z são os valores da cota a ser estimado; λ_1 é o peso associado ao estimador e (x_j, y_j) são localizações espaciais não observadas.

A correlação espacial entre os pontos podem ser quantificados por meio do variograma experimental, expressando o comportamento espacial da variável contínua amostrando sua zona de influência, seus aspectos anisotrópicos e a presença de anomalias provocadas por erros de amostragem ou por componentes aleatórios. O semivariograma experimental (Figura 3.9) é calculado como a metade da média do quadrado da diferença entre os componentes dos pares de dados (equação 3.3) (GOOVAERTS, 2000).

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(S_i) - Z(S_i + h)]^2 \quad (3.3)$$

onde h representa cada distância considerada entre quaisquer dois pontos; $Z(S_i)$ é o valor da variável Z medida em um local distanciado de s por uma distância h ; (S_i) é a posição amostral; N é o número de pares de pontos formados para uma dada distância h ; $\gamma(h)$ é a semivariância estimada.

Figura 3.9: Parâmetros do semivariograma experimental, alcance (a), contribuição (C_1), Efeito Pepita (C_0) e Patamar (C).



Fonte: GOOVAERTS, 2000.

Os parâmetros do semivariograma podem ser observados diretamente da Figura 3.9, contendo os parâmetros:

- *Alcance (a)*: distância dentro da qual as amostras apresentam-se correlacionadas espacialmente;
- *Patamar (C)*: é o valor do semivariograma correspondente a seu *alcance (a)*. Deste ponto em diante, considera-se que não existe mais dependência espacial entre as amostras, porque a variância da diferença entre pares de amostras ($\text{Var}[Z(x) - Z(x + h)]$) torna-se invariante com a distância.
- *Efeito Pepita (C_0)*: idealmente, $\gamma(0) = 0$. Entretanto, na prática, à medida h que tende para 0 (zero), $\gamma(h)$ se aproxima de um valor positivo chamado *Efeito Pepita (C_0)*, que revela a

descontinuidade do semivariograma para distâncias menores do que a menor distância entre as amostras (descontinuidade pode ser também devida a erros de medição).

· *Contribuição (C₁)*: é a diferença entre o *patamar (C)* e o *Efeito Pepita (C₀)*.

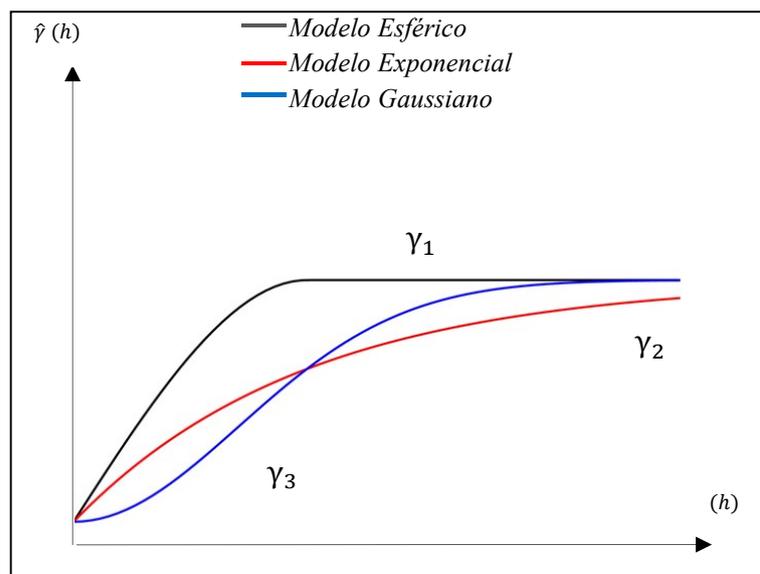
O ajuste do modelo é feito interativamente, manipulando-se os parâmetros (*a*, *C* e *C₀*) até que a função seja adequada. Existem modelos teóricos dos semivariogramas, dentre os principais têm-se o esférico (equação 3.4), exponencial (equação 3.5) e gaussiano (equação 3.6) (GOOVAERTS, 2000). A Figura 3.10 mostra a diferença dos principais modelos teóricos.

$$\gamma_1(h) = \begin{cases} C_0 + C_1 \left[\frac{3h}{2a} - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right], & 0 < h < a \\ C_0 + C_1 & h \geq a \end{cases} \quad (3.4)$$

$$\gamma_2(h) = C_0 + C_1 \left\{ 1 - \exp \left(-3 \frac{h}{a} \right) \right\} \quad (3.5)$$

$$\gamma_3(h) = C_0 + C_1 \left\{ 1 - \exp \left[-3 \left(\frac{h}{a} \right)^2 \right] \right\} \quad (3.6)$$

Figura 3.10: Modelos teóricos de semivariograma principais, esférico (linha preta), exponencial (linha vermelha) e gaussiano (linha azul).



Fonte: GOOVAERTS, 2000.

Para análise e escolha do modelo matemático que melhor se ajusta ao semivariograma experimental utilizou-se a técnica de validação cruzada (ISAAKS & SRIVASTAVA, 1989). A técnica de validação cruzada consiste em retirar temporariamente do conjunto de dados um valor observado e estimá-lo a partir dos outros. Esse processo é feito para todos os valores observados. Na avaliação dos modelos teóricos os seguintes erros foram analisados: Erro Viés (VIES) (equação 3.7), Raiz do Erro Quadrático Médio (REQM) (equação 3.8) e Erro Padrão Médio (EPM) (equação 3.9).

1) Erro Viés (VIES), que quantifica o erro sistemático da previsão:

$$\text{VIES} = \frac{1}{n} \sum (F - O) \quad (3.7)$$

2) Raiz do Erro Quadrático Médio (REQM), que quantifica o erro médio da previsão:

$$\text{REQM} = \sqrt{\frac{1}{n} \sum (F - O)^2} \quad (3.8)$$

3) Erro Padrão Médio (EPM), corresponde à média dos desvios da previsão:

$$\text{EPM} = \sqrt{\frac{1}{n} \sum \sigma^2} \quad (3.9)$$

onde, “F” é o valor modelado; “O” o valor observado e σ^2 o desvio padrão.

Após o ajuste dos modelos, foi obtido o grau de dependência espacial, através do índice de dependência espacial (IDE), expresso pela razão percentual entre o efeito pepita (C_0) e a contribuição (C_1) (equação 3.10). O IDE representa a porção da variabilidade espacial ao acaso, a partir dos critérios estabelecidos por Cambardella et al. (1994) destacados na Tabela 3.6.

$$\text{IDE} = \frac{C_0}{C_1 + C_0} \times 100\% \quad (3.10)$$

Tabela 3.6: Intervalo de classes do índice de dependência espacial.

Índice de Dependência Espacial (IDE)	Dependência Espacial
IDE < 25%	Forte
25% < IDE < 75%	Moderada
IDE > 75%	Fraca
IDE = 100%	Independente

Fonte: CAMBARDELLA et al., 1994.

O cálculo do semivariograma experimental, os ajustes dos modelos teóricos (esférico, exponencial e gaussiano) e a comparação estatística dos erros por meio da técnica de validação cruzada e a interpolação dos dados pluviométricos, por meio do método geostatístico de Krigagem, foram realizados com o suporte da extensão *Geostatistical Analyst* presente no software *ArcGIS 10.2.2* © (ESRI).

3.6 Identificação de regiões pluviométricas homogêneas

Para agrupar as informações definidas na interpolação de dados foi utilizado o método de classificação não supervisionada por análise de agrupamento, função *cluster*, implementado no software *IDRISI[®] Taiga*.

A classificação não supervisionada agrupa os pixels segundo as suas características espectrais, organizando-os em agrupamentos denominados de *clusters*. Nesta classificação é necessário fornecer alguns parâmetros como o número mínimo e máximo de classes desejadas e números de interações. As classes geradas podem ou não coincidir com as classes de interesse. Trata-se, portanto, de uma operação exploratória para verificar o que é estatisticamente separável ou não, quais as classes mais evidentes e sua relação com o quase deseja discriminar (WILKS, 2006).

Na climatologia essa técnica é bastante utilizada para identificar áreas homogêneas de precipitação. Por exemplo, o estudo de Barbosa (2006) identificou áreas homogêneas no estado de São Paulo, com os dados totais de precipitação mensais e anuais. Souza et al. (2012) aplicou tal método sobre dados pluviométricos médios trimestrais e anuais sobre Mato Grosso do Sul, e Oliveira (2014) caracterizou regiões no Nordeste do Brasil, a partir dos quantis de precipitação.

O processo de classificação *cluster* começa com um número aleatório de médias de agrupamentos arbitrários uniformemente distribuídos no espaço de dados, os quais representam uma hipotética possibilidade de centros de agrupamentos. Então, iterativamente as distâncias mínimas são calculadas para cada pixel da imagem e eles são reunidos nos agrupamentos mais próximos usando a técnica de distância mínima (menor distância ao centro dos agrupamentos) (MENESES & ALMEIDA, 2012).

A técnica de distância mínima se utiliza da menor medida de distância Euclidiana. Cada pixel será incorporado a um agrupamento através da análise da medida de similaridade de distância Euclidiana (equação 3.11).

$$D(x, n) = \sqrt{(x_i - m_i)^2} \quad (3.11)$$

onde x_i é o pixel candidato; m_i é a média das classes e n é o número de bandas.

No fim dessa primeira sequência de alocação, a média dos valores de todos os pixels alocados a cada agrupamento arbitrário é computada para cada uma das variáveis, obtendo-se as coordenadas dos centros de cada *cluster*. Usando esses novos centros uma nova iteração é realizada e a cada nova iteração é recalculada as médias, e os pixels são então reclassificados com relação às novas médias. As divisões ou fusões de *clusters* que irão ocorrer durante o processo de classificação dependem dos parâmetros dos padrões de entrada (MENESES e ALMEIDA, 2012).

Após a escolha das regiões homogêneas foram determinadas séries históricas de precipitação média para os anos de 1980 a 2010, utilizando as estações pluviométricas de cada região selecionada, diminuindo o número de estações pluviométricas inseridas no modelo, e calculou-se também a média e os quantis das novas séries históricas regionalizadas para caracterização das regiões obtidas.

3.7 Padronização das séries históricas

Para que as séries de dados de diferentes fontes sejam comparadas, destacando suas variabilidades (sem sazonalidade), os dados de precipitação e vazão foram padronizados pela média e desvio padrão de cada mês correspondente (equação 3.12) (WILKS, 2006).

$$x'(i,j) = \frac{x(i,j) - \mu(j)}{S(j)} \quad (3.12)$$

sendo que $x'(i,j)$ é o valor padronizado da variável do j -ésimo mês do i -ésimo ano, e onde $\mu(j)$ é a média para um mês j e pode também ser chamada de ciclo sazonal (equação 3.13); i é o índice que indica o ano e j é o índice que indica o mês; n é o número de anos; $S(j)$ é o desvio padrão do mês j (equação 3.14).

$$\mu(j) = \frac{1}{n} \sum_{i=1}^n x(i,j) \quad (3.13)$$

$$S(j) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x(i,j) - \mu(j))^2} \quad (3.14)$$

No caso dos índices climáticos a padronização foi realizada sobre toda a série de dados, pela média e desvio padrão da série completa.

3.8 Correlação defasada

Após a padronização dos dados foram investigados os preditores que influenciam a vazão e que podem contribuir para a previsão da vazão em Itaipu. Para tanto, foi calculado o coeficiente de correlação entre a série de vazão padronizada em Itaipu e as séries defasadas das seguintes variáveis no período selecionado 1980 a 2010: *i*) da própria vazão padronizada no referido ponto; *ii*) vazão padronizada em pontos a montante; *iii*) precipitação padronizada em pontos da bacia (selecionadas no item 3.6 regionalização da precipitação); *iv*) índices climáticos. Para verificar o grau de relacionamento entre as variáveis foi calculado o coeficiente de correlação, r de Pearson, através da equação 3.15:

$$r_{xy} = \frac{\sum_{i=1}^n x_i y_i - \frac{1}{n} (\sum_{i=1}^n x_i) (\sum_{i=1}^n y_i)}{\sqrt{\sum_{i=1}^n x_i^2 - \frac{1}{n} (\sum_{i=1}^n x_i)^2} \sqrt{\sum_{i=1}^n y_i^2 - \frac{1}{n} (\sum_{i=1}^n y_i)^2}} \quad (3.15)$$

Sendo que x_i e y_i são as variáveis padronizadas a serem correlacionadas.

A matriz de correlação mostra os coeficientes que medem o grau de relacionamento entre duas séries, podendo variar de +1,00 e -1,00, que indicam perfeitas correlações lineares positivas e negativas, respectivamente. Desta forma foram identificados os principais padrões climáticos relacionados com a vazão de rios que podem contribuir como preditores no modelo, além dos preditores relacionados à própria vazão defasada e da precipitação na bacia de contribuição.

Para avaliar se os coeficientes de correlação encontrados são considerados significativos para o nível de significância 0,05 (ou seja, nível de confiança de 0,95) foram aplicados o teste de hipótese – Teste T. Para tanto considera as hipóteses:

$$H_0: \rho = 0$$

$$H_1: \rho \neq 0$$

A estatística de teste é calculada a partir da equação 3.16:

$$t_c = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}} \quad (3.16)$$

Com n-2 graus de liberdade na tabela t de Student, em que r é o valor do coeficiente de correlação sujeito a teste e n é o número de observações. Caso o valor de t_c seja superior ao valor crítico de t, deve-se rejeitar a hipótese nula. Se a hipótese nula, ao nível de significância α , for rejeitada pode-se concluir que efetivamente existe uma relação significativa entre as variáveis (DEVORE, 2014).

3.9 Modelo empírico de regressão linear múltipla

O Modelo de Regressão Linear Múltipla é um modelo empírico que ao ser construído leva em consideração as relações empíricas entre as variáveis observadas, sem considerar os processos físicos, sendo de fácil ajuste e validação, uso e facilidade de ajuste para diferentes casos. Este modelo é aplicado para uma variável que se deseja estimar, cuja série histórica apresenta fortes relações com outras variáveis, sendo que essas relações se associam ao fenômeno (ou processo) que se deseja modelar. Como este estudo busca analisar as melhores variáveis que tornam o modelo mais preciso, não considerando somente as próprias vazões defasadas, mas também outras variáveis em diferentes defasagens, como a precipitação e os

índices climáticos, tal método pode atender o objetivo do estudo, assim como em outros estudos que demonstram sua habilidade para tais fins (CARDOSO e SILVA DIAS, 2002; GRIMM et al., 2004).

Este modelo é utilizado para estimar diferentes variáveis associadas a diversas áreas do conhecimento. Rodrigues et al. (2001) utilizaram para verificar a relação entre o florescimento da soja à temperatura e ao período de exposição solar. Gazalle et al. (2004) utilizaram este modelo para verificar a relação entre alguns sintomas depressivos em idosos e variáveis demográficas, socioeconômicas e comportamentais. Cardoso (2005) utilizou este modelo para verificar a relação entre a TSM nos oceanos Atlântico e Pacífico e as condições climáticas nas regiões sul e sudeste do Brasil. Alexandre (2012) utilizou este modelo para analisar o impacto da incorporação de informações climáticas na previsão de vazões mensais para o sistema interligado nacional. Malfatti et al. (2014) utilizaram este modelo para previsão de vazão na usina hidrelétrica de Itaipu, a partir de séries de vazão e precipitação.

O modelo de Regressão Linear Múltipla fornece a relação entre uma determinada variável e outras variáveis independentes, pelo método dos mínimos quadrados (WILKS, 2006). A equação de regressão (equação 3.17) possui a seguinte forma:

$$y = b_0 + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_kX_k \quad (3.17)$$

sendo y a variável dependente (vazão a ser prevista); X_n são as variáveis independentes (variáveis escolhidas que contribuem para a variação de vazão); b_0 é a intersecção da reta com o eixo de y ; b_n são os coeficientes angulares obtidos da regressão; k é o número de variáveis independentes.

Neste trabalho foram desenvolvidos modelos gerais (todos os meses consecutivos) e mensais (cada mês separadamente), *i*) modelos com apenas índices climáticos (Modelo I); *ii*) modelos com apenas precipitação nas regiões homogêneas (Modelo II); *iii*) modelos com apenas vazões a montante e Itaipu defasada (Modelo III) e *iv*) modelos com todos os itens anteriores (Modelo IV).

3.9.1 Seleção dos preditores – Método *Stepwise*

No conjunto de variáveis independentes pode haver variáveis que pouco influencia a variável dependente. O método *stepwise* é utilizado para adicionar e remover variáveis independentes de um modelo de regressão linear múltipla com base em sua significância estatística, podendo assim, diminuir o número de variáveis a compor a equação de regressão (DRAPER e SMITH, 1998).

Este método é realizado de forma interativa, adicionando e removendo variáveis, a partir de um critério de seleção, sendo o teste F o critério mais utilizado para a escolha das variáveis que contribuem significativamente para a regressão (Apêndice). Os procedimentos realizados no método *stepwise* são (DRAPER e SMITH, 1998):

- I. Selecionar variáveis independentes aleatórias, formando um modelo inicial qualquer;
- II. Calcular o p-valor do teste F para cada variável independente, se o p-valor for menor que o nível de significância ($\alpha_e = 0,15$) a variável é descartada do modelo;
- III. Se todas as variáveis independentes do modelo possuir p-valor superior ao nível de significância, adota-se um valor máximo de significância ($\alpha_s = 0,20$) e removem-se termos com valores maiores que este máximo;
- IV. Os passos anteriores são repetidos até que todas as variáveis independentes sejam testadas no modelo.

O método *stepwise* foi aplicado para selecionar as variáveis de precipitações, índices climáticos e vazões, separadamente. No caso das vazões foi realizada uma seleção prévia das estações predictoras, através dos coeficientes de correlações mais significativos em cada sub-bacia, para diminuir a quantidade de vazões a serem testadas pelo *stepwise*.

3.9.2 Validação do modelo

A determinação do grau em que o modelo é capaz de realizar uma representação precisa do mundo real a partir da perspectiva de suas simulações, procurando atingir o melhor ajuste, consiste na validação do modelo.

Para realizar a validação do modelo divide-se o conjunto de dados em duas partes, a primeira é utilizada para a calibração e ajuste da equação de regressão e a segunda para a validação (comparação com o observado).

Os dados utilizados para a etapa de calibração dos modelos foram dos anos de 1980 a 2000, que correspondem a 252 meses para os modelos gerais (todos os meses consecutivos) e 21 meses para os modelos mensais, para todas as variáveis incorporadas nos modelos.

No processo de calibração do modelo foi calculado o coeficiente de determinação R^2 , que é uma medida do poder explicativo do modelo de regressão, o qual fornece a proporção da variação da variável dependente, que é explicada em termos lineares pelas variáveis independentes (WILKS, 2006). O R^2 é calculado pela equação 3.18.

$$R^2 = \frac{\frac{n \sum_{j=1}^N y_{ic}^2 - (\sum_{j=1}^N y_i)^2}{n(n-1)}}{\frac{n \sum_{j=1}^N y_i^2 - (\sum_{j=1}^N y_i)^2}{n(n-1)}} \quad (3.18)$$

onde y_{ic} é o valor calculado através da função de regressão e y_i é o valor observado, N é o número de observações (WILKS, 2006).

O coeficiente R^2 é obtido através da análise de variância, na qual se determina o quanto da variabilidade da variável dependente é considerada pela regressão. Os valores de R^2 podem variar entre 0 e 1, quando este valor for 1 a regressão foi perfeita, sendo que, o inverso ocorre quando o valor de R^2 se aproxima de 0 (zero) (WILKS, 2006).

Para validar o modelo é necessário avaliar o quanto ele é capaz de reproduzir a realidade, aplicando uma avaliação nas saídas do modelo, para um período não considerando na calibração. Esta avaliação consiste na identificação de possíveis limitações do modelo, que possam exigir um novo processo de ajuste e validação, que no caso de modelos empíricos poderia ser o aumento da série histórica e a inclusão de períodos mais recentes de observação, como também a inclusão de outros preditores. Neste estudo, os dados utilizados para esta etapa de validação englobam anos de 2001 a 2010, que corresponde a 120 meses para os modelos gerais (todos os meses consecutivos) e 10 meses para os modelos mensais (cada mês separadamente).

No processo de validação do modelo foram calculados os seguintes parâmetros para a avaliação do desempenho do modelo: Coeficiente de Correlação (equação 3.15), Erro Viés (VIES) (equação 3.7), Raiz do Erro Quadrático Médio (REQM) (equação 3.8), Erro Absoluto (EA) (equação 3.19) e Erro Relativo (ER) (equação 3.20) (WILKS, 2006).

1) Erro absoluto (EA), que quantifica a amplitude do erro, através do módulo da diferença:

$$EA = \frac{1}{n} \sum |F - O| \quad (3.19)$$

2) Erro relativo (ER), que quantifica a razão entre o erro absoluto e o valor observado:

$$ER = \frac{1}{n} \sum \frac{|F - O|}{O} \quad (3.20)$$

Sendo, “F” é o valor estimado pelo modelo e “O” o valor observado.

CAPÍTULO 4

4. REGIÕES PLUVIOMÉTRICAS HOMOGÊNEAS

Neste capítulo são apresentados e discutidos os resultados da interpolação e regionalização dos dados de precipitação (estações pluviométricas) na BHRP. A interpolação dos dados de precipitação foi necessária para verificar a distribuição espacial dos dados de precipitação ao longo da bacia, principalmente em locais onde não existem estações pluviométricas, tornando a análise de cluster mais confiável, reduzindo a dimensão do conjunto inicial de dados de precipitação, a estabelecer regiões homogêneas (regionalização).

4.1 Interpolação

Para verificar o melhor modelo de semivariograma foram analisados os erros estatísticos da simulação da interpolação obtidos por meio da técnica de validação cruzada (VIES, REQM e EMP) e o índice de dependência espacial (IDE), indicados na Tabela 4.1.

O modelo que apresenta o melhor ajuste ao semivariograma deve contemplar todos os erros do prognóstico de maneira integrada. Conforme mostra a Tabela 4.1, os valores do VIES no modelo exponencial são menores para todos os dados (valores em laranja), já para o REQM o modelo gaussiano apresenta os menores valores, para o EMP para os dados médios e quantil 85 o modelo exponencial obteve menores resultados (valores em verde), enquanto que para os dados de quantil 15, 35 e 65 o modelo esférico obteve os menores resultados (valores em azul). A partir dos resultados dos erros foi possível verificar que o modelo exponencial apresenta menores valores em mais casos que os demais.

Tabela 4.1: Acurácia dos modelos teóricos (exponencial, esférico e gaussiano) de semivariograma em mm.

Dados	Modelo de semivariograma	Erros do Modelo			
		VIES	REQM	EMP	IDE (%)
Média	Exponencial	-0,15	144,60	123,02	4,86
	Esférico	-0,26	139,75	131,08	12,32
	Gaussiano	-0,46	138,32	132,83	19,65
Quantil 15	Exponencial	-0,08	124,06	107,70	9,01
	Esférico	-0,19	121,49	106,25	13,57
	Gaussiano	-0,56	120,37	111,64	23,10
Quantil 35	Exponencial	-0,45	115,82	83,73	1,29
	Esférico	-0,50	118,56	69,61	0
	Gaussiano	-0,51	107,36	101,87	15,19
Quantil 65	Exponencial	-0,20	127,50	99,34	0
	Esférico	-0,21	120,40	106,85	6,55
	Gaussiano	-0,28	118,86	109,44	13,88
Quantil 85	Exponencial	0,10	162,15	135,05	4,33
	Esférico	-0,18	157,30	144,63	11,69
	Gaussiano	-0,45	156,16	146,65	18,81

A partir do cálculo do índice de dependência, todos os casos considerados no estudo apresentam $IDE \leq 25\%$, indicando forte dependência espacial. Para o modelo teórico exponencial os IDE são os menores (valores em negrito) indicando que esse modelo apresenta uma dependência espacial maior que os outros modelos teóricos (esférico e gaussiano). Desta forma, o modelo que apresentou o melhor ajuste foi o modelo exponencial.

Os resultados das interpolações de dados médios, quantis 15, 35, 65 e 85, de precipitação acumulada anual, através do método da Krigagem ordinária, para o modelo de semivariograma exponencial estão representados nas Figuras 4.1, 4.2, 4.3, 4.4 e 4.5 e os outros modelos estão apresentados nas Figuras A.1, A.2, A.3, A.4 e A.5 no Apêndice.

Figura 4.1: Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com as precipitações médias acumuladas (mm).

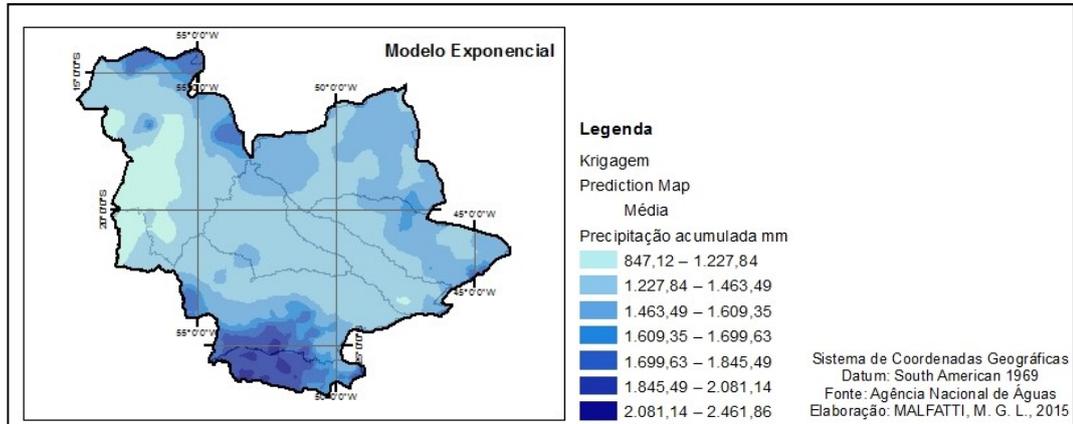


Figura 4.2: Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com os quantis 15% de precipitação acumulada (mm).

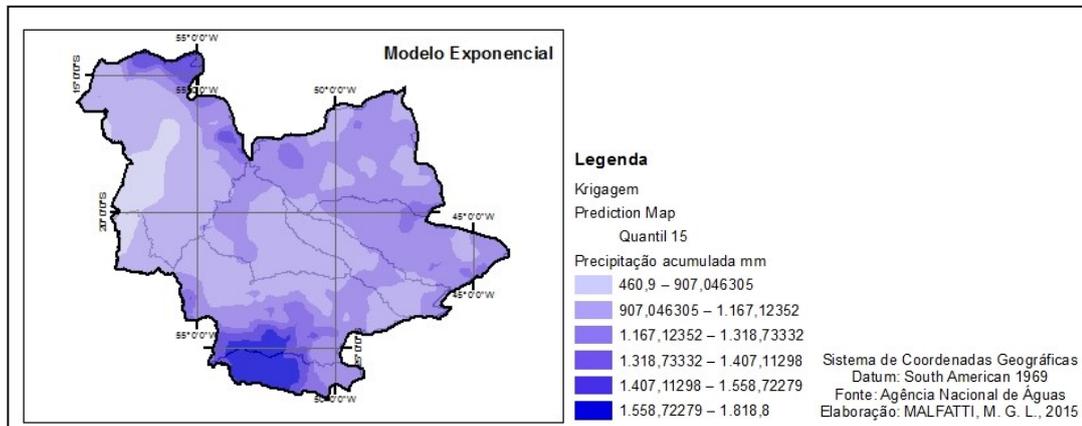


Figura 4.3: Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com os quantis 35% de precipitação acumulada (mm).

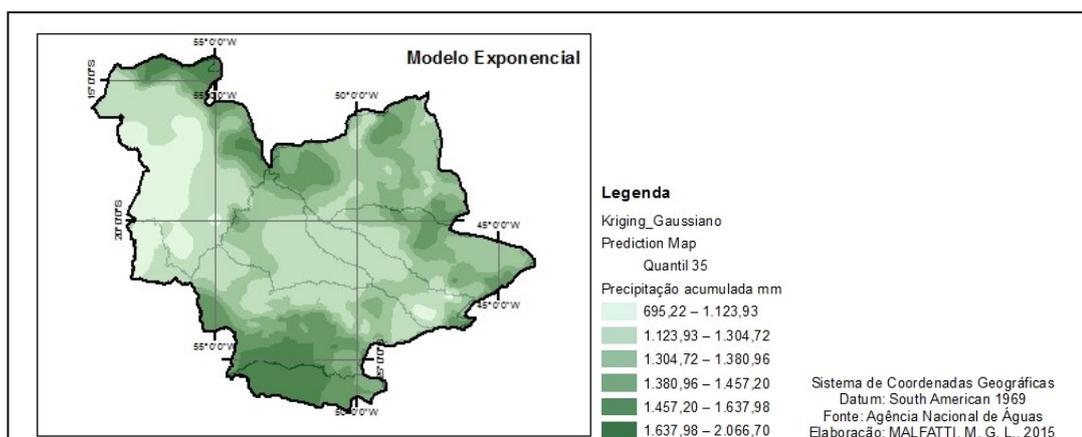


Figura 4.4: Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com os quantis 65% de precipitação acumulada (mm).

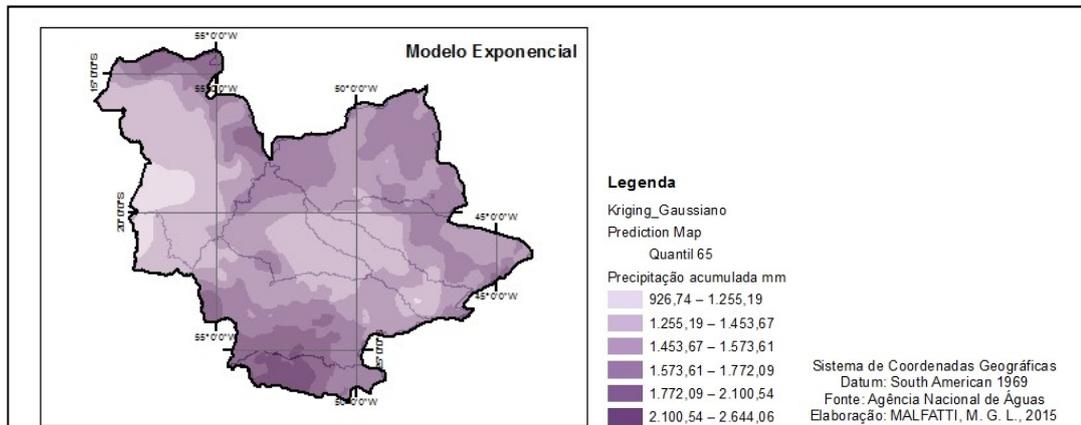
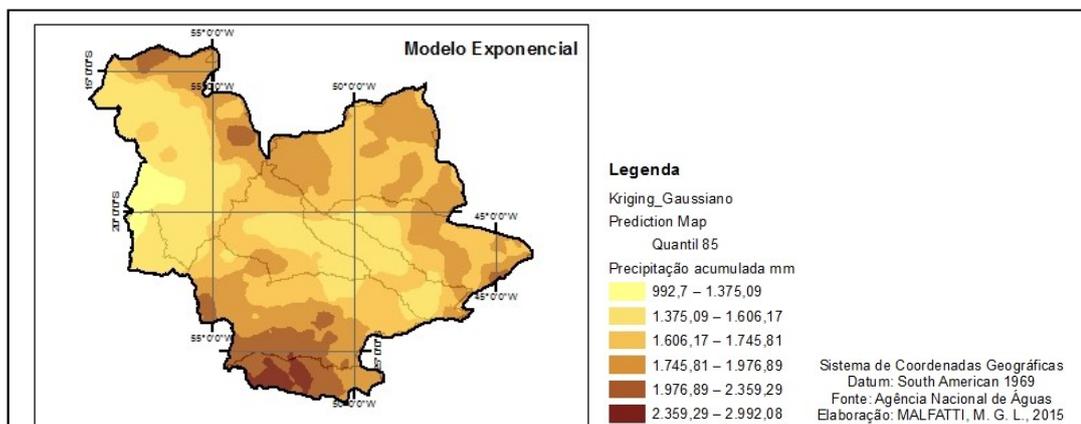


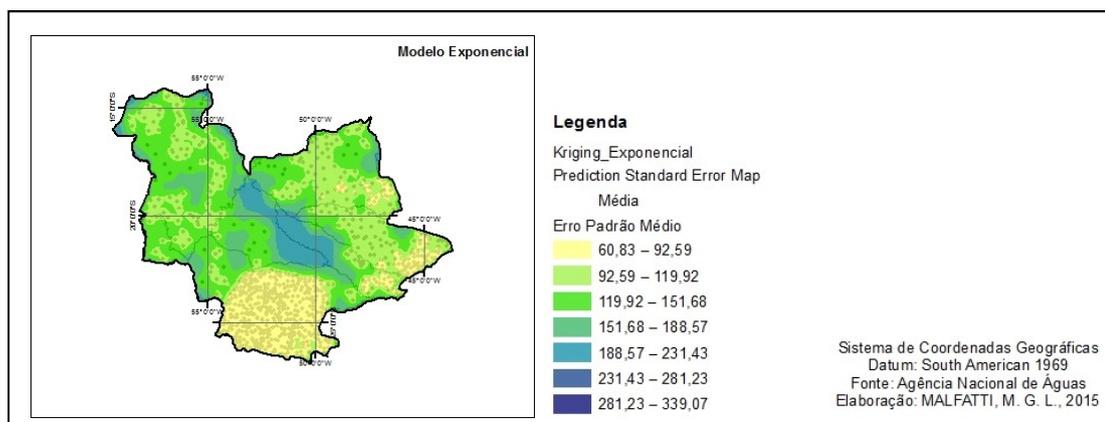
Figura 4.5: Interpolação de dados pelo método da Krigagem, para o modelo de semivariograma Exponencial, com os quantis 85% de precipitação acumulada (mm).



Por outro lado, ambos os modelos de ajuste apresentaram elevados erros médios padrão (acima de 100 mm), provavelmente devido à ausência de estações pluviométricas em determinados locais na BHRP.

A Figura 4.6 mostra a distribuição do erro médio padrão (EMP), onde os maiores erros estão concentrados na região central da BHRP e os menores erros na região sul da BHRP, indicando que quanto menor (maior) a densidade de estações maior (menor) será o erro do modelo. Para os quantis esse mesmo padrão é verificado, quanto maior (menor) a densidade dos dados pluviométricos, menor (maior) será o erro do modelo teórico exponencial (Figuras A.6, A.7, A.8 e A.9 disponível no Apêndice).

Figura 4.6: EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os dados médios de precipitação acumulada (mm).



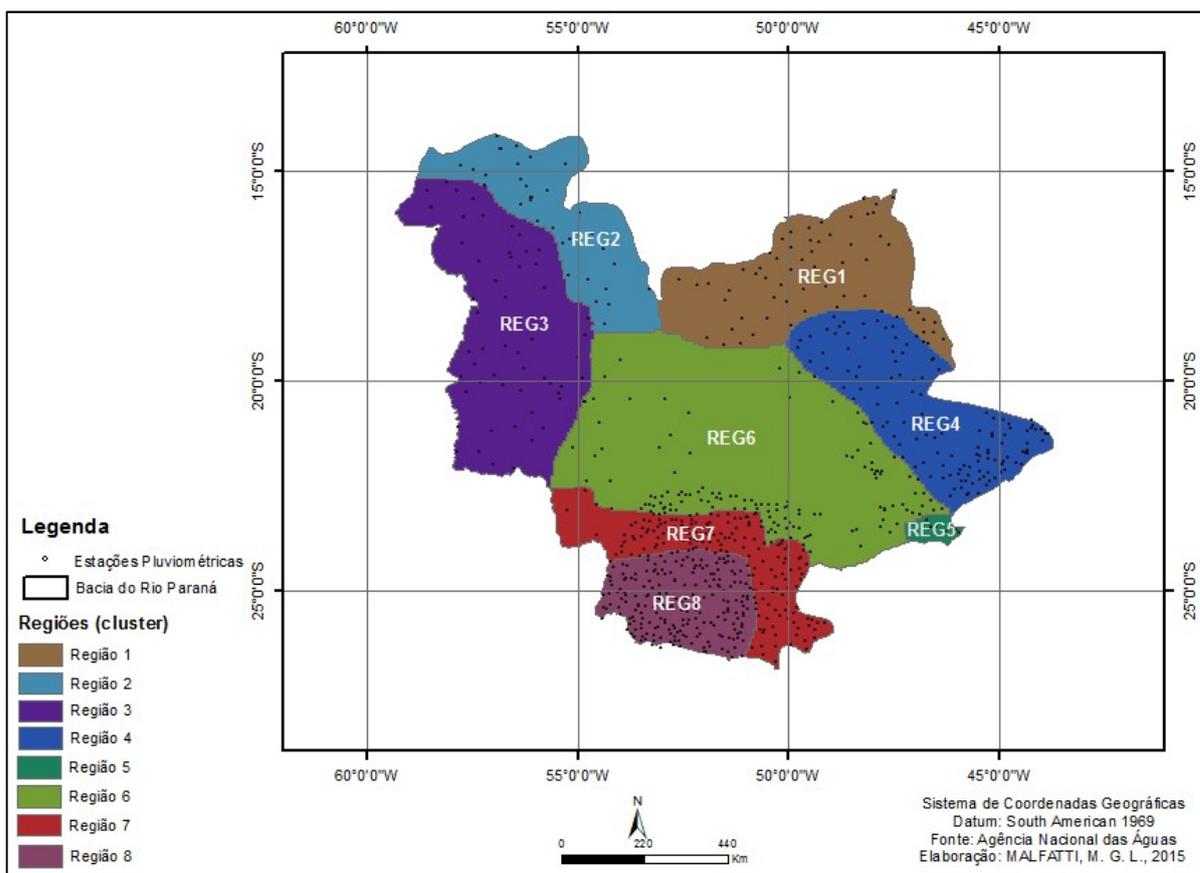
A partir da interpolação dos dados pluviométricos foi possível identificar faixas com características de precipitação semelhantes na área de estudo, tais como: Região Sul da Bacia (estado do Paraná, sul de Santa Catarina e sul de São Paulo) Região Central (estado de São Paulo), Região ao Leste (sul de Minas Gerais, sul de Goiás e leste de São Paulo), Região Noroeste (Mato Grosso) e Região Oeste (sul de Mato Grosso do Sul). Corroborando com os resultados obtidos por Cardoso (2005) disponível na Figura 3.6.

4.2 Regionalização

A partir da técnica de agrupamento (*cluster*) aplicada aos dados interpolados foram determinadas oito regiões pluviométricas homogêneas na BHRP, a Figura 4.7 mostra o resultado final obtido e a localização das estações pluviométricas utilizadas para a interpolação de dados e posteriormente para a análise de *cluster*. No desenvolvimento da regionalização foram excluídas pequenas regiões (com apenas uma estação pluviométrica, contida ou próxima de outra região maior), sendo englobadas em regiões similares adjacentes, ocorreram casos principalmente nas regiões 1 e 4.

Na Figura 4.7 observa-se que a região 6 apresenta maior área, provavelmente devido à baixa densidade de estações pluviométricas na região central, levando a uma interpolação de dados simplificada e conseqüentemente uma análise de agrupamento mais abrangente, generalizando os dados nesta região. A região 5 apresenta menor área, por ser uma pequena região litorânea, apresentando características distintas das regiões adjacentes 4 e 6.

Figura 4.7: Regionalização da precipitação na Bacia do Paraná para todas as estações do ano.



Após a identificação dos grupos com comportamento pluviométrico homogêneo, Figura 4.7, calculou-se a precipitação média anual acumulada sobre cada região homogênea. Posteriormente, transformaram-se a precipitação em quantis, identificando os limiares das categorias de chuva para estas regiões no período de 1980 a 2010, visando caracterizar os padrões de precipitação distinguindo pela análise de cluster.

Na Tabela 4.2 são apresentados os valores médios e quantis para as regiões pluviométricas homogêneas. Através desta tabela é possível observar em ordem crescente, as regiões mais secas e as mais chuvosas, analisando em conjunto os valores da média de precipitação e dos níveis quantílicos máximos e mínimos: REG 3 < REG 6 < REG 1 < REG 4 < REG 2 < REG 5 < REG 7 < REG 8. As regiões ao sul e sudeste da bacia são mais chuvosas (regiões 5, 7 e 8), enquanto que as regiões mais ao norte (1 a 4) e central (6) são mais secas.

Tabela 4.2: Valores da precipitação anual (mm) relacionados a média, quantil 15%, 35%, 65% e 85% para as regiões pluviométricas homogêneas no período de 1980 a 2010.

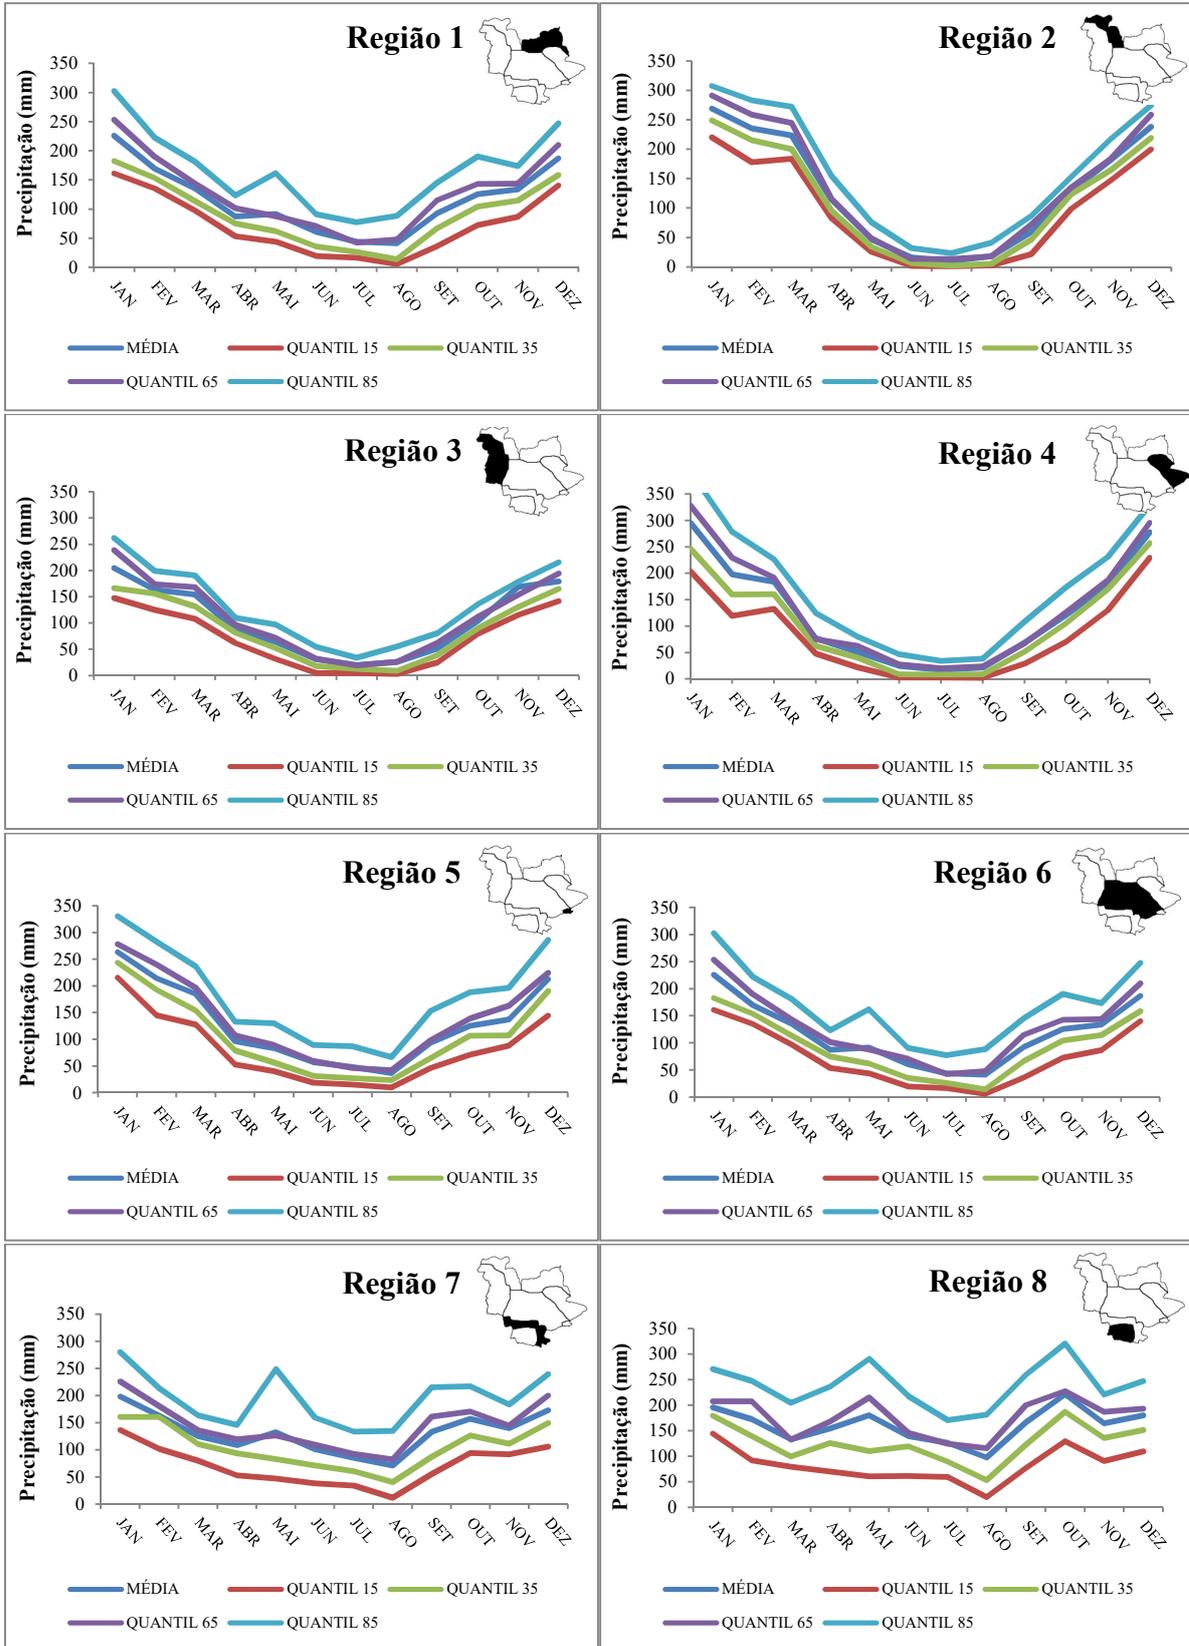
Dados	Regiões							
	REG1	REG2	REG3	REG4	REG5	REG6	REG7	REG8
Média	1480,76	1528,76	1220,44	1513,37	1553,22	1394,38	1569,11	1898,31
Quantil 15	1190,98	1233,69	945,66	1235,67	1282,76	1143,10	1271,26	1536,15
Quantil 35	1380,80	1415,84	1100,59	1392,53	1484,10	1285,60	1439,47	1724,66
Quantil 65	1585,46	1629,87	1301,04	1583,63	1658,67	1475,56	1646,54	1968,82
Quantil 85	1757,93	1811,33	1459,00	1768,50	1827,06	1642,70	1851,48	2190,20

A Figura 4.8 mostra os valores de precipitação mensal média (linha azul escura) e os quantis de 15% (linha vermelha), 35% (linha verde), 65% (linha roxa) e 85% (linha azul clara) sobre as oito regiões pluviométricas homogêneas identificadas para todos os meses do ano. Através desta figura é possível identificar os diferentes padrões de precipitação existentes ao longo da BHRP. As regiões 7 e 8, sul da bacia, apresentam menor variação ao longo dos meses do ano, com picos na primavera e outono, principalmente para os casos muito chuvosos (quantil 85%), enquanto as demais regiões (1 a 6), norte e centro da bacia, possuem um ciclo anual bem definido, caracterizado por uma estação seca no inverno (JUN, JUL e AGO) e uma estação chuvosa no verão (DEZ, JAN e FEV).

As regiões 7 e 8 se diferenciam pela amplitude da precipitação, sendo que a região 8 apresenta limiar de 85% com valor máximo de 320 mm no mês de outubro, enquanto que para a região 7 o limiar de 85% apresenta valor máximo de 280 mm no mês de janeiro.

As regiões 1 a 6 possuem um ciclo anual marcado por uma estação seca e chuvosa, que se diferem pela amplitude da diferença pico a pico (máximos-mínimos) verificada em todas as categorias de precipitação demonstradas. As regiões 1 a 4 apresentam estações secas mais pronunciadas nos meses de inverno (JUN, JUL, AGO), faixa norte da bacia, enquanto que nas regiões 5 e 6 a estação seca apresenta valores mais elevados de precipitação (menos pronunciada), faixa central da bacia.

Figura 4.8: Valores da precipitação mensal relacionados a média (linha azul escura) e aos quantis de 15% (linha vermelha), 35% (linha verde), 65% (linha roxa) e 85% (linha azul clara), calculados sobre cada região pluviométrica homogênea (REG1 a REG8) no período de 1980 a 2010.



4.3 Conclusão

Como a distribuição espacial dos dados de precipitação é bastante irregular ao longo da BHRP, a interpolação dos dados ajuda na identificação de faixas que apresentam padrões semelhantes de precipitação dentro da área de estudo, e principalmente a inferir sobre a precipitação dos locais não amostrados, tornando a análise de cluster mais confiável.

Os dados de precipitação foram tratados antes de serem interpolados, para aumentar a confiabilidade da análise. Visando tornar a elaboração da interpolação mais clara e objetiva, compararam-se as diferentes estações pluviométricas através de limiares representativos desta variável. Para tanto, foram considerados a média e os quantis de 15%, 35%, 65% e 85% dos dados de precipitação acumulada anual das séries pluviométricas preenchidas.

Neste estudo, o método da Krigagem ordinária mostrou-se satisfatório, para o qual o modelo exponencial apresentou os menores erros, sendo o mais indicado para interpolar dados de precipitação na BHRP. A partir desta análise foi possível identificar grandes faixas que apresentam padrões semelhantes de precipitação dentro da área de estudo, como: Região Sul da Bacia, Região Central, Região ao Leste e Região Noroeste.

Para agrupar as informações resultantes da interpolação de dados foi utilizado o método de *cluster*. A partir desta técnica foram determinadas regiões pluviométricas distribuídas sobre a BHRP, que podem ser consideradas com regime homogêneo de precipitação.

Desta caracterização foram encontradas oito regiões com padrões distintos, as regiões ao sul da bacia, apresentam menor variação ao longo dos meses do ano, com picos na primavera e outono, enquanto que as regiões ao norte e central da bacia, apresentam um ciclo anual bem definido, caracterizado por uma estação seca no inverno (JUN, JUL e AGO) e uma estação chuvosa no verão (DEZ, JAN e FEV).

Através da regionalização é possível obter novas séries temporais que representam em média o padrão de precipitação observado em cada região pluviométrica identificada, reduzindo a quantidade de estações predictoras no modelo. Além disso, pode ser investigada a relação da vazão em Itaipu com cada região pluviométrica, separadamente, buscando encontrar as influências específicas de cada região.

CAPÍTULO 5

5. MODELO GERAL DE REGRESSÃO LINEAR MÚLTIPLA

Neste capítulo são apresentados e discutidos os resultados obtidos no desenvolvimento do modelo geral de regressão linear múltipla, modelo que considera todos os meses do ano consecutivos, para os seguintes grupos de preditores: *i)* somente os índices climáticos; *ii)* somente precipitação em regiões pluviométricas homogêneas; *iii)* somente vazões em pontos a montante e a própria Itaipu defasada; e *iv)* o conjunto de preditores citados nos itens anteriores (*i, ii e iii*).

5.1 Correlações Itaipu X Preditores

Considerando a série completa de dados, ou seja, incluindo todos os meses consecutivos, foi realizada uma análise de correlação defasada de um a doze meses, entre a vazão de Itaipu e índices climáticos, precipitação nas regiões homogêneas, vazão em pontos a montante e a própria vazão de Itaipu, visando verificar o grau de influência de cada variável e identificar preditores para a vazão em Itaipu.

Dado que são muitos os pontos de vazão a montante levantados para o estudo, foi realizada uma análise de correlação preliminar, visando reduzir o número de variáveis, mantendo apenas os pontos mais estratégicos com correlações representativas. Deste modo, foram inicialmente avaliadas as correlações das 61 estações fluviométricas (Itaipu defasada e mais 60 pontos de vazões a montante) com defasagem de um a quatro meses. A Figura A.10 disponível no Apêndice, mostra a distribuição espacial dos valores de correlações para as quatro defasagens analisadas. A partir deste mapa de distribuição espacial foi possível selecionar as estações que apresentam maior correlação em cada sub-bacia a montante de Itaipu (Bacia do Paranaíba, Bacia do Grande, Bacia do Tietê e Bacia do Paranapanema).

Verificou-se que as vazões mais distantes a montante apresentam correlações mais significativas para defasagens mais longas, enquanto que para as mais próximas de Itaipu as correlações mais altas ocorrem com defasagens mais curtas (Figura A.10, apêndice). Portanto, considerando os pontos mais representativos em todas as defasagens, foram escolhidas as seguintes estações: Capim Branco 2 (Bacia do Paranaíba), Corumbá III (Bacia do Paranaíba), Furnas (Bacia do Grande), Jupiá (Rio Paraná, próximo a Bacia do Tiête), Rosana (Bacia do Paranapanema) e Itaipu defasada (Rio Paraná). Posteriormente, foram realizadas análises de correlações defasadas de um a doze meses entre estas estações fluviométricas selecionadas e a de Itaipu.

Como as correlações entre a vazão de Itaipu, vazões a montante de Itaipu, índices climáticos e precipitação nas regiões pluviométricas homogêneas, variam muito ao longo das doze defasagens, foi aplicado o teste t de Student para verificar as correlações significativas (5% nível de significância, ou seja, 95% nível de confiança). Considerando 370 o número de graus de liberdade (número de meses das séries históricas correlacionadas menos dois) e valor crítico igual a 1,96 (Tabela de Student bi-caudal) foram verificados os valores de CC significativos, acima de 0,10. Os valores em negrito apresentados nas Tabelas 5.1, 5.2 e 5.3 são considerados significativos a partir da métrica definida.

A partir das correlações identificadas entre a vazão de Itaipu e os índices climáticos (Tabela 5.1) foram identificadas correlações significativas (nível de significância de 5%) para todos os índices em diferentes defasagens. O índice TSA apresenta valores de CC significativos em todas as defasagens avaliadas, os índices NIÑO 3.4 e SOI apresentam CC significativos para quase todas as defasagens, com exceção lag12 e lag11-12, respectivamente. Os índices AMO, AMM, PDO, NAO, apresentam CC significativos apenas para os seguintes intervalos de defasagens lag6-12, lag4-8, lag1-3 e lag7-8, respectivamente. E, por fim, o índice AAO apresenta CC significativo apenas para o lag5, sendo o índice menos correlacionado com a vazão de Itaipu, na métrica analisada.

Tabela 5.1: Coeficientes de correlação entre a vazão de Itaipu e os índices climáticos para um período de doze meses de defasagem, em negrito os valores significativos, com 95% de confiança.

Defasagem (lag)	AAO	AMM	AMO	NAO	NIÑO 3.4	PDO	SOI	TSA
1	-0,005	0,024	-0,045	0,001	0,242	0,157	-0,244	-0,206
2	0,013	-0,013	-0,042	0,002	0,277	0,146	-0,256	-0,195
3	-0,064	-0,057	-0,053	0,049	0,301	0,123	-0,257	-0,193
4	-0,083	-0,114	-0,076	0,025	0,320	0,087	-0,303	-0,175
5	-0,121	-0,123	-0,095	0,019	0,329	0,057	-0,312	-0,180
6	-0,042	-0,127	-0,124	0,082	0,315	0,058	-0,292	-0,188
7	0,025	-0,134	-0,147	0,173	0,278	0,064	-0,301	-0,177
8	0,043	-0,125	-0,168	0,132	0,238	0,053	-0,264	-0,163
9	-0,022	-0,095	-0,188	0,024	0,201	0,029	-0,225	-0,177
10	-0,042	-0,090	-0,211	0,008	0,159	0,001	-0,154	-0,185
11	-0,052	-0,060	-0,213	0,008	0,115	-0,035	-0,078	-0,195
12	-0,017	-0,024	-0,190	0,030	0,071	-0,027	-0,058	-0,197

A partir das correlações identificadas entre a vazão de Itaipu e as regiões pluviométricas homogêneas (Tabela 5.2) foram identificadas correlações significativas (nível de significância de 5%) para todas as regiões em diferentes defasagens. As regiões mais próximas de Itaipu, 6, 7 e 8, apresentam CC significativos para as defasagens entre lag1-7, regiões com ciclo sazonal similar a área estudada (Itaipu). Enquanto que para as regiões 1 e 3 os CC significativos aparecem também em defasagens mais longas Lag11; Lag 9 e 11 respectivamente.

Observa-se também que a região 2 (norte da bacia) apresenta poucos CC significativos, apenas para os lags 1 e 2, não sendo correlacionada significativamente com a vazão de Itaipu em defasagens mais longas, possivelmente devido ao fato de possuir menor variabilidade de precipitação ao longo do ano, exceto entre janeiro a março, o que fica evidente pela diferença entre os limiares quantílicos de precipitação mensal (Figura 4.8).

Tabela 5.2: Coeficientes de correlação entre a vazão de Itaipu e as regiões pluviométricas homogêneas para um período de doze meses de defasagem, em negrito os valores significativos, com 95% de confiança.

Defasagem (lag)	REG 1	REG 2	REG 3	REG 4	REG 5	REG 6	REG 7	REG 8
1	0,380	0,255	0,290	0,524	0,466	0,554	0,485	0,442
2	0,207	0,116	0,170	0,317	0,261	0,289	0,257	0,279
3	0,126	0,011	0,131	0,197	0,110	0,147	0,171	0,202
4	0,118	0,025	0,133	0,173	0,104	0,147	0,173	0,221
5	0,116	0,095	0,218	0,185	0,107	0,191	0,168	0,149
6	0,131	0,095	0,167	0,153	0,094	0,202	0,191	0,164
7	0,083	-0,002	0,077	0,096	0,029	0,107	0,113	0,123
8	0,016	-0,085	0,020	0,036	-0,026	0,014	0,033	0,042
9	0,075	0,039	0,101	0,036	-0,013	0,014	0,025	0,020
10	0,105	0,048	0,083	0,040	-0,007	-0,004	-0,019	-0,006
11	0,096	0,035	0,110	0,089	0,080	0,101	0,077	0,078
12	0,041	-0,006	0,041	0,006	0,035	0,024	0,008	0,045

A partir das correlações identificadas entre a vazão de Itaipu e as vazões a montantes e a própria Itaipu defasada (Tabela 5.3) foram identificadas correlações significativas (nível de significância de 5%) para todas as vazões em diferentes defasagens. As vazões de Jupia e Corumbá III apresentam CC significativo para todas as defasagens analisadas. As vazões de Furnas e Capim Branco 2 só não apresenta CC significativo para o lag12. E a própria vazão de Itaipu defasada não é considerada significativa para a métrica analisada, para os lags 9, 11 e 12.

Observa-se também que a vazão de Rosana apresenta CC significativos apenas para as sete primeiras defasagens, sendo a variável com os menores CC significativos.

Tabela 5.3: Coeficientes de correlação entre a vazão de Itaipu e as vazões a montante e a própria Itaipu defasada para um período de doze meses de defasagem, em negrito os valores significativos, com 95% de confiança.

Defasagem (lag)	Capim Branco 2	Corumbá III	Furnas	Jupia	Rosana	Itaipu defasada
1	0,559	0,412	0,591	0,645	0,565	0,681
2	0,432	0,317	0,446	0,452	0,378	0,461
3	0,394	0,306	0,398	0,394	0,318	0,411
4	0,346	0,260	0,340	0,353	0,310	0,381
5	0,287	0,234	0,289	0,316	0,302	0,331
6	0,230	0,210	0,212	0,238	0,245	0,249
7	0,165	0,190	0,178	0,174	0,163	0,156
8	0,122	0,197	0,146	0,150	0,096	0,113
9	0,113	0,199	0,128	0,149	0,055	0,098
10	0,142	0,195	0,147	0,178	0,043	0,109
11	0,113	0,147	0,141	0,160	0,041	0,078
12	0,072	0,105	0,097	0,109	-0,047	0,005

A partir das análises dos CC foram definidas as defasagens mais altas e significativas de um a quatro meses para o desenvolvimento dos modelos a seguir.

5.2 Modelo geral de previsão de vazão em Itaipu

Um refinamento da seleção de preditores foi realizado aplicando-se o método *stepwise* nos seguintes grupos de dados padronizados previamente indicados pelas correlações: *i*) índices climáticos (oito preditores testados); *ii*) precipitação em regiões pluviométricas homogêneas (oito preditores testados) e *iii*) vazões a montante de Itaipu e a própria Itaipu defasada (seis preditores testados).

Neste método de seleção de preditores (*stepwise*) foram encontrados como principais preditores, as variáveis que apresentam maiores correlações para as diferentes defasagens identificadas no item anterior. Os resultados dessa seleção para as quatro defasagens testadas estão detalhados na Tabela 5.4, 5.5 e 5.6, que apresentam os índices climáticos, regiões pluviométricas homogêneas e vazões, respectivamente.

A partir da Tabela 5.4, nota-se, para as quatro defasagens analisadas, que os preditores NIÑO 3.4 e TSA são os melhores em todos os casos, indicando que estes padrões climáticos possuem forte influência até para defasagens mais longas, já o preditor AMO aparece como bom preditor apenas para defasagem de um mês, como complemento para os outros dois preditores mais significativos (NIÑO 3.4 e TSA).

Tabela 5.4: Preditores de índices climáticos selecionados no *stepwise* para defasagens de um a quatro meses.

Defasagem	Preditores – Índices Climáticos		
Lag 1	NIÑO 3.4	TSA	AMO
Lag 2	NIÑO 3.4	TSA	-
Lag 3	NIÑO 3.4	TSA	-
Lag 4	NIÑO 3.4	TSA	-

Para o grupo de precipitação nas regiões pluviométricas homogêneas, na Tabela 5.5, observa-se que a região 8 é um bom preditor para todas as defasagens analisadas, região onde Itaipu está inserida, já a região 4 só não aparece como preditora na defasagem de quatro meses, região mais distante de Itaipu que possui correlação significativa, enquanto que para as outras regiões 6, 7 e 2, aparecem como preditores nas defasagens de um mês e três meses respectivamente.

Tabela 5.5: Preditores de precipitação nas regiões pluviométricas homogêneas selecionados no *stepwise* para defasagens de um a quatro meses.

Defasagem	Preditores – Precipitação em regiões pluviométricas homogêneas			
Lag 1	REG6	REG8	REG4	-
Lag 2	REG8	REG4	-	-
Lag 3	REG7	REG2	REG8	REG4
Lag 4	REG8	-	-	-

Por fim, para o grupo das vazões a montante de Itaipu e a própria Itaipu defasada, na Tabela 5.6, observa-se que a vazão da própria Itaipu defasada é um bom preditor em todas as

defasagens analisadas, além dela outros preditores foram selecionados pelo método, na defasagem de dois meses a vazão de Furnas e na defasagem de três meses a vazão de Capim Branco 2, e para a defasagem com um mês são destacadas as vazões de Capim Branco 2, e Rosana.

Tabela 5.6: Preditores de vazões selecionados no *stepwise* para defasagens de um a quatro meses.

Defasagem	Preditores – Vazão		
Lag 1	Itaipu defasada	Capim Branco 2	Rosana
Lag 2	Itaipu defasada	Furnas	-
Lag 3	Itaipu defasada	Capim Branco 2	-
Lag 4	Itaipu defasada	-	-

Para avaliar a contribuição de cada grupo de preditores selecionado pelo método *stepwise* foram desenvolvidos quatro modelos de regressão linear múltipla para quatro defasagens (1-4 meses), conforme: Modelo I) somente os índices climáticos; Modelo II) somente precipitação em regiões homogêneas; Modelo III) somente vazões em pontos a montante e vazão em Itaipu defasada; e Modelo IV) o conjunto de preditores citados em I, II e III. Foram considerados os preditores selecionados para cada defasagem, ou seja, os modelos foram construídos conforme os preditores selecionados pelo método *stepwise* para cada defasagem.

Os resultados dos coeficientes de determinação (R^2), para os modelos I, II, III e IV em cada defasagem (1-4 meses) no período de 1980 a 2000 estão apresentados na Tabela 5.7.

A partir dos valores apresentados de R^2 pode-se inferir sobre o ajuste dos modelos, sendo verificado que a utilização de somente os índices climáticos não é suficiente para produção e estimativas confiáveis, o que é consequência de baixo potencial explicativo da regressão, demonstrado através dos valores de baixos de R^2 (lag1=0,14; lag2=0,14; lag3=0,15; e lag4=0,16). Evidenciou-se a importância da contribuição de vazões a montante (R^2 para lag1=0,51; lag2=0,26; lag3=0,20; e lag4=0,18) e precipitação das regiões pluviométricas homogêneas (R^2 para lag1=0,41; lag2=0,15; lag3=0,10; e lag4=0,06), principalmente na defasagem para um mês.

Os resultados também indicaram que a combinação dos três tipos de preditores (caso IV) aumenta o desempenho do modelo, principalmente no caso de defasagens mais longas,

evidenciando a importância da consideração dos índices climáticos para horizontes mais longos de previsão (lag1=0,62; lag2=0,32; lag3=0,33; e lag4=0,26). E no caso da adição da precipitação nas regiões pluviométricas homogêneas, o modelo apresenta melhor desempenho em curto prazo, para um mês de previsão, indicando que a precipitação incidente na BHRP contribui de forma significativa para a vazão de Itaipu em até um mês.

Tabela 5.7: Coeficiente de Determinação (R^2) para os modelos I, II, III e IV com defasagem de um a quatro meses.

Modelo	Coeficiente de Determinação R^2			
	Lag1	Lag 2	Lag 3	Lag 4
I	0,14	0,14	0,15	0,16
II	0,41	0,15	0,10	0,06
III	0,51	0,26	0,20	0,18
IV	0,62	0,32	0,33	0,27

Os resultados da validação dos modelos, apresentados na Tabela 5.8, mostra o desempenho geral dos modelos I, II, III e IV para todas as defasagens (1-4 meses), a partir dos seus erros gerados no período não considerado na calibração (2001 a 2010), através dos seguintes parâmetros: erro viés (VIES), raiz do erro quadrático médio (REQM), erro absoluto (EA), erro relativo (ER) e coeficiente de correlação (CC).

A partir do resultado obtido para o erro viés (VIES) pode-se concluir que todos os modelos apresentam erro sistemático positivo, ou seja, os modelos construídos superestimam as vazões de Itaipu. O erro relativo (ER) avalia a representatividade do erro, mostrando a relação entre do valor do erro absoluto (EA) e o valor do observado. Nos modelos desenvolvidos, o ER apresenta erros máximos de 25% do valor observado. A raiz do erro quadrático médio (REQM) apresenta valores menores que o erro absoluto (EA), indicando que os modelos apresentam pequenos desvios, o que possivelmente diminui o ER. E, por fim, o coeficiente de correlação, que avalia o grau de relacionamento entre a vazão modelada e a observada, cujos modelos apresentam valores acima de 0,80 indicando alta correlação entre o modelado e o observado.

Os gráficos disponíveis na Figura 5.1 comparam os valores dos parâmetros: erro viés (VIES), raiz do erro quadrático médio (REQM), erro absoluto (EA), erro relativo (ER) e coeficiente de correlação (CC) para todos os modelos e diferentes defasagens (1-4 meses).

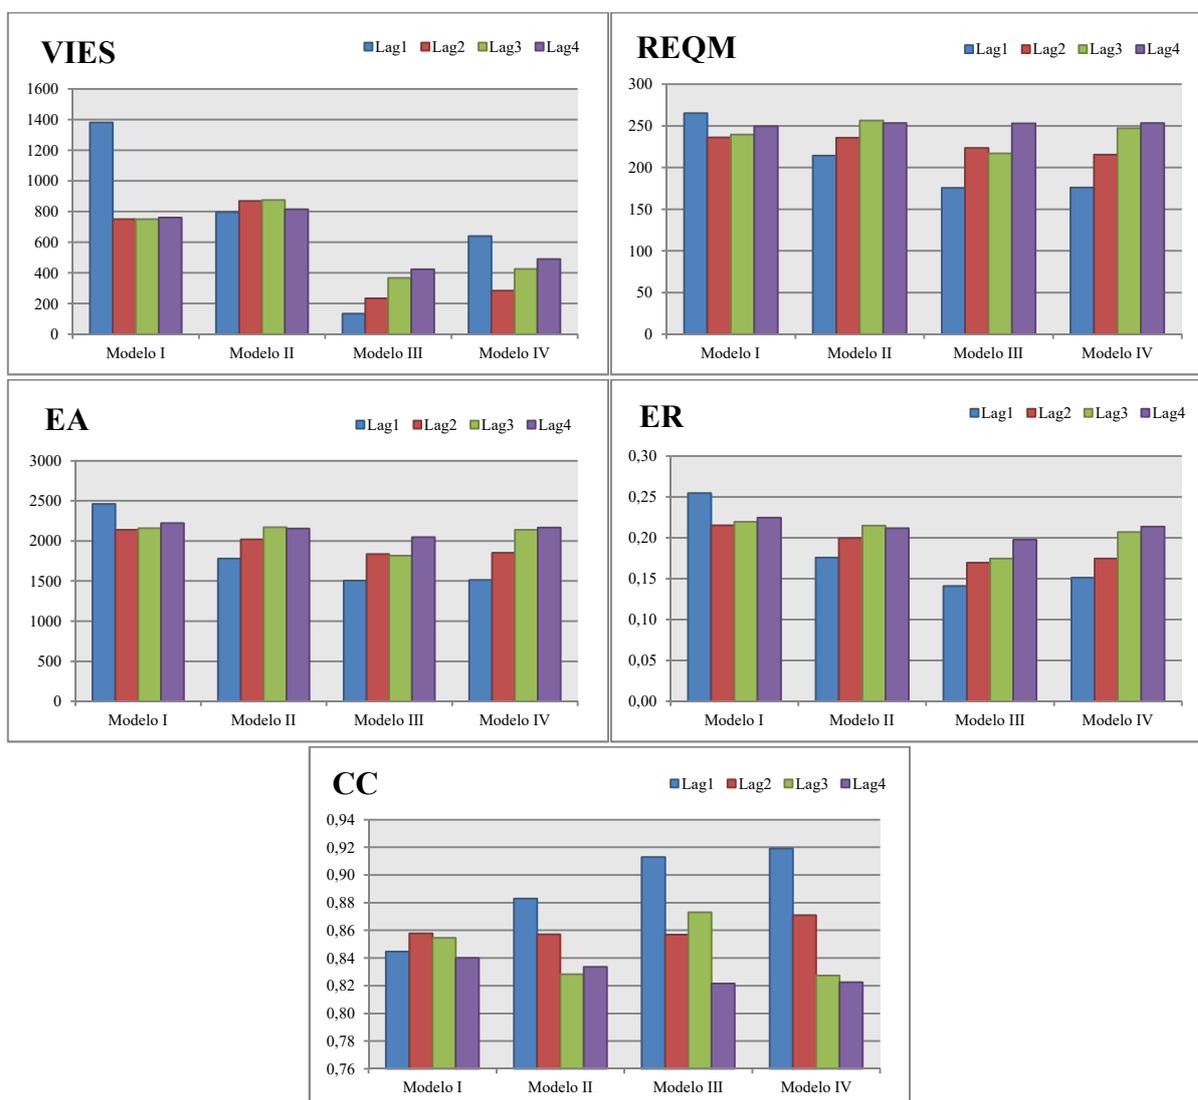
Tabela 5.8: Acurácia dos modelos I, II, III e IV em mm para as defasagens de um a quatro meses.

Parâmetro	Lag 1				Lag 2			
	I	II	III	IV	I	II	III	IV
VIES	1381,87	796,63	172,19	640,60	750,64	869,68	234,67	283,10
REQM	265,23	214,07	177,09	176,10	236,24	235,78	223,61	215,31
EA	2459,43	1782,03	1527,66	1511,97	2138,03	2017,46	1835,44	1851,84
ER	0,25	0,18	0,14	0,15	0,22	0,20	0,17	0,17
CC	0,84	0,88	0,91	0,92	0,86	0,86	0,86	0,87
Parâmetro	Lag 3				Lag 4			
	I	II	III	IV	I	II	III	IV
VIES	750,57	874,34	367,21	424,77	759,72	815,29	423,79	489,68
REQM	239,44	256,27	216,85	247,34	249,36	253,28	252,80	253,35
EA	2159,22	2169,47	1817,62	2137,43	2223,55	2153,28	2045,85	2167,75
ER	0,22	0,21	0,17	0,21	0,22	0,21	0,20	0,21
CC	0,85	0,83	0,87	0,83	0,84	0,83	0,82	0,82

Comparando os quatro modelos defasados de um a quatro meses verificou-se que o modelo que considera todos os grupos de preditores (modelo IV) no geral apresenta a maior correlação com a vazão de Itaipu em todas as defasagens, com exceção do lag3, cujos modelos I e III apresentam maior correlação, mesmo apresentando coeficiente de determinação inferior ao do modelo IV.

Avaliando os modelos a partir do VIES, verifica-se que o modelo III apresenta menor viés em todas as defasagens, superestimando os valores observados em menor amplitude, enquanto que os maiores valores são os modelos I e II, respectivamente. O EA e, conseqüentemente, o ER apresentam valores similares para todos os modelos avaliados, com exceção dos modelos III e IV que apresentam erros menores do que os modelos I e II. E, por fim, o modelo IV apresentam valores de REQM mais baixos em todas as defasagens, com exceção das defasagens mais longas (lag3-4), que para todos os modelos os valores são muito próximos, não havendo modelo com melhor desempenho para este parâmetro nesta defasagem.

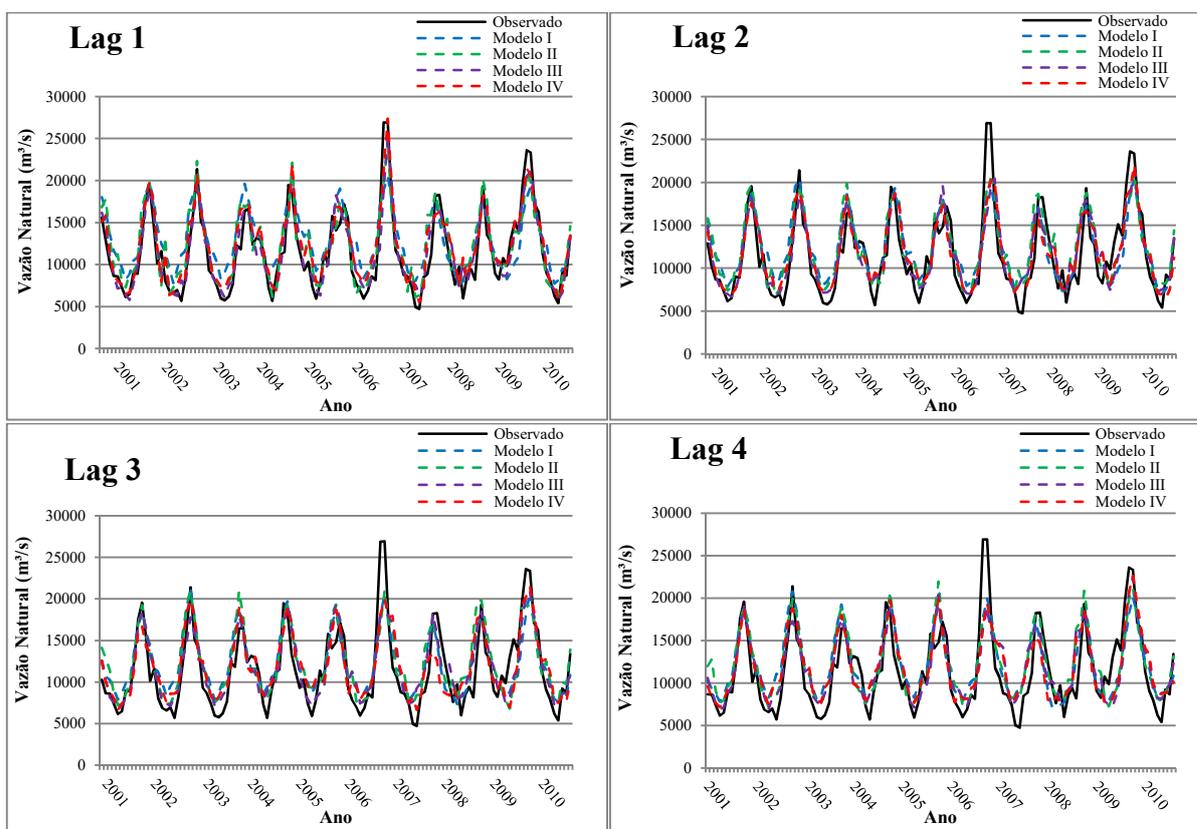
Figura 5.1: Resultados da avaliação dos modelos I, II, III e IV para as quatro defasagens para os parâmetros VIES, REQM, EA e ER.



A Figura 5.2 compara os valores de vazão natural em m^3/s dos modelos com o observado para o período de 2001 a 2010 para as quatro defasagens, a linha preta representa o valor observado, as linhas tracejadas de azul, verde, roxa e vermelha representam os modelos I, II, III e IV, respectivamente.

Nota-se que o modelo IV e III apresentam os melhores desempenhos, o modelo IV (linha tracejada vermelha) se aproxima dos valores extremos observados (linha preta) para o lag1, ou seja, é eficiente para detectar extremos, enquanto que para as outras defasagens o modelo falha para detectar os extremos, mas comparando esse modelo com os anteriores (modelos I, II e III) apresenta um desempenho melhor.

Figura 5.2: Comparação dos modelos I, II, III e IV com o observado para as defasagens de uma a quatro meses (lag 1-4 meses).



No geral os modelos ainda precisam melhorar o seu desempenho, visando aumentar a capacidade de estimativa dos valores extremos e das variabilidades, a previsão de extremos é bastante falha para as defasagens mais longas. Para tanto, no item a seguir foram desenvolvidos modelos empíricos mensais, de janeiro a dezembro, testando os mesmos grupos de preditores.

5.3 Conclusão

A análise de correlação desfasada entre a vazão em Itaipu e os potenciais preditores (índices climáticos, precipitação em regiões pluviométricas homogêneas e vazão em pontos a montante e a própria Itaipu desfasada), auxiliou na identificação do grau de influência de variáveis predictoras, analisando correlações desfasadas em doze meses, considerando todos os meses consecutivos na série.

Como as vazões a montantes formam um conjunto de dados de 61 séries históricas foi realizada uma análise de correlação desfasada preliminar de um a quatro meses, visando

reduzir o número de variáveis, mantendo apenas pontos mais estratégicos com correlações representativas.

Notou-se, no entanto, que os resultados das correlações significativas mostraram que correlacionando as variáveis para todos os meses consecutivos, conjuntamente, há perda de informação, devido ao comportamento distinto das variáveis ao longo do ano, principalmente em relação aos índices climáticos, sendo necessária a aplicação de uma análise de cada mês separadamente.

Ainda com a abordagem geral, foram desenvolvidos modelos empíricos de regressão linear múltipla, sendo aplicado para estimativas de vazão em Itaipu com defasagens variando de um a quatro meses, considerando todos os meses consecutivos. Para o desenvolvimento dos modelos, considerou-se o período de 1980 a 2000 para calibração e o período de 2001 a 2010, para validação. Estes modelos foram testados com diferentes grupos de preditores, conforme: I) somente os índices defasados; II) somente precipitação em regiões pluviométricas homogêneas; III) somente vazão em pontos a montante e a própria vazão em Itaipu; IV) o conjunto de preditores citados em I, II e III.

O método de *stepwise* foi útil para a seleção de preditores significativos nos modelos. No modelo geral os preditores selecionados com maior frequência para até quatro meses de defasagem foram: NIÑO 3.4 e TSA para os índices climáticos; região 8 para a precipitação em regiões homogêneas; Itaipu defasada e Capim Branco 2 para as vazões.

Na calibração, o modelo I desenvolvido com somente índices climáticos não é suficiente para produção e estimativas confiáveis para até quatro meses de defasagem, o que é consequência de um baixo potencial explicativo da regressão, demonstrado através dos valores baixos de R^2 . Tal resultado evidenciou a importância da contribuição de vazões a montante e de precipitações em regiões pluviométricas homogêneas, principalmente na defasagem para um mês. Os resultados também indicaram que a combinação dos três tipos de preditores (modelo IV) aumenta o desempenho do modelo, principalmente no caso de defasagens mais longas, evidenciando a importância da consideração dos índices climáticos para horizontes mais longos de previsão.

Os resultados da validação mostraram que o modelo que considera todos os grupos de preditores (modelo IV) no geral apresenta a maior correlação com a vazão de Itaipu em todas as defasagens, com exceção do lag3, cujos modelos I e III (índices e vazão) apresentam maior

correlação, mesmo apresentando coeficiente de determinação inferior ao do modelo IV. Nas defasagens com até dois meses os valores extremos e as variabilidades são reproduzidas, porém nas defasagens de três a quatro meses os extremos é bastante falha.

É importante explorar as maiores influências de cada preditor, em cada época do ano, visando assim atingir um melhor desempenho do modelo. No item a seguir será apresentada tal abordagem, através do desenvolvimento de modelos empíricos mensais, de janeiro a dezembro, testando os mesmos grupos de preditores.

CAPÍTULO 6

6. MODELO MENSAL DE REGRESSÃO LINEAR MÚLTIPLA

Neste capítulo são apresentados e discutidos os resultados obtidos no desenvolvimento do modelo mensal de regressão linear múltipla, modelo que considera os meses do ano separadamente, para os seguintes grupos de preditores: *i)* somente os índices climáticos; *ii)* somente precipitação em regiões pluviométricas homogêneas; *iii)* somente vazões em pontos a montante e a própria Itaipu defasada; e *iv)* o conjunto de preditores citados nos itens anteriores (*i*, *ii* e *iii*).

6.1 Correlação mensal com preditores

Para cada mês do ano foi realizada uma análise de correlação defasada de um a doze meses entre a vazão de Itaipu e as possíveis variáveis preditoras, visando verificar o grau de relacionamento entre tais variáveis para cada mês do ano. As Figuras 6.1, 6.2 e 6.3 mostram os coeficientes de correlação (CC) para defasagens de um a doze meses, entre a vazão em Itaipu e índices climáticos, precipitação em regiões homogêneas, vazão em pontos a montante e a própria vazão de Itaipu defasada.

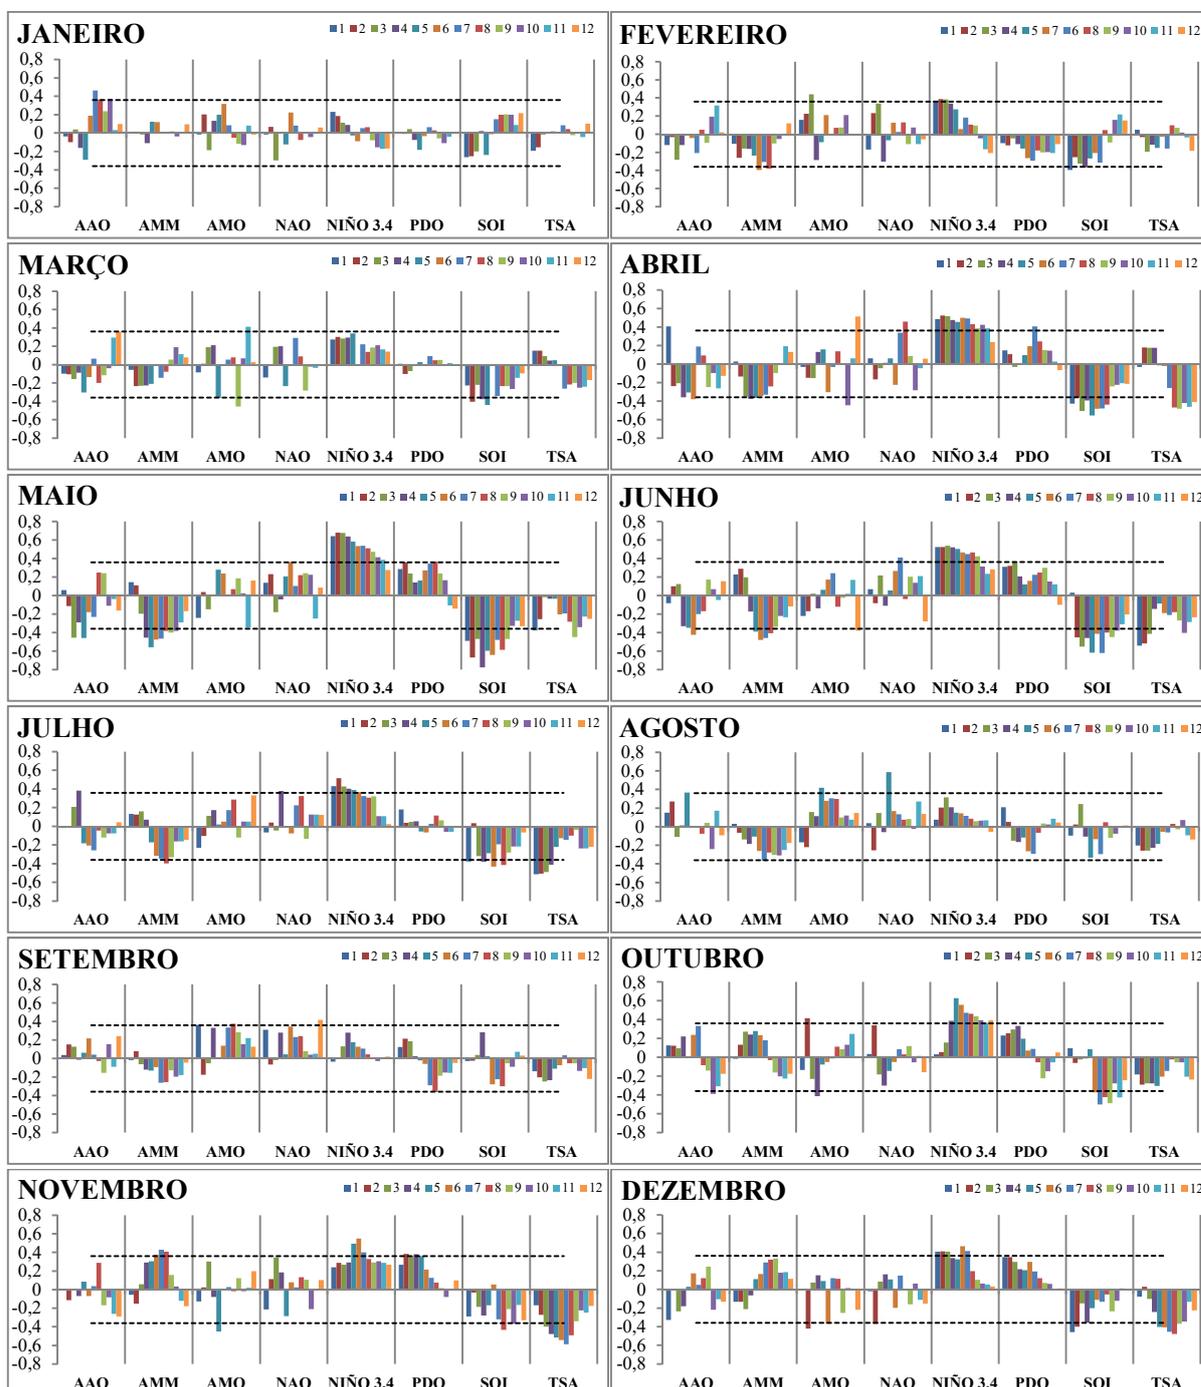
Como as correlações entre a vazão de Itaipu, vazões a montante de Itaipu, índices climáticos e precipitação nas regiões pluviométricas homogêneas, variam muito ao longo das doze defasagens e meses do ano, foi aplicado o teste t de Student para verificar as correlações significativas (5% nível de significância, ou seja, 95% nível de confiança). Considerando 29 o

número de graus de liberdade (número de meses das séries históricas correlacionadas menos dois) e valor crítico é de t igual a 2,045, de acordo com a Tabela de Student bi-caudal, sendo assim definidos valores de CC significativos, superiores e inferiores a $|0,36|$. Deste modo, as correlações superiores e inferiores às linhas tracejadas nas Figuras 6.1, 6.2 e 6.3 são consideradas significativas a partir da métrica definida. Na discussão dos resultados foram enfatizados apenas os padrões que apresentaram correlações significativas para os três grupos de preditores.

A partir das correlações entre a vazão de Itaipu e os índices climáticos (Figura 6.1) foram identificadas correlações significativas para o nível de significância de 5%, para todos os índices em diferentes defasagens em todos os meses do ano. Para o mês de janeiro verificam-se correlações negativas significativas apenas para o índice AAO nas defasagens mais curtas. Para o mês de fevereiro observaram-se correlações significativas positivas para os índices AMO e NIÑO 3.4, e negativas para o índice SOI nas defasagens mais curtas, enquanto que para o índice AMM observam-se correlações significativas negativas nas defasagens mais longas. No mês de março apenas os índices AMO e SOI apresentam correlações negativas significativas em diferentes defasagens, com destaque nas defasagens intermediárias. Para o mês de abril verificaram-se correlações significativas para todos os índices, com destaque para os índices NIÑO 3.4 e SOI. No mês maio encontram-se correlações significativas para quase todos os índices, exceto o AMO, destacando-se as correlações negativas com os índices SOI e AMM, e positivas para o NIÑO 3.4, que se tornam mais pronunciada do que nos meses anteriores. No mês de junho a correlação entre os índices destacados em maio começa a perder força, e o índice TSA começa a se tornar significativo nas primeiras defasagens.

Nas análises de julho a correlação com o índice TSA ganha força, sendo observadas correlações negativas significativas nas defasagens mais curtas. Em agosto, os índices AAO, AMM, AMO e NAO apresentam correlações significativas em poucas defasagens intermediárias (lag5 a 7), situação semelhante encontrada no mês de setembro, mas para os índices AMO, NAO e PDO. Em outubro, os índices voltam a apresentar correlações mais significativas ao longo das defasagens, com destaque para os índices NIÑO 3.4 e SOI, com correlações significativas positivas e negativas, respectivamente. E por fim, para os meses de novembro de dezembro verificaram-se correlações significativas negativas com o índice TSA e positivas para o índice PDO, somente em novembro.

Figura 6.1: Coeficiente de correlação (CC) entre os índices climáticos e a vazão de Itaipu para os doze meses do ano, defasados doze vezes (cada barra corresponde a uma diferente defasagem, conforme a legenda acima do gráfico). A linha tracejada corresponde ao valor limite de significância estabelecido através do teste t de Student, $-0,36 \leq CC \leq 0,36$.

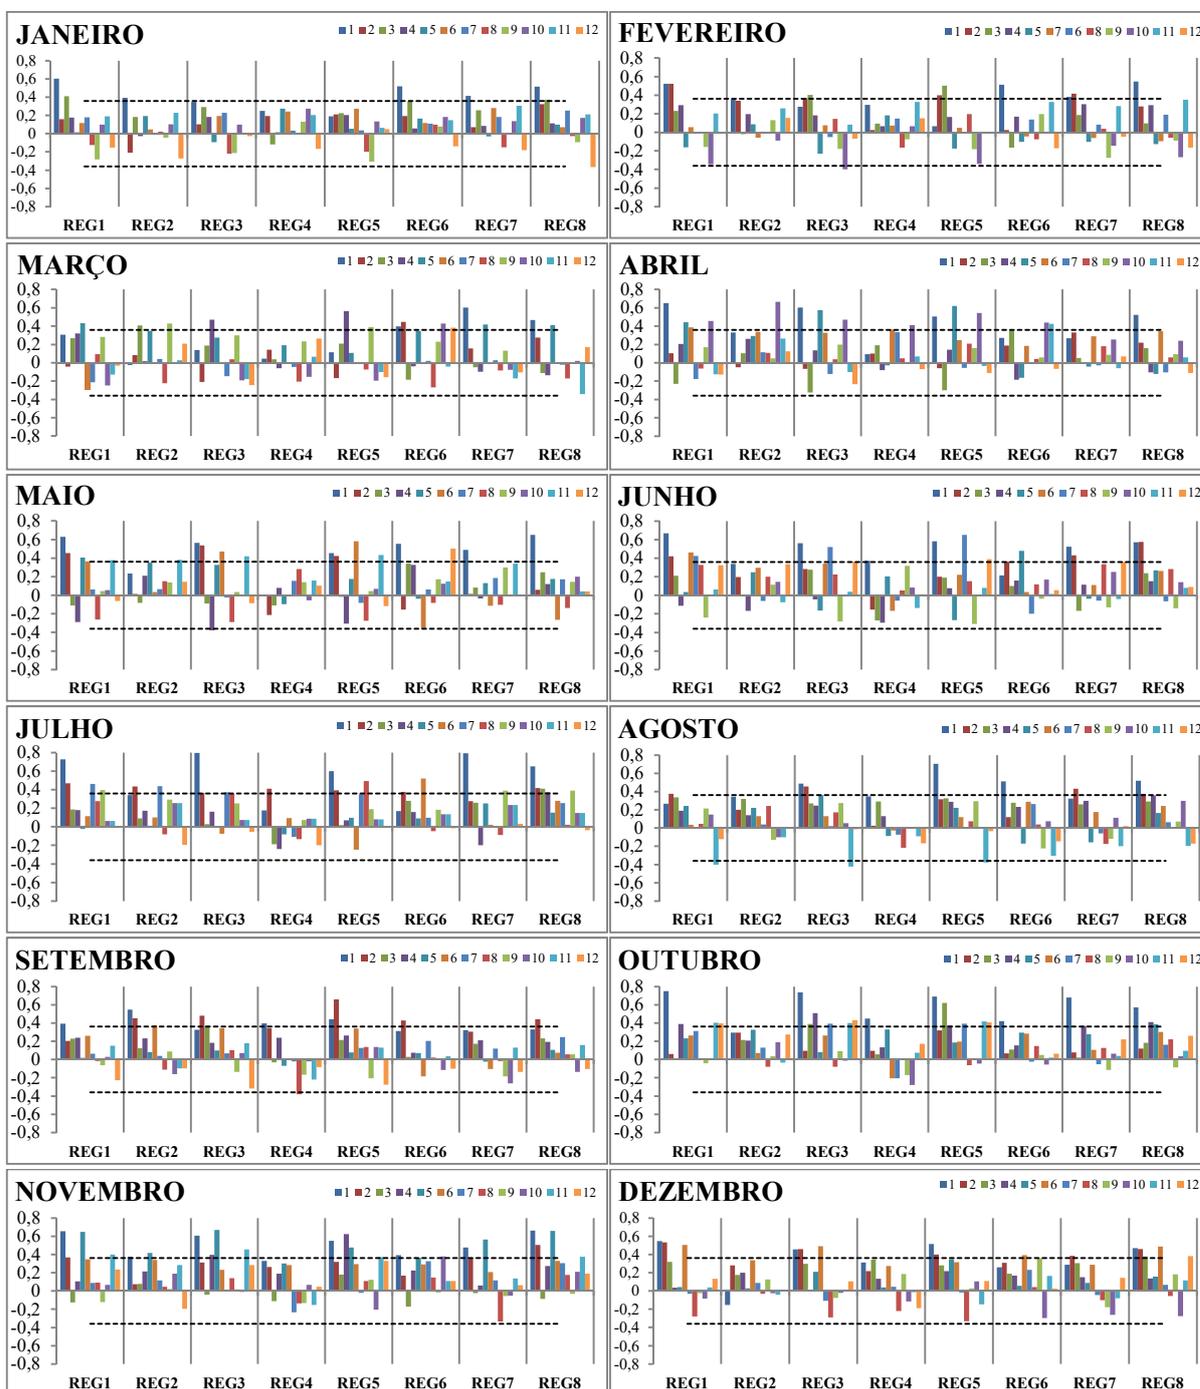


Resultados das correlações identificadas entre a vazão de Itaipu e a precipitação nas regiões pluviométricas homogêneas (Figura 6.2) possuem significância estatística, ao nível de significância de 5%, para todas as regiões em diferentes defasagens e em todos os meses do ano. Para o mês de janeiro observam-se correlações significativas positivas nas regiões das

faixas norte, central e sul (REG1, REG2, REG6, REG7 e REG8), apenas nas defasagens mais curtas, e correlação negativa com a REG8 (sul da BHRP) para as defasagens mais longas. No mês de fevereiro, além das regiões encontradas em janeiro, foram observadas correlações significativas positivas nas regiões da parte leste e oeste (REG3 e REG5), nas defasagens mais curtas e com a REG3, verificou-se também correlações significativas negativas para defasagens mais longas. No mês de março há correlações positivas significativas para as mesmas regiões de fevereiro, porém em alguns casos as correlações positivas foram encontradas para defasagens mais longas. Em abril, todas as correlações significativas encontradas em diferentes defasagens são positivas, tanto nas defasagens mais curtas quanto longas, para quase todas as regiões, exceto para a REG7. Um resultado similar foi encontrado para os meses de maio e junho, todas as correlações significativas são positivas, nas defasagens longas e curtas, para quase todas as regiões, exceto para REG4 em maio e REG2 para junho.

Para o mês de julho foram verificadas correlações significativas positivas para todas as regiões e obtiveram os valores mais altos da análise mensal, com destaque para REG1, REG3, REG7 e REG8, que apresentam $0,65 \leq CC \leq 0,80$ com um mês de defasagem. Já no mês de agosto observam-se correlações significativas positivas para as defasagens mais curtas em quase todas as regiões, exceto REG4, e correlações negativas nas defasagens mais longas para REG1 e REG5. No mês de setembro verificaram-se correlações significativas positivas nas defasagens mais curtas para quase todas as regiões, exceto REG7, e correlações negativas significativas para REG4 com oito meses de defasagem. No mês de outubro observam-se correlações positivas significativas em várias defasagens em quase todas as regiões, exceto REG2, com destaque nas primeiras defasagens para REG1, REG3, REG5 e REG7, que mostram valores altos de correlação entre $0,68 \leq CC \leq 0,75$. E, por fim, nos meses de novembro e dezembro verificam-se correlações significativas positivas em quase todas as regiões, exceto REG4 para novembro e dezembro e REG2 e REG7 para dezembro, com destaque para as defasagens entre cinco e seis meses, os valores de correlação são altos comparados com os outros meses entre $0,40 \leq CC \leq 0,67$.

Figura 6.2: Coeficiente de correlação (CC) entre a precipitação nas regiões pluviométricas homogêneas e a vazão de Itaipu para os doze meses do ano, defasados doze vezes (cada barra corresponde a uma diferente defasagem, conforme a legenda acima do gráfico). A linha tracejada corresponde ao valor limite de significância estabelecido através do teste t de Student, $-0,36 \leq CC \leq 0,36$.



A partir das correlações entre a vazão de Itaipu e vazões a montante e a própria vazão de Itaipu defasada (Figura 6.3) foram identificadas correlações significativas para o nível de significância de 5%, para todas as vazões em diferentes defasagens em todos os meses do ano. Para os meses de janeiro e fevereiro há correlações significativas positivas apenas para as defasagens mais curtas para quase todas os postos, exceto Capim Branco 2 em janeiro. Nos

meses de março a maio observa-se um aumento de correlações significativas positivas para defasagens mais longas. Nos meses de junho e julho as correlações positivas significativas aparecem com até sete meses de defasagem, apresentando correlações superiores a 0,86. Para os meses seguintes, agosto e setembro, o valor das correlações diminui e o número de defasagens significativas também. Já nos meses de outubro e novembro as correlações significativas positivas aumentam, destacando-se para novembro o fato de significativas correlações para maioria das vazões nas defasagens analisadas, sendo que no caso de Furnas apenas para doze meses defasados não há significância estatística. E por fim, no mês de dezembro os valores das correlações significativas voltam a diminuir, apresentando valores significativos apenas nas defasagens mais curtas.

Figura 6.3: Coeficiente de correlação (CC) entre as vazões a montante e Itaipu defasada e a vazão de Itaipu para os doze meses do ano, defasados doze vezes (cada barra corresponde a uma diferente defasagem, conforme a legenda acima do gráfico). A linha tracejada corresponde ao valor limite de significância estabelecido através do teste t de Student, $-0,36 \leq CC \leq 0,36$.

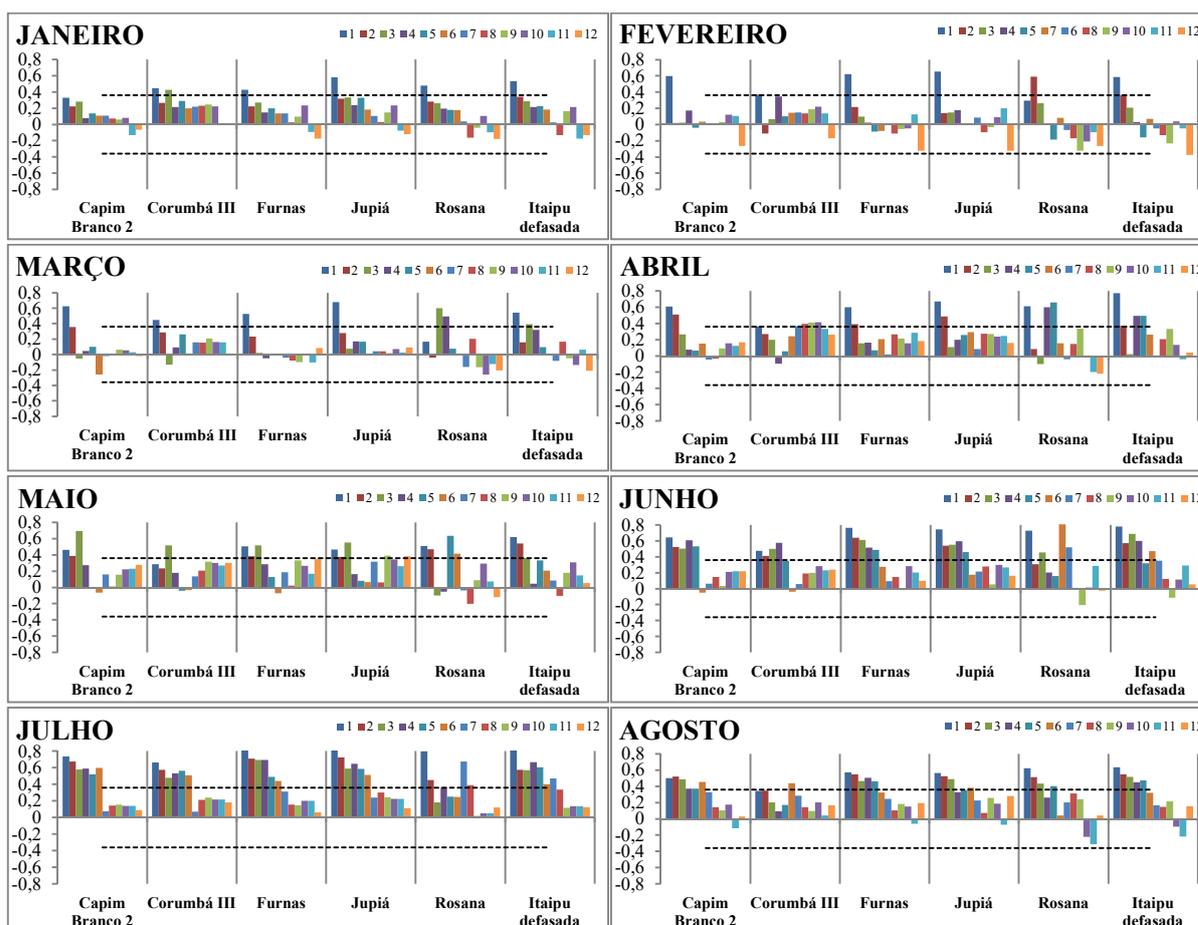
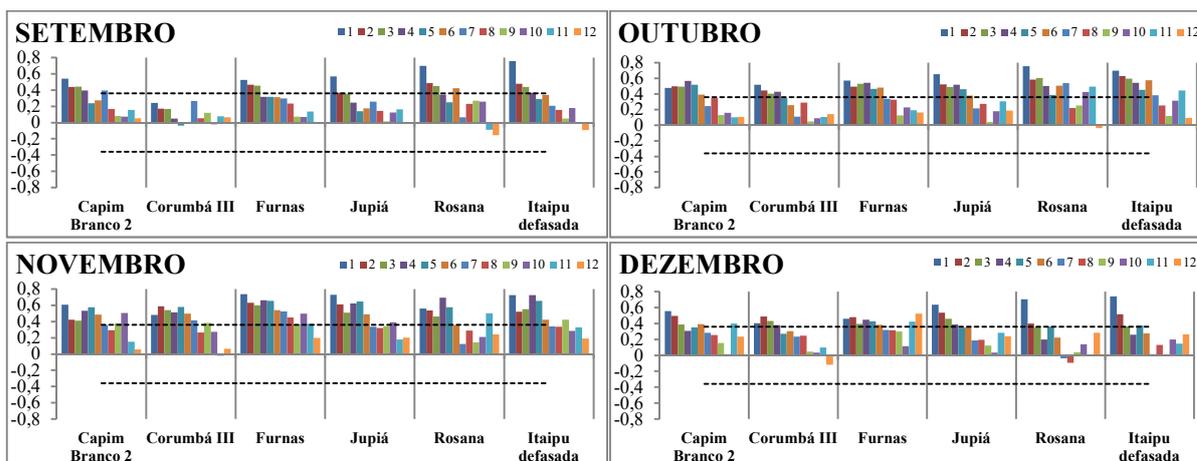


Figura 6.3: Continuação.



6.2 Modelos mensais de previsão de vazão em Itaipu

Para selecionar os melhores preditores dos modelos mensais foi aplicado o método *stepwise*, igualmente ao caso do modelo geral, considerando os seguintes grupos de dados padronizados, os mesmo utilizados para identificar as correlações mais significativas: *i*) índices climáticos (oito preditores testados); *ii*) precipitação em regiões pluviométricas homogêneas (oito preditores testados) e *iii*) vazões a montante de Itaipu e a própria Itaipu defasada (seis preditores testados).

No método de seleção dos preditores (*stepwise*) foram encontrados como principais preditores, as mesmas variáveis que apresentam maiores correlações para as diferentes defasagens identificadas no item anterior. Os resultados dessa seleção para as doze defasagens testadas estão detalhados na Tabela 6.1, 6.2 e 6.3, que indicam os índices climáticos, regiões pluviométricas homogêneas e os pontos de vazões, respectivamente.

A partir da Tabela 6.1 observa-se que os índices NIÑO 3.4 e SOI aparecem como preditores na maioria dos casos, influenciando a vazão de Itaipu nos meses de abril a novembro em diferentes defasagens, mas com maior intensidade nos meses de outono-primavera (ABR, MAI, JUN e OUT) para o NIÑO 3.4 e nos meses de outono-inverno (MAI, JUN e AGO) para o SOI. Esses dois índices evidenciam a influência do ENOS sobre a vazão em Itaipu ao longo do ano, com exceção do verão (DEZ a FEV).

O índice TSA foi apontado como preditor nas defasagens mais longas para os meses abril, novembro e dezembro, e nas primeiras defasagens para o mês de julho, enquanto que o

índice AMO foi selecionado em quase todos os meses, exceto julho, setembro e dezembro, em diferentes defasagens (lag4 a 12). Para o índice AAO o método sugere os meses de janeiro, março, abril, maio, agosto, novembro e dezembro como preditor, com maior intensidade no mês de maio.

Nota-se também que o índice AMM foi selecionado como preditor nos meses de abril, novembro e dezembro, com maior intensidade em novembro para as defasagens mais longas. Para o índice NAO, o método sugere os meses de abril, agosto a outubro, com maior intensidade no mês de setembro com defasagens mais longas. E, por fim, o índice PDO aparece apenas como preditor nos meses de setembro e dezembro, para o mês de setembro em defasagem mais longa (lag8), enquanto que para o mês de dezembro para um mês de defasagem.

Tabela 6.1: Preditores de índices climáticos selecionados no *stepwise* para defasagens de um a doze meses (lag1-12) para todos os meses do ano.

Mês	Lag1	Lag2	Lag3	Lag4	Lag5	Lag6	Lag7	Lag8	Lag9	Lag10	Lag11	Lag12
JAN	-	-	-	-	-	AMO	AAO	-	-	-	-	-
FEV	-	-	-	AMO	-	-	-	-	-	-	-	-
MAR	-	-	-	-	AMO	-	-	-	AMO	-	-	AAO
ABR	NIÑO 3.4 AAO	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	SOI NÃO	TSA	TSA	TSA	AMO
MAI	NIÑO 3.4 SOI	NIÑO 3.4	NIÑO 3.4 AAO	SOI	SOI AAO	SOI	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4 AMM AMO
JUN	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	SOI	NIÑO 3.4	SOI	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4	SOI	-
JUL	TSA	NIÑO 3.4	TSA	NIÑO 3.4 AAO TSA	NIÑO 3.4	NIÑO 3.4	-	SOI	-	-	-	-
AGO	-	-	NIÑO 3.4 SOI	-	NAO SOI	SOI AMO	SOI	-	-	AAO	-	-
SET	-	-	-	-	-	NAO	-	SOI, PDO NIÑO 3.4	-	-	-	NAO
OUT	-	NAO	-	NIÑO 3.4	NIÑO 3.4 SOI	NIÑO 3.4	NIÑO 3.4	NIÑO 3.4 AMO	SOI	NIÑO 3.4	SOI	NIÑO 3.4 NAO
NOV	-	-	-	TSA	TSA AMM	AMM TSA	AMM TSA	AMM AMO	-	SOI, AMM	-	AAO
DEZ	PDO	-	-	-	TSA	TSA AAO	TSA	TSA	AMM	TSA	-	-

De acordo com o método *stepwise*, os preditores de precipitação nas regiões homogêneas selecionados variam bastante ao longo dos meses e das doze defasagens analisadas (Tabela 6.2). A região 8 (sul da BHRP) foi selecionada pelo método para todos os meses do ano em diferentes defasagens e a região 6 (faixa central da BHRP) só não foi selecionada para os meses de setembro e outubro, sendo a região que aparece mais vezes como preditora na defasagem de um mês, indicando que a precipitação incidente na região demora no máximo um mês para compor a vazão em Itaipu.

Nota-se que a região 7 (sul da BHRP) influencia no segundo semestre do ano, principalmente no período de inverno, sugerindo que a vazão nesta época do ano tem contribuição maior da precipitação derivada da faixa sul da bacia do Paraná, região com um padrão de chuva mais regular ao longo do ano. Em contrapartida, a região 1 (norte da BHRP) influencia mais no primeiro semestre, em especial nos meses de abril e maio, e a região 2 (norte da BHRP) influencia no outono, com defasagens mais longas, e na primavera, com defasagens mais curtas.

As regiões 3, 4 e 5 (oeste e leste da BHRP) são as regiões que foram selecionadas pelo método com menor frequência, aparecendo nos meses de abril e setembro para a região 3, maio, junho e dezembro para a região 4, e março e junho para a região 5.

Tabela 6.2: Preditores de precipitação nas regiões pluviométricas homogêneas selecionados no stepwise para defasagens de um a doze meses (lag1-12) para todos os meses do ano.

Mês	Lag1	Lag2	Lag3	Lag4	Lag5	Lag6	Lag7	Lag8	Lag9	Lag10	Lag11	Lag12
JAN	REG6	-	REG8	-	-	-	-	-	-	-	-	-
FEV	REG1 REG6	REG6	REG8	-	-	-	-	-	-	-	-	-
MAR	REG7	REG6	-	REG8	REG6	-	-	-	REG8	REG1 REG2	REG4	REG1
ABR	REG6	-	REG1	-	REG8 REG3	REG3	REG2 REG6	-	-	REG3 REG8	REG1	
MAI	REG4 REG6	REG7	-	-	-	-	REG7	-	-	-	REG8	REG1
JUN	REG6	REG4 REG2	-	-	REG1	REG6	REG8	REG5	-	-	-	REG8
JUL	REG7 REG1 REG4	REG6 REG1	-	-	-	REG1	REG6	REG8	REG6	-	-	-
AGO	REG8	-	REG6	-	-	-	-	-	-	-	-	-
SET	REG3	REG8	-	-	-	REG7	-	-	-	-	-	-
OUT	REG7 REG2	-	REG8 REG2	-	REG2		REG7	-	-	-	REG7	REG7
NOV	REG7 REG2	REG4	-	REG8	REG6	-	-	-	-	REG1	REG7	-
DEZ	REG7 REG4 REG8	REG7	-	-	-	REG6	-	-	-	-	-	REG7 REG2

Para o caso das vazões em pontos a montante (Tabela 6.3), observou-se que no geral, para as defasagens mais longas não foram selecionados preditores de vazão pelo método *stepwise*, com exceção dos meses abril, outubro, novembro e dezembro, que indicam alguns postos nas defasagens de nove a doze meses. Em abril, o posto mais distante Corumbá III aparece na defasagem dez, sugerindo uma contribuição do escoamento de base desse posto para a vazão de Itaipu, enquanto que nos meses de outubro, novembro e dezembro, os postos mais próximos de Itaipu foram selecionados pelo método.

A vazão de Itaipu defasada aparece como preditor em quase todos os meses do ano, com exceção dos três primeiros meses do ano (JAN a MAR), com maior frequência nas primeiras defasagens (lag1-5). A vazão de Rosana (Bacia do Paranapanema) também aparece em quase todos os meses do ano, com exceção dos meses dezembro e janeiro, mas diferente de Itaipu defasada, Rosana aparece em todas as defasagens analisadas (lag1-12).

A vazão de Jupuíá (Bacia do Paraná) foi selecionada como preditor na maior parte do verão (DEZ e JAN), do inverno (JUN e JUL) e do outono (MAR e ABR) e no final da primavera (NOV), na maioria das defasagens. Enquanto que o posto de Furnas (Bacia do Grande) apareceu nos meses fevereiro, março, junho, julho, novembro e dezembro, com maior frequência nas primeiras defasagens (lag1-5).

As vazões de Capim Branco 2 (Bacia do Paranaíba) e Corumbá III (Bacia do Paranaíba) aparecem como preditoras com pouca frequência, apenas nos para os meses de janeiro, maio, junho e julho para Capim Branco 2, nas primeiras defasagens (lag1-6) e abril, junho, agosto, setembro e outubro para Corumbá III, nas defasagens mais longas (lag4-10).

Tabela 6.3: Preditores de vazão selecionados no stepwise para defasagens de um a doze meses (lag1-12) para todos os meses do ano.

Mês	Lag1	Lag2	Lag3	Lag4	Lag5	Lag6	Lag7	Lag8	Lag9	Lag10	Lag11	Lag12
JAN	Jupuíá Capim Branco 2	-	-	-	-	-	-	-	-	-	-	-
FEV	Furnas	Rosana	-	-	-	-	-	-	-	-	-	-
MAR	Jupuíá	-	Rosana Furnas	Rosana	-	-	-	-	-	-	-	-
ABR	Itaipu def.	Jupuíá		Rosana	Rosana	-	-	-	-	Corumbá III	-	-
MAI	Itaipu def.	Itaipu def.	Capim Branco 2	-	Rosana	Rosana	-	-	-	-	-	-
JUN	Furnas Rosana	Furnas	Itaipu def.	Corumbá III Itaipu def.	Jupuíá	Rosana Capim Branco 2	Rosana	-	-	-	-	-
JUL	Itaipu def.	Jupuíá	Furnas	Furnas	Itaipu def. Capim Branco 2	Jupuíá	Rosana	Rosana	-	-	-	-
AGO	Itaipu def.	Itaipu def.	Itaipu def.	Itaipu def.	Itaipu def.	Corumbá III	-	Rosana	-	-	-	-
SET	Itaipu def.	Rosana	Rosana	Rosana	-	Rosana	Corumbá III	-	-	-	-	-
OUT	Rosana	Itaipu def.	Rosana	Itaipu def.	Itaipu def.	Itaipu def.	Rosana	Corumbá III	-	Rosana	Rosana	-
NOV	Jupuíá	Furnas	Furnas	Itaipu def.	Itaipu def.	Jupuíá	Furnas	-	Itaipu def.	Jupuíá	Rosana	-
DEZ	Itaipu def.	Jupuíá	-	Furnas	Furnas	Jupuíá	-	-	-	-	Furnas	Furnas

Para avaliar a contribuição de cada grupo de preditores selecionado pelo método *stepwise* foram desenvolvidos quatro modelos de regressão linear múltipla para as doze defasagens em todos os meses, conforme: Modelo I) somente os índices climáticos; Modelo

II) somente precipitação em regiões homogêneas; Modelo III) somente vazões em ponto a montante e vazão em Itaipu defasada; e Modelo IV) o conjunto de preditores citados em I, II e III. Foram considerados os preditores selecionados para cada defasagem, ou seja, os modelos foram construídos conforme os preditores selecionados pelo método *stepwise* para cada defasagem e para cada mês correspondente.

Os resultados da calibração, através do coeficiente de determinação (R^2), para os modelos I, II, III e IV para cada defasagem (1-12 meses) de janeiro a dezembro no período de 1980 a 200 estão apresentados na Figura 6.4. Os modelos estão representados pelas cores: Modelo I – barra azul, Modelo II – barra verde, Modelo III – barra roxa e Modelo IV – barra vermelha.

A partir dos valores apresentados de R^2 pode-se inferir sobre a validação dos modelos (análise do coeficiente de determinação), sendo verificado que para os meses janeiro, fevereiro e março os índices climáticos não contribuem para a previsão de vazão nas primeiras defasagens (lag1-3), a contribuição dos índices será importante nas defasagens mais longas lag6, lag5 e lag4 para os meses de jan, fev e março respectivamente. Para os meses de abril e maio a contribuição dos índices climáticos é evidenciada desde as primeiras defasagens, para o mês de maio o R^2 atinge o valor de 0,76 para o lag3. No mês de junho e julho os valores de R^2 para os índices climáticos continuam altos, mas sua contribuição é menor para as defasagens mais curtas. Nos meses seguintes a contribuição dos índices é novamente comprovada nas defasagens mais longas, sendo que nas defasagens acima de oito meses, apenas os índices climáticos conseguem obter preditores significativos, sendo os únicos preditores de vazão de Itaipu nas defasagens mais longas.

Figura 6.4: Coeficiente de Determinação (R^2) para todos os meses do ano e nas diferentes defasagens (lag1-12) para os modelos: modelo I (barra azul), modelo II (barra verde), modelo III (barra roxa) e modelo IV (barra vermelha).

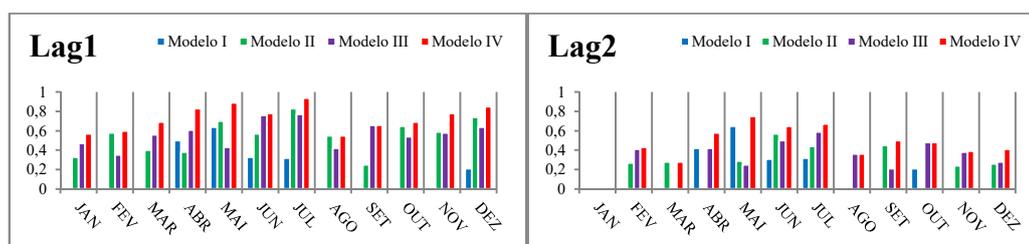
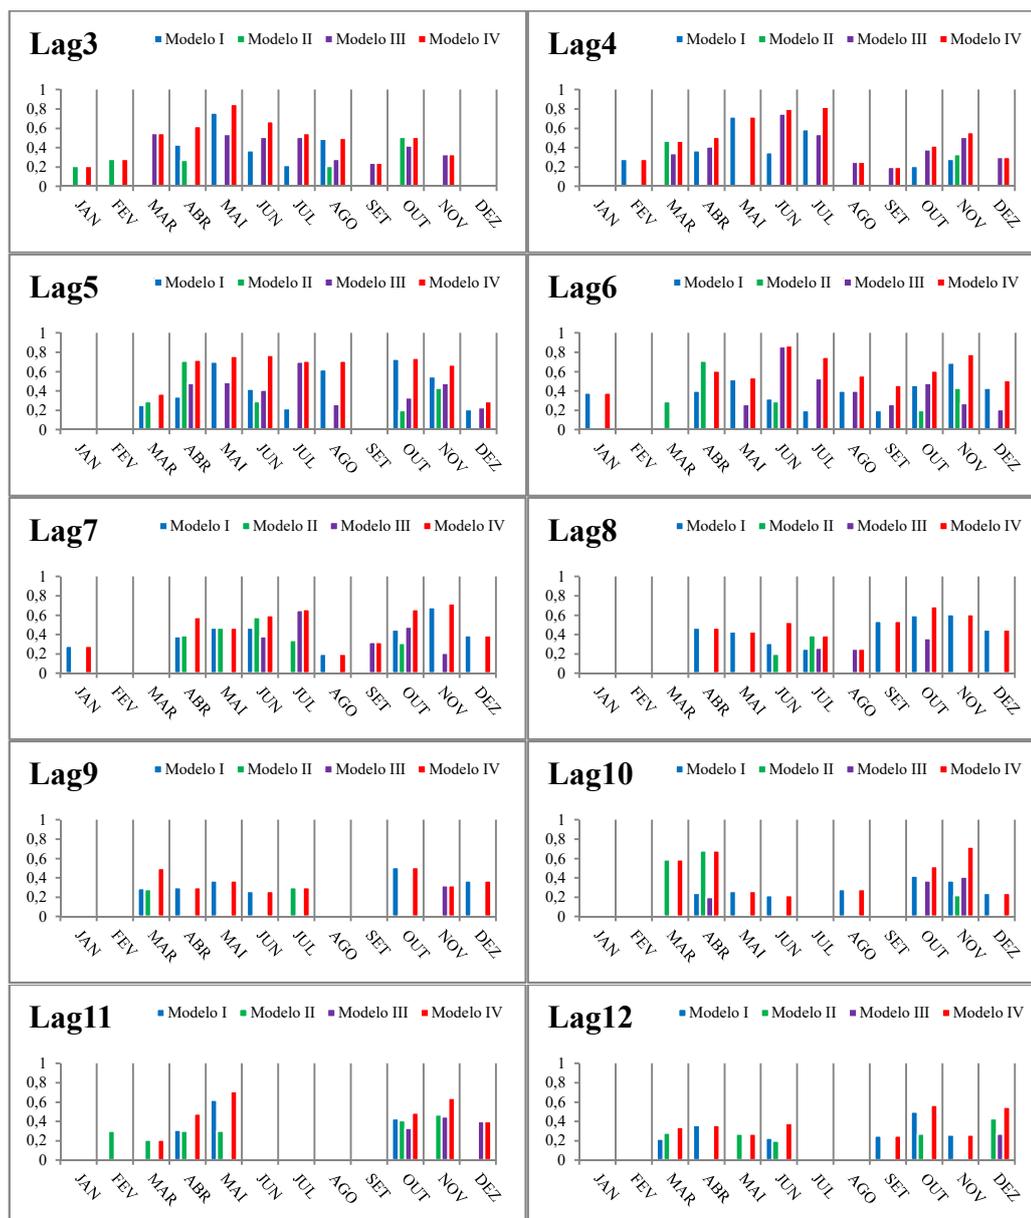


Figura 6.4: Continuação.

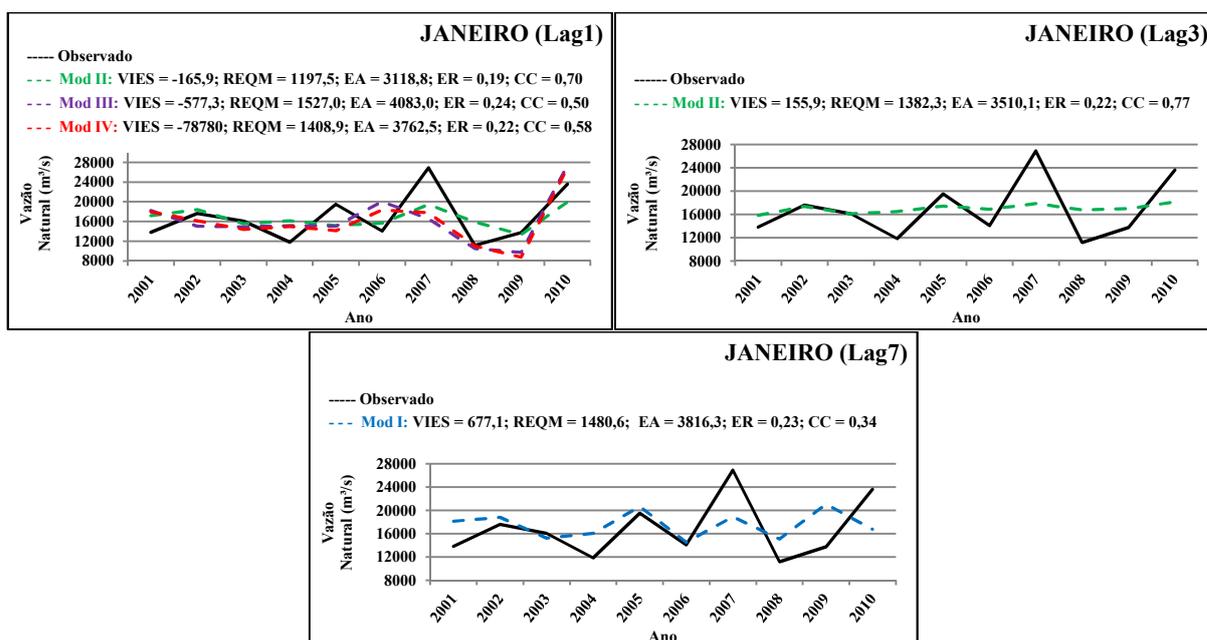


As Figuras 6.5 a 6.16 destacam a comparação entre as vazões observadas (linha contínua preta) e previstas pelos quatro modelos desenvolvidos (linhas tracejadas), destacando os parâmetros de validação (VIES, REQM, EA, ER e CC), para cada mês e defasagens que apresentam melhores resultados. No apêndice estão disponíveis os resultados para todos os meses e defasagens, expressos na Tabela A.2 (resultados do CC para as doze defasagens em todos os meses).

Na Figura 6.5 foram selecionadas as defasagens lag 1, lag 3 e lag 7. Através dos gráficos torna-se claro que para as defasagens mais curtas (lag 1 e lag 3), a precipitação é o

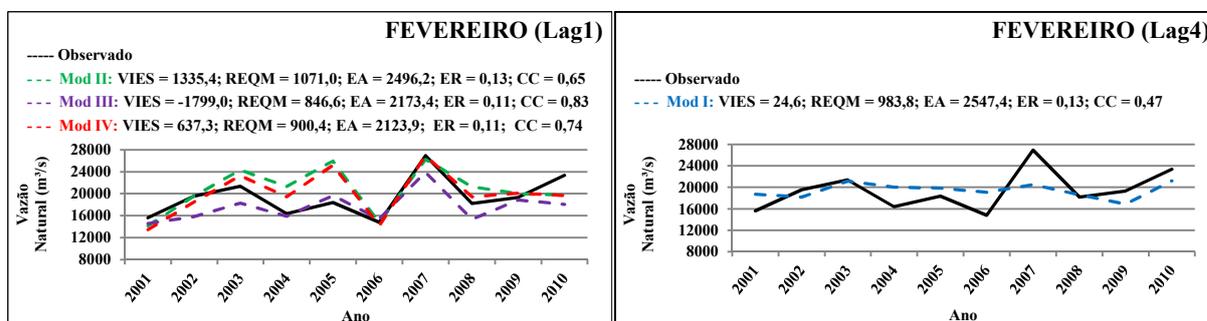
principal preditor no mês de janeiro, $CC \geq 0,70$. No entanto, os índices climáticos irão auxiliar na previsão em defasagens mais longas (lag7), $CC = 0,34$. Em nenhum dos casos analisados os modelos conseguem simular os extremos de vazão no mês de janeiro, subestimando os picos máximos e superestimando os picos mínimos. Para as demais defasagens os erros são elevados e o $CC \leq 0,20$ (Tabela A.2, apêndice).

Figura 6.5: Comparação da vazão observada (linha contínua preta) com as previstas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de janeiro nas defasagens: lag1, lag3 e lag7. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



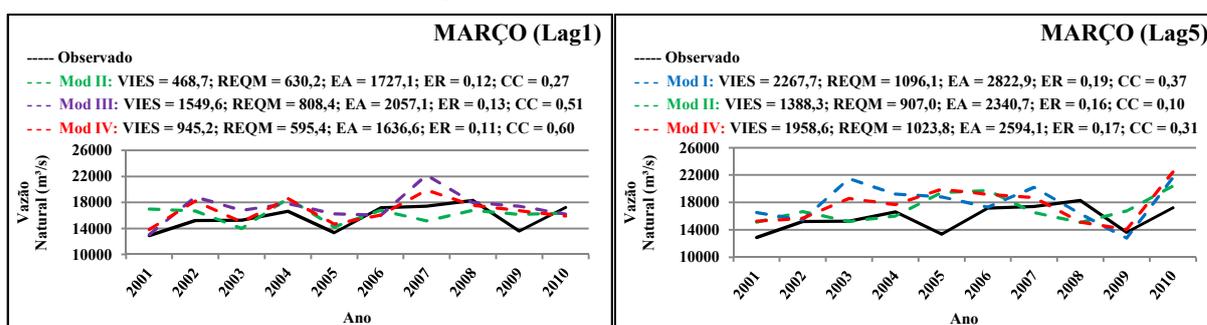
Para fevereiro, destacam-se as defasagens lag 1 e lag 4 (Figura 6.6), para a defasagem mais curta (lag 1), sendo a precipitação e a vazão os melhores preditores neste mês ($CC \geq 0,40$), demonstrando que o modelo IV apresenta menores erros do que os modelos separados (II e III). Nos lags 1 e 2 os extremos máximos e mínimos são previstos em quase todos os anos, apresentando pequenos VIES em alguns casos (CC disponível na Tabela A.2, apêndice). Para as defasagens mais longas (lag 4) os índices climáticos auxiliam na melhoria da previsão ($CC = 0,47$), porém os modelos não conseguem prever todos os extremos máximos e mínimos. Os demais modelos para a defasagem lag 3 não apresentaram parâmetros satisfatórios, indicando um baixo desempenho. (Tabela A.2, apêndice).

Figura 6.6: Comparação da vazão observada (linha contínua preta) com as previstas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de fevereiro nas defasagens: lag1 e lag4. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



Para o mês de março destacam-se as defasagens lag 1 e lag 5 (Figura 6.7), sendo observado para o lag 1 que o modelo IV apresenta os menores erros e $CC = 0,60$, enquanto que no lag 5, o modelo I apresenta melhores resultados ($CC \geq 0,30$). Comportamento semelhante é observado para o lag 9, porém são modelados apenas alguns extremos de vazão, evidenciando mais uma vez a contribuição dos índices climáticos para defasagens mais longas. Para as outras defasagens analisadas os erros são elevados e o $CC \leq 0,30$ (Tabela A.2, apêndice).

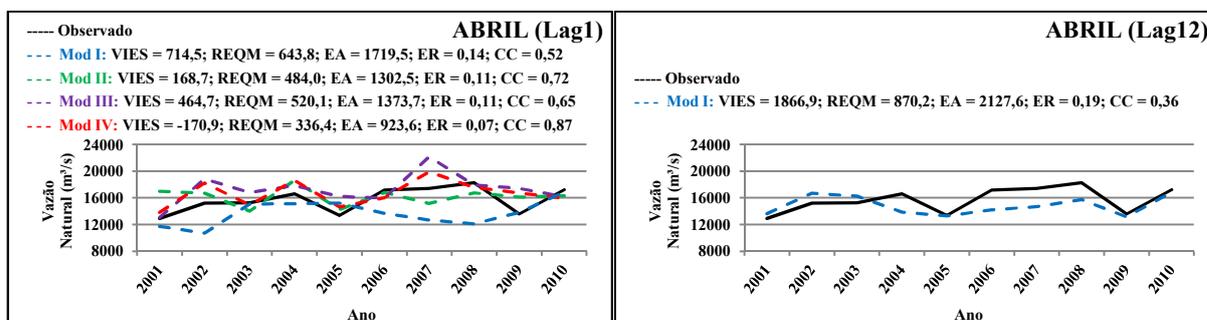
Figura 6.7: Comparação da vazão observada (linha contínua preta) com as previstas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de março nas defasagens lag1 e lag5. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



Estimativas para o para o mês de abril (Figura 6.8), a partir do lag 1, apresentam altas correlações com o observado de todos os modelos ($CC \geq 0,50$), mas o modelo IV apresenta os menores erros, subestimando os valores extremos. Para as defasagens mais longas apenas o modelo I apresenta preditores significativos, indicando que os índices climáticos auxiliam na previsão de vazão em Itaipu para as defasagens mais longas (Figura 6.8, lag 12). Para as demais defasagens analisadas, os erros dos modelos são elevados e $CC \leq 0,25$, em quase todos os casos, com exceção do lag 5 no qual o modelo III apresenta $CC = 0,56$, indicando que mesmo para defasagens mais longas a precipitação e a vazão à montante podem

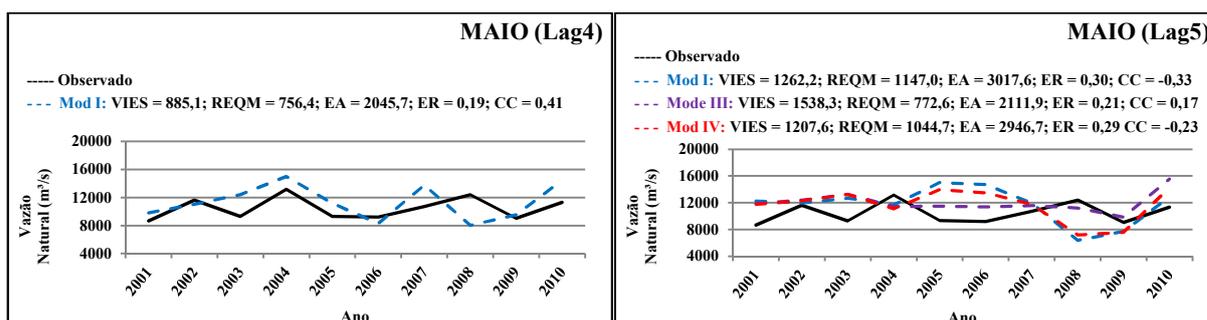
contribuir para a previsão de vazão de Itaipu (contribuição do escoamento de base) (Tabela A.2, apêndice).

Figura 6.8: Comparação da vazão observada (linha contínua preta) com as previstas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de abril nas defasagens lag1 e lag12. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



Na Figura 6.9 são apresentados os resultados da avaliação dos modelos para as defasagens 4 e 5 no mês de maio. Neste mês os modelos com preditores climáticos apresentam os melhores resultados na avaliação, porém o $CC \leq 0,41$ e os erros apresentam valores elevados, indicando que os modelos desenvolvidos para este mês apesar de apresentar um bom ajuste (expresso pelos valores altos de R^2) apresentam um baixo desempenho para a previsão de vazão em Itaipu.

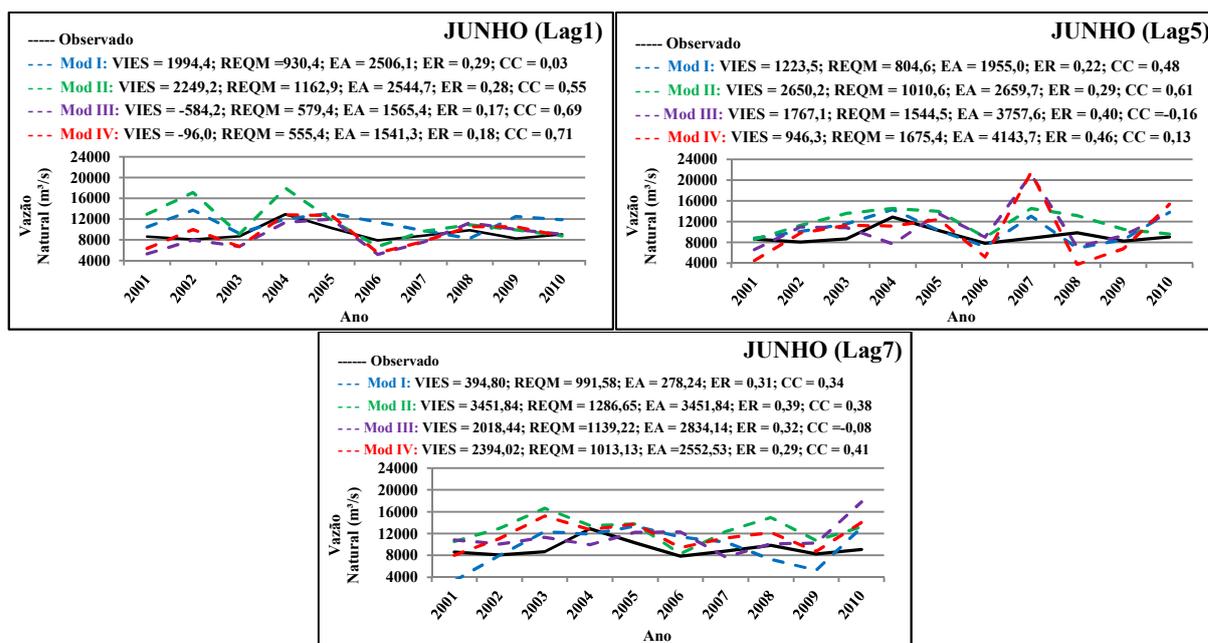
Figura 6.9: Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de maio nas defasagens lag4 e lag5. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



Para o mês de junho destacam-se as defasagens 1, 5 e 7 (Figura 6.10), sendo observado para o lag1 que o modelo IV apresenta o melhor desempenho, com menores erros e $CC > 0,70$, enquanto que para o lag 5 os modelos I e II apresentam melhores previsões. Neste caso, a combinação dos três grupos de preditores (modelo IV) leva a perda de desempenho, devido à baixa importância dos preditores de vazão no modelo final, semelhantemente ao encontrado para os lags 2 e 4 (Tabela A.2, apêndice). Em contrapartida, o modelo IV

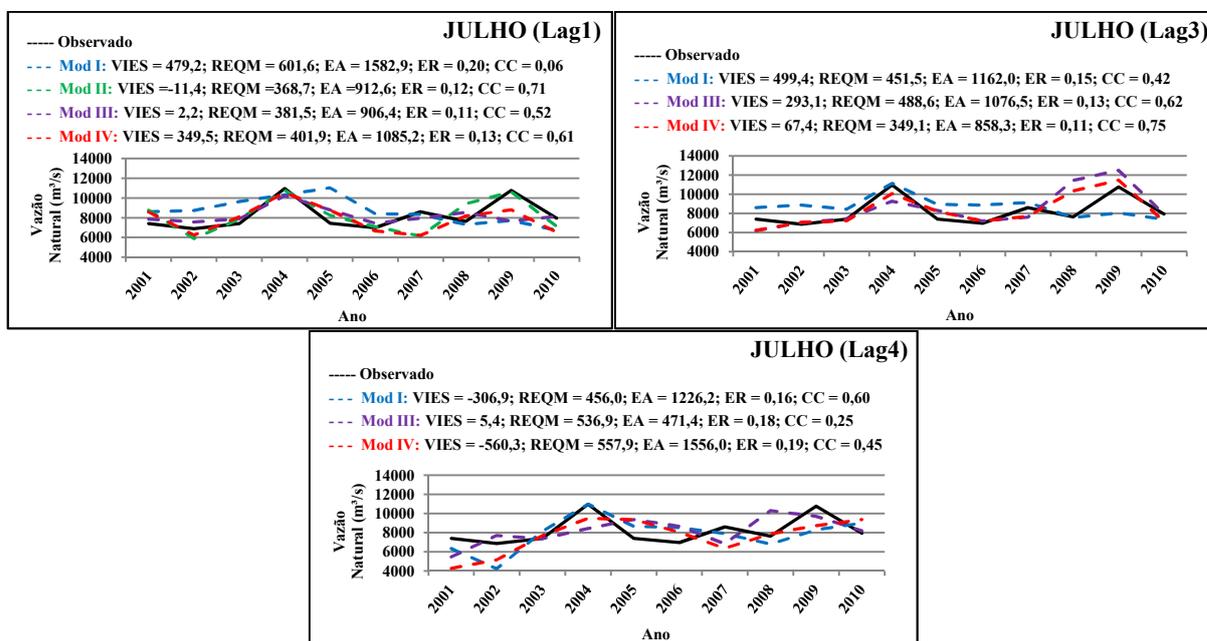
apresentou aumento de desempenho no lag 7. Nas outras defasagens os resultados da validação não foram satisfatórios, as correlações com o observado foram baixas e erros elevados (Tabela A.2, apêndice).

Figura 6.10: Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de junho nas defasagens lag1, lag5 e lag7. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



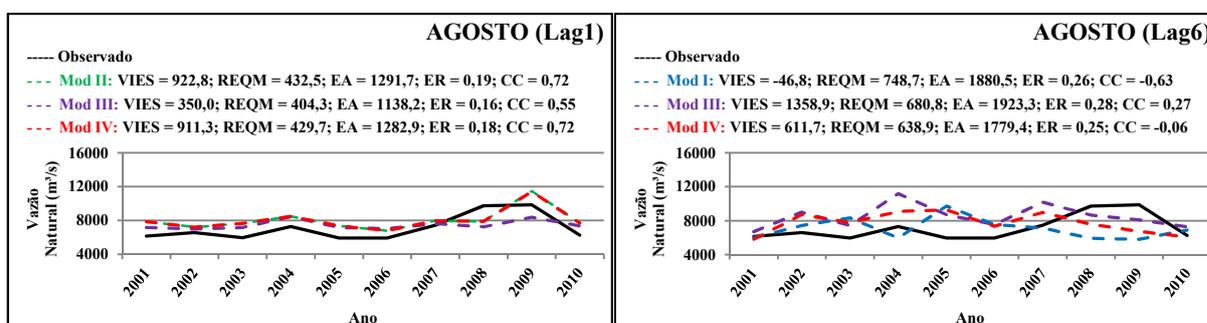
A avaliação para a previsão de julho destaca para o lag 1 (Figura 6.11), os modelos II e III que apresentam menores erros e $CC > 0,50$, demonstrando a importância da vazão a montante e precipitação na bacia para a previsão de vazão nas defasagens mais curtas, enquanto que para as defasagens mais longas a partir do lag 3 o modelo I tem uma contribuição mais relevante que os demais, apresentando $CC > 0,40$ apenas utilizando os índices climáticos como preditores, sendo também verificado um alto desempenho ao se considerar o modelo IV. Em outras defasagens os resultados da validação não foram satisfatórios (Tabela A.2, apêndice).

Figura 6.11: Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de julho nas defasagens lag1, lag3 e lag4. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



Para o mês de agosto destacam-se duas defasagens, lags 1 e 6 (Figura 6.12). Para o lag1, o modelo II apresenta melhor desempenho, mesmo quando combinados os preditores (modelo III), verifica-se um bom desempenho, com boas estimativas dos extremos máximos e mínimos de vazão e $VIES \geq 900 \text{ m}^3/\text{s}$. Para o lag 6, o modelo I apresenta melhor desempenho que os demais, porém o $CC = -0,63$, indicando que o modelo falha na captura das variações aos longo dos anos, a ponto de estima-las inversamente. Para as outras defasagens os modelos não apresentam resultados satisfatórios (Tabela A.2, apêndice).

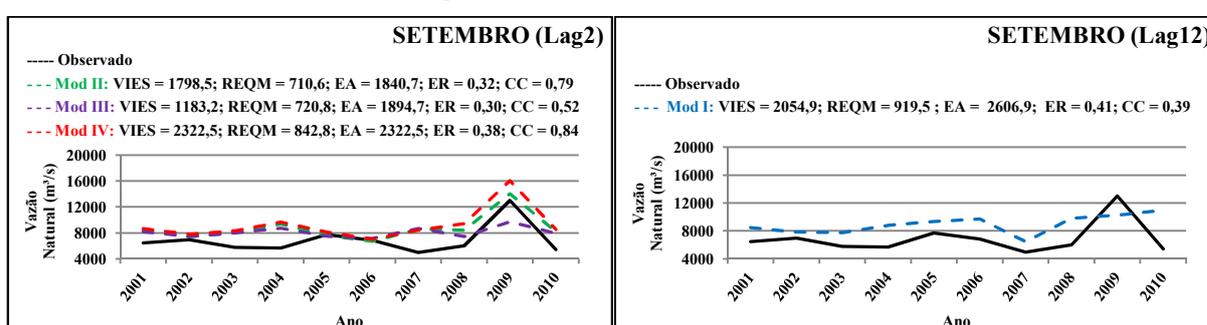
Figura 6.12: Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de agosto nas defasagens lag1 e lag6. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



Na Figura 6.13 são apresentados os gráficos de comparação das vazões previstas (modelos) x observado em setembro, com defasagens de 2 e 12 meses. Nota-se para a

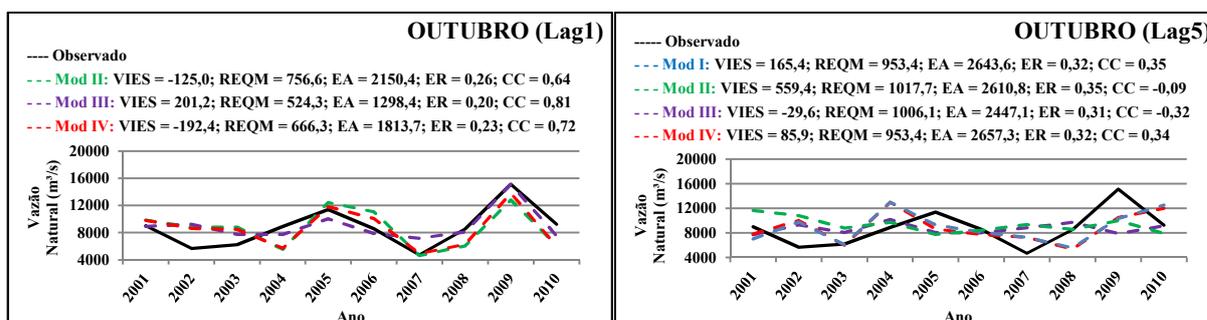
defasagem mais curta que os modelos II e III apresentam melhores desempenhos, com $CC \geq 0,52$ e quando combinados os preditores (modelo IV) aumenta o $CC = 0,84$, mas aumenta a superestima dos casos extremos, o que é também observado para o lag 1. Para defasagens mais longas (lag 12), o modelo I apresenta melhor desempenho que os demais, porém os erros são elevados, $CC = 0,39$ e os extremos não são captados. Nas demais defasagens os modelos não obtiveram bons resultados em sua avaliação (Tabela A.2, apêndice).

Figura 6.13: Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de setembro nas defasagens lag1 e lag2. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



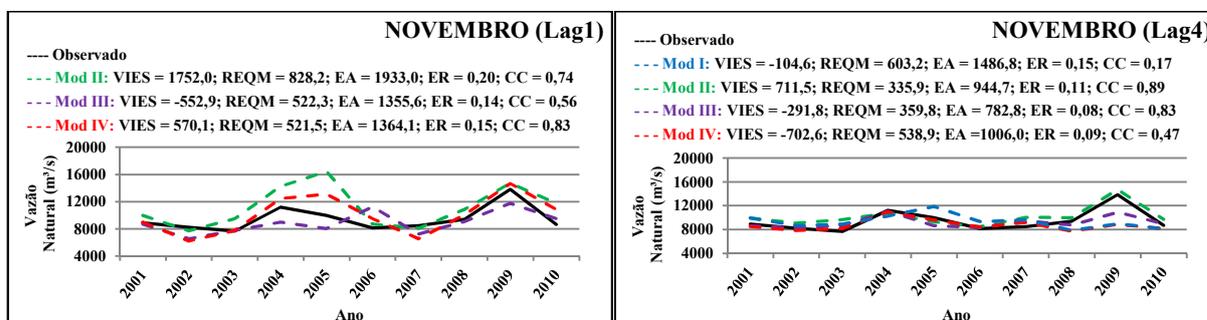
Para o mês de outubro também ocorrem resultados similares, conforme apresentado na Figura 6.14, para os lags 1 e 5. Nas defasagens mais curtas os modelos II e III apresentam melhores desempenhos, e quando combinados os preditores, pelo modelo IV, verifica-se uma melhoria nas previsões para os extremos máximos e mínimos, apresentando apenas um pequeno VIES negativo, subestimando o valor observado. Nas defasagens mais longas o modelo I apresenta melhor desempenho e para as demais defasagens a avaliação não foi satisfatória (Tabela A.2, apêndice).

Figura 6.14: Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de outubro e nas defasagens lag1 e lag5. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



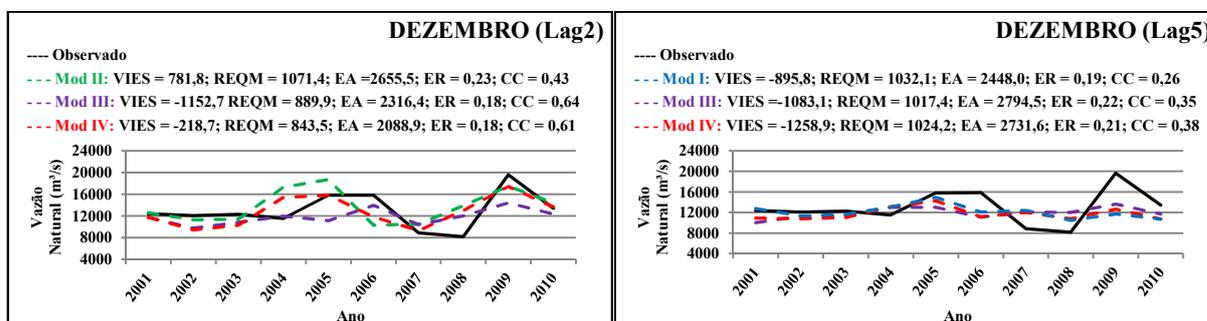
O comportamento dos modelos para novembro é semelhante ao mês anterior. Para as defasagens mais curtas lag 1 e lag 2 os modelos II e III apresentam melhor desempenho e quando combinados aumenta-se o desempenho, o que pode ser observado pela Figura 6.15 (lag 1). Na defasagem 4 os índices climáticos também contribuem para a previsão de vazão. Porém neste caso os modelos II e III combinados provavelmente gerariam um modelo mais eficiente, que simula os extremos com melhor desempenho, visto que os índices climáticos aumentam o VIES do modelo neste caso. Para os lags 3, 5 e 7 ainda são observados valores de $CC \geq 0,72$ para os modelos II e III, indicando que a vazão a montante e a precipitação na bacia são fatores importantes até nas defasagens mais longas, para a previsão de vazão em Itaipu em novembro. Para as defasagens mais longas (lag 12) observa-se contribuição dos índices climáticos, com o modelo I apresentando erros menores em relação aos demais, porém a correlação entre o observado x estimado é negativa, $CC = -0,39$ (Tabela A.2, apêndice), não obtendo um bom desempenho. Nas demais defasagens os desempenhos dos modelos não foram satisfatórios (Tabela A.2, apêndice).

Figura 6.15: Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de novembro e nas defasagens lag1 e lag4. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



Para o mês de dezembro o desempenho dos modelos nas defasagens mais curtas é similar aos dos outros meses do ano, com os modelos II e III apresentando melhor desempenho e o modelo IV destaca-se no caso de defasagens mais altas (Figura 6.16). Nos prazos mais longos as estimativas do modelo IV se devem principalmente pela contribuição do modelo I (índices climáticos), indicando mais uma vez que nas defasagens mais altas os índices climáticos contribuem para a previsão de vazão em Itaipu. Nas demais defasagens, não apresentadas, os modelos não obtiveram resultados satisfatórios em sua avaliação (Tabela A.2, apêndice).

Figura 6.16: Comparação da vazão observada (linha contínua preta) com as modeladas, Modelo I (linha tracejada azul), Modelo II (linha tracejada verde), Modelo III (linha tracejada roxa) e Modelo IV (linha tracejada vermelha) para o mês de dezembro e nas defasagens lag2 e lag5. Acima de cada gráfico estão os valores dos parâmetros: VIES, REQM, EA, ER e CC.



6.3 Conclusão

Conforme o modelo geral (Capítulo 5) foi investigado o grau de influência das possíveis variáveis predictoras, através da análise de correlação defasada em defasagens variando de um a doze meses, porém neste capítulo foi avaliada a correlação para todos os meses separadamente (modelo mensal), diferente do anterior que a correlação era avaliada para todos os meses consecutivos (modelo geral).

Os resultados da análise de correlação mês a mês sugerem que no geral a vazão de Itaipu é influenciada principalmente pelo ENOS (índices NIÑO 3.4 e SOI), exceto no verão (DEZ, JAN e FEV), e pelas anomalias de TSM no Atlântico tropical sul (índice TSA) no final do outono e da primavera e no início do inverno e do verão. Para as variáveis de precipitação, verifica-se que nas regiões localizadas na faixa sul da BHRP (REG7 e REG8) a influencia na vazão de Itaipu acontece durante todo o ano, principalmente no inverno e no verão, enquanto que da faixa norte (REG1 e REG2) ocorre na primavera e no outono, demonstrando uma defasagem na influência das variações ocorridas nas estações seca e chuvosa dessas regiões, que apresentam um ciclo sazonal bem marcante (chuvoso no verão e seco no inverno). E por fim, para as vazões a influência é maior nas defasagens mais curtas, nos meses de inverno e outono pela própria vazão de Itaipu defasada, e nos outros meses do ano pelas vazões a montante.

Levando-se em conta as variações mensais, foram desenvolvidos modelos empíricos de regressão linear múltipla, sendo aplicado para estimativas de vazão em Itaipu com defasagens variando de um a doze meses, considerando todos os meses separadamente (modelo mensal). Para o desenvolvimento dos modelos, considerou-se o período de 1980 a

2000 para calibração e o período de 2001 a 2010, para validação. Estes modelos foram testados com diferentes grupos de preditores defasados, conforme: I) somente os índices climáticos; II) somente precipitação em regiões pluviométricas homogêneas; III) somente vazão em pontos a montante e a própria vazão em Itaipu; IV) o conjunto de preditores citados em I, II e III.

O método de *stepwise* indicou como preditores de vazão nos meses janeiro a março apenas os índices AMO e AAO, em abril e julho separaram-se os índices NIÑO 3.4 e TSA, em maio, junho, agosto e outubro NIÑO 3.4 e SOI, em setembro NAO, em novembro TSA e AMM, e por fim em dezembro somente o índice TSA. Para os preditores de precipitação as regiões que mais foram apontadas pelo método com maior frequência foram as regiões localizadas ao sul, norte e centro da bacia (REG1, REG2, REG6, REG7, REG8). Para o caso das vazões, observou-se que no geral, a vazão da própria Itaipu defasada é apontada pelo método com maior frequência, principalmente nas defasagens mais curtas.

De um modo geral, os modelos mensais apresentaram um maior desempenho nas defasagens mais curtas quando considerados os preditores de vazão e precipitação, exceto para os meses de janeiro, julho e agosto, casos em que a precipitação tem maior contribuição. Nestes casos são bem capturadas as variabilidades e alguns extremos. Em contrapartida, para o mês de maio, todos os modelos possuem um baixo desempenho, não sendo capaz de estimar as variabilidades e os extremos. Para todos os meses, verificou-se que o melhor desempenho para as defasagens mais longas, ocorre para o modelo considerando somente os índices climáticos, mas na maioria dos casos os extremos não são capturados, exceto nos meses de abril, junho e julho. Portanto, os resultados deste estudo demonstram a importância de serem consideradas as influências remotas do clima nas estimativas de vazão. A abordagem mensal além de evidenciar a contribuição de índices climáticos não identificados no modelo geral, tais como o AAO, NAO e AMM, separa os mais significativos para cada mês de previsão, considerar as maiores influências de cada mês.

Observa-se também que os índices climáticos não aparecem com persistência para os três primeiros meses do ano, mesmo nas defasagens mais longas, não contribuindo para a previsão para esses meses. Uma hipótese para aumentar o desempenho de alguns destes modelos mensais é utilizar as previsões de vazões defasadas, geradas pela contribuição dos índices climáticos. Isto poderia ser aplicado para os meses como fevereiro e março, cuja

própria vazão defasada contribuir consideravelmente, assim a influência do remota seria indireta, pois afeta vazões passadas que influênciam o estado inicial.

CAPÍTULO 7

7. CONCLUSÕES

7.1 Conclusões

O desempenho de um modelo empírico é bastante impactado pelas variáveis apresentadas como preditoras no modelo. Assim, são necessárias longas bases de dados, confiáveis, que englobem registros com diversas variações, ou seja, séries com variabilidades intrínsecas, que possam ser relacionadas ao preditanto, que no caso deste estudo foi a vazão em Itaipu. Neste sentido, o levantamento, tratamento e adequação dos dados tornam-se primordiais para possibilitar uma boa modelagem. O processo de identificação dos *outliers* através do Diagrama de *Box Plot* permitiu verificar dados duvidosos de precipitação e analisar a variabilidade espacial dos dados pluviométricos na BHRP. O preenchimento de dados faltantes foi necessário para obter séries históricas de precipitação mais completas, alterando o quadro de 30% de estações com séries história completas para 80% de séries completas.

Como a distribuição espacial dos dados de precipitação é irregular, a interpolação dos dados ajuda na identificação de faixas que apresentam padrões semelhantes de precipitação dentro da área de estudo. O método da Krigagem ordinária mostrou-se satisfatório para este fim, sendo que o modelo exponencial o mais indicado para interpolar dados de precipitação na BHRP, por apresentar os menores erros. A partir desta análise, foi possível identificar grandes faixas que apresentam padrões semelhantes de precipitação dentro da área de estudo, como: Região Sul da Bacia, Região Central, Região ao Leste e Região Noroeste. Além disso, a interpolação dos dados auxiliou na definição mais detalhada das regiões homogêneas de precipitação, pela análise de *cluster*. As regiões consideradas homogêneas pela métrica aplicada foram utilizadas para obter as médias regionais das estações pluviométricas, reduzindo o número de preditores no modelo, mantendo regiões com padrões distintos de precipitação.

Para investigar o grau de influência das possíveis variáveis preditoras (índices climáticos, precipitação em regiões pluviométricas homogêneas e vazão em pontos a montante e a própria Itaipu defasada) foi realizada uma análise de correlação defasada para todos os meses consecutivos e para cada mês separadamente defasados em até doze meses. Os resultados mostraram que correlacionando as variáveis para todos os meses conjuntamente, há perda de informação, devido ao comportamento distinto das variáveis ao longo do ano, principalmente dos índices climáticos, sendo necessária aplicar uma análise de correlação para cada mês separadamente. A análise também foi realizada em diferentes defasagens, sendo verificado o tempo de contribuição de cada variável na vazão de Itaipu.

Os resultados da análise de correlação mensal sugerem que no geral a vazão de Itaipu é influenciada principalmente pelo ENOS (índices NIÑO 3.4 e SOI) ao longo do ano, exceto no verão (DEZ, JAN e FEV) e pelas anomalias de TSM no Atlântico tropical sul (índice TSA) no final do outono e da primavera e início do inverno e do verão. Para as variáveis de precipitação, verifica-se que nas regiões localizadas na faixa sul da BHRP (REG7 e REG8) a influência na vazão de Itaipu acontece durante todo o ano, principalmente no inverno e no verão, enquanto que na faixa norte (REG1 e REG2) na primavera e no outono. E por fim, para as vazões a influência é maior nas defasagens mais curtas, nos meses de inverno e outono pela própria vazão de Itaipu defasada, e nos outros meses do ano pelas vazões a montante (Capim Branco 2, Corumbá III, Furnas, Jupia e Rosana).

Deste modo, foram desenvolvidos modelos empíricos, de regressão linear múltipla, sendo aplicado para estimativas de vazão em Itaipu com defasagens variando de um a quatro meses, considerando todos os meses consecutivos (modelo geral). Também foram desenvolvidos modelos mensais, para cada mês do ano, separadamente, com defasagens variando de 1 a 12 meses. Para o desenvolvimento dos modelos, considerou-se o período de 1980 a 2000 para calibração e o período de 2001 a 2010, para validação. Estes modelos foram testados com diferentes grupos de preditores, conforme: I) somente os índices defasados; II) somente precipitação em regiões pluviométricas homogêneas; III) somente vazão em pontos a montante e a própria vazão em Itaipu; IV) o conjunto de preditores citados em I, II e III.

Para selecionar os preditores significativos para os modelos gerais e mensais foi utilizado o método de *stepwise*. No modelo geral os preditores selecionados com maior frequência para até quatro meses de defasagem foram: NIÑO 3.4 e TSA para os índices climáticos; região 8 para a precipitação em regiões homogêneas; Itaipu defasada e Capim

Branco 2 para as vazões. Para o modelo mensal, nos meses janeiro, fevereiro e março apenas os índices AMO e AAO aparecem como preditores, em abril e julho os índices NIÑO 3.4 e TSA, em maio, junho, agosto e outubro NIÑO 3.4 e SOI, em setembro NAO, em novembro TSA e AMM, e por fim em dezembro somente o índice TSA. Para os preditores de precipitação as regiões que mais foram apontadas pelo método com maior frequência foram as regiões localizadas ao sul, norte e centro (REG1, REG2, REG6, REG7, REG8). Para o caso das vazões, observou-se que no geral, a vazão da própria Itaipu defasada é apontada pelo método com maior frequência, principalmente nas defasagens mais curtas.

No modelo geral, o modelo I desenvolvido com somente índices climáticos não é suficiente para produção e estimativas confiáveis para até quatro meses de defasagem, o que é consequência de baixo potencial explicativo da regressão, demonstrado através dos valores de baixos de R^2 . Evidenciou-se a importância da contribuição de vazões a montante e precipitação em regiões pluviométricas homogêneas, principalmente na defasagem para um mês. Os resultados também indicaram que a combinação dos três tipos de preditores (modelo IV) aumenta o desempenho do modelo, principalmente no caso de defasagens mais longas, evidenciando a importância da consideração dos índices climáticos para horizontes mais longos de previsão.

Os resultados da validação mostraram que o modelo que considera todos os grupos de preditores (modelo IV) no geral apresenta a maior correlação com a vazão de Itaipu em todas as defasagens, com exceção do lag3, cujos modelos I e III (índices e vazão) apresentam maior correlação, mesmo apresentando coeficiente de determinação inferior ao do modelo IV. Nas defasagens com até dois meses os valores extremos e as variabilidades são reproduzidas, porém nas defasagens de três a quatro meses muitos extremos não são reproduzidos.

De um modo geral, os modelos mensais apresentaram um maior desempenho nas defasagens mais curtas quando considerados os preditores de vazão e precipitação, exceto para os meses de janeiro, julho e agosto, casos em que a precipitação tem maior contribuição. Nestes casos são bem capturadas as variabilidades e alguns extremos. Em contrapartida, para o mês de maio, todos os modelos possuem um baixo desempenho, não sendo capaz de estimar as variabilidades e os extremos. Para todos os meses, verificou-se que o melhor desempenho para as defasagens mais longas, ocorre para o modelo considerando somente os índices climáticos, mas na maioria dos casos os extremos não são capturados, exceto nos meses de abril, junho e julho. Portanto, os resultados deste estudo demonstram a importância de serem

consideradas as influências remotas do clima nas estimativas de vazão, com abordagem mensal, pois os impactos dos padrões climáticos são diferenciados ao longo do ano e, portanto, precisam ser explorado de forma específica. Neste sentido, os modelos empíricos são bastante úteis dada, pois podem facilmente serem ajustados a diferentes localidades, períodos e conjuntos de preditores.

7.2 Sugestões para trabalhos futuros

Assim, sugere-se para trabalhos futuros estudar a contribuição dos modelos em cadeia para a melhoria de previsões de vazão, com horizontes mais longos, considerando vazões previstas para estivar vazões com defasagens mais curtas. Também podem ser consideradas precipitações previstas para a inclusão nos modelos empíricos, dada a grande contribuição da precipitação passada para a vazão. Além disso, é importante investigar o desempenho de outros tipos modelos, por exemplo, modelos numéricos, conceituais e de inteligência artificial, utilizando os principais preditores identificados neste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

ALEXANDRE, A. M. B. **Previsão de vazões mensais para o sistema interligado nacional utilizando informações climáticas**. 2012. 293 f. Tese (Doutorado em Engenharia Civil) – Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará, Fortaleza, 2012.

ANA. Agência Nacional de Águas (Brasil). Relatório de Conjuntura dos Recursos Hídricos do Brasil. Brasília, 2009. 204 p.

ANDREOLI, R. V.; KAYANO, M. T. ENSO-related rainfall anomalies in South America and associated circulation features during warm and cold Pacific Decadal Oscillation regimes. **International Journal of Climatology**, Reading, v. 25, n. 15, p. 2017-2030, dec. 2005.

ANDREOLI, R. V.; KAYANO, M. T. A importância relativa do Atlântico Tropical Sul e Pacífico Leste na variabilidade de precipitação do Nordeste do Brasil. **Revista Brasileira de Meteorologia**, São Paulo, v. 22, n. 1, p. 63-74, abr. 2007.

ANTICO, P. L. Relationship between autumn precipitation anomalies in southeastern South America and El Niño event classification. **International Journal of Climatology**, Reading, v. 29, n. 5, p. 719-727, apr. 2009.

ÁVILLA, L. F.; MELLO, C. R.; VIOLA, M. R. Mapeamento da precipitação mínima provável para o sul de Minas Gerais. **Revista Brasileira Engenharia Agrícola Ambiental**, Campina Grande, v. 13, suplemento, p. 906-915, nov./dez. 2009.

BARBOSA, J. P. M. Utilização de métodos de interpolação para análise e espacialização de dados climáticos: o SIG como ferramenta. **Caminhos de Geografia**, Uberlândia, v. 9, n. 17, p.85-96, fev. 2006.

BASTOS, C. C.; FERREIRA, N. J. Análise climatológica da alta subtropical do Atlântico Sul. In: Congresso Brasileiro de Meteorologia, 11., 2000, Rio de Janeiro. **Anais...** Rio de Janeiro: SBMET, 2000.

BERRI, G. J.; GHIETTO, M. A.; GARCIA, N. O. The influence of ENSO in the flows of the upper Paraná River of South America over the past 100 years. **Journal of Hydrometeorology**, Boston, v. 3, n. 1, p. 57-65, feb. 2002.

BOMBARDI, R. J.; CARVALHO, L. M. V. The South Atlantic dipole and variations in the characteristics of the South American Monsoon in the WCRP-CMIP3 multi-model simulations. **Climate Dynamics**, Berlin, v. 36, n. 11, p. 2091-2102, jun. 2011.

BOMBARDI, R. J. et al. Precipitation over eastern South America and the South Atlantic sea surface temperature during neutral ENSO periods. **Climate Dynamics**, Berlin, v. 42, n. 6, p. 1553-1568, mar. 2014.

BRAVO, J. et al. Coupled hydrologic-hydraulic modeling of the upper Paraguay River basin. **Journal of Hydrologic Engineering**, Reston, v. 17, n. 5, p. 635-646, may. 2012.

BRUN, G. W.; TUCCI, C. E. M. Previsão em tempo real do volume afluente ao reservatório de Ernestina. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 6, n. 2, p. 73-79, abr./jun. 2001.

CAMBARDELLA, C. A., et al. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society of America Journal**, Madison, v. 58, n. 5, p. 1240-1248, sep. 1994.

CARDOSO, A. O.; SILVA DIAS, P. L. Relação entre a vazão de alguns rios do Estado de São Paulo e anomalias de TSM no Atlântico e Pacífico. In: Congresso Brasileiro de Meteorologia, 12., 2002, Foz do Iguaçu. **Anais...** Rio de Janeiro: SBMET, 2002.

CARDOSO, A. O.; SILVA DIAS, P. L. Identificação de trimestres extremos no regime pluviométrico do Sul e Sudeste do Brasil e relação com anomalias da TSM. **Revista Brasileira de Meteorologia**, São Paulo, v. 19, n. 2, p.149-162, set. 2004.

CARDOSO, A. O. **Relações entre a TSM nos oceanos Atlântico e Pacífico e as condições climáticas nas regiões Sul e Sudeste do Brasil**. 2005. 192 f. Tese (Doutorado de Meteorologia) – Instituto de Astronomia Geofísica e Ciências Atmosféricas, Universidade São Paulo, São Paulo, 2005.

CARDOSO, A. O.; SILVA DIAS, P. L. The relationship between ENSO and Paraná River flow. **Advances in Geosciences**, Göttingen, v. 6, n. 1, p. 189-193, feb. 2006.

CARDOSO, A. O.; CATALDI, M. Relações de índices climáticos e vazão de rios no Brasil. In: Congresso Brasileiro de Meteorologia, 17., 2012, Gramado. **Anais...** Rio de Janeiro: SBMET, 2012.

CARUSO, C.; QUARTA, F. Interpolation methods comparison. **Computers & Mathematics with Applications**, Amsterdam, v. 35, n. 12, p. 109-126, jun. 1998.

CARVALHO, L. M. V.; JONES, C.; LIEBMANN, B. The South Atlantic convergence zone: Intensity, form, persistence, and relationships with intraseasonal to interannual activity and extreme rainfall. **Journal of Climate**, Boston, v. 17, p. 88–108, jan. 2004.

CAVALCANTI, I. F. A.; OLIVEIRA, G. S. **Teleconexões**. Climanálise Especial – Edição Comemorativa de 10 anos. 1. ed. Cachoeira Paulista: CPTEC/INPE, 1996.

CAVALCANTI, I. F. A. et al. **Tempo e Clima no Brasil**. 1. ed. São Paulo: Oficina de Textos, 2009, p. 464.

CEPEL. Centro de Pesquisas de Energia Elétrica (CEPEL). **PREVIVAZ – Modelos computacionais para previsão de afluências diárias, semanais e mensais**. Disponível em: <<http://www.cepel.br/>> Acesso em: 11/06/2015.

CHANG, P.; JI, L.; LI, H. A decadal climate variation in the tropical Atlantic Ocean from thermodynamic air-sea interactions. **Nature**, London, v. 385, n. 6616, p. 516-518, feb. 1997.

CHAVES, R. R. Conexões entre a TSM do Atlântico Sul e a Convecção de verão sobre a América do Sul – Análise observacional. **Revista Brasileira de Geofísica**, Rio de Janeiro, v. 29, n. 1, p. 5-10, out. 2011.

CHIANG, J. H.; VIMONT, D. J. Analogous Pacific and Atlantic Meridional Modes of Tropical atmosphere-ocean variability. **Journal of Climate**, Boston, v.17, n.21, p.4143-4158, nov. 2004.

CHIESSI, C. M., Possible impact of the Atlantic Multidecadal Oscillation on the South American summer monsoon. **Geophysical Research Letters**, Washington, v. 36, n. 21, p. 1-5, nov. 2009.

COELHO, C. A. S.; UVO, C. B.; AMBRIZZI, T. Exploring the impacts of the tropical Pacific SST on the precipitation patterns over South America during ENSO periods. **Theoretical and Applied Climatology**, Berlin, v. 71, n. 3, p. 185-197, feb. 2002.

COLLISCHONN, W. et al. Modelo hidrológico distribuído para previsão de vazões incrementais na bacia do rio Paranaíba entre Itumbiara e São Simão. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 12, n. 3, p. 43-56, jul./set. 2007.

DANTAS, L. G. et al. Oscilação Decadal do Pacífico e Multidecadal do Atlântico no clima da Amazônia Ocidental. **Revista Brasileira de Geografia Física**, Recife, v. 5, n. 3, p. 600-611, out. 2012.

DRAPER, N.R.; SMITH, H. **Applied regression analysis**. 3. ed. Nova Jersey: Wiley, 1998. 706 p.

DETTINGER, M. D. et al. Multiscale streamflow variability associated with El Niño/Southern Oscillation. In: DIAZ, H. F.; MARKGRAF, V. (Org.). **El Niño and the Southern Oscillation - Multiscale Variability, Global and Regional Impacts**, Cambridge: University Press, 2000. p.114-147.

DEVORE, J. L. **Probabilidade e Estatística para Engenharia e Ciência**. 8. ed. São Paulo: Cengage Learning, 2014. 693 p.

ELFIELD, D. B.; MAYER, D. A. Tropical Atlantic sea surface temperature variability and its relation to El Niño-Southern Oscillation. **Journal of Geophysical Research: Oceans**, Washington, v. 102, n.1, p. 929-945, jan. 1997.

ELFIELD, D. B. et al. How ubiquitous in the dipole relationship in tropical Atlantic sea surface temperatures? **Journal of Geophysical Research**, Washington, v. 104, n. 4, p. 7841-7848, abr. 1999.

ELFIELD, D. B. The Atlantic Multidecadal oscillation and its relation to rainfall and river flows in the continental U.S. **Geophysical Research Letters**, Washington, v. 28, n. 10, p. 2077-2080, may. 2001.

GARCIA, S. R.; KAYANO, M. T. Climatological aspects of Hadley, Walker and monsoon circulations in two phases of the Pacific Decadal Oscillation. **Theoretical and Applied Climatology**, Berlin, v. 91, n. 1-4, p. 117-127, feb. 2008.

GAZALLE, F. K. et al. Sintomas depressivos e fatores associados em população idosa no Sul do Brasil. **Revista de Saúde Pública**, São Paulo, v. 38, n. 3, p. 365-371, jun. 2004.

GONG, D., WANG, S. Definition of Antarctic Oscillation Index. **Geophysical Research Letters**, Washington, v. 26, n. 4, p. 459-462, feb. 1999.

GOOVAERTS, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. **Journal of Hydrology**, Amsterdam, v. 228, n. 1-2, p. 113-129, feb. 2000.

GRIMM, A. M.; FERRAZ, S. T.; GOMES, J. Precipitation anomalies in Southern Brazil associated with El Niño and La Niña Events. **Journal of Climate**, Boston, v. 11, n. 11, p. 2863-2880, nov. 1998.

GRIMM, A. M. The El Nino impact on the summer monsoon in Brazil: Regional processes versus remote influences. **Journal of Climate**, Boston, v. 16, n. 2, p. 263-280, jan. 2003.

GRIMM, A. M.; LEITE, A. E.; SAHAIR, A. K. Previsão de precipitação sazonal para a bacia do rio Paranaíba utilizando um modelo linear. In: Congresso Brasileiro de Meteorologia, 13., 2004, Fortaleza. **Anais...** Rio de Janeiro: SBMET, 2004.

GRIMM, A.M.; TEDESCHI, R.G. ENSO and Extreme Rainfall Events in South America. **Journal of Climate**, Boston, v. 22, n. 7, p. 1589-1609, apr. 2009.

GUILHON, L. G. F.; ROCHA, V. F.; MOREIRA, J. C. Comparação de métodos de previsão de vazões naturais afluentes a aproveitamentos hidroelétricos. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 12, n. 3, p. 13-20, jul./set. 2007.

HURRELL, J. W. Decadal trends in the North Atlantic: Regional temperatures and precipitation. **Science**, Washington, v. 269, n. 5224, p. 676-679, aug. 2003.

ISAAKS, E.H.; SRIVASTAVA, R.M. **An Introduction to Applied Geostatistics**. New York: Oxford University Press, 1989.

ITAIPU BINACIONAL (ITAIPU). Disponível em: <<http://www.itaipu.gov.br/>>. Acesso: 06/11/2015.

KAPLAN, A. et al. Analysis of global sea surface temperature 1856-1991. **Journal of Geophysical Research: Oceans**, Washington, v. 103, n. 9, p. 18567-18589, aug. 1998.

KAYANO, M. T.; ANDREOLI, R. V. Variabilidade Decenal a Multidecenal. In: I. F. A. Cavalcanti, N. J.; Ferreira, M. G. A. J.; Silva, M. A. F. **Tempo e Clima no Brasil**. 1. ed. São Paulo: Oficina de Textos, 2009. p. 375-383.

KAYANO, M. T.; OLIVEIRA, C. P.; ANDREOLI, R. V. Interannual relations between South American rainfall and tropical sea surface temperature anomalies before and after 1976. **International Journal of Climatology**, Reading, v. 29, n. 10, p. 1439-1448, nov. 2009.

KAYANO, M. T.; CAPISTRANO, V. B. How the Atlantic multidecadal oscillation (AMO) modifies the ENSO influence on the South American rainfall. **International Journal of Climatology**, Reading, v. 34, n. 1, p. 162-178, jan. 2014.

LÉLLIS, F. S.; BARROSO, G. F. Modelagem geoestatística da precipitação pluviométrica na bacia do rio Jacaraípe, Serra (ES). In: Simpósio Brasileiro de Sensoriamento Remoto, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011.

LIMA, K.C. **Descargas Eléctricas Atmosféricas em Sistemas Convectivos de Mesoescala no Sul da América do Sul**. 2005. 118 f. Dissertação (Mestrado em Meteorologia) – Faculdade de Meteorologia, Universidade Federal de Pelotas, Pelotas, 2005.

LOREIRO, G. E.; LISBOA, E. G. Comparação dos métodos de Interpolação Espacial aplicados a dados pluviométricos da Região Hidrográfica Tocantins-Araguaia. In: Simpósio Brasileiro de Recursos Hídricos, 19., 2011, Maceió, **Anais...** Porto Alegre: ABRH, 2011.

MADDOX, R. A. Mesoscale convective complexes. **Bulletin of American Meteorological Society**, Boston, v. 61, n. 11, p. 1374-1387, dez. 1980.

MALFATTI, M. G. L.; LINGIARDI, A. M.; CARDOSO, A. O. Modelo Empírico para previsão de vazão de rios – Caso Itaipu. In: Congresso Brasileiro de Meteorologia, 18., 2014, Recife, **Anais...** Rio de Janeiro: SBMET, 2014.

MANTUA, N. J. et al. A Pacific interdecadal climate oscillation with impacts on salmon production. **Bulletin of American Meteorological Society**, Boston, v. 78, n. 6, p. 1069-1079, jun. 1997.

MARENGO, J. A. et al. Two contrasting severe seasonal extremes in Tropical South America 2012: Flood in Amazonia and drought in Northeast Brazil. **Journal of Climate**, Boston, v. 26, n. 22, p. 9137-9154, nov. 2012.

McBRIDE, J. L.; EBERT, E. E. Verification of quantitative precipitation forecasts from operational numerical weather prediction models over Australia. **Weather and Forecasting**, Boston, v. 15, n. 1, p. 103-121, feb. 2000.

MELO, M. L., Impacto do fenômeno El Niño sobre a região Centro-Oeste do Brasil. In: Congresso Brasileiro de Meteorologia, 11., 2000, Rio de Janeiro, **Anais...** Rio de Janeiro: SBMET, 2000.

MELLO, Y. R. et al. Distribuição de precipitação anual na bacia hidrográfica do rio Cubatão Norte. **Revista Geonorte**, Manaus, Edição especial 2, v. 1, n. 5, p. 535-546, nov. 2012.

MENDES, M. C. D.; CAVALCANTI, I. F. A. The relationship between the Antarctic oscillation and blocking events over the South Pacific and Atlantic Oceans. **International Journal of Climatology**, Reading, v. 34, n. 3, p.529-544, mar. 2014.

MENESES, P. R.; ALMEIDA, T. (org.) **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: CNPq, p.266, 2012.

MINE, M. R. M.; TUCCI, C. E. M. Previsão em Tempo Real de vazões afluentes a reservatórios de Usinas Hidrelétricas. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 4, n. 2, p. 73-95, abr./jun. 1990.

MINUZZI, R. B. et al. Influência do fenômeno climático El Niño no período chuvoso da região sudeste do Brasil. **Geografia**, Londrina, v. 15, n. 2, p. 5-19, jul./dez. 2006.

MINUZZI, R. B.; SEDIYAMA, G. C.; COSTA, J. M. N.; VIANELLO, R. L. Influência da La Niña na estação chuvosa da região sudeste do Brasil. **Revista Brasileira de Meteorologia**, São Paulo, v. 22, n. 3, p. 354-353, dez. 2007.

MOLION, L. C. B. Perspectivas Climáticas para os próximos 20 anos. **Revista Brasileira de Climatologia**, Curitiba, v. 3, n.1, p. 117-128, ago. 2008.

MOQUET, J. S. et al. Variabilidade Multidecadal do sistema de monções de verão durante os últimos 2000 anos na região centro-oeste do Brasil (Goiás) com base em registros de

espeleotemas. In: Congresso da Associação Brasileira de Estudos do Quaternário, 14., 2013, Natal, **Anais...** São Paulo: ABEQUA, 2013.

MOURA, G. B. de A. et al. Relação entre a precipitação do leste do Nordeste do Brasil e a temperatura dos oceanos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 13, n. 4, p. 462-469, jul./ago. 2009.

NAGHETTINI, M.; PINTO, E. J. A. **Hidrologia Estatística**. Belo Horizonte: CPRM, 2007. 552 p.

OLIVA, F. G. **Relações entre o índice de oscilação antártica e as vazões na bacia hidrográfica do rio Uruguai, região Sul do Brasil**. 2011. 68 f. Dissertação (Mestrado em Ciências) – Instituto de Geociências, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

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

OLIVEIRA, A. O.; SARAIVA, J. M. B. Efeitos de um bloqueio atmosférico no campo de precipitação e temperatura no Rio Grande do Sul. In: Congresso Brasileiro de Meteorologia, 11., 2000, Rio de Janeiro, **Anais...** Rio de Janeiro: SBMET, 2000.

OLIVEIRA, P. T. de. **Estudo estatístico sobre eventos de precipitação intensa no Nordeste do Brasil**. 2014. 114 f. Tese (Doutorado em Ciências Climáticas) – Centro de Ciências Exatas da Terra, Universidade Federal do Rio Grande do Norte, Natal, 2014.

OLIVEIRA, C. D. et al. Detecção de fraudes, anomalias e erros em análise de dados contábeis: Um estudo com base em *outliers*. **Redeca**, São Paulo, v. 1, n. 1, p. 102-127, jan./jun. 2014.

ONS. Operador Nacional do Sistema Elétrico (ONS). **Relatório Anual de Avaliação das Previsões de Vazões – 2013**. Diretoria de Planejamento Programação da Operação. Rio de Janeiro: ONS, 2014.

PICCILLI, D. G. A. **Avaliação da precipitação hidroclimática no Alto Paraguai**. 2007. 342 f. Tese (Doutorado em Recurso Hídrico e Saneamento Ambiental) – Instituto de Pesquisa Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

PINTO, E. J. A.; NAGHETTINI, M.; ABREU, M. L., Metodologia para previsão sazonal de vazões na bacia do Alto Rio São Francisco, incorporando as estimativas das prováveis trajetórias temporais de precipitação associadas às condições de indicadores climáticos. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 11, n. 4, p. 137-151, out./dez. 2006a.

_____. Utilização de Indicadores Climáticos na Previsão Probabilística de Precipitações e Vazões na Bacia do Alto São Francisco. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 11, n. 4, p. 121-135, out./dez. 2006b.

PRANDO, V. C. **Resposta Oceânica às Forçantes Atmosféricas na Escala Intra-Sazonal – Abordagem Observacional com Ênfase no Hemisfério Sul**. 2010. 91 f. Dissertação (Mestrado em Ciências Atmosféricas) – Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2010.

PSCHEIDT, I.; GRIMM, A. M. Impactos da variabilidade interanual e interdecadal na frequência de eventos extremos de chuva sobre o Sul do Brasil. In: Congresso Brasileiro de Meteorologia, 14., 2006, Florianópolis, **Anais...** Rio de Janeiro: SBMET, 2006.

REBELLO, E. R. G. A Oscilação Decadal do Pacífico e sua possível influência no regime de precipitação do Rio Grande do Sul. In: Congresso Brasileiro de Meteorologia, 14., 2006, Florianópolis, **Anais...** Rio de Janeiro: SBMET, 2006.

REBOITA, M. S.; GAN, M. A.; AMBRIZZI, T.; Regimes de Precipitação na América do Sul: uma Revisão Bibliográfica. **Revista Brasileira de Meteorologia**, São Paulo, v. 25, n. 2, p. 185-204, jun. 2010.

RIBEIRO JÚNIOR, P. J.; DIGGLE, P. P. geoR: A Package for Geostatistical Analysis. **R - News**, v. 21, n. 2, p. 15-18, jun. 2001.

ROBERTSON, A. W.; MECHOSO, C. R. Interannual and decadal cycles in river flows of southeastern South America. **Journal of Climate**, Boston, v. 11, n. 10, p. 2570-2581, oct. 1998.

RODRIGES, O.; DIDONET, A. D.; LHAMBY, J. C. B.; BERTAGNOLL, LUZ, J. S. Resposta quantitativa do florescimento da soja à temperatura e ao fotoperíodo. **Pesquisa Agropecuária Brasileira**, Brasília, v. 36, n. 3, p. 431-437, mar. 2001.

RODRIGUES, R. R. et al. The impacts of Inter-El Niño variability on the Tropical Atlantic and Northeast Brazil Climate. **Journal of Climate**, Boston, v. 24, n. 13, p. 3402-3422, jul. 2011.

ROPELEWSKI, C. F.; HALPERT, M. S. Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation. **Monthly Weather Review**, Boston, v. 115, p. 1606-1626, agu. 1987.

SAHU, N. et al. La Niña impactos on austral summer extremely high-streamflow events of the Paranaíba River in Brazil. **Advances in Meteorology**, Cairo, v. 2013, n. 1, p. 1-6, oct. 2013.

_____. El Niño Modoki connection to extremely-low streamflow of the Paranaíba River in Brazil. **Climate Dynamics**, Berlin, v. 42, n. 5-6, p. 1509-1516, mar. 2014.

SANSIGOLO, C. A. Influência dos eventos El Niño e La Niña no regime de precipitação de Pelotas (RS). **Revista Brasileira de Meteorologia**, São Paulo, v. 15, n. 1, p. 69-75, jun. 2000.

SANTOS, E. P.; C. FILHO, I. M.; BRITO, J. I. B. Influência do Índice de Oscilação Sul (IOS) e Anomalia do Niños sobre as chuvas no Nordeste Brasileiro. In: Congresso Brasileiro de Meteorologia, 18., 2010, Belém, **Anais...** Rio de Janeiro: SBMET, 2010.

SALIO, P.; NICOLINI, M.; ZIPSER, E. J. Mesoscale Convective Systems over Southeastern South America and their relationship with the South American Low-Level Jet. **Monthly Weather Review**, Boston, v. 135, n. 4, p. 1290-1309, apr. 2007.

SATYAMURTY, P.; NOBRE, C. A.; SILVA DIAS, P. L. Tropics – South America. In: KAROLY, D. J.; VICENT. D. G. (Org.). **Meteorology of the Southern Hemisphere**, Boston, v. 27, n. 49, p. 119-139, 1998.

SELUCHI, M. E.; MARENGO, J. A. Tropical-midlatitude exchange of air masses during summer and winter in South America: climatic aspects and examples of intense events. **International Journal of Climatology**, Reading, v. 20, n. 10, p. 1167-1190, aug. 2000.

SEVERO, D. L. **Padrões de circulação anômala associada a episódios úmidos e secos no Sul do Brasil**. 2007. 225 f. Tese (Doutorado de Meteorologia) – Instituto Nacional de Pesquisas Espaciais, Ministério da Ciência e Tecnologia, São José dos Campos, 2008.

SILVA, D. F. Influência Interdecadal (ODP e OMA) nas Cotas do Rio São Francisco. **Revista Brasileira de Geografia Física**, Recife, v. 6, n.6, p. 1529-1538, jan. 2013.

SIQUEIRA, A. H. B.; MOLION, L. C. B. Análises Climáticas: O filtro Hodrick-Prescott aplicado aos índices atmosféricos da Oscilação Sul e da Oscilação do Atlântico Norte. **Revista Brasileira de Meteorologia**, São Paulo, v. 30, n. 3, p. 307-318, jul./set. 2015.

SOARES, F.S.; BESSA, M. R. Otimização da Operação de Reservatórios de superfície: Um estudo comparativo entre diferentes metodologias aplicadas ao sistema de Furnas, In: Seminário Nacional de Produção e Transmissão de Energia Elétrica, 16., 2001, Campinas. **Anais...** Rio de Janeiro: CIGRÉ, 2001.

SOUZA FILHO, F. A.; LALL, U. Modelo de Previsão de vazões sazonais e interanuais. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 9, n. 2, p. 61-74, abr./jun. 2004.

SOUZA P.; CAVALCANTI, I. F. A. Atmospheric centres of action associated with the Atlantic ITCZ position. **International Journal Climatology**, Hoboken, v. 29, n. 14, p. 2091-2105, nov. 2009.

SOUSA, A. J. S. et al. Oscilação Decadal do Pacífico e sua influência na precipitação de Goiânia – GO. In: Congresso Brasileiro de Meteorologia, 16., 2010, Belém. **Anais...** Rio de Janeiro: SBMET, 2010.

SOUZA, A.; FERNANDES, W. A.; ALBREZ, E. A.; GALVÍNCIO, J. D. Análise de Agrupamento da Precipitação e da Temperatura no Mato Grosso do Sul. **ACTA Geográfica**, Roraima, v. 6, n. 12, p. 109-124, mai./ago. 2012.

TEDESCHI, R. G.; CAVALCANTI, I. F. A.; GRIMM, A. M. Influences of two types of ENSO on South American precipitation. **International Journal of Climatology**, Reading, v. 33, n. 6 p. 1382-1400, may. 2013.

TEIXEIRA, R. F. B. A Oscilação do Atlântico Norte e a qualidade da quadra chuvosa do Ceará. In: Congresso Brasileiro de Meteorologia, 12., 2002. Foz do Iguaçu. **Anais...** Rio de Janeiro: SBMET, 2002.

TRENBERTH, K. E. The definition of El Niño. **Bulletin of American Meteorological Society**, Boston, v. 78, n. 12, p. 2771-2777, dec. 1997.

TRENBERTH, K. E.; STEPANIAK, D. P. Indices of El Niño Evolution. **Journal of Climate**, Boston, v. 14, n. 8, p. 1697-1701, apr. 2001.

TUCCI, C. E. M. et al. Long-term flow forecasts based on climate and hydrologic modeling: Uruguay River basin. **Water Resources Research**, New York, v. 39, n. 7, p. 1-11, jul. 2003.

TUCCI, C. E. M. **Modelos Hidrológicos**. 2. ed. Porto Alegre: UFRGS/ABRH, 2005, 680 p.

TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. 4. ed. Porto Alegre: UFRGS/ABRH, 2007. 943 p.

VAREJÃO-SILVA, M. A. **Meteorologia e Climatologia**, 2. Versão Digital. Recife: INTERNET, 2006. 449 p.

VASCONCELLOS, F. C.; CAVALCANTI, I. F. A. Extreme precipitation over Southeastern Brazil in the austral summer and relations with the Southern Hemisphere annular mode. **Atmospheric Science Letters**, Hoboken, v. 11, n. 1, p. 21-26, jan. 2010.

VIANA, D. R. **Comportamento espaço-temporal da precipitação na região sul do Brasil utilizando dados TRMM e SRTM**. 2009. 162 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, Ministério da Ciência e Tecnologia, São José dos Campos, 2009.

VIANA, D. R., et al. Mesoscale convective complexes in Rio Grande do Sul between October and December of 2003 and associated precipitation. **Revista Brasileira de Meteorologia**, São Paulo, v. 24, n. 3, p. 276-291, dez. 2009.

VIOLA, M. R. et al. Método de interpolação espacial para o mapeamento da precipitação pluvial. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 14, n. 9, p. 970-978, set. 2010.

VON SPERLING, M. **Estudo e modelagem da qualidade da água de rios**. 1. ed. Belo Horizonte: UMFG, 2007. 588 p.

WAINER, I.; VENEGAS, S. A. South Atlantic multidecadal variability in the climate system model. **Journal of Climate**, Boston, v. 15, n. 12, p. 1408-1420, jun. 2002.

WILKS, D.S. **Statistical Methods in the Atmospheric Sciences**. 2. ed. Filadélfia: Elsevier Academic Press Publications, 2006. 634 p.

XAVIER, T. de M. B. S.; XAVIER, A. F. S. Classificação e monitoração de períodos secos ou chuvosos e cálculo e índices pluviométricos para região Nordeste do Brasil. **Revista Brasileira de Engenharia/Caderno de Recursos Hídricos**, Porto Alegre, v. 5, n. 2, 1987.

APÊNDICE

Tabela A.1: Estações fluviométricas e seu respectivo código de referência.

Código	Estação	Latitude	Longitude	Código	Estação	Latitude	Longitude
1	Batalha	-17,34556	-47,48944	32	A. S. Oliveira	-21,62472	-47,00944
2	Serra do Facão	-18,06670	-47,66700	33	Marimbondo	-20,29330	-49,20110
3	Emborcação	-18,45139	-47,98694	34	Água Vermelha	-19,85833	-50,34306
4	Nova Ponte	-19,13667	-47,69222	35	Ilha Solteira	-20,38000	-51,37028
5	Miranda	-18,98361	-48,03194	36	Ponte Nova	-23,55000	-45,83333
6	Capim Branco 1	-18,79028	-48,14722	37	Billings	-23,78944	-46,54611
7	Capim Branco 2	-18,65972	-48,43528	38	Pedreira	-23,70306	-46,67444
8	Corumbá IV	-16,32278	-48,18750	39	Guarapiranga	-23,73111	-46,75417
9	Corumbá III	-16,78610	-47,94190	40	Traição	-23,59500	-46,69389
10	Corumbá I	-17,98333	-48,51667	41	Edgard de Souza	-23,45389	-46,91028
11	Itumbiara	-18,40417	-49,09944	42	Barra Bonita	-22,51944	-48,53417
12	C. Dourada	-18,50278	-49,49083	43	Bariri	-22,15389	-48,75444
13	São Simão	-19,02139	-50,49667	44	Ibitinga	-21,75806	-48,99139
14	Caçu	-18,52944	-51,15000	45	Promissão	-21,29694	-49,78361
15	Barra dos Coqueiros	-18,72333	-51,00306	46	N. Avandava	-21,11694	-50,20167
16	Foz do Rio Claro	-19,11583	-50,64361	47	Três Irmãos	-20,67056	-51,29917
17	Salto	-18,80083	-51,18222	48	Jupia	-20,77806	-51,62917
18	Salto Rio Verdinho	-19,14556	-50,76722	49	Porto Primavera	-22,47944	-52,95694
19	Espora	-18,67694	-51,86694	50	Jurumirim	-23,21667	-49,23333
20	Camargos	-21,32500	-44,61639	51	Piraju	-23,21056	-49,23056
21	Itutinga	-21,29194	-44,62528	52	Chavantes	-23,12694	-49,73111
22	Funil-Grande	-21,08333	-44,91667	53	Ourinhos	-23,06889	-49,83806
23	Furnas	-20,66972	-46,31750	54	L. N. Garcez	-22,90306	-49,99806
24	Mascarenhas de Moraes	-20,28639	-47,06333	55	Canoas II	-22,93861	-50,25111
25	L.C. Barreto	-20,15000	-47,28083	56	Canoas I	-22,94056	-50,51722
26	Jaguara	-20,02472	-47,43500	57	Mauá	-24,06333	-50,70139
27	Igarapava	-19,98333	-47,75000	58	Capivara	-22,65972	-51,35917
28	Volta Grande	-20,03472	-48,22278	59	Taquaruçu	-22,54167	-51,99972
29	Porto Colômbia	-20,12583	-48,57222	60	Rosana	-22,60194	-52,87222
30	Caconde	-21,57472	-46,62361	61	Itaipu	-25,40833	-54,58889
31	E. da Cunha	-21,60139	-46,95083				

TESTE F

O teste F é um teste para determinar se há uma relação linear entre a variável resposta Y e algumas das variáveis regressoras x_1, x_2, \dots, x_p contribui significativamente para o modelo. Para tanto, considera-se as hipóteses.

$$H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0$$

$$H_1: \beta_j \neq 0 \text{ para qualquer } j = 1, \dots, p$$

Se rejeitar H_0 , terá ao menos uma variável explicativa x_1, x_2, \dots, x_p que contribui significativamente para o modelo.

Sob H_0 , temos pelo Teorema – Distribuição de forma quadrática” que

$$\frac{SQR}{\sigma^2} \sim X^2_{(p)} \text{ e que } \frac{SQE}{\sigma^2} \sim X^2_{(n-p-1)} \quad (\text{A.1})$$

Além disso, tem que SQR e SQE são independentes. Logo, conclui-se sob H_0 , que

$$F_0 = \frac{\frac{SQR}{p}}{\frac{SQE}{n-p-1}} = \frac{QMR}{QME} \sim F_{(p;n-p-1)} \quad (\text{A.2})$$

Portanto, rejeita-se H_0 se $F_0 > F_{(1-\alpha;p;n-p-1)}$ e se p – valor = $P[F_{p;n-p-1} > F_0] < \alpha$, em que α é o nível de significância considerado. Geralmente adota-se $\alpha = 5\%$, mas para testes aplicados ao método stepwise, esse valor é muito rigoroso, portanto adotam-se valores de α entre 15% e 20%.

INTERPOLAÇÃO DE DADOS

Figura A.1: Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Esférico; e b) Gaussiano, com as precipitações médias acumuladas.

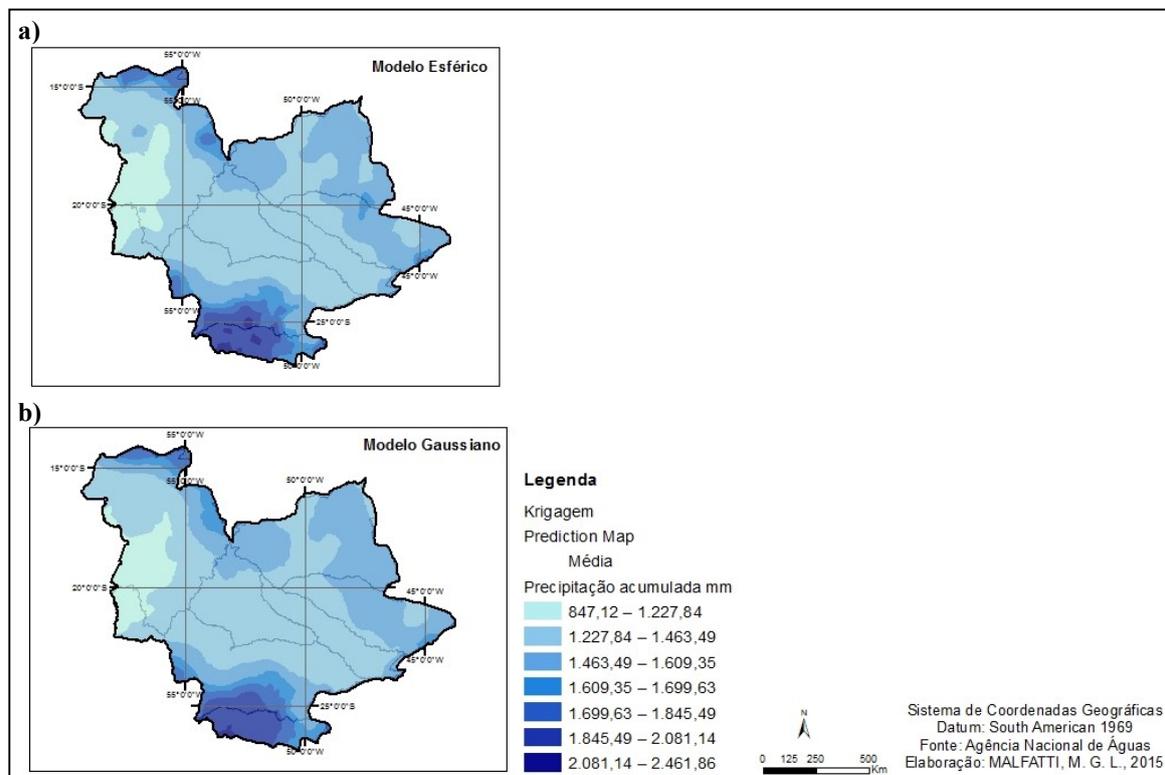


Figura A.2: Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Esférico; e b) Gaussiano, com os quantis 15 de precipitação acumulada.

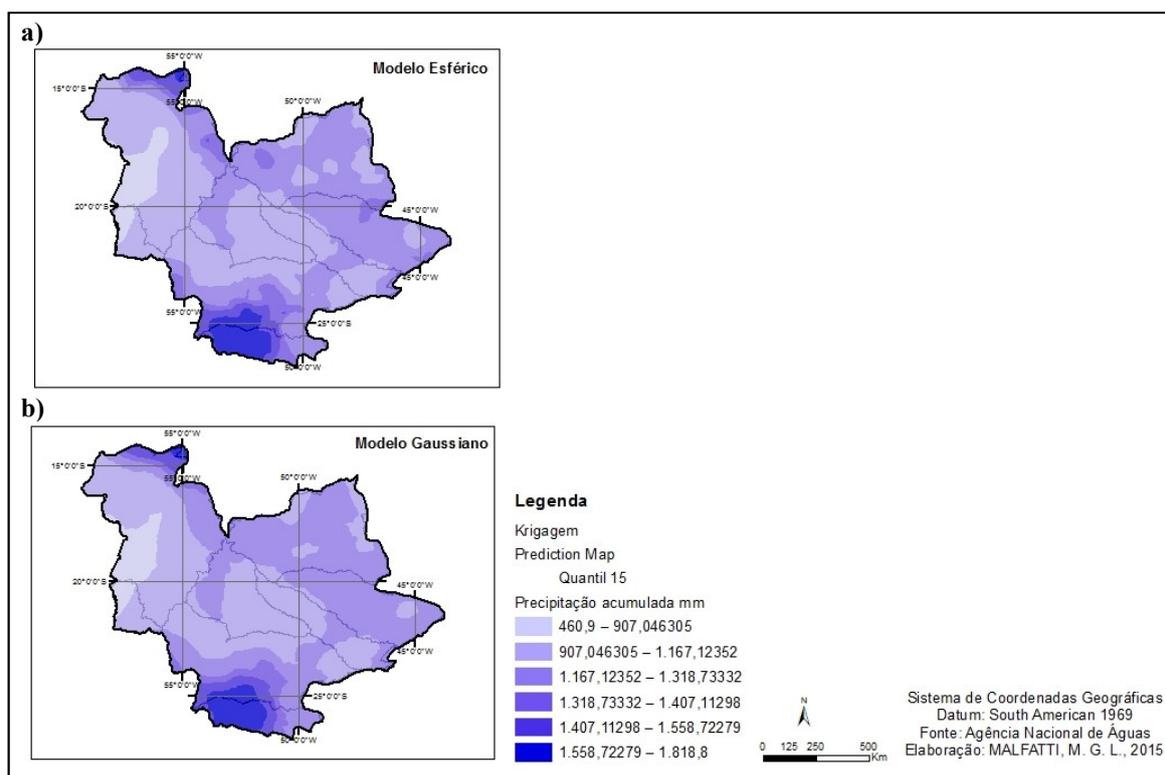


Figura A.3: Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Esférico; e b) Gaussiano, com os quantis 35 de precipitação acumulada.

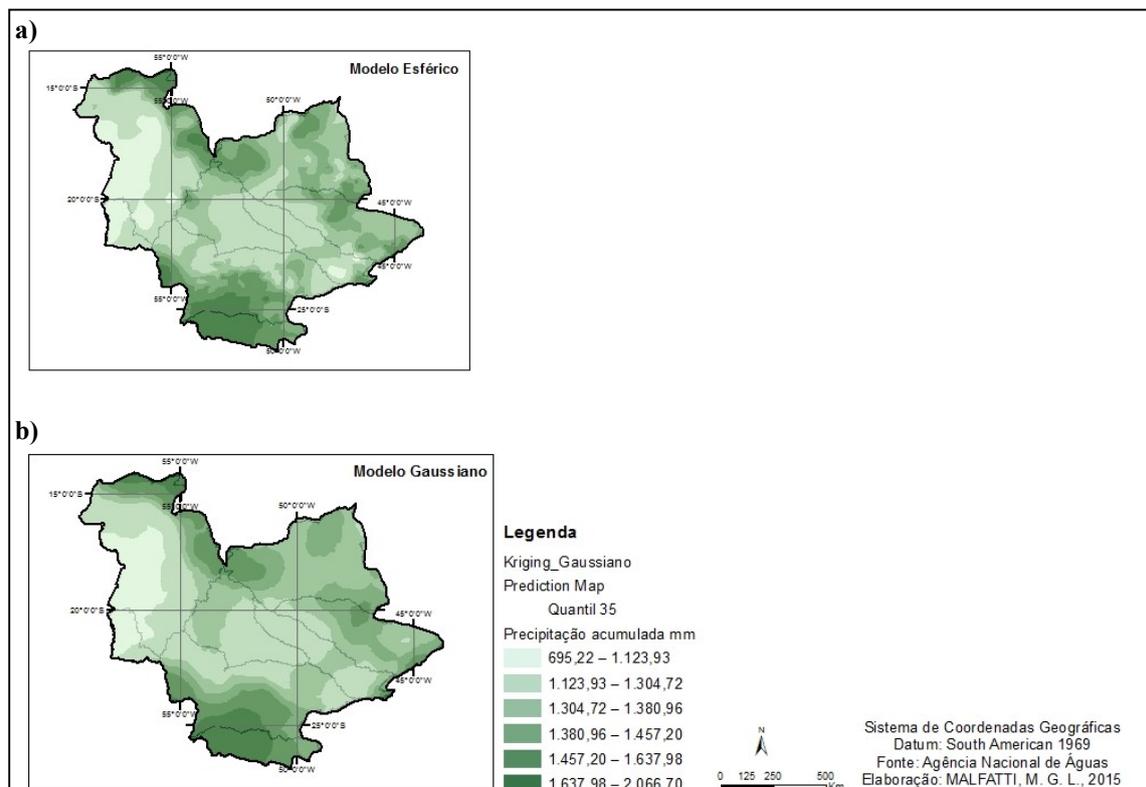


Figura A.4: Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Esférico; e b) Gaussiano, com os quantis 65 de precipitação acumulada.




Figura A.5: Interpolação de dados pelo método da Krigagem, para os Modelos de semivariograma a) Exponencial; b) Esférico; e c) Gaussiano, com os quantis 85 de precipitação acumulada.

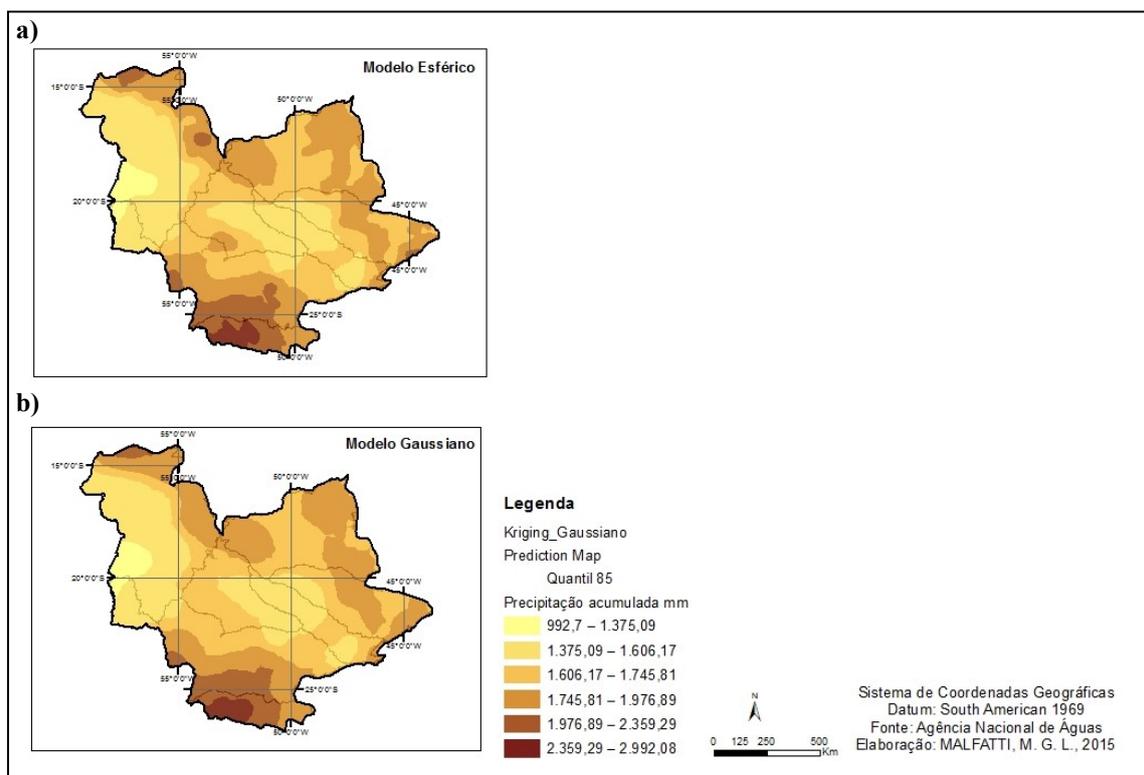


Figura A.6: EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os quantis 15 de precipitação acumulada.

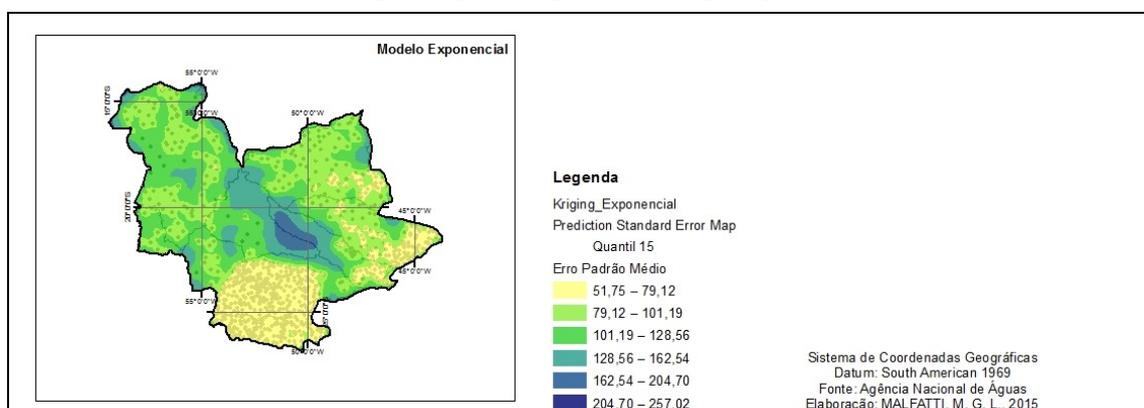


Figura A.7: EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os quantis 35 de precipitação acumulada.

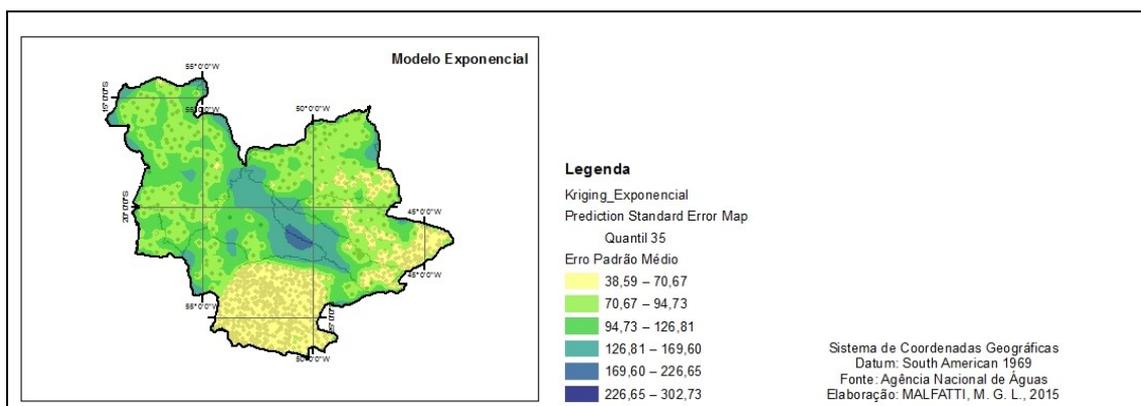


Figura A.8: EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os quantis 65 de precipitação acumulada.

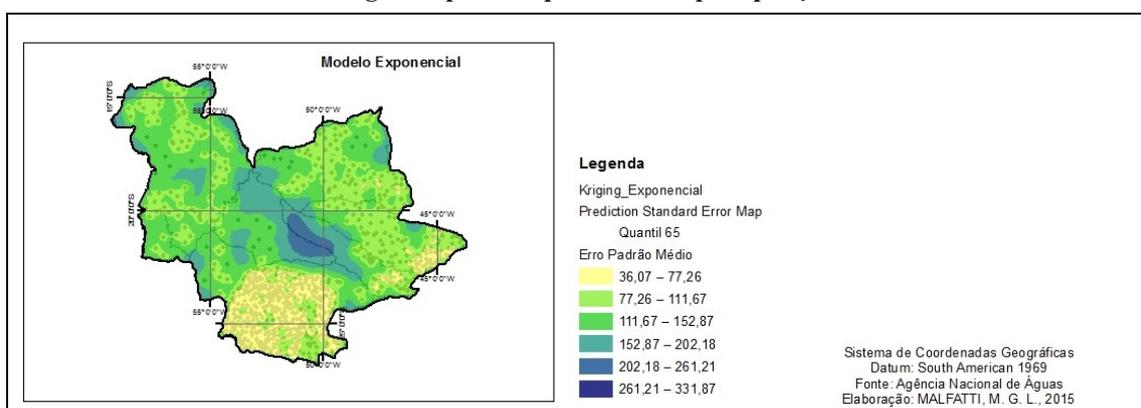


Figura A.9: EMP da interpolação de dados pelo método da Krigagem para o modelo exponencial de semivariograma para os quantis 85 de precipitação acumulada.

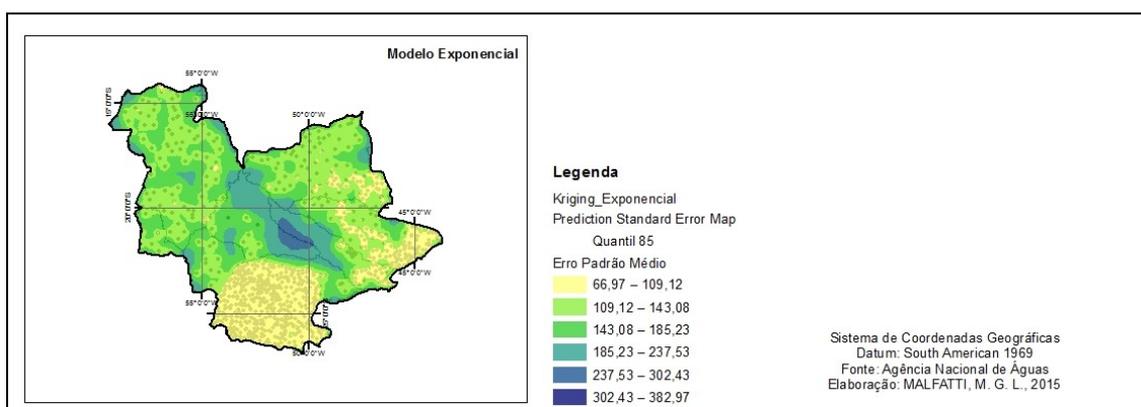


Figura A.10: Distribuição espacial dos coeficientes de correlações entre a vazão de Itaipu e vazões a montante e própria Itaipu defasada para um período de 4 meses de defasagem na Bacia do Paraná.

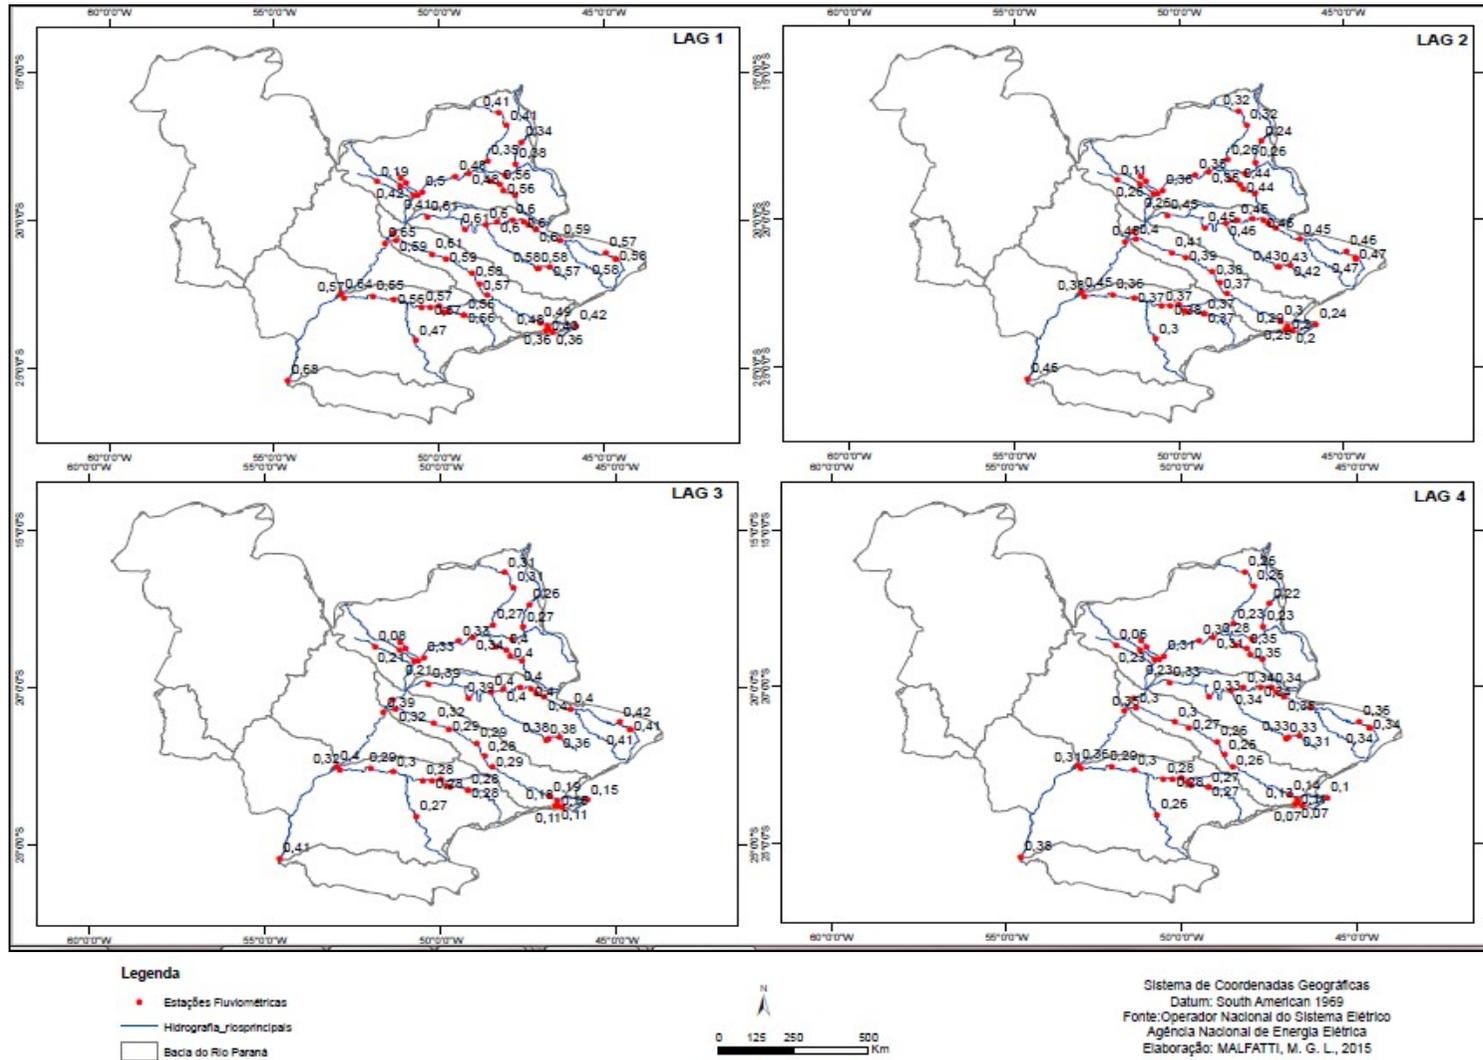
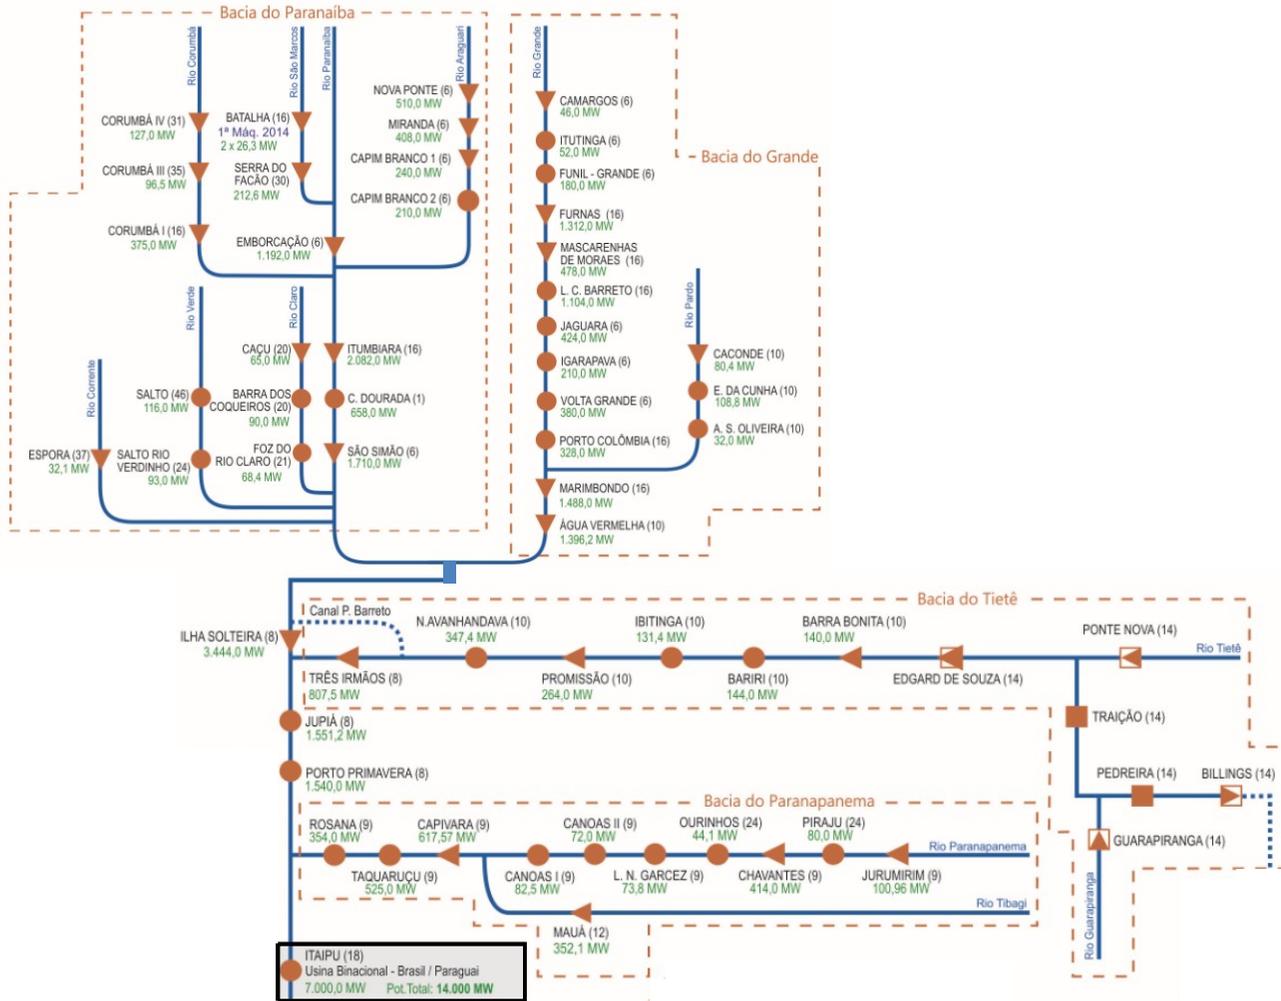


Tabela A.2: Coeficiente de Correlação (CC) entre a vazão de Itaipu observada e os modelos simulados (I, II, III e IV) para todo os meses do ano nas doze defasagens (lag1-12).

Coeficiente de Correlação (CC) - Observado x Modelado													
Lag	Modelo	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	I				0,52	-0,05	0,03	0,06					0,09
	II	0,70	0,65	0,27	0,72	0,48	0,55	0,71	0,72	0,63	0,64	0,74	0,20
	III	0,50	0,83	0,51	0,65	0,14	0,69	0,52	0,55	0,50	0,81	0,56	0,54
	IV	0,58	0,74	0,60	0,87	0,30	0,71	0,61	0,72	0,52	0,74	0,83	0,40
2	I				-0,03	0,03	0,13	0,14			0,18		
	II		0,57	0,23		0,38	0,89	0,1		0,79		0,55	0,43
	III		0,40		-0,08	0,66	0,23	0,34	0,09	0,52	0,41	0,81	0,64
	IV		0,49		-0,04	0,23	0,57	0,01		0,84	0,41	0,85	0,61
3	I				0,03	0,05	0,09	0,42	-0,02				
	II	0,77	0,09		-0,16				0,01		0,69		
	III			0,30		0,57	0,16	0,62	0,29	-0,37	0,42	0,82	
	IV				-0,06	0,32	0,18	0,75	0,01		0,69		
4	I		0,47		0,12	0,41	0,39	0,6			0,17	0,17	
	II			0,14								0,89	
	III			0,06	0,36		0,44	0,25	0,14	-0,48	0,09	0,83	0,30
	IV			0,16	0,25		0,39	0,45			0,19	0,47	
5	I			0,37	0,12	-0,33	0,48	-0,02	0,34		0,35	-0,10	0,26
	II			0,10	0,02		0,61				-0,09	0,72	
	III				0,56	0,17	-0,16	0,42	0,19		-0,32	0,31	0,35
	IV			0,31	0,20	-0,23	-0,13	0,39	0,36		0,34	0,02	0,38
6	I	-0,16			0,12	-0,33	-0,29	-0,02	-0,63	-0,02	0,05	-0,25	-0,12
	II				-0,10	0,17	-0,29	0,00		-0,53			0,35
	III						-0,06	-0,07	0,27	-0,41	0,09	0,3	-0,13
	IV				0,00	-0,23	0,07	-0,05	-0,06	-0,3	0,10	-0,16	-0,02
7	I	0,34			0,07	-0,03	0,34		-0,31		-0,21	-0,12	-0,01
	II				-0,41	-0,38	0,38	-0,32			-0,29		
	III						-0,08	-0,39		-0,17	-0,34	0,79	
	IV				-0,22	-0,03	0,41	-0,40			-0,32	0,09	
8	I				0,25	-0,13	0,19	-0,09		0,09	-0,48	-0,32	-0,11
	II						-0,26	-0,05					
	III							-0,25	-0,55		-0,22		
	IV						-0,03	-0,09			-0,50		
9	I			0,3	0,04	-0,06	0,13				-0,31		-0,36
	II			-0,43				0,01					
	III												
	IV			-0,04									
10	I				-0,08	0,11	-0,10		-0,29		-0,31	-0,19	-0,19
	II			0,23	-0,17						-0,37	0,06	
	III				0,11							-0,25	
	IV				-0,15						-0,39	-0,25	
11	I				-0,16	0,26					-0,24		
	II			-0,13	-0,18	-0,41					-0,14	-0,34	
	III										0,24	-0,59	-0,02
	IV				-0,25	0,13					-0,11	-0,52	
12	I			-0,09	0,36		0,14			0,39	-0,33	-0,38	
	II			-0,07		0,31	-0,28				0,42		-0,79
	III												0,62
	IV			-0,09			-0,06				-0,01		-0,57

ANEXO

Figura A.1: Diagrama Esquemático das Usinas Hidrelétricas do SIN na Bacia do Paraná.



Fonte: Operador Nacional do Sistema Elétrico (ONS).