

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Instituto de Pesquisas Hidráulicas

**Subsídios à operação de reservatórios baseada
na previsão de variáveis hidrológicas**

Juan Martín Bravo

Tese submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito parcial para a obtenção do título de Doutor em Recursos Hídricos e Saneamento Ambiental

Orientador: Prof. Dr. Walter Collischonn

Co-orientador: Prof. Dr. Carlos Eduardo Morelli Tucci

Banca Examinadora

Prof. Eduardo Sávio Martins

FUNCEME / UFC

Profa. Eloiza Cauduro Dias de Paiva

UFSM

Prof. Olavo Pedrollo

IPH/UFRGS

Porto Alegre, 5 de julho de 2010

O presente trabalho foi desenvolvido no Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul, sob a orientação do prof. Walter Collischonn e co-orientação do prof. Carlos Eduardo Morelli Tucci.

Nunca é tarde demais para sermos o que poderíamos ter sido

George Elliot

Agradecimentos

Finalizar uma tese de doutorado resulta muito gratificante e representa uma das maiores satisfações dessa etapa da minha vida. Eu não teria conseguido sem a ajuda de um grupo de pessoas às quais quero agradecer nesse pequeno espaço.

Em primeiro lugar, a minha família, que graças a seu apoio incondicional e sacrifício fizeram possível a minha vinda ao IPH e que me apoiaram incondicionalmente na realização desse trabalho.

A Rutinéia Tassi e Daniel Allasia, que pela convivência dos últimos seis anos passaram a ser mais dois novos irmãos. Eu não quero esquecer de seu filho, o Gabi, meu afilhado, que com apenas três anos traz alegria à vida de todos.

A Eder Nonnemacher, Livia Antunes e seu filho, o Ederzinho, pela amizade ao longo de todo esse tempo que eu estou no Brasil.

Ao Prof. Walter Collischonn e Carlos Tucci, por seu apoio, orientação e ajuda em todas as etapas desse trabalho. À profa. Cíntia Uvo, pelo apoio e a hospitalidade durante minha estadia na Suécia e por ter me introduzido no conhecimento dos fenômenos climáticos.

A um colega e amigo, Adriano Rolim da Paz, pelo grande número de pesquisas e publicações feitas em conjunto durante esse doutorado, que contribuiu no aumento de meu desempenho como pesquisador.

A um amigo, pesquisador, professor, Jorge Pilar, que me mostrou o caminho ao IPH e que sempre me ajudou com discussões e recomendações interessantes.

A Vivi e Walter, pelo apoio e o grande incentivo na etapa final desse trabalho.

Ao IPH pela educação proporcionada através de seus prestigiosos professores e pelo ambiente muito cordial de trabalho. A meus amigos e colegas: Bruno, Adalberto, Lidi, Grazi, Dante Diogo Rodrigo, Benedito, Ferdnando, Ruberto, Christopher, Francisco, Angélica e Néia.

A meus amigos de toda a vida, Marcelo Recalde, Marcelo Aquino, Germán Genovese, Fidel Juarez e Atilio Ramirez, por sempre me receber de braços abertos nas minhas voltas a casa, fazendo sentir-me como se nunca tivesse passado tanto tempo fora.

A Kirsten e Bose, pela sua hospitalidade ao compartilhar sua casa durante minha estadia em Lund. A Diego, Paulina e os Eriks, pela convivência no período em que fiquei na Suécia.

Ao CNPq, pela concessão de bolsa de Doutorado.

Finalmente, e sem diminuir sua importância, eu gostaria de agradecer aos integrantes do Dpto. de Hidráulica da Facultad de Ingeniería da UNNE, Carlos Depettris, Teresa Clemente, Alejandro Ruberto e Néstor Romero por seu apoio na realização desse trabalho.

Resumo

Diversas atividades humanas são fortemente dependentes do clima e da sua variabilidade, especialmente aquelas relacionadas ao uso da água. A operação integrada de reservatórios com múltiplos usos requer uma série de decisões que definem quanta água deve ser alocada, ao longo do tempo para cada um dos usos, e quais os volumes dos reservatórios a serem mantidos. O conhecimento antecipado das condições climáticas resulta de vital importância para os operadores de reservatórios, pois o insumo dos reservatórios é a vazão dos rios, que por sua vez é dependente de condições atmosféricas e hidrológicas em diferentes escalas de tempo e espaço.

A pesquisa trata sobre três importantes elementos de subsídio à tomada de decisão na operação de reservatórios baseada na previsão de variáveis hidrológicas: (a) as previsões de vazão de curto prazo; (b) as previsões de precipitação de longo prazo e (c) as medidas de desempenho das previsões. O reservatório de Furnas, localizado na bacia do Rio Grande, em Minas Gerais, foi selecionado como estudo de caso devido, principalmente, à disponibilidade de previsões quantitativas de chuva e pela importância desse reservatório na região analisada. A previsão de curto prazo de vazão com base na precipitação foi estimada com um modelo empírico (rede neural artificial) e a previsão de precipitação foi obtida pelo modelo regional ETA. Uma metodologia de treinamento e validação da rede neural artificial foi desenvolvida utilizando previsões perfeitas de chuva (considerando a chuva observada como previsão) e utilizando o maior número de dados disponíveis, favorecendo a representatividade dos resultados obtidos. A metodologia empírica alcançou os desempenhos obtidos com um modelo hidrológico conceitual, mostrando-se menos sensível aos erros na previsão quantitativa de precipitação nessa bacia. Os resultados obtidos mostraram que as previsões de vazão utilizando modelos empíricos e conceituais e incorporando previsões quantitativas de precipitação são melhores que a metodologia utilizada pelo ONS no local de estudo. A redução dos erros de previsão relativos à metodologia empregada pelo ONS foi em torno de 20% quando usadas previsões quantitativas de precipitação definidas pelo modelo regional ETA e superiores a 50% quando usadas previsões perfeitas de precipitação. Embora essas últimas previsões nunca possam ser obtidas na prática, os resultados sugerem o quanto o incremento do desempenho das previsões quantitativas de chuva melhoraria as previsões de vazão.

A previsão de precipitação de longo prazo para a bacia analisada foi também estimada com um modelo empírico de redes neurais artificiais e utilizando índices climáticos como variáveis de entrada. Nesse sentido, foram estimadas previsões de precipitação acumulada no período mais chuvoso (DJF) utilizando índices climáticos associados a fenômenos climáticos, como o El Niño - Oscilação Sul e a Oscilação Decadal do Pacífico, e a modos de variabilidade climática, como a Oscilação do Atlântico Norte e o Modo Anular do Hemisfério Sul. Apesar das redes neurais artificiais terem sido aplicadas em diversos problemas relacionados a hidrometeorologia, a aplicação dessas técnicas na previsão de precipitação de longo prazo é ainda rara. Os resultados obtidos nesse trabalho mostraram que consideráveis reduções dos erros da previsão relativos ao uso apenas da média climatológica como previsão podem ser obtidos com a metodologia utilizada. Foram obtidas reduções dos erros de, no mínimo 50%, e chegando até um valor próximo a 75% nos diferentes testes efetuados no estudo de caso.

Uma medida de desempenho da previsão foi desenvolvida baseada no uso de tabelas de contingência e levando em conta a utilidade da previsão. Essa medida de desempenho foi calculada com base nos resultados do uso das previsões por um modelo de operação de reservatório, e não apenas na comparação de vazões previstas e observadas. Nos testes realizados durante essa pesquisa, ficou evidente que não existe uma relação unívoca entre qualidade das previsões e utilidade das previsões. No entanto, em função de comportamentos particulares das previsões, tendências foram encontradas, como por exemplo nos modelos cuja previsão apresenta apenas defasagem. Nesses modelos, a utilidade das previsões tende a crescer na medida que a qualidade das mesmas aumenta. Por fim, uma das grandes virtudes da medida de desempenho desenvolvida nesse trabalho foi sua capacidade de distinguir o desempenho de modelos que apresentaram a mesma qualidade.

Palavras-chaves: previsão de vazão, previsão de precipitação, medidas de desempenho, redes neurais artificiais, algoritmos evolucionários, operação de reservatórios, tabelas de contingência.

Abstract

Several human activities are strongly dependent on climate and its variability, especially those related to water use. The operation of multi-purpose reservoirs systems defines how much water should be allocated and the reservoir storage volumes to be maintained, over time. Knowing in advance the weather conditions helps the decision making process, as the major inputs to reservoirs are the streamflows, which are dependent on atmospheric and hydrological conditions at different time-space scales.

This research deals with three important aspects towards the decision making process of multi-purpose reservoir operation based on forecast of hydrological variables: (a) short-term streamflow forecast, (b) long-range precipitation forecast and (c) performance measures. The Furnas reservoir on the Rio Grande basin was selected as the case study, primarily because of the availability of quantitative precipitation forecasts from the Brazilian Center for Weather Prediction and Climate Studies and due to its importance in the Brazilian hydropower generation system.

Short-term streamflow forecasts were estimated by an empirical model (artificial neural network – ANN) and incorporating forecast of rainfall. Quantitative precipitation forecasts (QPFs), defined by the ETA regional model, were used as inputs to the ANN models. A methodology for training and validating the ANN models was developed using perfect precipitation forecasts (i.e., using the observed precipitation as if it was a forecast) and considering the largest number of available samples, in order to increase the representativeness of the results. The empirical methodology achieved the performance obtained with a conceptual hydrological model and seemed to be less sensitive to precipitation forecast error relative to the conceptual hydrological model. Although limited to one reservoir, the results obtained show that streamflow forecasting using empirical and conceptual models and incorporating QPFs performs better than the methodology used by ONS. Reduction in the forecast errors relative to the ONS method was about 20% when using QPFs provided by ETA model, and greater than 50% when using the perfect precipitation forecast. Although the latter can never be achieved in practice, these results suggest that improving QPFs would lead to better forecasts of reservoir inflows.

Long-range precipitation forecast was also estimated by an empirical model based on artificial neural networks and using climate indices as input variables. The output variable is the

summer (DJF) precipitation over the Furnas watershed. It was estimated using climate indices related to climatic phenomena such as El Niño - Southern Oscillation and the Pacific Decadal Oscillation and modes of climate variability, such as the North Atlantic Oscillation and the Southern Annular Mode. Despite of ANN has been applied in several problems of hydro-meteorological areas, the application of such technique for long-range precipitation forecast is still rare. The results obtained demonstrate how the methodology for seasonal precipitation forecast based on ANN can be particularly helpful, with the use of available time series of climate indices. Reductions in the forecast errors achieved by using only the climatological mean as forecast were considerable, being at least of 50% and reaching values close to 75% in several tests.

A performance measure based on the use of contingency tables was developed taking into account the utility of the forecast. This performance measure was calculated based on the results of the use of the forecasts by a reservoir operation model, and not only by comparing streamflow observed and forecast. The performed tests show that there is no unequivocal relationship between quality and utility of the forecasts. However, when the forecast has a particular behavior, trends were found in the relationship between utility and quality of the forecast, such as models that generate streamflow forecast with lags in comparison to the observed values. In these models, the utility of the forecasts tends to enhance as the quality increases. Finally, the ability to distinguish the performance of forecast models having similar quality was one of the main merits of the performance measure developed in this research.

Keywords: streamflow forecast, precipitation forecast, performance measures, artificial neural networks, evolutionary algorithms, reservoir operation, contingency tables.

Sumário

1- Introdução	1
1.1- Justificativa e caracterização do problema	1
1.2- Objetivos.....	5
1.3- Organização do trabalho	6
2- Previsão de variáveis hidrológicas.....	8
2.1- Previsão de vazão de curto prazo	9
2.1.1- Modelos de previsão de vazão de curto prazo.....	11
2.1.2- Usos da previsão de vazão de curto prazo.....	13
2.2- Previsão de precipitação de longo prazo	14
2.2.1- Previsibilidade da precipitação em Sul América.....	15
2.2.1.1- <i>A monção de Sul América e sua influência no regime de precipitação</i>	15
2.2.1.2- <i>Principais modos de variabilidade climática influenciando a SMSA e a previsibilidade da precipitação</i>	17
2.2.2- Modelos de previsão de precipitação de longo prazo	24
2.2.2.1- <i>Métodos dinâmicos de previsão de precipitação de longo prazo</i>	25
2.2.2.2- <i>Métodos empíricos de previsão de precipitação de longo prazo</i>	27
2.2.3- Usos da previsão de precipitação de longo prazo	29
2.3- Redes neurais artificiais.....	30
2.3.1- Variáveis de entrada	32
2.3.2- Escolha da arquitetura	33
2.3.3- Divisão e pré-processamento dos dados.....	35
2.3.4- Treinamento	36
2.3.5- Verificação do desempenho	44
2.4- Resumo do capítulo	45
3- Operação de reservatórios com base na previsão de vazão	47
3.1- Regras de operação de reservatórios	47
3.2- Modelos de simulação da operação de reservatórios com base na previsão	51
3.3- O modelo AMANDA	54
3.4- Benefícios da previsão de vazão.....	55
3.5- Resumo do capítulo	59
4- Medidas de desempenho das previsões	61
4.1- Medidas de desempenho tradicionais	61
4.2- Medidas de desempenho e número de parâmetros do modelo	62
4.3- Medidas de desempenho baseadas em tabelas de contingência	65
4.4- Problema da relação custo/perda	68
4.5- Qualidade vs utilidade das previsões	70
4.6- Resumo do capítulo	72
5- Metodologia	74
5.1- Previsões de vazão de curto prazo	74
5.1.1- Previsões com modelos	74
5.1.2- Previsões hipotéticas	78
5.2- Previsões de longo prazo de chuva.....	81
5.3- Medida de desempenho com base na utilidade da previsão	83
5.4- Resumo da metodologia	89
6- Aplicação da metodologia.....	91
6.1- O estudo de caso 1	91

6.2- O estudo de caso 2	93
6.3- Dados dos estudos de caso.....	94
6.3.1- Dados utilizados nas previsões de vazão de curto prazo.....	94
6.3.2- Dados utilizados nas previsões de chuva de longo prazo.....	104
6.3.3- Dados disponíveis para operação de reservatórios.....	108
6.3.3.1- <i>Reservatório de Furnas</i>	109
6.3.3.2- <i>Reservatório de Três Marias</i>	111
6.4- Previsões de curto prazo de vazão de afluência ao reservatório de Furnas.....	115
6.4.1- Variáveis de entrada.....	115
6.4.2- Escolha do tipo de rede neural	118
6.4.3- Divisão e pré-processamento dos dados.....	118
6.4.4- Treinamento da rede neural.....	120
6.5- Previsões de longo prazo de chuva na bacia de Furnas.....	121
6.5.1- Variáveis de entrada e escolha da rede neural.....	121
6.5.2- Divisão e pré-processamento dos dados.....	124
6.5.3- Treinamento da rede neural e otimização com restrições	125
6.6- Medidas de desempenho das previsões	125
6.7- Resumo da aplicação da metodologia	130
7- Resultados e discussão	132
7.1- Previsões de vazão de curto prazo	132
7.1.1- Resultados com a metodologia proposta.....	132
7.1.2- Comparação de resultados com modelos conceituais	139
7.1.3- Eficiência e eficácia em comparação à RNA tradicional.....	145
7.2- Previsões de longo prazo de precipitação.....	150
7.2.1- Resultados com variáveis de entrada em função de correlação	151
7.2.2- Resultados com variáveis de entrada limitadas aos dois trimestres prévios	154
7.3- Medidas de desempenho das previsões	157
7.3.1- Benefícios vs Qualidade das previsões.....	157
7.3.2- Benefícios vs Utilidade das previsões.....	162
7.3.3- Utilidade das previsões vs Qualidade das previsões	165
8- Conclusões e Recomendações.....	169
8.1- Aspectos gerais	169
8.2- Previsão de vazão de curto prazo	169
8.3- Previsão de precipitação de longo prazo	171
8.4- Medida de desempenho com base na utilidade	173
8.5- Recomendações	174
Referências bibliográficas.....	176
Anexos	187
Anexo 1: Modelo AMANDA.....	188
A.1.1. Modelo de balanço hídrico do reservatório.....	188
A.1.2. Módulo de previsão da operação	191
A.1.3. Módulo de operação real.....	197
Anexo 2: Séries diárias de precipitação e vazão	198
Anexo 3: Séries por trimestres de precipitação e índices climáticos.....	202

Lista de figuras

Figura 2. 1. Classificação das previsões de curto prazo (Fonte: Tucci, 2005).....	10
Figura 2. 2. Classificação dos modelos conceituais: (a) Concentrado; (b) Concentrado por sub-bacias e (c) Distribuído. (Adaptado de Tucci, 2005).	12
Figura 2. 3. (a) Média de DJF do vetor de vento em 200 mb e (b) Média de DJF do vetor de vento em 850 mb, com base no reanalysis NCEP / NCAR (1950-2007) - a localização da bacia do rio Grande também é indicada. Imagem obtida de NOAA/ESRL Physical Sciences Division, Boulder Colorado a partir do seu Web site at http://www.esrl.noaa.gov/psd/	16
Figura 2. 4. Modelo conceitual do SALLJ ao leste dos Andes (Fonte: Marengo et al., 2004).16	
Figura 2. 5. Estrutura dinâmica da fase negativa da NAO. Fonte: http://puddle.mit.edu/~czaja/airsea.html	18
Figura 2. 6. Estrutura dinâmica da fase positiva da NAO. Fonte: http://puddle.mit.edu/~czaja/airsea.html	18
Figura 2. 7. Efeitos globais de El Niño durante o inverno (superior) e o verão (inferior) austral. Fonte: http://enos.cptec.inpe.br/	20
Figura 2. 8. Efeitos globais de La Niña durante o inverno (superior) e o verão (inferior) austral. Fonte: http://enos.cptec.inpe.br/	21
Figura 2. 9. (a) Correlação entre a série de altura equipotencial de 850 hPa obtida dos dados de reanálise do NCEP-NCAR e o índice do SAM para Dezembro e Janeiro; (b) idem (a) para Março e Abril; (c) valor médio anual da pressão no nível do mar no Hemisfério Sul (Allasia, 2007).	22
Figura 2. 10. Anomalias da temperatura na superfície do mar (cores), da pressão no nível mar (contornos) e da intensidade do vento na superfície, durante a fase (a) fria e (b) quente do PDO. Fonte: http://jisao.washington.edu/pdo/	23
Figura 2. 11. Série temporal da precipitação acumulada em DJF e valores médios dessa variável durante o período de PDO frio (1950-1977) e quente (1978-2000).	24
Figura 2. 12. Processos simulados por GCMs: Interações entre atmosfera, oceanos e continentes. (Adaptado de Kimura, 2002).	26
Figura 2. 13. Esquema de representação da resolução espacial de GCMs e dos modelos baseados na técnica de <i>downscaling</i>	27
Figura 2. 14. Esquema de rede neural artificial progressiva de múltiplas camadas.	32
Figura 2. 15. Alternativas na geração do novo indivíduo num sub-complexo.	42
Figura 2. 16. Arquitetura de uma rede neural artificial progressiva.	44
Figura 3. 1. Curvas-guia num reservatório com múltiplos usos.	47
Figura 3. 2. Representação esquemática do dilema do operador.	56
Figura 3. 3. Influência da frequência e do horizonte de previsão nos benefícios do uso de previsões de vazão. Fonte: Bravo et al., (2008b).	57
Figura 3. 4. Benefícios da previsão perfeita de longo prazo em função do quociente: volume do sistema e volume afluente médio anual (Adaptado de Bravo et al., 2007b).	58
Figura 4. 1. Quociente AIC / AIC_{p1} , para um erro padrão igual $100 \text{ m}^3 \cdot \text{s}^{-1}$, em função do número de parâmetros e para diferentes valores do número de dados (n).	64
Figura 4. 2. Quociente BIC / BIC_{p1} , para um erro padrão igual $100 \text{ m}^3 \cdot \text{s}^{-1}$, em função do número de parâmetros e para diferentes valores do número de dados (n).	64

Figura 4. 3. Quociente EPM / EP, para um erro padrão igual $100 \text{ m}^3 \cdot \text{s}^{-1}$, em função do número de parâmetros e para diferentes valores do número de dados (n).	65
Figura 4. 4. Tabela de contingência de um evento dicotômico em termos de: (i) frequência absoluta e (ii) frequência relativa.	66
Figura 4. 5. (a) Função de perda para a relação custo/perda; (b) Tabela correspondente obtida a partir de previsões probabilísticas caracterizadas pela distribuição de probabilidade conjunta $p(f_i, o_j)$ transformada em previsões categóricas através da relação custo/perda. 70	70
Figura 4. 6. Previsões hipotéticas de vazão (Adaptado de IPH,2005).	71
Figura 5. 1. Estrutura metodológica para a geração de previsões de vazão de curto prazo com modelos.	75
Figura 5. 2. Cálculo da variável precipitação média na bacia diária acumulada ($P_{ma12}(t)$) em função do intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão (o primeiro dia da previsão é $t+1$).	76
Figura 5. 3. Arquitetura de uma rede neural artificial progressiva de três camadas.	77
Figura 5. 4. Procedimento de experimentação sistemática para estimativa da arquitetura de uma rede neural artificial progressiva de três camadas.	77
Figura 5. 5. Estrutura metodológica para a geração de previsões de precipitação de longo prazo.	82
Figura 5. 6. Exemplo de curva-guia para controle de cheias com volume de espera variável durante o ano.	84
Figura 5. 7. Exemplo de flexibilizações de curva-guia para controle de cheias com base na previsão de vazão, (A) com previsão perfeita para um evento menor (na cor verde) ou maior (na cor vermelha) que o de projeto (na cor preta); (B) com previsão com modelos durante um evento menor ao de projeto.	86
Figura 5. 8. Estrutura metodológica para definição da medida de desempenho com base na utilidade das previsões.	86
Figura 5. 9. Resultados da operação de um reservatório: (a) sem o uso de previsões de vazão de curto prazo; (b) utilizando previsões perfeitas de vazão e (c) utilizando previsões de vazão obtidas com modelos.	87
Figura 5. 10. Tabela de contingência para a definição da medida de desempenho com base na utilidade.	89
Figura 6. 1. Localização da área de estudo.	92
Figura 6. 2. Localização dos principais aproveitamentos hidroelétricos na bacia do Rio Grande classificados pela potência de geração de energia (Fonte: IPH, 2005).	92
Figura 6. 3. Esquema da configuração espacial do sistema analisado.	93
Figura 6. 4. Localização da bacia do rio Grande, com destaque na bacia de contribuição ao reservatório de Furnas, e postos pluviométricos com dados disponibilizados.	94
Figura 6. 5. Exutórios das sub-bacias.	95
Figura 6. 6. Precipitação mensal média nas sub-bacias e na bacia de contribuição ao reservatório de Furnas.	96
Figura 6. 7. Precipitações totais anuais adimensionalizadas com relação a sua média, nas sub-bacias e na bacia de contribuição ao reservatório de Furnas.	96
Figura 6. 8. Características da precipitação média mensal nas sub-bacias e na bacia de contribuição ao reservatório de Furnas.	97
Figura 6. 9. Características da vazão média mensal adimensionalizadas com relação à média de longo período, nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas.	98

Figura 6. 10. Vazões médias anuais adimensionalizadas com relação à média de longo período, nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas.	98
Figura 6. 11. Características da vazão média mensal nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas.....	99
Figura 6. 12. Malha do modelo ETA-40km sobre a região da bacia do Rio Grande. Fonte: IPH (2005).	100
Figura 6. 13. Chuva diária acumulada para o horizonte de 7 dias, observada e prevista pelo modelo ETA, no período de jan/96 a out/99 – valores médios sobre a sub-bacia de Camargos. Fonte: IPH (2005).	101
Figura 6. 14. Chuva diária acumulada para o horizonte de 7 dias, observada e prevista pelo modelo ETA, no período de jan/96 a out/99 – valores médios sobre a sub-bacia Incremental de Furnas. Fonte:IPH(2005).....	101
Figura 6. 15. Avaliação da qualidade da previsão de precipitação do modelo ETA-40km na região analisada: coeficiente de correlação em função do período de acumulação da precipitação.	102
Figura 6. 16. Precipitação observada vs. precipitação prevista pelo modelo ETA na sub-bacia incremental de Furnas, considerando diferentes períodos de acumulação (1 a 6 dias)..	103
Figura 6. 17. Precipitação observada vs. precipitação prevista pelo modelo ETA na sub-bacia incremental de Furnas, considerando diferentes períodos de acumulação (7 a 10 dias).	104
Figura 6. 18. Séries padronizadas: (a) Precipitação acumulada por trimestre; (b) NAOI médio trimestral; (c) SAMI médio trimestral.....	106
Figura 6. 19. Séries padronizadas: (a) El Niño 3.4 médio trimestral e (b) PDOI médio trimestral.....	107
Figura 6. 20. Precipitação mensal na bacia de contribuição ao reservatório de Furnas em cada ano da série histórica e valores médios, mínimos e máximos.....	107
Figura 6. 21. Precipitação acumulada no trimestre DJF na bacia de contribuição ao reservatório de Furnas.	108
Figura 6. 22. Regras de operação (curva-guia para controle de cheias) adotadas no reservatório de Furnas.	111
Figura 6. 23. Curva de descarga do vertedor considerando apenas uma comporta com diferentes aberturas (a envoltória superior representa a condição da comporta completamente aberta).	112
Figura 6. 24. Regras de operação (curva-guia para controle de cheias) adotadas no reservatório de Três Marias.....	114
Figura 6. 25. Coeficiente de correlação (de Pearson) entre diferentes variáveis (precipitação média diária nas sub-bacias e na bacia de montante de Furnas) e a vazão afluente ao reservatório de Furnas com defasagens de um a doze dias.	116
Figura 6. 26. Coeficiente de correlação (de Pearson) entre diferentes variáveis (precipitação média diária, na bacia, acumulada em diferentes períodos de tempo) e a vazão afluente ao reservatório de Furnas com defasagem de um dia.....	116
Figura 6. 27. Coeficiente de correlação (de Pearson) entre diferentes variáveis de entrada (vazão nos exutórios das sub-bacias de montante e valor médio diário QM4(t)) e a vazão afluente ao reservatório de Furnas com defasagens de um a doze dias.	117
Figura 6. 28. Arquitetura da RNPMC para previsão de vazão de afluência ao reservatório de Furnas nos primeiros sete dias do horizonte de previsão.	121
Figura 6. 29. Arquitetura da RNPMC para previsão de precipitação na bacia de contribuição ao reservatório de Furnas.	122
Figura 6. 30. Coeficiente de correlação r (de Pearson) entre diferentes variáveis (índices climáticos) e a precipitação DJF a montante de Furnas com defasagens de um a oito	

trimestres (as linhas tracejadas indicam o r_{crit} usando o teste t ($H_0: r=0$), para um nível de significância de 0,05).	123
Figura 6. 31. Divisão dos dados em conjuntos de treinamento, validação e verificação.	124
Figura 6. 32. Tabela de contingência de frequências de ocorrência de vertimentos menores, iguais ou maiores aos definidos utilizando previsões perfeitas de vazão, modelo número 19 (modelo que atrasa em nove dias as previsões de vazão). Estudo de caso: reservatório de Furnas.	128
Figura 6. 33. Tabela de contingência de frequências de ocorrência de vertimentos menores, iguais ou maiores aos definidos utilizando previsões perfeitas de vazão, modelo número 221 (previsões por persistência). Estudo de caso: reservatório de Furnas.	129
Figura 6. 34. Tabela de contingência de frequências de ocorrência de vertimentos menores, iguais ou maiores aos definidos utilizando previsões perfeitas de vazão, modelo número 100 (modelo com erros segundo uma distribuição normal). Estudo de caso: reservatório de Furnas.	129
Figura 6. 35. Tabela de contingência de frequências de ocorrência de vertimentos menores, iguais ou maiores aos definidos utilizando previsões perfeitas de vazão, modelo número 1 (modelo que antecipa em dez dias as previsões de vazão). Estudo de caso: reservatório de Furnas.	129
Figura 7. 1. Valores das medidas de desempenho para os diferentes dias do horizonte de previsão (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)): a) Coeficiente de Nash-Sutcliffe (CE); b) Erro médio absoluto (EMA); c) Erro médio relativo (EMR); d) Erro padrão de previsão (EP).	133
Figura 7. 2. Previsões contínuas de vazão afluente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996. Data da previsão: 29/10/1996.	134
Figura 7. 3. Previsões contínuas de vazão afluente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996. Data da previsão: 5/11/1996.	135
Figura 7. 4. Previsões contínuas de vazão afluente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996. Data da previsão: 12/11/1996.	135
Figura 7. 5. Previsões contínuas de vazão afluente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996. Data da previsão: 19/11/1996.	136
Figura 7. 6. Vazão de afluência ao reservatório de Furnas observada vs. Vazão prevista com chuvas do modelo ETA, com antecedências de 1 a 6 dias.	137
Figura 7. 7. Vazão de afluência ao reservatório de Furnas observada vs. Vazão prevista com chuvas do modelo ETA, com antecedências de 7 a 12 dias.	138
Figura 7. 8. Valores das medidas de desempenho para os diferentes dias do horizonte de previsão: a) Coeficiente de Nash-Sutcliffe (CE); b) Erro médio absoluto (EMA); c) Erro médio relativo (EMR); d) Erro padrão de previsão (EP).	140
Figura 7. 9. Previsões contínuas de vazão afluente ao reservatório de Furnas utilizando os modelos baseados em RNAs com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 11/12/1996 a 26/01/1997.	141

Figura 7. 10. Previsões contínuas de vazão afluente ao reservatório de Furnas utilizando o modelo conceitual MGB-IPH com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 11/12/1996 a 26/01/1997.....	142
Figura 7. 11. Comparação entre Vazões de afluência ao reservatório de Furnas observadas vs. Vazão prevista com chuvas do modelo ETA utilizando o modelo empírico (RNA) e o modelo conceitual (MGB), com antecedências de 1 a 6 dias.....	143
Figura 7. 12. Comparação entre Vazões de afluência ao reservatório de Furnas observadas vs. Vazão prevista com chuvas do modelo ETA utilizando o modelo empírico (RNA) e o modelo conceitual (MGB), com antecedências de 7 a 12 dias.....	144
Figura 7. 13. Coeficiente de Nash-Sutcliffe para os diferentes dias do horizonte de previsão.	146
Figura 7. 14. Erro médio relativo (%) para os diferentes dias do horizonte de previsão.	147
Figura 7. 15. Curvas de permanência do erro da previsão nos seis primeiros dias do horizonte de previsão.....	148
Figura 7. 16. Curvas de permanência do erro da previsão nos últimos seis dias do horizonte de previsão.	149
Figura 7. 17. Estimativa de eficiência do método desenvolvido nesse trabalho (RNA) e do método tradicional (RNA_old) em 20 processos de treinamento.	150
Figura 7. 18. Precipitação DJF observada e calculada no conjunto de verificação (a linha tracejada representa o valor da precipitação DJF média de longo período).....	151
Figura 7. 19. Precipitação DJF observada e calculada no conjunto de validação (a linha tracejada representa o valor da precipitação DJF média de longo período).....	152
Figura 7. 20. Precipitação DJF observada e calculada no conjunto de treinamento (a linha tracejada representa o valor da precipitação DJF média de longo período).....	152
Figura 7. 21. Precipitação DJF observada vs precipitação DJF calculada, nos conjuntos de treinamento, validação e verificação (a linha tracejada corresponde a previsão perfeita).	153
Figura 7. 22. Precipitação DJF observada e calculada no conjunto de verificação (a linha tracejada representa o valor da precipitação DJF média de longo período).....	155
Figura 7. 23. Precipitação DJF observada e calculada no conjunto de validação (a linha tracejada representa o valor da precipitação DJF média de longo período).....	155
Figura 7. 24. Precipitação DJF observada e calculada no conjunto de treinamento (a linha tracejada representa o valor da precipitação DJF média de longo período).....	156
Figura 7. 25. Precipitação DJF observada vs precipitação DJF calculada, nos conjuntos de treinamento, validação e verificação (a linha tracejada corresponde a previsão perfeita).	156
Figura 7. 26. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).	158
Figura 7. 27. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).	159
Figura 7. 28. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do terceiro conjunto de parâmetros).....	159
Figura 7. 29. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do quarto conjunto de parâmetros).....	160

Figura 7. 30. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).....	160
Figura 7. 31. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).....	161
Figura 7. 32. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).....	162
Figura 7. 33. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).....	163
Figura 7. 34. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do terceiro conjunto de parâmetros).....	163
Figura 7. 35. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do quarto conjunto de parâmetros).....	164
Figura 7. 36. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).....	164
Figura 7. 37. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).....	165
Figura 7. 38. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).....	166
Figura 7. 39. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).....	166
Figura 7. 40. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do terceiro conjunto de parâmetros).....	167
Figura 7. 41. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do quarto conjunto de parâmetros).....	167
Figura 7. 42. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).....	168
Figura 7. 43. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).....	168

Lista de tabelas

Tabela 3. 1. Classificação da situação da operação nos reservatórios do SIN.....	51
Tabela 6. 1. Relação Cota-Área-Volume do reservatório de Furnas.	109
Tabela 6. 2. Evaporação líquida média mensal do reservatório Furnas (ONS, 2004).	111
Tabela 6. 3. Relação Cota-Área-Volume do reservatório de Três Marias.	112
Tabela 6. 4. Relação entre nível da água no reservatório e vazão turbinada no reservatório de Três Marias, adotada neste trabalho.	113
Tabela 6. 5. Evaporação líquida média mensal do reservatório Três Marias (Brandão, 2004).	114
Tabela 6. 6. Estatísticas das cinco variáveis de entrada nos conjuntos de treinamento e de validação.....	119
Tabela 7. 1. Medidas de desempenho das previsões obtidas com a metodologia proposta, o modelo conceitual MGB-IPH e com os modelos atualmente utilizados pelo ONS.....	145

Lista de símbolos

α'	Parâmetro do algoritmo SCE-UA: número de vezes em que os passos de evolução de cada sub-complexo são realizados
AGCM	Modelos de circulação geral da atmosfera
AIC	Akaike's information criterion
AMANDA	Modelo de simulação da operação de um reservatório com base na previsão de vazão afluente
ANA	Agência Nacional de Águas
ANEEL	Agência Nacional de Energia Elétrica
AOGCM	Modelos acoplados de circulação geral
AR	Auto-Regressive
ARIMA	Auto-Regressive Integrated Moving Average
ARMA	Auto-Regressive Moving Average
b	Tendência ou bias do valor de saída de um neurônio matemático
β	Parâmetro do algoritmo SCE-UA: número de vezes em que os passos de evolução de cada complexo são realizados
BIC	Bayesian information criterion
CCE	Curva de capacidade de produção de energia firme
CE	Coefficiente de eficiência ou de Nash-Sutcliffe
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
Δt	Intervalo de tempo
D	Vetor que indica a direção de busca no treinamento
DJF	Trimestre Dezembro, Janeiro e Fevereiro
E_i	Valores de entrada a um neurônio matemático
E_t	Evaporação líquida diária no tempo t
El Niño x	Índice climático do ENSO
EMA	Erro médio absoluto
EMR	Erro médio relativo
ENSO	El Niño – Oscilação Sul
EP	Erro padrão de previsão

ETA	Modelo atmosférico regional
F	Função de ativação em um neurônio matemático
FO	Função-objetivo
freq	Frequência da previsão de vazão
γ	Tamanho do passo de uma iteração para a subsequente
g	Centróide dos q-1 melhores pontos de um sub-complexo no algoritmo SCE-UA
GCM	Modelos de circulação geral
GMSS	Gandin-Murphy skill score
H_t	Nível da água do reservatório
H_{max}	Valor da restrição que limita o nível da água no reservatório para evitar inundações na cidade de montante
H_{seg}	Parâmetro do modelo AMANDA que reflete o grau de confiança nas previsões de vazão afluente ao reservatório
Horiz	Horizonte da previsão de vazão
IOS	Índice de Oscilação Sul
JJA	Trimestre Junho, Julho e Agosto
Linear (.)	Função de ativação linear
Logsig (.)	Função de ativação log-simóide unipolar
m	Parâmetro do algoritmo SCE-UA: número de indivíduos em cada complexo
MAM	Trimestre Março, Abril e Maio
N	Número de intervalos de tempo da simulação, Número de valores no conjunto de verificação
NAO	Oscilação do Atlântico Norte
NAOI	Índice climático da Oscilação do Atlântico Norte
OCW	<i>Overall connection weight approach</i>
OCW_{X_1}	Overall connection weight da variável de entrada X_1
ONS	Operador Nacional do Sistema
p	Parâmetro do algoritmo SCE-UA: número de complexos
P_t	Valor que combina evaporação e outras perdas na equação de balanço do reservatório no intervalo t e t+1
par	Número de parâmetros do modelo de previsão

PAR	Periodic Auto-Regressive
PDO	Oscilação decadal do Pacífico
PDOI	Índice climático da Oscilação decadal do Pacífico
Pen	Termo correspondente a penalidades na função-objetivo pelo não atendimento de restrições
Pma12(t)	Precipitação acumulada de 12 dias
q	Parâmetro do algoritmo SCE-UA: número de indivíduos que integram um sub-complexo
QA	Vazão afluente ao reservatório
QE	Vazão efluente do reservatório
QF(t)	Vazão em Furnas no dia t
Q _{lim}	Valor da vazão efluente limite, definido pela restrição na vazão efluente máxima do reservatório para evitar inundações a jusante
QM4(t)	Valor médio diário das quatro vazões de montante a Furnas
Q _o	Valor observado de uma variável
$\overline{Q_o}$	Valor médio dos valores observados de uma variável
Q _p	Valor previsto de uma variável
Q ⁱ _{pEn}	Valor da previsão com erro segundo uma distribuição normal com média μ e desvio padrão σ
Q ⁱ _{pEu}	Valor da previsão com erro segundo uma distribuição uniforme entre $\mu-Lim$ e $\mu+Lim$, no intervalo de tempo i, sendo μ o ponto central do intervalo de variação do erro e Lim os extremos
Q ^{i+j} _{pP}	Valor da previsão de persistência no intervalo de tempo i+j
QR	Valor dos incrementos e decrementos limites na vazão efluente de um intervalo de tempo para o seguinte
QT	Vazão turbinada
QV	Vazão vertida
QV _R	Valor mínimo dos vertimentos em função das restrições nos decrementos da vazão efluente
Rn	Espaço vetorial de n dimensões
REMQ	Razão entre o Erro médio quadrático obtido com modelo e o Erro médio quadrático ao utilizar o valor médio de longo período como previsão

RNA	Rede neural artificial
RNPMC	Rede neural progressiva de múltiplas camadas
ROCW _{X₁}	Valor relativo do Overall connection weight da variável de entrada X ₁
s	Tamanho da população de indivíduos no algoritmo SCE-UA
S	Resposta de um neurônio matemático
SALLJ	<i>South American Low-level jet</i>
SAM	Modo Anular Sul
SAMI	Índice climático do Modo Anular Sul
SCE-UA	Algoritmo de otimização (Shuffled complex evolution algorithm – University of Arizona)
SCGM	Scaled Conjugate Gradient Method
SIN	Sistema Interligado Nacional
SMSA	Sistema da monção de Sul América
PNM	Pressão no nível do mar
SON	Trimestre Setembro, Outubro e Novembro
σ	Desvio padrão de uma série
TA	Taxa de acertos (<i>Hit rate</i>)
TAF	Taxa de alarme falsos (<i>False alarm rate</i>)
Tansig(.)	Função de ativação tangente hiperbólica sigmóide
TSM	Temperatura da superfície do mar
μ	Valor médio de uma série
V	Volume do reservatório
w _i	Pesos sinápticos num modelo de rede neural artificial
X _i	Variáveis de entrada em modelos empíricos
x _{max}	Valor mínimo da variável original
x _{min}	Valor máximo da variável original
x _{novo}	Valor da variável padronizada
x _{orig}	Valor da variável original
Y _j	Variáveis previstas por modelos empíricos
ZCAS	Zona de convergência do Atlântico Sul
ZCIT	Zona de convergência Inter-Tropical

1- Introdução

1.1- Justificativa e caracterização do problema

A construção e operação de reservatórios apresentam, como princípio fundamental, o desenvolvimento de reservas nos períodos de excesso hídrico para seu posterior uso nos períodos de escassez. Múltiplos usos da água podem ser atendidos com a construção e a operação de reservatórios, como o abastecimento de populações, geração de energia, irrigação, controle de cheias e navegação.

Muitos fatores contribuem para fazer a operação de reservatórios com múltiplos usos uma tarefa difícil. Alguns desses fatores são: as características estocásticas do processo hidrológico; a quantificação e definição dos objetivos e a necessidade de um processo seqüencial de decisões, onde a decisão tomada em um estágio afeta as decisões a serem tomadas nos estágios posteriores. De acordo com o *World Commission on Dams* (WCD, 2000), muitos projetos de reservatórios falham em produzir os benefícios que justificaram sua viabilidade. Sendo a água um dos mais importantes recursos naturais, os tomadores de decisão são pressionados a operar seus sistemas de forma cada vez mais eficiente (Bessler et al., 2003).

A operação integrada de reservatórios, com múltiplos usos, requer uma série de decisões que definem quanta água deve ser alocada, ao longo do tempo, para cada um dos usos, e quais os volumes dos reservatórios a serem mantidos, visando o atendimento ideal de usos pré-definidos. O caráter de múltiplo uso da água pode gerar grandes conflitos entre os vários usuários.

No Brasil, o uso preponderante da água dos reservatórios de grande porte é a geração de energia. O Brasil possui um dos maiores sistemas de usinas hidrelétricas do mundo, com uma capacidade instalada de 75.728MW, representando 71% da capacidade instalada no país

(BIG-ANEEL, 2010). As principais características do sistema hidrelétrico brasileiro são: a grande extensão em área das bacias hidrográficas contribuintes, o regime de vazões plurianual, a grande quantidade de usinas hidrelétricas e a grande participação das usinas hidrelétricas na geração elétrica do país (Cicogna, 2002).

O Brasil conta com um sistema principal de geração e transmissão de energia elétrica denominado Sistema Interligado Nacional (SIN). O SIN abrange as regiões Sul, Sudeste, Centro-Oeste, Nordeste e parte do Norte. Além disso, abriga 96,6% de toda a capacidade de produção de energia elétrica do país (oriunda de fontes internas ou de importações, principalmente do Paraguai por conta do controle compartilhado da usina hidrelétrica de Itaipu) (ANEEL, 2008).

O Operador Nacional do Sistema Elétrico (ONS) é responsável pela coordenação e controle da operação do SIN, realizada pelas companhias geradoras e transmissoras, sob a fiscalização e regulação da ANEEL (Agência Nacional de Energia Elétrica). A possibilidade de troca de energia elétrica entre as regiões é um dos principais benefícios da integração e operação coordenada (ANEEL, 2008).

A opção de troca de energia entre regiões resulta de vital importância para um país como o Brasil, onde existem marcadas diferenças no clima ao longo de sua extensão, se apresentando regiões com regimes hidrológicos diferentes. Dessa forma, os períodos de estiagem de uma região podem corresponder aos períodos chuvosos de outras. A integração permite a sinergia entre os reservatórios, já que através do sistema é possível transmitir a energia gerada pelos reservatórios mais cheios para as regiões onde os reservatórios estão mais vazios.

Esta forte dependência das hidrelétricas para produção de energia envolve importantes riscos de oferta, pois o insumo das usinas hidrelétricas é a vazão dos rios, que por sua vez depende do clima e de sua variabilidade temporal e espacial. Assim, a tomada de decisão quanto à operação de reservatórios, à entrada em funcionamento de sistemas térmicos, que possuem maiores custos de operação, e à própria segurança da barragem a eventos extremos, depende da previsão do clima a curto e longo prazo.

O SIN é operado de forma integrada com o objetivo principal de: (1) minimizar o risco de déficits na geração de energia e (2) reduzir o risco da geração térmica pela manutenção de volumes de espera para controle de cheias nos reservatórios (ONS, 2009a).

A previsão de vazão de curto prazo, com antecedência de algumas horas até alguns dias, é empregada na operação em tempo real de reservatórios com o objetivo de maximizar os benefícios decorrentes da geração de energia, navegação, irrigação e abastecimento de

água. Ainda, pode ser útil para minimizar os conflitos entre os diferentes usos da água nos reservatórios.

O cálculo das previsões de curto prazo de vazões de afluência aos reservatórios de grande porte do SIN foi realizado, até o ano 2008, com base apenas nas vazões, através de modelos estatísticos, como os modelos AR (*Auto-Regressive*); PAR (*Periodic Auto-Regressive*); ARMA (*Auto-Regressive Moving Average*) e PARMA (*Periodic Auto-Regressive Moving Average*) (Serra Costa et al., 2007; Maceira e Damazio, 2005; Guilhon, 2002). A inclusão de previsões de precipitação num modelo de previsão hidrológica pode permitir estender o horizonte da previsão para além do tempo de concentração da bacia, e melhorar a qualidade da previsão dentro de horizontes determinados. Isso pode trazer benefícios na operação de um reservatório, como foi apresentado em Bravo et al. (2006) e em Bravo (2006). Assim, a partir do ano 2008, através da Autorização N° ANEEL 96/2008, o ONS passou a utilizar outros modelos de previsão de vazões que incorporam também previsão de precipitação, em algumas das bacias do sistema (ONS, 2008).

Diversas atividades humanas são fortemente dependentes do clima e da sua variabilidade, especialmente aquelas relacionadas ao uso da água. A precipitação sazonal governa a necessidade de irrigação na agricultura, as condições de navegação nos rios, a operação de reservatórios com múltiplos usos e os recursos hídricos em geral. A previsão de precipitação durante semanas, ou meses, à frente, pode melhorar a tomada de decisão, levando a um melhor gerenciamento e operação de sistemas de recursos hídricos, gerando benefícios econômicos.

Os Modelos de Circulação Geral (GCMs) têm sido aplicados amplamente para previsão de precipitação de longo prazo. No entanto, apesar do crescente aprimoramento desses modelos, estes ainda não conseguem apresentar desempenhos aceitáveis em áreas específicas no nível local (Koutsoyiannis et al., 2008). Além disso, apesar do avanço na eficiência dos computadores, a execução desses modelos ainda exige um grande esforço computacional.

Entre os diferentes modelos matemáticos que têm sido desenvolvidos para realizar previsões de variáveis hidrológicas, as redes neurais artificiais (RNAs) se apresentam como um dos modelos empíricos mais utilizados (Dawson e Wilby, 2001; Maier e Dandy, 2000). A aplicação de RNAs na área de recursos hídricos tem apresentado um notável incremento na última década.

As RNAs podem ser consideradas uma solução relativamente recente para o problema de previsão da saída de sistemas complexos, sendo utilizadas em uma ampla gama de campos,

tais como a ciência ambiental, o reconhecimento de padrões, o sensoriamento remoto e a economia (ASCE, 2000b; Dawson e Wilby, 2001). As RNAs têm sido também aplicadas especificamente na modelagem hidrológica como, por exemplo, no processo de transformação chuva-vazão (Minns e Hall, 1996; Tokar e Johnson, 1999), na previsão de curto prazo de vazão (Dawson e Wilby 2001; Maier e Dandy 2000; Jeong e Kim, 2005) e na previsão de longo de prazo de precipitação (Silverman e Dracup, 2000; Zwiers e von Storch, 2004; Nasrallah et al., 2001).

Os modelos, como as RNAs, aplicados na previsão de variáveis hidrológicas podem ser facilmente integrados a um sistema de suporte à tomada de decisão, subsidiando o gerenciamento e a tomada de decisões estratégicas (McIntosh et al. 2007; Hansen, 2002; Ogallo et al., 2000).

Como apresentado previamente, as previsões de variáveis hidrológicas auxiliam à tomada de decisão na operação de reservatórios. Resulta de principal interesse, para o tomador de decisões, conhecer o desempenho dos modelos de previsão ao estimar as variáveis hidrológicas. Com esse fim, diferentes medidas de desempenho das previsões podem ser utilizadas.

A utilização de medidas de desempenho permite ainda identificar os melhores modelos de previsão de variáveis hidrológicas na operação de reservatórios. Quando diferentes modelos de previsão são aplicados a um estudo de caso, o desempenho desses modelos é, normalmente, avaliado em função da qualidade das previsões. As medidas de desempenho tradicionalmente utilizadas para avaliar a qualidade das previsões de vazão são baseadas no erro entre os valores previstos e observados. Assim, qualquer dessas medidas de desempenho compara uma série de pares de valores (previstos e observados) e pondera as diferenças de uma forma particular. Aqueles modelos que geram previsões com os menores valores de erro são considerados melhores.

Nesse sentido, Murphy (1993) ressalta que podem existir diferentes formas de ver o que constitui uma boa previsão. Ainda, o que pode ser considerada como uma boa previsão para um usuário pode não ser, necessariamente, verdade para outros usuários, sobretudo, nos casos de reservatórios com múltiplos usos conflitantes.

Enquanto as medidas de desempenho baseadas nos erros da previsão medem o grau de aproximação entre valores previstos e observados, o valor ou utilidade da previsão depende dos benefícios esperados do uso da previsão por usuários específicos (Wilks, 2006). Nesse sentido, os modelos cujas previsões levem aos maiores benefícios na tomada de decisão devem ser considerados como os de melhores desempenho.

A estimativa da utilidade das previsões não é uma tarefa simples (Murphy, 1993). Como consequência, metodologias simplificadas têm sido aplicadas baseadas em eventos dicotômicos (por exemplo, a vazão superará um certo valor ou não,) ou na transformação a esse tipo de eventos (Wilks, 2001; Thornes e Stephenson, 2001; Richardson, 2000).

Em função do previamente apresentado, existe uma grande demanda pelo desenvolvimento de novas metodologias que permitam obter boas previsões de variáveis hidrológicas e ainda medidas de desempenho que permitam identificar os modelos de previsão que melhores resultados trazem na operação de reservatórios, ambos elementos de vital importância para os tomadores de decisão na operação de reservatórios e no gerenciamento dos recursos hídricos.

1.2- Objetivos

O objetivo dessa pesquisa é investigar a importância do uso de previsões de precipitação, como entradas em modelos empíricos de chuva-vazão, tendo em conta a utilidade da previsão, em um contexto de operação de reservatórios.

Como forma de alcançar tal objetivo, propõe-se responder às seguintes perguntas:

- Qual o efeito dos erros da previsão de chuvas nas previsões de curto prazo de vazão?
- Os modelos empíricos de previsão de vazão que incorporam previsões quantitativas de precipitação são mais sensíveis aos erros nessa variável que os modelos conceituais?
- Podem modelos empíricos, como as redes neurais artificiais, alcançar o mesmo desempenho que os modelos conceituais na previsão de curto prazo?
- Podem as previsões de longo prazo baseadas em índices climáticos alcançar desempenhos aceitáveis?
- Existe uma relação unívoca entre a qualidade das previsões e a utilidade das previsões empregadas na operação de reservatórios?
- Pode uma medida de desempenho das previsões levar em conta a utilidade utilizando previsões não probabilísticas?

- Os benefícios obtidos na operação de reservatórios são influenciados pelas características dos erros das previsões?

1.3- Organização do trabalho

O trabalho foi dividido em sete etapas que são descritas brevemente a seguir.

No capítulo 2 são apresentados os conceitos fundamentais sobre previsão de variáveis hidrológicas e a terminologia utilizada no contexto do trabalho. Basicamente esse capítulo mostra que existem dois tipos de modelos que podem ser utilizados para previsões de variáveis hidrológicas de curto ou longo prazo: os modelos conceituais e os modelos empíricos. As características desses modelos e as suas principais vantagens e desvantagens são ressaltadas. Nesse contexto, é também apresentada uma discussão sobre as diferentes metodologias utilizadas na previsão de variáveis hidrológicas, dando ênfases aos modelos empíricos baseados em redes neurais artificiais (RNAs). As principais etapas para o desenvolvimento de uma RNA para previsão de variáveis hidrológicas são descritas, se destacando: a identificação das variáveis de entrada; a escolha da arquitetura; a divisão e o pré-processamento dos dados; o treinamento e a verificação do desempenho.

O capítulo 3 apresenta os principais elementos que intervêm na operação de reservatórios com base na previsão de vazão. Inicialmente, é introduzido o conceito de regras de operação, através das quais se definem as vazões efluentes em função do volume ou nível da água nos reservatórios e das demandas do sistema. Posteriormente são descritos os modelos de simulação da operação de reservatórios que utilizam previsões de variáveis hidrológicas como subsídio à tomada de decisão. Por fim, esse capítulo apresenta os principais fatores que influenciam os benefícios econômicos do uso de previsões hidrológicas na operação de reservatórios.

No capítulo 4 são apresentados os principais conceitos associados às medidas de desempenho das previsões e à forma em que as previsões podem ser avaliadas, sendo o foco do texto a qualidade e a utilidade das previsões. Esse capítulo mostra as diferentes equações matemáticas utilizadas na estimativa de medidas de desempenho e ressalta as diferenças entre as qualidades das previsões e a utilidade das previsões.

O capítulo 5 apresenta os métodos de estimativa de cada um dos elementos de subsídio à tomada de decisão. Inicialmente descreve a metodologia, com base em redes neurais

artificiais, para prever as vazões de aflúncias a reservatórios utilizando previsões quantitativas de chuva. Na sequência apresenta a metodologia utilizada na previsão de precipitação de longo prazo com base nos índices climáticos. Por fim, a medida de desempenho baseada na utilidade das previsões na operação de reservatórios é apresentada. Esta medida de desempenho é baseada no uso de um modelo de operação do reservatório que incorpora as previsões de vazão e de tabelas de contingência.

O capítulo 6 é dedicado à caracterização do estudo de caso, à apresentação dos principais dados utilizados neste trabalho e à aplicação da metodologia.

O capítulo 7 mostra os resultados obtidos durante a aplicação da metodologia e as correspondentes discussões.

Finalmente, as conclusões e as recomendações deste trabalho são apresentadas no capítulo 8.

If you think the weather is unpredictable, consider the weathermen!

The Economist, April 21st, 2007

2- Previsão de variáveis hidrológicas

A previsão de variáveis hidrológicas é a estimativa do(s) valor(es) de uma determinada variável para um(ou mais) intervalo(s) de tempo específico(s) no futuro (Lettenmaier e Wood, 1993). O maior período de tempo no futuro, que define a antecedência da previsão recebe o nome de horizonte da previsão. Com base no horizonte de previsão, a previsão de variáveis hidrológicas pode ser classificada em: (1) previsão de curto prazo, quando o horizonte for de poucas horas até alguns dias; (2) previsão de longo prazo, para horizontes de até nove meses (Georgakakos e Krzysztofowicz, 2001).

Outro elemento que caracteriza as previsões de variáveis hidrológicas é a sua frequência. A frequência da previsão define o período de tempo no qual são emitidos novos dados de previsão. Assim por exemplo, uma previsão de vazão que se estende por três dias e que é repetida a cada dia tem uma frequência diária e um horizonte de três dias.

As variáveis hidrológicas tipicamente previstas são as vazões ou níveis em determinados locais de interesse nos rios e as precipitações sobre regiões ou bacias hidrográficas que contribuem aos locais de interesse. Mais recentemente, previsões de outras variáveis hidrológicas tem começado a serem feitas, como a umidade do solo (Saldanha, 2009).

No Brasil, as previsões de curto prazo de vazão afluente aos reservatórios do SIN (Sistema Interligado Nacional) são definidas semanalmente pelo ONS (frequência de sete dias) e tem um horizonte de 12 dias. Por sua vez, as previsões de longo prazo de precipitação são calculadas tipicamente com horizontes de até seis meses ou como valores médios por estação do ano, como por exemplo, previsão de precipitação média ou acumulada nos meses mais chuvosos.

Uma característica típica da previsão de variáveis hidrológicas é que sua precisão diminui na medida em que o horizonte da previsão aumenta (Lettenmaier e Wood, 1993).

2.1- Previsão de vazão de curto prazo

Lettenmaier e Wood (1993) estabeleceram que as previsões possam ser classificadas em função de dois critérios: (1) a relação entre a antecedência desejada e o tempo de concentração da bacia de contribuição ao local de interesse e (2) a relação entre a escala espacial do evento de precipitação e a escala espacial da bacia. Com base nos dois critérios, Lettenmaier e Wood (1993) identificam quatro casos fundamentais, apresentados a seguir e na Figura 2. 1.

(1) Quando a antecedência das previsões de vazão é maior que o tempo de concentração da bacia de contribuição ao local de interesse, é necessária a utilização de previsões quantitativas de precipitação, dado que parte da água que é incluída na previsão de vazão ainda não precipitou sobre a bacia no momento em que a previsão de vazão é feita.

(2) Quando a antecedência das previsões de vazão é menor que o tempo de concentração da bacia e este último é dominado pelo tempo de propagação do escoamento através da rede de drenagem, as previsões de vazão de curto prazo podem ser baseadas nas vazões ou níveis observados em locais a montante. A principal vantagem do uso de informações de postos de montante reside em que, tipicamente, os erros de previsão são menores que aqueles da previsão de um modelo chuva-vazão. Evidentemente, nesse caso o aporte lateral entre os postos deve ser desprezível se comparado com o volume do posto de montante (Tucci e Collischonn, 2003).

(3) Quando a antecedência das previsões de vazão é menor que o tempo de concentração da bacia e este último é dominado pelo tempo de resposta da bacia, as previsões de vazão de curto prazo podem ser baseadas nas precipitações ocorridas e coletadas na rede de postos pluviométricos da bacia.

(4) Quando a relação entre a escala espacial do evento de precipitação e a escala espacial da bacia é inferior a 0,7 (valor definido em forma subjetiva pelos próprios autores) existe, em consequência, uma cobertura parcial da bacia pelo evento de precipitação. Nesse caso a qualidade das previsões obtidas com modelos chuva-vazão do tipo concentrado, que assumem uma distribuição uniforme da precipitação será inferior.

É importante ressaltar que as maiores dificuldades na previsão de vazão de curto prazo ocorrem nos períodos chuvosos, quando a incerteza é maior devido à maior variabilidade da precipitação. Nos períodos de estiagem toda a água disponível que gera as vazões nos rios já

se encontra dentro da bacia, e a previsão é baseada unicamente, em metodologias que estimam o escoamento subterrâneo e a propagação do escoamento nos rios.

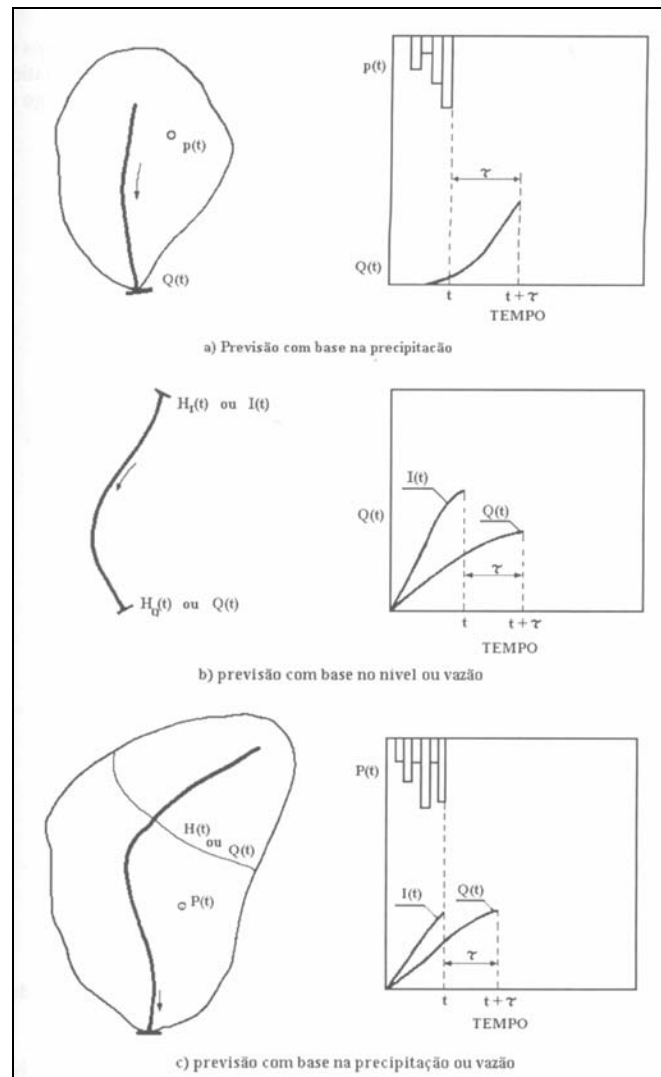


Figura 2. 1. Classificação das previsões de curto prazo (Fonte: Tucci, 2005).

Outros fatores que influenciam o tipo de metodologia a ser empregada na previsão de vazão de curto prazo são as características geológicas e pedológicas das bacias. Bacias com solos e rochas permeáveis favorecem a infiltração da água e geram menos escoamento superficial. Os rios de bacias com estas características têm variações lentas da vazão, ou seja, apresentam grande memória. Bacias com solos rasos e com rochas pouco permeáveis tendem a gerar mais vazão superficial, que escoam mais rapidamente, apresentando memória curta Silva (2005).

A seguir são apresentados os principais modelos de previsão de vazão de curto prazo.

2.1.1- Modelos de previsão de vazão de curto prazo

Os modelos de previsão de vazão de curto prazo podem ser classificados em empíricos, conceituais ou combinados.

Os modelos de previsão de vazão de curto prazo são empíricos quando as relações matemáticas empregadas não possuem relação com o comportamento físico dos processos hidrológicos. Os modelos estatísticos, como os modelos AR (*Auto-Regressive*), PAR (*Periodic Auto-Regressive*), ARMA (*Auto-Regressive Moving Average*) e ARIMA (*Auto-Regressive Integrated Moving Average*), os modelos de regressão entre variáveis (regressões simples ou múltiplas) e os modelos baseados em redes neurais artificiais pertencem ao grupo de modelos empíricos. As vantagens dos modelos empíricos são, tipicamente, a rapidez na sua elaboração e a capacidade de ajustar bem aos dados observados, conseguindo prever adequadamente eventos semelhantes. As desvantagens principais desses modelos estão associadas à deficiência da capacidade de extrapolação e de representação de processos, que por carecer de sustento físico, podem levar a resultados inesperados, provocando grandes erros em eventos que não foram representados no ajuste.

Os modelos chuva-vazão utilizados na previsão de vazão de curto prazo são conceituais quando usam a equação de continuidade, associada a uma ou mais equações empíricas, para relacionar as variáveis e parâmetros dos processos representados (Tucci, 2005). Os modelos conceituais procuram retratar os processos físicos, sendo sua principal vantagem a maior capacidade de extrapolação e tratamento das variantes hidrológicas. A desvantagem dos modelos conceituais está na necessidade de um maior número de dados e do tempo necessário para a montagem, além da maior complexidade computacional.

Os modelos conceituais geralmente possuem dois componentes, ou módulos, principais (Silva, 2005): (a) precipitação-vazão: transforma a precipitação em vazão através da representação do balanço de água no solo e geração de escoamento, incluindo a interceptação, infiltração, evapotranspiração, escoamento subterrâneo e superficial; (b) propagação em rios e reservatórios: simula o escoamento em trechos de rios e reservatórios a partir da contribuição da bacia obtida do módulo anterior.

Os modelos conceituais podem ainda ser classificados como distribuídos ou concentrados (Figura 2. 2). Um modelo conceitual é concentrado quando não leva em conta a variabilidade espacial dos fenômenos. A precipitação média da bacia é um exemplo de integração espacial de uma das variáveis de entrada no modelo. Por sua vez, um modelo é dito distribuído quando as variáveis e parâmetros do modelo dependem do espaço e do tempo

(Tucci, 2005). Os modelos distribuídos permitem melhor descrever a variabilidade espacial dos processos e das variáveis de entrada.

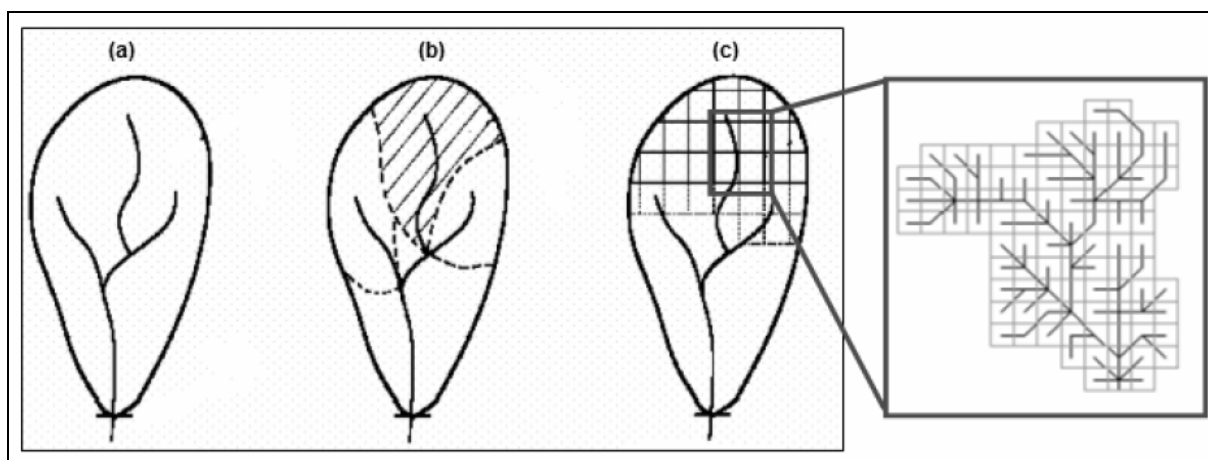


Figura 2. 2. Classificação dos modelos conceituais: (a) Concentrado; (b) Concentrado por sub-bacias e (c) Distribuído. (Adaptado de Tucci, 2005).

Por fim, os modelos combinados buscam aproveitar as vantagens dos dois tipos anteriores de modelo.

Tucci (2005) apresenta uma classificação alternativa, mais abrangente, dos procedimentos e modelos utilizados na previsão de vazão ou nível de curto prazo:

- 1- *Previsão meteorológica da precipitação, integrada a um modelo chuva-vazão.* Nessa situação é obtida a maior antecedência possível a partir do início dos eventos, mas os erros potenciais são maiores, já que são agregados os erros da previsão da precipitação e do processo de transformação da mesma em vazão (Bravo et al., 2009; Silva, 2005; Collischonn et al., 2005).
- 2- *Estimativa da precipitação com base em radar e rede telemétrica de pluviógrafos integrada a um modelo chuva-vazão.* Essa alternativa é uma das mais promissoras dentro do âmbito de pequenas e médias bacias hidrográficas. Devido à rapidez das respostas dessas bacias, é requerida uma pequena antecedência no conhecimento das precipitações futuras.
- 3- *Estimativa da precipitação com base em rede telemétrica e transformação em vazão através de modelo chuva-vazão.* Essa alternativa é inferior à anterior, mas na maioria das bacias não existe radar e a rede telemétrica bem distribuída

pode permitir bons resultados ao disponibilizar os totais de precipitação recém ocorridas.

- 4- *Previsão da vazão com base em níveis ou vazões do rio a montante e dos seus afluentes.* Essa situação é normalmente aplicável quando existe antecedência suficiente e a contribuição lateral é pequena.
- 5- *Previsão da vazão com base em níveis ou vazões a montante e com uma das alternativas 1-, 2- ou 3- para a bacia de contribuição lateral, quando esses aportes são considerados importantes.* Essa alternativa contempla a defasagem do deslocamento de montante e a rapidez da contribuição lateral mais próxima à seção principal da bacia.

Em cada uma dessas alternativas, qualquer um dos tipos de modelos previamente apresentados pode ser utilizado. Nesse trabalho foram utilizados modelos empíricos baseados em redes neurais artificiais para estimar previsões de vazão de curto prazo. As características e propriedades desses modelos são apresentadas em detalhe no item 2.3.

2.1.2- Usos da previsão de vazão de curto prazo

A previsão de vazão de curto prazo é uma das técnicas utilizadas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos (Tucci e Collischonn, 2003).

A previsão de curto prazo é principalmente utilizada para minimização dos danos decorrentes de inundações ribeirinhas, como parte de sistemas de alerta ou como elemento que define diretrizes de planejamento urbano (Moore et al., 2005; Hsu et al., 2003; Koussis et al., 2003). Essas previsões são ainda comumente utilizadas como subsídio à tomada de decisão na operação de reservatórios, tanto na estimativa da energia gerada, na disponibilidade hídrica para irrigação ou no abastecimento de água, como para navegação (Yeh et al., 1982; Andreolli; 2003; Forsund, 2007; Bravo et al., 2008c) e na mitigação de desastres naturais (Fall et al., 2007).

No caso da operação de reservatórios, boas previsões de vazão de curto prazo podem ser úteis para minimizar os conflitos entre os diferentes usos da água (Bravo, 2006; Bravo et al., 2008c).

2.2- Previsão de precipitação de longo prazo

A previsão de precipitação é a estimativa do total ou da intensidade de precipitação em um determinado período de tempo no futuro. A previsão de precipitação pode ser obtida em valores absolutos (quantidade de precipitação), ou em valores característicos associados a categorias definidas em função de estatísticas da série histórica.

Quando a previsão é obtida em valores absolutos recebe o nome de previsão quantitativa de precipitação e o resultado é uma variável contínua, ou seja, que pode assumir qualquer valor (dentro de um intervalo razoável). Por sua vez, a previsão em categorias é uma previsão qualitativa de precipitação, onde a variável prevista é discreta, podendo assumir um valor, e apenas um, de um conjunto finito de valores possíveis (Wilks, 2006). Assim, por exemplo, pode ser prevista uma precipitação total de 100 mm para o mês que vem (previsão quantitativa), ou a previsão pode ser que a precipitação do mês seguinte será acima do normal ou muito úmida (previsão qualitativa-categórica). A escolha de previsões quantitativas ou qualitativas depende de vários fatores, incluindo o horizonte de tempo desejado, os efeitos da previsão, os dados disponíveis, e o modelo utilizado (Galvão, 1999).

As previsões quantitativas e qualitativas de precipitação podem ser obtidas ainda em termos de valor médio espacial ou do campo espacial, na região de interesse, sendo a escolha dependente do modelo de previsão e dos dados disponíveis. Existem outras variáveis relacionadas à precipitação que podem ser previstas, tais como o número de dias chuvosos (Tantaneet et al., 2005), o início e o final da estação das chuvas ou da seca (por exemplo, Liebmann et al., 2007; Nguyen et al., 2007) e a probabilidade de persistência de uma seca extrema ou período chuvoso (Ogallo et al., 2000).

É importante ressaltar que a previsão de precipitação de longo prazo é uma área em recente desenvolvimento na hidrologia, tendo apresentado grandes avanços ao longo dos últimos anos. Isto vem ocorrendo graças ao maior número de dados coletados e ao uso de computadores de maior capacidade de armazenamento e de processamento. Assim, aumentou-se gradativamente a compreensão mundial das relações entre as variáveis climáticas e os eventos hidrológicos, como os períodos de seca ou de inundação. Um grande número de trabalhos tem sido feito nesse sentido, propondo novas metodologias de previsão de precipitação, conforme é apresentado nos itens seguintes. Entretanto, a seguir são apresentados os principais fenômenos influenciado o regime de precipitação em Sul América.

2.2.1- Previsibilidade da precipitação em Sul América

2.2.1.1- A monção de Sul América e sua influência no regime de precipitação

O sistema da monção de Sul América (SMSA) refere-se às características climatológicas do verão austral, época de atividade convectiva profunda e circulação de grande escala no continente sul-americano (Jones e Carvalho, 2002). Os sistemas de circulação do tipo monção, como o SMSA, representam um dos principais componentes do regime de precipitação continental na estação de verão. Na América do Sul, mais de 50% da precipitação total anual sobre as regiões tropicais e subtropicais ocorre durante o verão austral (DJF).

O SMSA se desenvolve em resposta a mudanças sazonais no contraste térmico entre o continente e as regiões oceânicas adjacentes (Vera et al., 2006). Nos níveis superiores da atmosfera e, durante o verão (Figura 2. 3a), o SMSA é caracterizado por uma circulação anticiclônica centrada sobre a Bolívia (conhecida como Alta da Bolívia) e um cavado sobre o Nordeste do Brasil (conhecido como cavado do Nordeste). Além disso, nos baixos níveis (Figura 2. 3b), o fluxo de leste do oceano Atlântico é canalizado para o sul pelas montanhas dos Andes para a Baixa do Chaco, localizado no Norte da Argentina e Paraguai (Nogués-Paegle et al., 2002). Isto é feito pelos chamados ventos de jatos de baixo nível (*South American Low-level jet – SALLJ*), caracterizados por um fluxo estreito que é canalizado próximo da superfície entre os trópicos e latitudes médias ao leste da cordilheira dos Andes (Figura 2. 4), e relacionado ao transporte de umidade da Amazônia para o sul do Brasil e norte da Argentina (Marengo et al., 2004).

Vários estudos, conforme apresentado por Marengo et al. (2004), sugeriram um papel ativo do SALLJ no posicionamento e intensidade da Zona de Convergência do Atlântico Sul (ZCAS) e da precipitação e da convecção na região de saída do jato no sudeste da América do Sul. A ZCAS é uma nebulosidade dominante no período de verão na América do Sul subtropical e no oceano Atlântico sul ocidental (Liebmann et al., 1999). Outra zona de convergência tropical influenciando a precipitação do SMSA é a Zona de Convergência Inter-Tropical (ZCIT), uma zona de baixa pressão, perto do equador, onde os ventos de nordeste e sudeste convergem (Hastenrath, 1991).

A posição e intensidade das zonas de convergência tropical são uns dos fatores que influenciam a variabilidade interanual da precipitação do SMSA. Outros fatores também relacionados são: anomalias de temperatura da superfície do mar, condições da superfície terrestre, transporte de vapor d'água e circulações de grande escala (Vera et al., 2006; Grimm

et al., 2007). Nesse sentido, o SMSA é influenciado por vários modos de variabilidade climática, através de teleconexões, que podem ser definidas como uma forte relação estatística entre o clima em diferentes partes do mundo.




Figura 2. 3. (a) Média de DJF do vetor de vento em 200 mb e (b) Média de DJF do vetor de vento em 850 mb, com base no reanalysis NCEP / NCAR (1950-2007) - a localização da bacia do rio Grande também é indicada. Imagem obtida de NOAA/ESRL Physical Sciences Division, Boulder Colorado a partir do seu Web site at <http://www.esrl.noaa.gov/psd/>.

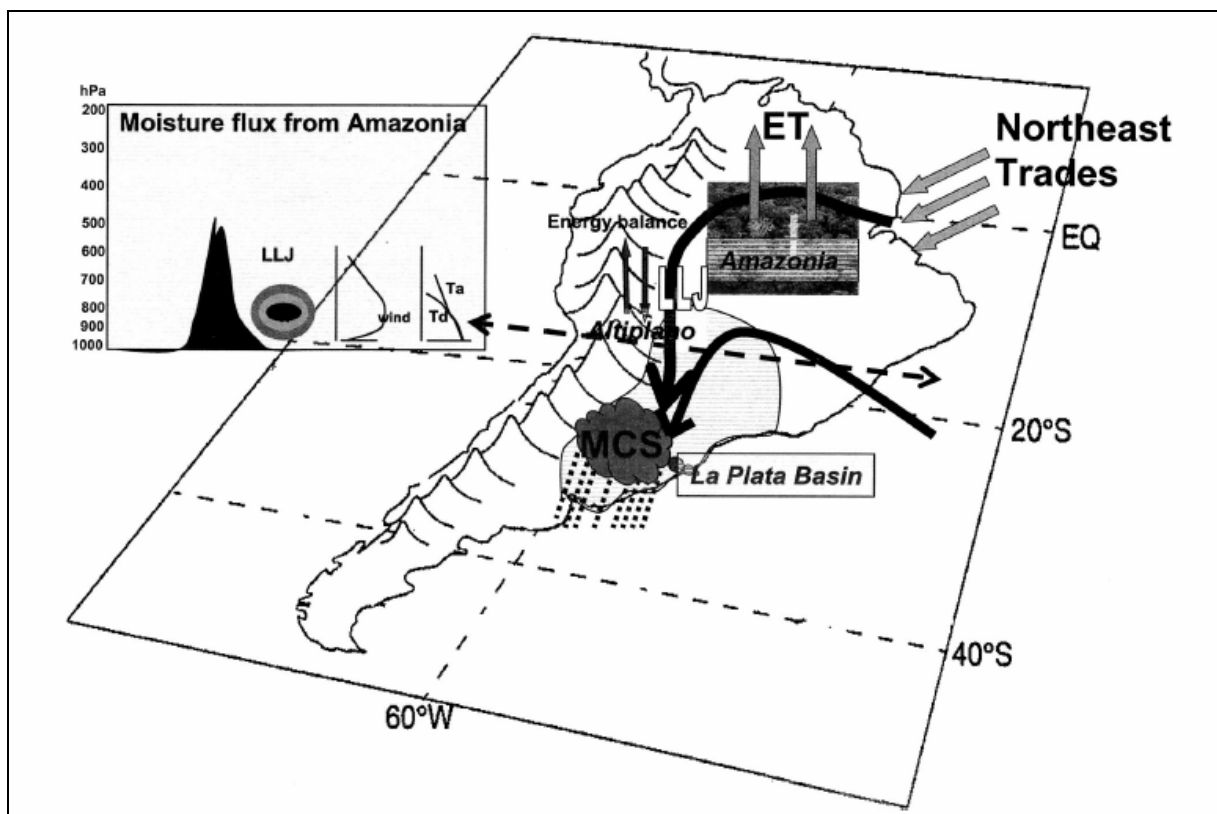


Figura 2. 4. Modelo conceitual do SALLJ ao leste dos Andes (Fonte: Marengo et al., 2004).

2.2.1.2- Principais modos de variabilidade climática influenciando a SMSA e a previsibilidade da precipitação

Vários modos de variabilidade climática e fenômenos climáticos de grande escala foram identificados como os principais responsáveis da variabilidade do clima em todo o mundo através de teleconexões, que abrangem diferentes frequências de tempo que vão desde intrasazonais até multidecadais. A Oscilação do Atlântico Norte (NAO) e o Modo Anular do Hemisfério Sul (SAM) são dois dos mais conhecidos modos de variabilidade climática, enquanto que o El Niño - Oscilação Sul (ENSO) e a Oscilação Decadal do Pacífico (PDO) são conhecidos fenômenos de integração oceano-atmosfera.

A NAO é uma redistribuição da massa atmosférica entre o centro de alta pressão localizado no oceano Atlântico subtropical (Alta de Açores) e o centro de baixa pressão localizado no Ártico (Baixa da Islândia). Este fenômeno oscila entre fases positivas e negativas produzindo grandes alterações na velocidade média do vento e na sua direção sobre o oceano Atlântico, no transporte de umidade e calor entre dito oceano e os continentes vizinhos, e na intensidade, trajetórias e número de tempestades (Hurrell et al., 2003).

Esse modo de variabilidade climática se manifesta em todas as estações do ano e apresenta sinais principalmente atmosféricos.

A NAO apresenta duas fases: a fase negativa e a fase positiva. Durante a fase negativa (Figura 2. 5), a Alta de Açores e a Baixa da Islândia se encontram mais fracas, sendo o gradiente de pressão relativamente baixo ao longo do oceano Atlântico norte, e os ventos úmidos para o leste são direcionados para a região do Mediterrâneo. Dessa forma, a fase negativa da NAO tende a estar associada a um aumento nos totais precipitados no sul da Europa e no norte da África, enquanto que o inverno no norte da Europa resulta mais frio e seco.

Durante a fase positiva da NAO (Figura 2. 6), a Alta de Açores e a Baixa de Islândia se intensificam, se apresentando um grande gradiente de pressão ao longo do oceano Atlântico norte, que intensifica também os ventos úmidos para o leste, direcionando-os para o norte da Europa. Esses ventos em contato com as águas aquecidas pela corrente do Golfo influenciam o inverno do Norte europeu. A fase positiva da NAO tende a estar associada a precipitações acima da média no Norte europeu e abaixo da média no Sul europeu e norte da África.

A influência da NAO na América do Sul não está muito bem definida, embora alguns trabalhos recentes tenham estabelecido teleconexões que incluem esse modo de variabilidade

climática e o clima na região central do continente sul-americano (por exemplo, Allasia, 2007).




Figura 2. 5. Estrutura dinâmica da fase negativa da NAO. Fonte:<http://puddle.mit.edu/~czaja/airsea.html>.




Figura 2. 6. Estrutura dinâmica da fase positiva da NAO. Fonte: <http://puddle.mit.edu/~czaja/airsea.html>.

O ENSO é uma oscilação no sistema oceano-atmosfera sobre o oceano Pacífico tropical que afeta o clima mundial. Este fenômeno é caracterizado por um aumento ou

diminuição da temperatura da superfície do mar no oceano Pacífico tropical central (El Niño), acoplado a uma diminuição ou aumento da velocidade dos ventos de leste, que é um resultado de oscilações no padrão de pressão do oceano Pacífico sul (Rasmusson e Carpenter, 1982).

A Oscilação Sul é uma medida da intensidade dos centros de pressão atmosférica no nível do mar entre o oceano Pacífico ocidental (Darwin, Austrália) e o Pacífico oriental (Taití).

Durante os eventos do El Niño, caracterizados por um aquecimento anormal das águas superficiais no oceano Pacífico tropical, ocorre uma alteração dos padrões atmosféricos sobre o oceano Pacífico, afetando o clima regional e global, com o aumento ou redução dos regimes de precipitação. Padrões típicos de alteração no comportamento da chuva e temperatura em diferentes partes do globo, durante a ocorrência do El Niño, são indicados na Figura 2. 7.

Por sua vez, durante os eventos da La Niña, devido ao esfriamento anormal das águas superficiais do oceano Pacífico tropical, os impactos tendem a ser opostos aos do El Niño, mas nem sempre uma região afetada pelo El Niño apresenta impactos significativos no tempo e clima devido à La Niña (Figura 2. 8 - CPTEC, 2009).

O continente sul-americano apresenta grande influência do ENSO e um grande número de estudos tem relacionado estatisticamente esses eventos a mudanças dos padrões de precipitação (por exemplo, Uvo e Graham, 1998, entre outros). Esses estudos têm indicado que as regiões cujas precipitações estão mais influenciadas por eventos do ENSO são: Amazônia, sudeste do Brasil e nordeste de Argentina, nordeste do Brasil, Peru e Ecuador.

Vários estudos têm mostrado o ENSO e a NAO como os dois principais fatores relacionados à variabilidade da temperatura da superfície do mar (TSM) do oceano Atlântico tropical (por exemplo, Namias, 1972; Kayano e Andreolli, 2004). Czaja et al. (2002) mostraram que uma fase negativa (positiva) da NAO e uma fase positiva (negativa) do ENSO estão associadas a uma fase quente (fria) da TSM no oceano Atlântico tropical. Por sua vez, a TSM no oceano Atlântico tropical influencia a posição da ZCIT, o desenvolvimento típico da SMSA e a intensidade dos SALLJ (Robertson e Mechoso, 1998; Nogués-Peagle e Mo, 1997). Nesse sentido, Noble e Shukla (1996) e Allasia (2007) mostraram um incremento da precipitação nos meses de Dezembro-Janeiro-Fevereiro (DJF) sobre o sudeste do Brasil em anos de elevada TSM no oceano Atlântico tropical, ou seja, durante os períodos de fase negativa da NAO e positiva do ENSO. Outra característica associada à fase positiva do ENSO e a elevadas TSM no oceano Atlântico Norte tropical, é a tendência da ZCIT a estar localizada ao norte da sua posição média e, conseqüentemente, a diminuição da incursão de umidade sobre a região sul da Amazônia e Nordeste do Brasil (Nobre e Shukla, 1996, entre outros).

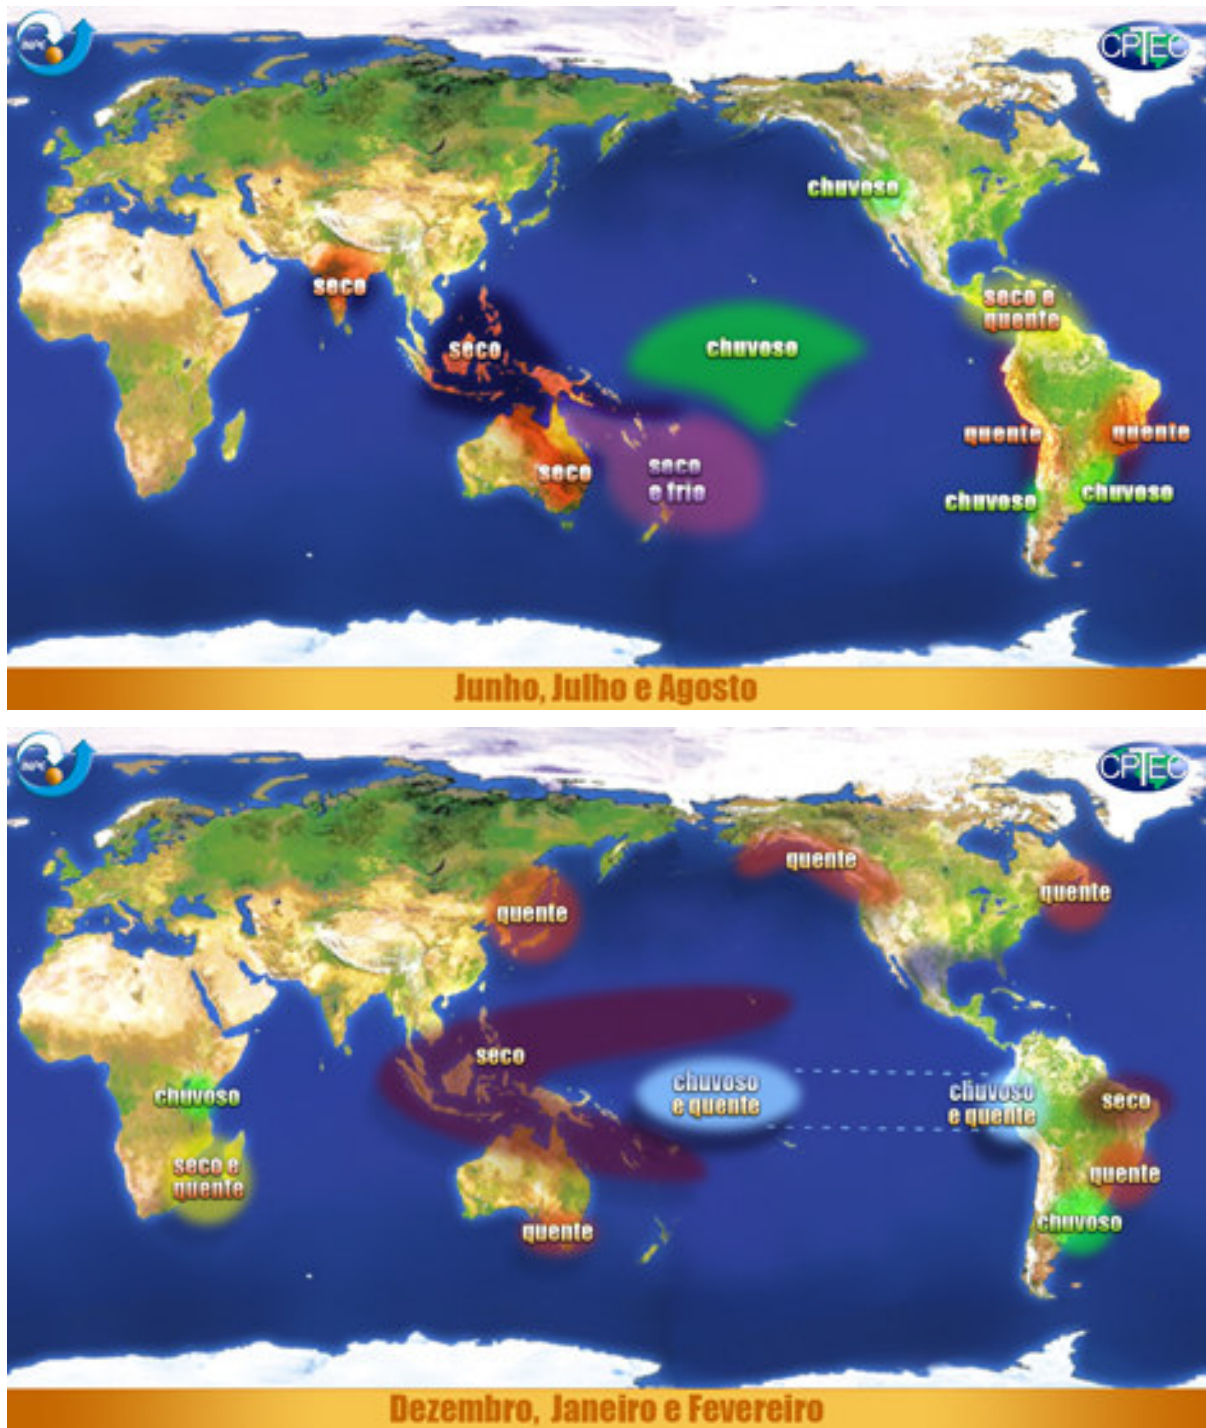


Figura 2. 7. Efeitos globais de El Niño durante o inverno (superior) e o verão (inferior) austral. Fonte: <http://enos.cptec.inpe.br/>.

O SAM (Modo Anular do Hemisfério Sul) é também chamado de Oscilação Antártica (AAO) e refere-se a uma alternância de massa atmosférica, em grande escala, entre as latitudes médias e altas no hemisfério sul (Gong e Wang, 1999). Esta oscilação é também caracterizada por uma estrutura simétrica com perturbações de altura geopotencial de sinais

opostos na Antártida e no anel circundante centrado próximo dos 45° de latitude (Thompson e Wallace, 2000; Reboita et al., 2009).

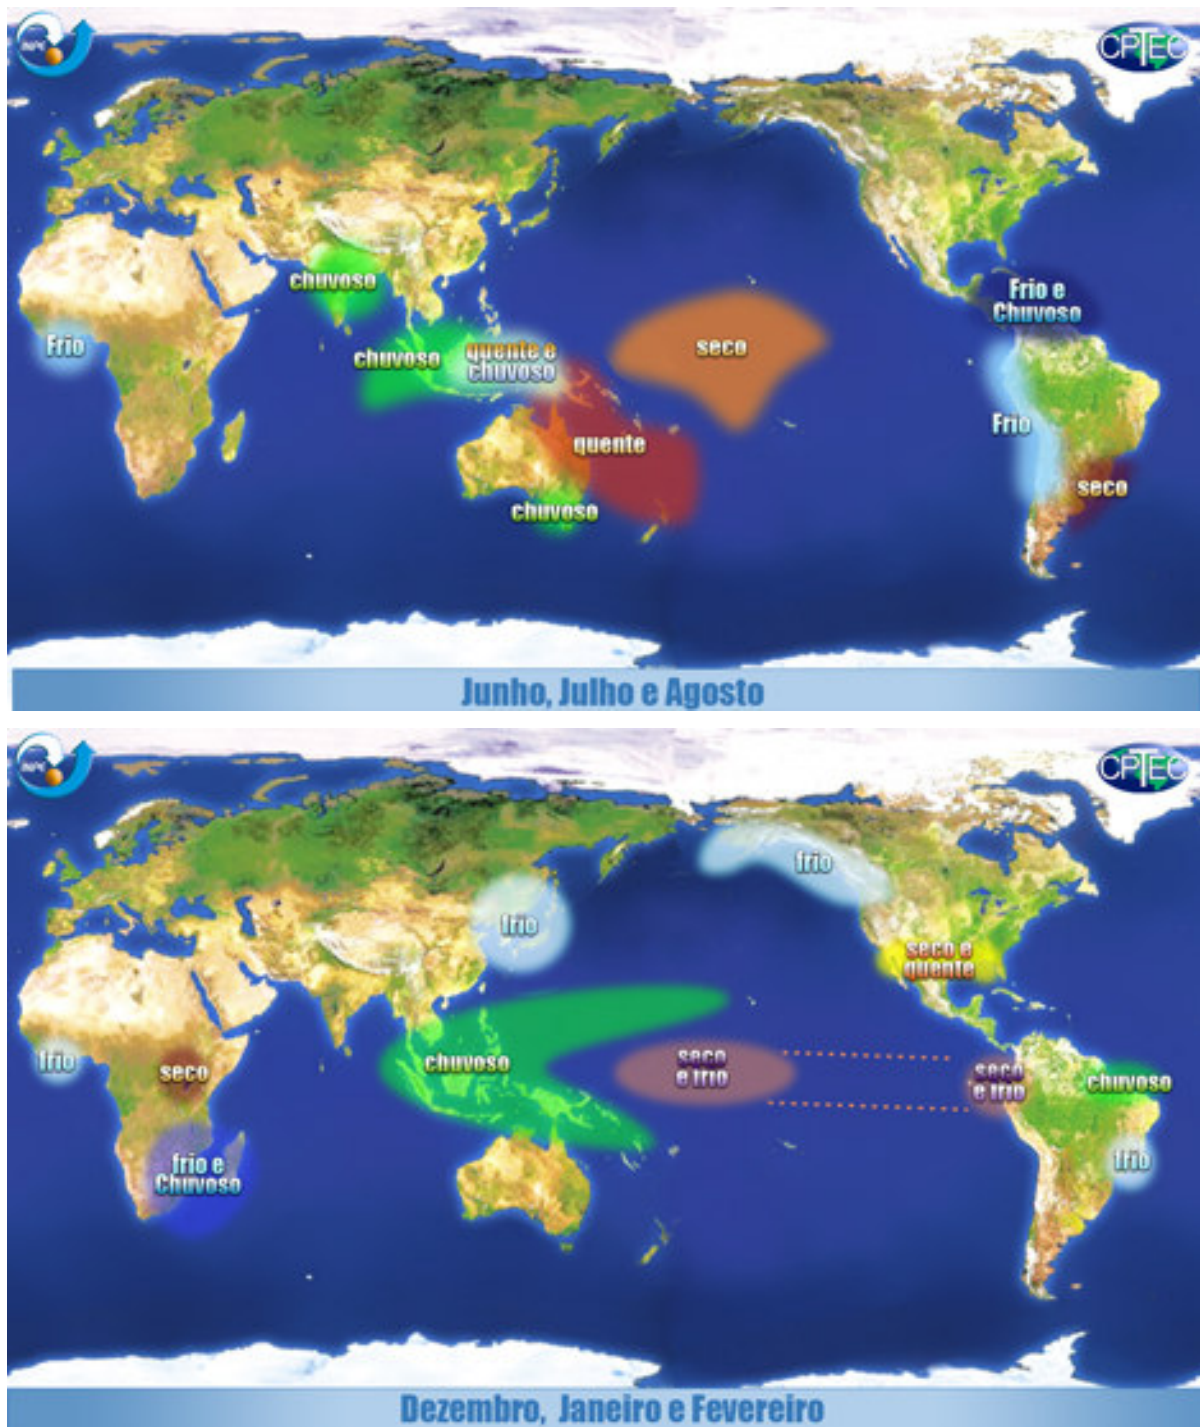


Figura 2. 8. Efeitos globais de La Niña durante o inverno (superior) e o verão (inferior) austral. Fonte: <http://enos.cptec.inpe.br/>.

O SAM existe durante todo o ano na troposfera, no entanto, a sua estação ativa é no período de Outubro a Dezembro, quando se amplifica com a altura dentro da estratosfera (Thompson e Wallace, 2000).

A intensidade do SAM ao longo do tempo pode ser representada pelo índice SAMI, definido como a diferença no valor médio zonal normalizado da pressão no nível do mar entre as latitudes 40°S e 70°S, como indicado na Figura 2. 9 (Nan e Li, 2003).

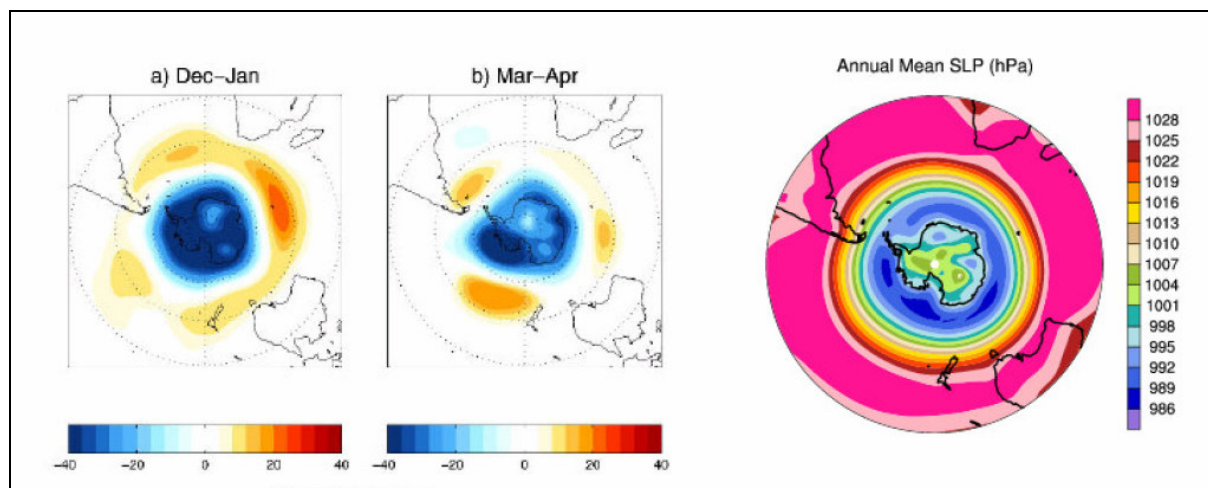


Figura 2. 9. (a) Correlação entre a série de altura equipotencial de 850 hPa obtida dos dados de reanálise do NCEP-NCAR e o índice do SAM para Dezembro e Janeiro; (b) idem (a) para Março e Abril; (c) valor médio anual da pressão no nível do mar no Hemisfério Sul (Allasia, 2007).

A influência do SAM sobre a precipitação da América do Sul tem sido estudada mais recentemente, como apresentado em Carvalho et al. (2005), Silvestri e Vera (2003), Allasia (2007) e Watterson (2009). Silvestri e Vera (2003) e Allasia (2007) mostraram correlação positiva entre o SAM e as anomalias de precipitação sobre o sudeste da América do Sul, enquanto Carvalho et al. (2005) e Allasia (2007) constataram que durante a fase positiva da SAM, o SALLJ parece ser mais fraco, favorecendo a presença de ZCAS e de convecção sobre a região sudeste do Brasil.

Finalmente, o PDO é um fenômeno oceânico-atmosférico caracterizado por (Figura 2. 10): (1) anomalias da temperatura da superfície do mar no oceano Pacífico norte central e sobre o oceano Pacífico norte, próximo da costa americana, e (2) anomalias da pressão no nível do mar sobre o oceano Pacífico norte (Mantua et al., 1997). As oscilações do clima no oceano Pacífico, com fases de 20-30 anos, foram identificadas por Minobe (1999) e a transição de um período frio para um quente nos anos 1976-1977 tem sido muito bem documentada (por exemplo, Trenberth 1990; Trenberth e Hurrell, 1994).

O PDO pode ser considerado como um padrão de variabilidade climática do oceano Pacífico similar ao ENSO. Quando visto com o ENSO, os extremos nos padrões do PDO são

caracterizados por grandes variações do clima no oceano Pacífico e na América do Norte. Duas principais características distinguem o PDO do ENSO: (1) Os eventos típicos do PDO têm apresentado uma marcada persistência, se comparados aos eventos do ENSO, com fases de 20-30 anos; (2) os fenômenos do clima relacionados ao PDO são mais visíveis no oceano Pacífico norte e na América do Norte, sendo que nos trópicos acontecem sinais secundários. No caso do ENSO ocorre o contrário, com sinais bem definidos sobre os trópicos, e sinais secundários no oceano Pacífico Norte (Hare e Mantua, 2000).




Figura 2. 10. Anomalias da temperatura na superfície do mar (cores), da pressão no nível mar (contornos) e da intensidade do vento na superfície, durante a fase (a) fria e (b) quente do PDO. Fonte: <http://jisao.washington.edu/pdo/>.

A influência do PDO no clima da América do Sul tem sido apresentada em diferentes trabalhos (por exemplo, Allasia, 2007) e parece emergir na série histórica de precipitação DJF (Dezembro-Janeiro-Fevereiro) sobre bacia hidrográfica de contribuição ao reservatório de Furnas, conforme apresentado na Figura 2. 11. A precipitação durante DJF na bacia hidrográfica é significativamente diferente (ao nível de significância de 0,05) na fase fria (1950-1977) e quente (1978-2000) do PDO, com um valor médio de precipitação DJF menor que a média climatológica durante o primeiro período e superior do que o normal durante o segundo.

As previsões de longo prazo efetuadas em várias regiões da América do Sul mostraram razoáveis graus de previsibilidade de variáveis hidrológicas, como por exemplo, na bacia Amazônica (Uvo e Graham, 1998). No entanto, o Sudeste do Brasil, é considerada uma região de baixa previsibilidade de longo prazo, conforme apresentado pelos resultados de modelos climáticos que não conseguem apresentar bons desempenhos (Rauscher et al. 2007).




Figura 2. 11. Série temporal da precipitação acumulada em DJF e valores médios dessa variável durante o período de PDO frio (1950-1977) e quente (1978-2000).

Em função das análises físicas dos fenômenos climáticos e dos modos de variabilidade climática influenciando a SMSA, os modelos de previsão de precipitação na região sudeste do Brasil, que utilizem índices climáticos como variáveis de entradas associados ao ENSO, deveriam apresentar uma contribuição positiva nos totais precipitados quando o índice for positivo. Enquanto que no caso de ser utilizado um índice climático associado à NAO, a contribuição nos totais precipitados deveria ser positiva quando o índice for negativo. Já no caso de serem utilizados índices associados ao SAM e ao PDO as contribuições esperadas aos totais precipitados deveriam ser positivas quando os índices forem positivos.

Dessa forma, as principais características do comportamento físico do sistema poderiam ser levadas em conta pelo modelo de previsão de precipitação e existiria uma maior probabilidade de resultados coerentes quando novos dados sejam apresentados ao modelo.

2.2.2- Modelos de previsão de precipitação de longo prazo

O mais antigo método de previsão de precipitação é baseado em indicadores ambientais e no conhecimento tradicional, como a observação das condições atmosféricas e astronômicas (vento, mar, nuvens, lua), o comportamento animal e fenologia de plantas (florescimento, amadurecimento e apodrecimento precoce dos frutos, desenvolvimento das

gemas, etc). Esse método é ainda utilizado na atualidade, porém com uma falta de respaldo científico (por exemplo, Galacgac e Balisacan, 2009).

Os métodos de previsão de precipitação de longo prazo mais utilizados pertencem a dois grandes grupos: (1) métodos dinâmicos e (2) métodos empíricos. A seguir é apresentada uma descrição de cada um dos métodos.

2.2.2.1- Métodos dinâmicos de previsão de precipitação de longo prazo

A previsão de precipitação com métodos dinâmicos é realizada utilizando modelos de circulação geral (GCM), os quais são baseados em equações matemáticas relativas aos processos que governam a física do fenômeno, para simular o comportamento acoplado do oceano e da atmosfera, no caso dos Modelos Acoplados de Circulação Geral (AOGCM), ou apenas as condições atmosféricas (Modelos de Circulação Geral da Atmosfera - AGCM).

Os modelos dinâmicos de previsão de longo prazo são desenvolvidos com o objetivo de representar, com equações físicas, os processos que compõem o sistema climático, o qual inclui a atmosfera, a hidrosfera, a biosfera e a geosfera (McGuffie e Henderson-Sellers, 1997). Conforme esses mesmos autores, os GCMs podem ser definidos como modelos matemáticos tridimensionais no espaço que consideram os principais processos que governam a circulação geral da atmosfera e dos oceanos.

Os GCMs geram uma gama de variáveis meteorológicas, além dos campos de precipitação, como a nebulosidade, umidade, fluxo de calor e os ventos. Devido à conduta caótica da atmosfera, que mostra uma alta sensibilidade às condições iniciais, as previsões de longo prazo obtidas com GCMs são probabilísticas. Essas previsões são baseadas em um conjunto de simulações do mesmo modelo ou em um conjunto de simulações de diferentes modelos variando as condições iniciais (Hansen et al., 2009).

A Figura 2. 12 mostra as principais interações entre atmosfera, oceanos e continente representadas nos GCMs, que geralmente discretizam o globo terrestre em elementos de 20km a 100km, na escala horizontal e 100m a 5km na escala vertical. A topografia e os processos físicos do sistema em cada elemento são representados com valores médios (Silva, 2005; Allasia, 2007).

A principal desvantagem do uso de GCMs para a previsão de precipitação é a necessidade de grandes esforços computacionais e de modelagem, dado que a execução de um GCM não é ainda uma tarefa simples, além do alto custo associado a esse tipo de modelo. Os GCMs também apresentam uma limitação na estimativa de previsões de precipitação de longo

prazo em locais específicos, devido a que a saída do modelo representa médias areais em grades cobrindo dezenas ou centenas de quilômetros quadrados (Garcia-Moya, 2010). Dado que a discretização desses modelos leva em conta os processos atmosféricos de macroescala na superfície terrestre, muitos processos são representados com limitações. Para melhor representar esses processos seria necessária uma discretização mais detalhada (maior resolução espacial na representação dos processos) que torna inviáveis os custos e o tempo de processamento.

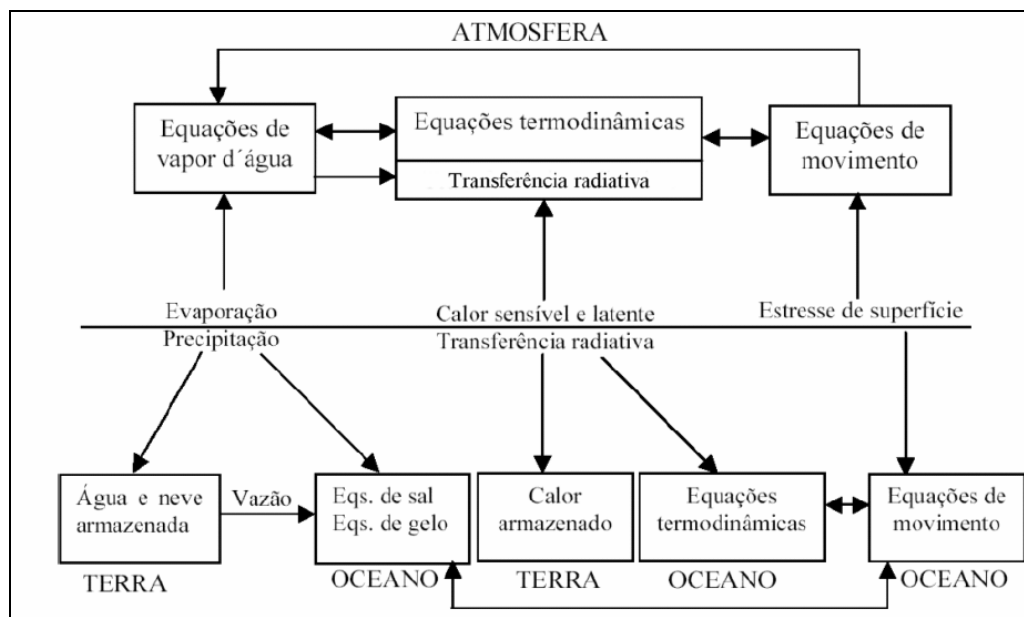


Figura 2. 12. Processos simulados por GCMs: Interações entre atmosfera, oceanos e continentes. (Adaptado de Kimura, 2002).

É importante, ainda, ressaltar que, apesar do aprimoramento e de aumento da qualidade dos dados coletados em todo o mundo, muitas das limitações detectadas nas previsões de precipitação de longo prazo são consequência da escassez de dados para inicializar os GCMs, principalmente dados dos oceanos (Silva, 2005).

Um procedimento alternativo ao aumento da resolução espacial dos GCMs é o *downscaling*. O *downscaling* consiste em técnicas de adensamento que, a partir dos resultados dos GCMs na resolução espacial mais grosseira, estimam os valores das variáveis hidrológicas para uma resolução espacial maior, na escala regional. Esses modelos são alimentados nas fronteiras pelas condições produzidas pelo GCM ou por dados observados e são tipicamente denominados de modelos regionais.

Conforme representado na Figura 2. 13, o modelo regional usa as condições de fronteira na célula B do modelo global (por exemplo, resolução espacial de 200km x 200km),

para gerar uma simulação com resolução espacial de 40km x 40km, internamente a B, de forma que os processos de troca de energia entre a atmosfera e a superfície sejam mais bem descritos que no GCM (Silva, 2005; Allasia, 2007).

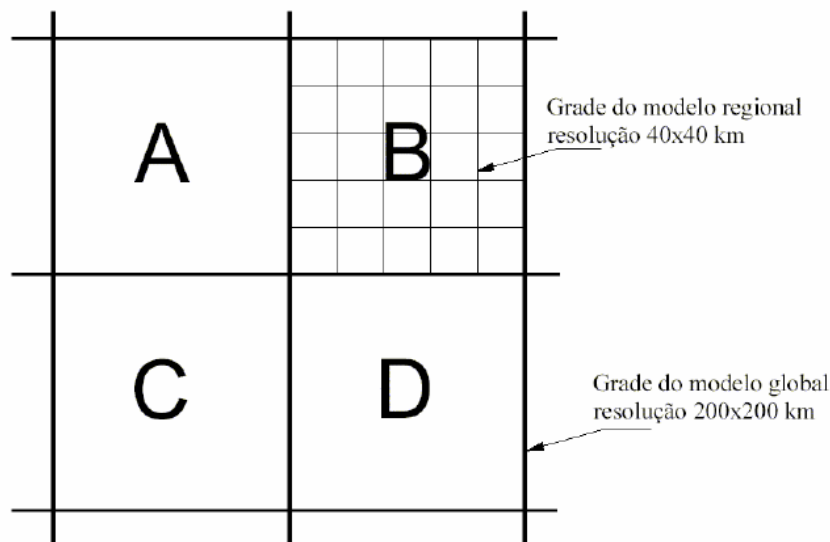


Figura 2. 13. Esquema de representação da resolução espacial de GCMs e dos modelos baseados na técnica de *downscaling*.

Existe uma série de vantagens práticas em relação aos modelos regionais (Roads et al., 2003; Kerr, 2004). Um dos principais benefícios se refere à possibilidade de aplicar o modelo em regiões específicas, onde existam redes de coleta de dados com maior densidade, permitindo a validação dos modelos.

As aplicações dos modelos regionais na área de recursos hídricos mostram que, de maneira geral, são obtidos melhores resultados do que utilizando os modelos globais (Hay e Clark, 2003; Koussis, et al., 2003; Roads et al., 2003). Nesse sentido, uma abordagem mais recente e promissora de *downscaling* é o uso de modelos empíricos que, a partir dos resultados dos GCMs, estimam os valores das variáveis hidrológicas para locais específicos (Nilsson et al. 2008; Ash et al., 2007; Ramirez et al., 2005; Olsson et al., 2004; Goddard et al., 2001).

2.2.2.2- Métodos empíricos de previsão de precipitação de longo prazo

Os métodos empíricos procuram identificar as relações entre os valores passados das variáveis de entrada (X_i , $i = 1, n$) e as variáveis previstas (Y_j , $j = 1, m$), a fim de poder prever os valores futuros de Y de acordo com a disponibilidade de novos valores de X . As relações

são construídas usando uma abordagem estatística e podem servir como um modelo de previsão, mas não para explicar ou descrever o funcionamento do sistema. As análises de regressão multivariada (por exemplo, Bretherton et al., 1992) e redes neurais artificiais (Paz et al., 2010; Karamouz et al., 2008; Chattopadhyay, 2007; Olsson et al., 2004; Bishop, 1995) são exemplos de métodos empíricos utilizados na previsão de precipitação.

Os modelos empíricos se caracterizam por seu baixo custo computacional e de modelagem, quando comparado aos GCMs, e podem, ainda, ser desenvolvidos em forma personalizada para definir previsões de precipitação de longo prazo em locais específicos. No entanto, as principais desvantagens dos modelos empíricos residem na sua falta de representação física dos fenômenos e na sua dependência nos dados históricos disponibilizados para o ajuste.

As variáveis de entrada mais utilizadas por modelos empíricos de previsão de longo prazo de precipitação são: a temperatura na superfície do mar (TSM), a extensão das geleiras, as variáveis relacionadas aos padrões de circulação atmosférica e os índices climáticos (Goddard et al., 2001; Wilby et al., 2004; Morid et al., 2007). Nesse trabalho é utilizado um modelo empírico (rede neural artificial), e índices climáticos como variáveis de entrada para prever precipitação.

Os índices climáticos são representativos da intensidade, ao longo do tempo, dos modos de variabilidade climática e fenômenos climáticos. Vários modos de variabilidade climática e fenômenos climáticos de grande escala foram identificados como os principais responsáveis da variabilidade climática em todo o mundo através de teleconexões, que abrangem diferentes frequências de tempo, que vão desde intra-sazonais até multi-decadais. A oscilação do Atlântico Norte (NAO) e o Modo Anular do Hemisfério Sul (SAM) são dois dos mais conhecidos modos de variabilidade climática, enquanto que o El Niño - Oscilação Sul (ENSO) e a Oscilação Decadal do Pacífico (PDO) são conhecidos fenômenos de integração oceano-atmosfera.

Existem diferentes índices climáticos que levam em conta a intensidade da Oscilação do Atlântico Norte, um dos mais utilizados é o NAOI, definido como a diferença normalizada entre a pressão no nível do mar em Stykkisholmur (Islândia) e Ponta Delgada (Açores), representativas da intensidade da Baixa da Islândia e da Alta dos Açores, respectivamente (Hurrell, 1995).

A intensidade do SAM ao longo do tempo pode ser representada pelo índice SAMI, definido como a diferença no valor médio zonal normalizado da pressão no nível do mar entre as latitudes 40°S e 70°S (Nan e Li, 2003).

O ENSO pode ser representado por um dos índices: El Niño 1, El Niño 2, El Niño 3, El Niño 3.4 ou El Niño 4, que medem a intensidade das anomalias da temperatura da superfície do mar em diferentes regiões do oceano Pacífico equatorial.

Além de índices baseados nos valores da temperatura da superfície do mar no oceano Pacífico equatorial, o ENSO pode ser também quantificado pelo Índice de Oscilação Sul (IOS). Esse índice representa a diferença entre a pressão no nível do mar entre o oceano Pacífico central (Taiti) e o oceano Pacífico ocidental (Darwin/Austrália). Esse índice está relacionado com as mudanças na circulação atmosférica nos baixos níveis da atmosfera, consequência do aquecimento/resfriamento das águas superficiais na região. Valores negativos e positivos da IOS são indicadores da ocorrência do El Niño e La Niña respectivamente.

Uma medida da intensidade do PDO é dada pelo índice PDOI, definido como as anomalias da temperatura da superfície do mar na região central do oceano Pacífico norte, tal como apresentado por Trenberth (1990), Trenberth e Hurrell (1994), Zhang et al. (1997) e Mantua et al. (1997).

Tipicamente, os modelos empíricos utilizados na previsão de precipitação de longo prazo são baseados na existência de relações entre a precipitação e a temperatura na superfície do mar ou índices climáticos, como os previamente descritos, conforme apresentado em Paz et al. (2010); Maurer e Lettenmaier (2003); Wernstedt e Hersh (2002).

2.2.3- Usos da previsão de precipitação de longo prazo

As previsões de precipitação de longo prazo são utilizadas, principalmente, para o planejamento e otimização de recursos hídricos (Olsson et al., 2004; Nilsson et al., 2006), tais como alocação de água para irrigação (Ogallo et al., 2000), operação de reservatórios (Hamlet et al., 2002; Hsieh et al., 2003), avaliação e implementação de medidas contra secas e inundações (Changnon e Vonnahme, 2003), recursos pesqueiros (Neal et al., 2002), abastecimento de água (Chiew, et al., 2003), e diversas outras atividades sócio-econômicas como o turismo, transporte e navegação.

Particularmente, a agricultura é vulnerável à variabilidade climática interanual e à sua imprevisibilidade (Hansen, 2002; Ogallo et al., 2000). O tempo de semeadura, o preparo do solo, o manejo da irrigação e a escolha das variedades, as estimativas de produtividade e colheita, são alguns exemplos de práticas agrícolas que dependem da variabilidade do clima.

Devido às incertezas climáticas, as decisões na agricultura, tomadas com horizonte de vários meses, são feitas de forma conservadora, considerando um cenário quase pessimista (Hansen, 2002; Jones et al., 2000). Boas previsões de precipitação de longo prazo podem ajudar à visão estratégica, à mitigação dos impactos indesejados e ao aproveitamento das condições mais favoráveis. No caso das precipitações previstas indicarem um período de escassez, as áreas de cultura podem ser reduzidas, ou aumentadas as demandas esperadas para irrigação nos reservatórios. Por sua vez, se uma marcada estação chuvosa é esperada, a decisão pode ser a expansão das áreas de cultura e/ou reduzir as demandas para irrigação.

A previsão de longo prazo pode ainda diminuir a incerteza da avaliação econômica de algumas *commodities* relacionadas com a água, como: o planejamento da formação do preço da energia hidrelétrica, importante para países como o Brasil, Uruguai, Canadá e Noruega, onde grande parte da energia gerada é hidrelétrica; a produção agrícola na medida que seja possível estimar também a umidade do solo e o gerenciamento dos conflitos da água (Tucci, 2005).

2.3- Redes neurais artificiais

As redes neurais artificiais (RNAs) são modelos matemáticos que procuram imitar o funcionamento do cérebro humano e que têm mostrado um bom desempenho como ferramenta de regressão, especialmente devido a sua capacidade de aprendizado e generalização (Bishop, 1995; Maier e Dandy, 2000).

Entre os diferentes modelos matemáticos que têm sido desenvolvidos para realizar previsões de variáveis hidrológicas, as redes neurais artificiais se apresentam como um dos modelos empíricos mais utilizados (Dawson e Wilby, 2001; Maier e Dandy, 2000).

Os modelos matemáticos baseados em RNAs se apresentam como uma solução relativamente recente para o problema de prever a saída de sistemas complexos, utilizados em uma ampla gama de campos, tais como a ciência ambiental, o reconhecimento de padrões, o sensoriamento remoto e a gestão financeira (ASCE, 2000a, Dawson e Wilby, 2001).

As redes neurais artificiais têm sido utilizadas para modelar diferentes processos hidrológicos, incluindo o processo de transformação da chuva em vazão (Minns e Hall, 1996; Tokar e Johnson, 1999), a previsão de vazões de curto e longo prazo (Dawson e Wilby 2001; Maier e Dandy 2000; Jeong e Kim, 2005; Muluye e Coulibaly, 2007; Wu et al., 2009; Wang

et al., 2009), a previsão de níveis (Chau, 2006; Dornelles, 2007) e a previsão de precipitações de curto e longo prazo (French et al., 1992; Luk et al., 2001).

O número de aplicações de RNAs na área de recursos hídricos tem apresentado um notável incremento na última década. Trabalhos como os de Maier e Dandy (2000); Dawson e Wilby (2001); ASCE (2000a); ASCE (2000b) apresentam os conceitos básicos para a aplicação destes modelos na área de recursos hídricos, com ênfase na sua utilização para prever variáveis hidrológicas.

A unidade de processamento das RNAs é o neurônio matemático, sendo seu funcionamento definido pela equação 2.1:

$$S = F\left(\sum_{i=1}^n w_i \cdot E_i + b\right) \quad (2.1)$$

onde S é o valor da resposta do neurônio; F é a função de ativação; w_i são os pesos sinápticos; E_i são os valores das entradas que são processadas no neurônio; b é a tendência ou bias do valor de saída.

Observa-se na equação 2.1 que a resposta ou saída de um neurônio é calculada através da aplicação de uma função de ativação a uma soma ponderada das entradas ao neurônio.

As RNAs são compostas por um determinado número de neurônios, dispostos em camadas de processamento. Dentro das diferentes arquiteturas de RNAs, a rede neural progressiva (*feedforward*) de múltiplas camadas (RNPMC) tem sido comumente utilizada (Birikundavy et al., 2002; Dawson et al., 2002; Stokelj et al., 2002; Dawson e Wilby, 2001; Bravo et al., 2007a; Chattopadhyay, 2007). Uma RNPMC (Figura 2. 14) é composta por uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. Os dados que alimentam a rede ingressam através da camada de entrada e são posteriormente processados através das diferentes camadas intermediárias produzindo, ao final, um resultado apresentado na camada de saída.

As RNPMCs se caracterizam por apresentarem, unicamente, conexões entre neurônios de camadas subsequentes. Tais conexões são representadas pelos pesos (ponderadores) que, juntamente com os “bias” de cada neurônio, representam os parâmetros da RNPMC, a serem definidos através de um processo de otimização conhecido como treinamento.

No treinamento, os valores dos pesos e “bias” são ajustados com o objetivo de minimizar alguma medida de desempenho, baseada, comumente, nos erros entre a saída da rede e o valor observado.

Além das RNPMC, outras RNAs têm sido utilizadas na previsão de variáveis hidrológicas no Brasil, entre elas: redes neurais difusas (por exemplo, Alvim et al., 2005, Cicogna et al., 2003) e redes recorrentes de Elman (por exemplo, Costa Rohn et al., 2006; Chow e Cho, 1997; Muluye e Coulibaly, 2007).




Figura 2. 14. Esquema de rede neural artificial progressiva de múltiplas camadas.

Definida a variável de saída do modelo, as etapas subsequentes para o desenvolvimento dos modelos de RNAs podem ser resumidas em (Dawson e Wilby, 2001): (1) identificação das variáveis de entrada; (2) escolha da arquitetura da RNA; (3) divisão e pré-processamento dos dados; (4) treinamento da RNA; (5) verificação do desempenho da RNA. Essas etapas são descritas a seguir.

2.3.1- Variáveis de entrada

Existe um grande número de variáveis de entrada possíveis à rede neural. Dessa forma, a escolha das variáveis de entrada requer um estudo detalhado das condições físicas e meteorológicas que mais influenciam a variável hidrológica que será prevista.

Maier e Dandy (1997) mostraram que a escolha das variáveis de entrada com base em análises estatísticas (correlação múltipla) pode melhorar o desempenho das RNAs em alguns casos. Bowden et al. (2005) sugerem que a escolha das variáveis de entrada seja feita a partir de um sistema que combine *Partial Mutual Information* com *Self Organizing Map*, o que permite que sejam também detectadas relações não lineares entre as variáveis. Outras metodologias utilizadas para definir as variáveis de entrada a modelos de RNA incluem a análise de componentes principais e de espectro singular (Wu et al., 2009; Stokelj et al., 2002). Ainda, na definição das variáveis de entrada é importante compreender as características físicas da bacia e do processo hidrológico analisado (Dawson et al., 2002).

No caso das previsões de vazão de curto prazo, estas dependem de diferentes fatores, como características da bacia, precipitação antecedente e futura, temperatura, condições antecedentes, etc. Apesar das diferenças nas estruturas e no funcionamento das diversas RNAs utilizadas na previsão de variáveis hidrológicas, uma característica comum são as variáveis tomadas como entrada. Tipicamente, modelos baseados em RNAs têm definido previsões de vazão a partir de valores prévios da vazão no próprio posto (por exemplo, Cicogna et al., 2003) e nos postos de montante (por exemplo, Sarmento, 1996; Imrie et al., 2000). Nas previsões de vazão de curto prazo, informações quantitativas de chuva nos intervalos prévios e futuros são também variáveis de entrada a serem consideradas, como apresentado nos trabalhos de Costa Rohn et al. (2006); Coulibaly et al. (2000a); Thirumalaiah e Deo (2000), Zealand et al., (1999); Stokelj et al., (2002); Figueiredo et al., (2007).

Por sua vez, as previsões de precipitação de longo prazo dependem de fenômenos complexos, de envergadura continental e mundial, que interagem alterando o comportamento normal do sistema. Dessa forma, as variáveis de entrada tipicamente utilizadas são a temperatura da superfície do mar, a pressão atmosférica no nível do mar, extensão de gelo das geleiras, variáveis relacionadas a padrões de circulação e índices climáticos (Goddard et al., 2001; Wilby et al., 2004; Morid et al., 2007). Os índices climáticos são representativos da variação da intensidade, ao longo do tempo, dos modos de variabilidade atmosférica e de fenômenos climáticos.

2.3.2- Escolha da arquitetura

Uma vez conhecidas as variáveis de entradas e de saídas, a arquitetura de rede é determinada quando se define o tipo de RNA, o número de camadas intermediárias e a quantidade de neurônios em cada uma dessas camadas.

O número de camadas intermediárias e o número de neurônios dessa camada dependerão do problema analisado. Tipicamente são utilizadas três camadas: uma de entrada, uma de saída e uma intermediária devido a que o Teorema de Kolmogorov (Kolmogorov (1957) *apud* Pedrollo (2005)) estabelece que para uma função de \mathbb{R}^n em \mathbb{R}^n , existe sempre uma reprodução exata possível com uma rede neural de três camadas, com $2n+1$ neurônios na camada intermediária.

As RNPMCs são as mais utilizadas na previsão de variáveis hidrológicas, conforme apresentado por Maier e Dandy (2000), após uma extensa revisão de trabalhos anteriores. Nesse tipo de RNA os neurônios de uma camada se encontram conectados a neurônios da camada subsequente, não existindo conexões entre neurônios de uma mesma camada. Exemplos de utilização desse modelo são apresentados em Maier e Dandy, (1997); Tchaban et al., (1998); Hu et al., (2005); Bruen e Yang, (2005); Pedrollo, (2005); Costa Lima et al., (2005); Freitas e Gondim, (2005); Carvalho et al., (2005); Marinho et al., (2005); Costa Rohn e Mine, (2005); Costa Rohn et al., (2006); Dornelles et al., (2006).

Algumas outras arquiteturas de RNAs foram também utilizadas na previsão de variáveis hidrológicas, como por exemplo, as redes neurais recorrentes (Chow e Cho, 1997; Costa Rhon et al., 2006; Coulibaly et al., 200b). À diferença das anteriores, esses modelos apresentam conexões entre neurônios de uma mesma camada e ainda, entre neurônios de camadas subsequentes e precedentes.

Na definição do número ótimo de camadas intermediárias e de seu correspondente número de neurônios tem sido utilizado, tradicionalmente, um processo de experimentação sistemática com busca de melhores resultados (Maier e Dandy, 2000).

Por fim, na etapa final da escolha da arquitetura são selecionadas as funções de ativação das diferentes camadas da RNA. Existe um grande número de funções de ativação, sendo as mais utilizadas: a log-sigmóide unipolar (equação 2.2), a tangente hiperbólica sigmóide (equação 2.3) e a linear (equação 2.4), apresentadas a seguir:

$$\log \text{sig}(n) = \frac{1}{1 + e^{-n}} \quad (2.2)$$

$$\tan \text{sig}(n) = \frac{2}{1 + e^{-2n}} - 1 \quad (2.3)$$

$$\text{linear}(n) = n \quad (2.4)$$

Essas funções de ativação são aplicadas a todos os neurônios de uma camada da RNA. No entanto, os neurônios de diferentes camadas da RNA podem utilizar funções de ativação distintas.

2.3.3- Divisão e pré-processamento dos dados

Definidas as variáveis de entrada e o tipo de RNA, é feita a divisão dos dados em pelo menos dois conjuntos: treinamento e verificação. O conjunto de treinamento é utilizado durante o processo de calibração dos parâmetros da RNA, enquanto que o conjunto de verificação é utilizado durante a avaliação da capacidade de generalização da RNA.

Quando existem séries curtas de dados o processo de reamostragem pode ser o mais adequado (Dawson e Wilby, 2001). Esse método consiste em dividir a série de dados em N conjuntos de igual tamanho. Posteriormente, N-1 conjuntos são utilizados durante o treinamento e o restante é utilizado durante a verificação. Esse processo se repete N vezes, trocando em cada repetição, o conjunto utilizado na verificação. Outras técnicas específicas para os casos em que existem séries curtas de dados são apresentadas em Maier e Dandy (2000).

Idealmente, a divisão dos dados deve ser feita em três conjuntos: treinamento, validação e verificação. Essa divisão dos dados é necessária para a utilização da validação cruzada como critério de parada durante o treinamento das redes neurais. A validação cruzada é um método mais utilizado para determinar o momento em que o treinamento deve ser parado, com o objetivo de evitar o super-ajustamento (*overfitting*), assim, é obtida uma RNA com adequada capacidade de generalização (Bishop, 1995). O super-ajustamento acontece quando uma RNA reproduz os ruídos existentes no conjunto de treinamento, perdendo sua capacidade de generalizar quando outros dados de entrada são utilizados. Portanto o super-ajustamento pode ser evitado utilizando um conjunto de validação para avaliar o desempenho do processo de treinamento (Tchaban et al. 1998; Maier e Dandy 2000).

Na validação cruzada, os valores dos pesos são ajustados com base no conjunto de treinamento e o processo de treinamento é parado apenas quando o erro no conjunto de validação encontra um valor mínimo. Assim, o conjunto de verificação não é utilizado no treinamento da rede, embora seja muito importante ao avaliar a sua capacidade de generalização.

A divisão das séries de dados para treinamento e validação deve ser feita de forma a se obter um conjunto de dados que sejam representativos da mesma população (Maier e Dandy, 2000). Geralmente, algumas estatísticas de ambos os conjuntos dos dados são estimadas para verificar as similaridades entre eles (por exemplo, a média e o desvio padrão).

Posteriormente, é feito o pré-processamento das variáveis de entrada e saída. Os valores das variáveis são padronizados utilizando-se, por exemplo, a equação apresentada a seguir:

$$x_{novo} = 0,1 + \left(\frac{x_{orig} - x_{min}}{x_{max} - x_{min}} \right) \times 0,8 \quad (2.5)$$

onde x_{novo} é o valor da variável padronizada no intervalo [0,10 ; 0,90]; x_{orig} é o valor original da variável na sua respectiva unidade; x_{min} é o valor mínimo da variável original na sua respectiva unidade; x_{max} é o valor máximo da variável original na sua respectiva unidade.

A padronização dos dados é importante para que seja obtida uma melhora na eficiência das técnicas utilizadas no treinamento da RNA. Essas técnicas podem ter seu desempenho prejudicado quando utilizadas variáveis que incluem grandes magnitudes ou quando existem grandes diferenças entre os valores das mesmas, devido às diferentes unidades. Ainda, uma outra vantagem da utilização da padronização no intervalo [0,10 ; 0,90] durante a modelagem hidrológica é que eventos extremos (cheias ou estiagens) mais severos que os existentes no conjunto de treinamento podem ser obtidos (Hsu et al., 1995).

2.3.4- Treinamento

O treinamento da RNA consiste no estabelecimento dos valores dos pesos entre as conexões dos diferentes neurônios. Dessa forma, no treinamento, os valores dos pesos são ajustados com o objetivo de minimizar alguma medida de desempenho baseada nos erros entre a saída da rede e o valor observado. O erro médio quadrático é, geralmente, a medida de desempenho mais utilizada nessa etapa (Maier e Dandy, 2000; Pedrollo, 2005).

O treinamento das RNAs é normalmente feito com base em métodos de busca local. Os métodos de busca local podem ser divididos em duas classes: (1) de primeira ordem e (2) de segunda ordem. Os métodos de primeira ordem são baseados em modelos lineares (gradiente descendente). Por sua vez, os métodos de segunda ordem são baseados em modelos

quadráticos, como o método de Newton. Em ambos os casos, diferentes técnicas iterativas são utilizadas durante o treinamento para minimizar/maximizar a medida de desempenho utilizada. Os valores dos pesos são modificados em cada iteração em função da seguinte equação:

$$w_{n+1} = w_n + \gamma_n \cdot D_n \quad (2.6)$$

onde w_{n+1} é o vetor dos pesos na iteração $n+1$; w_n é o vetor dos pesos na iteração n , γ_n é o tamanho do passo de uma iteração para a subsequente, na iteração n , e D_n é o vetor que indica a direção de busca na iteração n . A principal diferença entre os métodos se encontra no termo D_n .

O algoritmo mais utilizado no treinamento das RNAs aplicadas na área de recursos hídricos é o retropropagativo (*backpropagation*), que é essencialmente o método de busca local onde D_n é igual ao valor negativo do gradiente da função do erro (Rumelhart et al., 1986 *apud* Pedrollo, 2005). Nesse algoritmo, o tamanho do passo para o ajuste dos pesos, o qual é conhecido como taxa de aprendizagem, deve ser especificado. A taxa de aprendizagem é um fator importante do algoritmo. Quando o valor dessa taxa é baixo, o processo de aprendizagem pode ser muito lento, além de ter uma maior chance de ficar preso em mínimos locais. Por sua vez, se seu valor for grande, pode provocar instabilidade no treinamento. Algumas variações desse algoritmo permitem a mudança dinâmica do valor do passo em cada iteração incluindo mais um parâmetro, chamado de taxa de momento (Dawson e Wilby, 2001).

Os métodos de busca local de segunda ordem utilizam a inversa da matriz Hessiana para definir a direção de busca D_n em cada iteração. Assim, esses métodos apresentam um maior esforço computacional (armazenamento e processamento), se comparados aos métodos de primeira ordem. Porém, esses métodos têm ainda uma maior capacidade de conseguir contornar ótimos locais.

Existe um grande número de métodos de busca local de segunda ordem que foram utilizados no treinamento de RNAs usadas para previsão hidrológica, entre eles se destacam: o método de Levenberg-Marquardt (Golden, 1996 *apud* Maier e Dandy, 2000; Figueiredo et al., 2007) e o *scaled conjugate gradient method* (SCGM) desenvolvido por Moller (1993).

É importante ressaltar que a utilização de um método de busca local no treinamento da RNA não garante que o conjunto de pesos obtidos corresponda ao ótimo global do problema

de otimização. Porém, teoricamente, ao repetir o treinamento um determinado número de vezes, a partir de diferentes condições iniciais, e sendo sempre obtido como resultado o mesmo conjunto de pesos, isto pode ser considerado evidência suficiente de ter sido encontrado o ótimo global.

Na prática, o melhor resultado obtido de um grande número de tentativas tende a apresentar menores erros com o aumento do número de tentativas (Dornelles et al., 2006).

Além dos métodos de busca local, como os previamente apresentados, outros procedimentos podem ser utilizados em processos de otimização, como, por exemplo, os métodos de busca global.

Os métodos de busca global mais utilizados no treinamento de modelos de redes neurais artificiais são os algoritmos evolucionários. Os algoritmos evolucionários são métodos de otimização e busca baseados em analogias com a natureza. Uma das principais características desses métodos é que utilizam uma população de soluções candidatas para explorar o espaço de busca, ao invés de uma única solução, como geralmente ocorre nos métodos numéricos clássicos. Dessa forma, é possível explorar simultaneamente múltiplos pontos do espaço de busca, aumentando as possibilidades de se encontrar o ótimo global em problemas que possuem diversos ótimos locais.

Dentre os diferentes algoritmos evolucionários, os algoritmos genéticos tem sido os mais utilizados. Os estudos dos algoritmos genéticos originados em meados da década de 1970 têm-se convertido em um poderoso método de otimização, consagrando-se como umas das técnicas heurísticas mais utilizadas em problemas de otimização. Os algoritmos genéticos são métodos de otimização e busca inspirados nos mecanismos de evolução de populações de seres vivos. Eles seguem o princípio de seleção natural e sobrevivência do mais apto, introduzido por Charles Darwin (Goldberg, 1989; Lacerda e Carvalho, 1999; Coelho, 2003). Um algoritmo genético mono-objetivo parte de uma população inicial de pontos (conjunto de soluções), aleatoriamente distribuídos no espaço factível, que evolui em direção ao ótimo global através de sucessivas iterações e avaliações da função-objetivo. A chance de um indivíduo da população ser selecionado para participar no processo de evolução depende do valor da função de aptidão do indivíduo. Quanto melhor o valor da função de aptidão de um indivíduo, maior é a probabilidade de ser escolhido para participar do processo de evolução. A função de aptidão é, geralmente, a função-objetivo, ou uma transformação simples desta que permita uma otimização sem restrições.

Os indivíduos selecionados evoluem a cada iteração através de três processos heurísticos aplicados de forma probabilística: cruzamento, reprodução e mutação. A evolução

continua até satisfazer um critério de parada obtendo como resultado um conjunto de soluções próximas a um valor ótimo. Embora não exista garantia de que o valor ótimo encontrado seja o ótimo global, o conjunto de soluções estará próximo ao ótimo global quando forem utilizados valores corretos dos parâmetros do algoritmo genético, fundamentalmente, um número suficiente de indivíduos na população. Esses valores são determinados numa etapa inicial onde são avaliadas a eficiência e a eficácia do algoritmo genético na resolução do problema. Uma medida da eficiência de um algoritmo genético é o número de gerações necessárias para sua convergência a uma solução. Quanto menor seja esse número, maior será sua eficiência. Por sua vez, uma forma de avaliar a eficácia de um algoritmo genético é através do número de “falhas” em encontrar o ótimo global em diferentes inícios do processo de otimização. Quanto maior esse número, menor sua eficácia.

O algoritmo SCE-UA é um algoritmo evolucionário de otimização global mono-objetivo, inicialmente desenvolvido para a calibração de modelos hidrológicos. No entanto, o algoritmo foi utilizado na resolução de vários problemas relacionados com a otimização de outros processos hidrológicos, mostrando eficácia e eficiência na obtenção do ótimo global (por exemplo, Kingston et al., 2005; Bravo et al. 2008a; Koutsoyiannis et al., 2002; Koutsoyiannis e Economou, 2003).

Como algoritmo evolucionário, o algoritmo SCE-UA é semelhante aos algoritmos genéticos. O processo de busca começa a partir de uma população de soluções candidatas, selecionadas aleatoriamente a partir do espaço factível, inicialmente estabelecido de acordo com a definição dos limites superior e inferior dos parâmetros. A população inicial é então dividida em grupos, denominados "complexos", cada um constituído por $2n+1$ soluções candidatas, onde n é o número de parâmetros do modelo (número de pesos e bias, no caso dos modelos de redes neurais artificiais). Cada complexo evolui para um ótimo em forma independente, através de gerações, usando um procedimento baseado no método simplex (Nelder e Mead, 1965). No entanto, em um número pré-definido de gerações, os complexos são embaralhados para promover o compartilhamento das informações encontradas por cada grupo.

Os passos do algoritmo são apresentados a seguir, conforme Duan et al. (1992):

- 1) Início do processo: são selecionados os valores dos parâmetros do algoritmo, $p \geq 1$ e $m \geq 2n+1$, onde p representa o número de complexos, m o número de pontos em

cada complexo e n o número de parâmetros do problema de otimização (variáveis de decisão). O tamanho da população (s) é igual ao produto de p e m .

- 2) Geração da população: são gerados s conjuntos de parâmetros do modelo de simulação, entre os limites máximo e mínimo definidos para cada parâmetro. Estes conjuntos são escolhidos de forma aleatória, utilizando uma distribuição de probabilidades uniforme.
- 3) Hierarquização dos pontos: os pontos da população são avaliados com a função-objetivo e reorganizados, em ordem crescente de função-objetivo, formando o conjunto D . O primeiro ponto de D apresenta o menor (melhor) valor da função-objetivo.
- 4) Divisão em complexos: a população D de s pontos é dividida em p complexos, cada um com m pontos. A divisão de complexos segue a regra $A^k = \{x_j^k, f_j^k\}$ onde $x_j^k = x_{k+p(j-1)}$ e $f_j^k = f_{k+p(j-1)}$, para $j = 1, \dots, m$. Onde k é o número de complexo, que varia de 1 a p , j é o número do ponto dentro do complexo, que varia de 1 a m , x é o grupo de parâmetros e f é o valor da função-objetivo. Esta regra obriga a que cada complexo esteja integrado por um certo número de soluções “boas” (baixo valor da função-objetivo) e de soluções “ruins” (altos valores da função-objetivo).
- 5) Evolução dos complexos: a cada complexo é dada a oportunidade de evoluir com base no método de Evolução Competitiva de Complexos, explicado mais adiante.
- 6) Mistura dos complexos: os complexos A^k são novamente agrupados na população D , e os pontos reorganizados, em ordem crescente de função-objetivo.
- 7) Teste de convergência: se o critério de convergência é satisfeito, o algoritmo se encerra. Caso contrário, o procedimento retorna ao passo 3.

O algoritmo de Evolução Competitiva de Complexos, usado no passo 5 para a evolução de cada complexo do algoritmo SCE-UA, foi descrito por Duan et al. (1992) como segue:

- 1- Início: são selecionados os valores de q , α' e β , que são parâmetros do SCE-UA. Os valores são escolhidos de forma que $2 \leq q \leq m$, $\alpha' \geq 1$, e $\beta \geq 1$.
- 2- Atribuição de pesos: cada um dos pontos do complexo recebe um peso, proporcional a sua posição na hierarquia do complexo. Os pesos são atribuídos em

função de uma distribuição de probabilidades trapezoidal, considerada em cada um dos complexos através da equação 2.7:

$$p_i = \frac{2 \times (m + 1 - i)}{m \times (m + 1)} \quad i = 1, \dots, m \quad (2.7)$$

onde p_i é o peso do ponto i ; i é a posição do ponto no complexo.

Os valores dos pesos variam de forma linear entre o valor máximo, atribuído ao ponto $i=1$, até o valor mínimo, superior a zero, atribuído ao ponto $i=m$.

3- Seleção dos pais: um sub-complexo de q pontos (u_j onde $j=1, \dots, q$) é escolhido de forma aleatória de cada complexo. A probabilidade de cada ponto do complexo ser parte do sub-complexo é dada pelo peso definido em 2.

4- Geração dos filhotes: os pontos do sub-complexo são organizados de forma crescente de função-objetivo e calculado o centróide dos $q-1$ melhores pontos do sub-complexo, segundo a equação 2.8.

$$g = \frac{1}{q-1} \times \sum_{j=1}^{q-1} u_j \quad (2.8)$$

A continuação, as coordenadas de um novo ponto são calculadas como segue:

- a) O ponto X_R é chamado de “ponto de reflexão” e suas coordenadas são calculadas de acordo com a equação $X_R=2g-u_q$.
- b) Se X_R estiver contido no espaço factível dos parâmetros é calculado o valor da função-objetivo F_R e o procedimento continua no passo c. Caso contrário é definido o menor hipercubo que contém todos os pontos do complexo e gerado um ponto X_A , de forma aleatória, no interior deste hipercubo. Posteriormente é calculada F_A e feito $X_R=X_A$ e $F_R=F_A$ (passo de mutação).
- c) Se $F_R < F_q$, u_q é substituído por X_R e o procedimento continua no passo e. Caso contrário, as coordenadas de um novo ponto (X_C), chamado de “ponto de contração”, são calculadas com a equação $X_C=(g+u_q)/2$. Posteriormente é calculada F_C .
- d) Se $F_C < F_q$, u_q é substituído por X_C e o procedimento continua no passo e. Caso contrário é definido o menor hipercubo que contém todos os pontos

do complexo e gerado um ponto X_A , de forma aleatória, no interior deste hipercubo. Posteriormente é calculada F_A e substituído u_q por X_A .

e) Repetir os passos a-d um número α' de vezes.

5- Os pontos de cada um dos sub-complexos são devolvidos, modificados, a cada complexo.

6- Os passos 1 a 5 são repetidos um número β de vezes.

A Figura 2. 15 apresenta as alternativas na geração do novo ponto num sub-complexo considerando um problema hipotético de otimização com duas variáveis de decisão. Os pontos pretos pertencem a um complexo. Os pontos X_i ($i=1, 2, 3$) foram selecionados para formar um sub-complexo onde o ponto X_3 apresenta o maior valor de função-objetivo e, em consequência, é o pior indivíduo do sub-complexo.




Figura 2. 15. Alternativas na geração do novo indivíduo num sub-complexo.

O algoritmo SCE-UA foi desenvolvido para resolver problemas de otimização sem restrições. No entanto, adicionando um termo de penalidade na função-objetivo, que dependa da verificação de restrições, permite trabalhar com problema de otimização com restrições.

O algoritmo SCE-UA está descrito de forma mais detalhada nos textos de Duan et al. (1992), Sorooshian e Gupta (1995) e Diniz (1999).

Diferentes trabalhos têm comprovado a superioridade dos algoritmos evolucionários como técnicas de treinamento de redes neurais artificiais, principalmente, quando existem poucos dados (por exemplo, Chau, 2006).

Uma grande vantagem dos algoritmos evolucionários é sua capacidade de levar em conta restrições no processo de treinamento de redes neurais artificiais. Dessa forma, apesar das redes neurais artificiais serem modelos empíricos, o uso de técnicas como o *overall connection weight approach* (Olden et al., 2004; Kingston et al., 2005), que introduzem restrições na contribuição de cada variável de entrada na estimativa da variável de saída, permite que seja verificada a plausibilidade física da relação entre variáveis de entrada e saída do modelo.

Assim, a relação entre as variáveis de entrada e a variável de saída do modelo de rede neural artificial pode ser avaliada, e a busca durante o processo de treinamento orientada a uma região fisicamente factível do espaço de busca. Isto resulta de vital importância quando poucos dados existem e onde a função-objetivo resulta complexa, com um grande número de ótimos locais que dificulta a obtenção do ótimo global.

O OCW de uma variável de entrada, por exemplo X_1 na Figura 2. 16, é calculado utilizando a seguinte equação:

$$OCW_{x_1} = w_{1,1} \cdot Wh_1 + w_{1,2} \cdot Wh_2 + w_{1,3} \cdot Wh_3 + w_{1,4} \cdot Wh_4 \quad (2.9)$$

onde OCW_{x_1} é o *Overall Connection Weight* da variável de entrada X_1 ; $w_{1,hi}$, é o peso de conexão entre os primeiro neurônio da camada de entrada e o h_i neurônio da camada intermediária ($h_i = 1,4$; na Figura 2. 16); Wh_i é o peso de conexão entre o h_i neurônio da camada intermediária e o neurônio da camada de saída.

Kingston et al. (2005) propôs o uso de um valor relativo, chamado ROCWs, ao invés do OCWs, para determinar a contribuição relativa de cada entrada, conforme apresentado a seguir na equação 2.10:

$$ROCW_{x_1} = \frac{OCW_{x_1}}{|OCW_{x_1}| + |OCW_{x_2}| + |OCW_{x_3}| + |OCW_{x_4}|} \quad (2.10)$$

Os OCWs e os ROCWs são aproximações da contribuição real de uma variável de entrada. No entanto, este procedimento proporciona os melhores resultados em termos de

quantificação da importância de cada variável de entrada ao modelo de rede neural artificial, em comparação com outros métodos comumente utilizados (Olden et al., 2004).

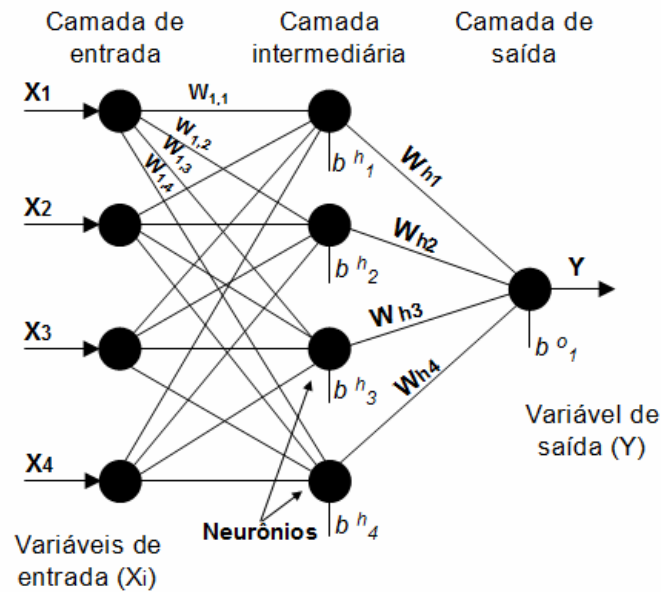


Figura 2. 16. Arquitetura de uma rede neural artificial progressiva.

2.3.5- Verificação do desempenho

As medidas de desempenho mais utilizadas na avaliação dos resultados do funcionamento de modelos de redes neurais para previsão de variáveis hidrológicas são: (a) Erro padrão de previsão (EP); (b) Erro médio absoluto (EMA); (c) Erro médio relativo (EMR); (d) Coeficiente de eficiência ou coeficiente de Nash-Sutcliffe (CE, Nash e Sutcliffe, 1970), sendo apresentadas a seguir:

$$EP = \left[\frac{1}{N} \sum_{i=1}^N (Qp_i - Qo_i)^2 \right]^{1/2} \quad (2.11)$$

$$EMA = \frac{1}{N} \sum_{i=1}^N |Qp_i - Qo_i| \quad (2.12)$$

$$EMR = \frac{1}{N} \sum_{i=1}^N \left| \frac{Qp_i - Qo_i}{Qo_i} \right| \quad (2.13)$$

$$CE = 1 - \frac{\sum_{i=1}^N (Qo_i - Qp_i)^2}{\sum_{i=1}^N (Qo_i - \overline{Qo})^2} \quad (2.14)$$

onde Qp_i é o valor previsto; Qo_i é o valor observado; \overline{Qo} é o valor médio dos valores observados no período de verificação; N é o número de valores no conjunto de verificação.

Essas medidas de desempenho são aplicadas ao conjunto de verificação para conferir a capacidade de generalização do modelo de RNA previamente treinado. É importante lembrar que o conjunto de verificação não deve ser utilizado durante o treinamento para que essa avaliação não seja tendenciosa.

Quando o desempenho obtido no conjunto de treinamento é bastante diferente do obtido no conjunto de verificação, é provável que os dois conjuntos de dados não sejam representativos da mesma população, e uma nova divisão dos dados deve ser feita. Outro motivo pelo qual podem existir grandes diferenças no desempenho do modelo nos conjuntos de treinamento e verificação é a ocorrência do super-ajustamento (Maier e Dandy, 2000).

2.4- Resumo do capítulo

Nesse capítulo são apresentados os conceitos fundamentais sobre previsão de variáveis hidrológicas e a terminologia utilizada no contexto do trabalho. O horizonte de previsão, definido como o maior período de tempo no futuro, que define a antecedência das previsões, permite a classificação das previsões em: (1) previsões de curto prazo, horizonte de poucas horas até alguns dias e (2) previsões de longo prazo, horizonte de até nove meses. As variáveis hidrológicas tipicamente previstas são as vazões ou níveis em determinados locais de interesse nos rios e as precipitações sobre regiões ou bacias hidrográficas que contribuem aos locais de interesse.

Basicamente existem dois tipos de modelos que podem ser utilizados para previsões de variáveis hidrológicas de curto ou longo prazo, os modelos conceituais e os modelos empíricos. Os modelos conceituais procuram retratar os processos físicos, sendo sua principal vantagem a maior capacidade de extrapolação e tratamento das variantes hidrológicas. A desvantagem dos modelos conceituais está na necessidade de um maior número de dados e do

tempo necessário para a montagem, além da maior complexidade computacional. Os modelos empíricos empregam funções matemáticas que não possuem relação com o comportamento físico dos processos hidrológicos. As vantagens dos modelos empíricos são a rapidez na sua elaboração e a capacidade de ajustar bem aos dados observados. As desvantagens principais desses modelos estão associadas a uma falta de capacidade de extrapolação e de representação de processos, que por carecer de sustento físico, podem levar a resultados inesperados, provocando grandes erros em eventos que não foram representados no ajuste.

Nesse sentido, esse capítulo apresenta uma discussão sobre as diferentes metodologias utilizadas na previsão de variáveis hidrológicas, dando ênfase aos modelos empíricos baseados em redes neurais artificiais (RNAs). As principais etapas para o desenvolvimento de uma RNA para previsão de variáveis hidrológicas são descritas, sendo destacadas: a identificação das variáveis de entrada; a escolha da arquitetura; a divisão e o pré-processamento dos dados; o treinamento e a verificação do desempenho.

No caso das previsões de precipitação de longo prazo, os índices climáticos são tipicamente utilizados como variáveis de entrada em modelos empíricos e esse capítulo apresenta uma descrição dos principais modos de variabilidade climática e fenômenos climáticos: Oscilação do Atlântico Norte (NAO), Modo Anular do Hemisfério Sul (SAM), El Niño – Oscilação Sul (ENSO) e Oscilação Decadal do Pacífico (PDO).

Por fim, os principais usos das previsões de variáveis hidrológicas são discutidos, destacando-se o planejamento e a otimização de recursos hídricos, tais como alocação de água para irrigação, subsídio à operação de reservatórios, avaliação e implementação de medidas contra secas e inundações, e diversas outras atividades sócio-econômicas como o turismo, transporte e navegação.

3- Operação de reservatórios com base na previsão de vazão

3.1- Regras de operação de reservatórios

Existem diferentes regras de operação, mas todas indicam a vazão efluente ou o volume do reservatório que se pretende atingir em determinados períodos de tempo como o diário, semanal, decenal ou mensal (Loucks et al., 1981). Estas regras visam atender aos requerimentos de vazão efluente e demandas do sistema para otimizar determinados objetivos (Mays e Tung, 1992).

Uma das regras de operação mais utilizadas inclui a divisão do volume útil do reservatório em diferentes “zonas” que possuem políticas de descargas específicas (Wurbs, 1996). A distribuição do volume útil do reservatório nessas zonas pode ser constante ao longo do ano ou pode variar de forma sazonal. Na Figura 3. 1 se apresenta um esquema particular de subdivisão em zonas, de um reservatório com dois usos predominantes: a geração de energia e o controle de cheias.

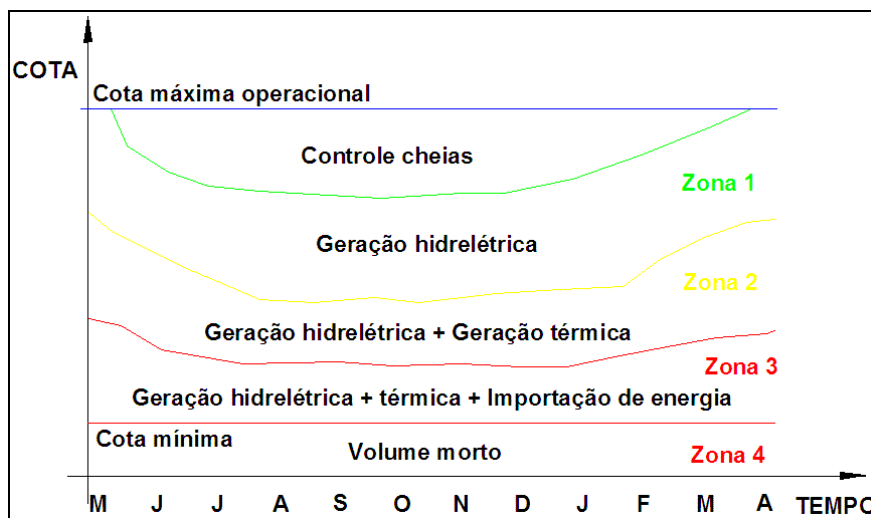


Figura 3. 1. Curvas-guia num reservatório com múltiplos usos.

Essas regras de operação são chamadas de curvas-guia e usadas para indicar volumes (ou níveis da água) alvos ou ideais do reservatório visando determinados objetivos. As curvas-guia definem as vazões efluentes, ao longo do ano, em função do volume (ou nível da água) do reservatório (Wurbs, 1996).

Para interpretar essas curvas pode ser considerada a seguinte operação de um reservatório com dois usos: o controle de cheias e a geração de energia (Figura 3. 1). Assim, se o nível da água do reservatório se encontra acima da “curva-guia para controle de cheias”, são atendidas as demandas de geração de energia em 100%, podendo existir um excedente de energia que seria exportado. Ainda, são necessários vertimentos para levar o armazenamento ao nível definido por essa curva-guia. Dessa forma, é assegurado o chamado volume de espera para amortecer futuras cheias. Se o nível da água estiver na zona 1, a demanda de energia é atendida e os vertimentos não são necessários. Quando se encontrar na zona 2, a demanda de energia não pode ser atendida exclusivamente com geração hidrelétrica e, em consequência, são necessárias fontes complementares de geração de energia. Assim, nesse caso poderiam ser ligadas as usinas térmicas para atender a demanda de energia. Já na zona 3, a utilização conjunta de geração hidrelétrica e de geração térmica não é suficiente para o atendimento da demanda. Para evitar déficits, energia deve ser importada desde outros sistemas. Finalmente, se o armazenamento estiver na zona 4, não existe geração hidrelétrica e o atendimento da demanda dependerá da capacidade de geração das usinas térmicas e da disponibilidade de energia para importação desde outros sistemas. Nesse caso, pode ocorrer déficit no atendimento da demanda que, inclusive, leve ao racionamento de energia.

Nos locais onde a geração de energia representa o uso predominante, podem ser utilizadas curvas-guia chamadas de curvas de capacidade de produção de energia firme (CCE). Estas curvas definem o nível de armazenamento no reservatório, ao longo do ano, que permite assegurar uma produção de energia firme previamente estabelecida por contrato, conforme apresentado em Hamlet et al., (2002).

As regras de operação de sistemas de múltiplos reservatórios definem a descarga ou armazenamento alvo de cada reservatório em função da época do ano e do armazenamento total do sistema (Oliveira e Loucks, 1997).

Um trabalho pioneiro na definição de regras de operação para sistemas de múltiplos reservatórios foi feito por Bower et al. (1962) *apud* Oliveira e Loucks (1997) que sugeriram duas regras gerais de operação:

- 1) *Pack rule*, estabelece que onde existe um excesso de água, produzindo vertimentos acima do valor “alvo”, ele será utilizado para obter benefícios. Esses vertimentos geram uma liberação do espaço do reservatório, diminuindo a probabilidade de futuros vertimentos.
- 2) *Hedging rule*, estabelece que quando existe escassez de água é melhor aceitar um pequeno déficit atual diminuindo a probabilidade de déficit mais severos no futuro.

Bower et al. (1962) *apud* Oliveira e Loucks (1997) ainda apresentaram duas regras de operação de múltiplos reservatórios em paralelo:

- 1) *NYC rule*, que tem o objetivo de igualar a probabilidade de enchimento de cada reservatório;
- 2) *Space rule*, que tem o objetivo de igualar o espaço disponível em cada um dos reservatórios ao volume afluente esperado a cada um deles durante o período de enchimento.

Autores como Lund e Guzman (1999) definiram um conjunto de regras de operação de sistemas de múltiplos reservatórios, todos eles unicamente em série ou em paralelo, atendendo um único uso (provisão de água, controle de cheias ou geração de energia) a jusante do sistema. A comparação das regras de operação propostas para ambos sistemas mostrou a existência de uma diferença conceitual no sentido que, nos sistemas de reservatórios em paralelo, vertimentos adicionais de vazões superestimadas não podem ser mais utilizados por outros reservatórios localizados a jusante, como acontece no caso de sistemas de reservatórios em série.

Quando os usos da água nos reservatórios são conflitantes, como no caso da geração de energia e o controle de cheias, a regra de operação mais conveniente não resulta tão óbvia, conforme foi apresentado por Kelman et al. (1989). Esses autores mostraram que, apesar de ser comum a alocação de volumes de espera nos reservatórios localizados mais a jusante, dado que as descargas dos reservatórios de montante serão propagadas ainda através destes, podem se apresentar algumas exceções, como no caso de reservatórios com relações cota-volume muito diferentes. Nesse caso pode acontecer que no reservatório localizado a jusante, o volume de espera gere uma grande perda de queda, enquanto que no reservatório localizado a montante, praticamente não exista essa perda.

O Brasil conta com um sistema principal de geração e transmissão de energia elétrica denominado Sistema Interligado Nacional (SIN). O SIN abrange as regiões Sul, Sudeste, Centro-Oeste, Nordeste e parte da região Norte do país. O Operador Nacional do Sistema Elétrico (ONS) é responsável pela coordenação e controle da operação do SIN. A operação do SIN é realizada pelas companhias geradoras e transmissoras, sob a fiscalização e regulação da ANEEL (Agência Nacional de Energia Elétrica). A possibilidade de troca de energia elétrica entre as regiões é o um dos principais benefícios da integração e operação coordenada (ANEEL, 2008). Os usos principais dos reservatórios de grande porte do SIN são a geração de energia e o controle de cheias.

No SIN, os sistemas de reservatórios para controle de cheias podem ser classificados em dois tipos: interdependentes e independentes. Os sistemas de reservatórios interdependentes para controle de cheias são constituídos por dois ou mais reservatórios que apresentam as seguintes características: (a) tenham capacidade de influenciar na proteção de locais situados a jusante de outros reservatórios, sujeitos à restrição de vazão máxima ou (b) possam ser influenciados por outros reservatórios situados a montante, na proteção de locais situados imediatamente a jusante (ONS, 2009a). Nesse caso, a operação de cada reservatório é feita em forma integrada, procurando atender todas as restrições do controle de cheias e de atendimento às demandas de geração de energia.

Os reservatórios que não possuem as características previamente apresentadas são considerados como sistemas independentes, e operados em forma isolada, atendendo suas próprias restrições do controle de cheias.

Conforme a metodologia utilizada no SIN, a situação de operação pode ser classificada em Normal, Atenção, Alerta e Emergência (Tabela 3. 1), em função de: (1) a caracterização de cheia na bacia hidrográfica; (2) a ocupação de volumes de espera dos reservatórios e (3) o indicativo ou a ocorrência de violação das restrições hidráulicas de vazões máximas (Q_{max}) na bacia hidrográfica.

O ONS utiliza as seguintes definições para a classificação da situação de operação (ONS, 2009b):

Caracterização de cheias: é definida pela previsão ou ocorrência de vazões naturais nos pontos de controle superiores às restrições de vazões máximas.

Ocupação de volumes de espera: os volumes de espera são definidos pela metodologia do CEPEL em função de um período de recorrência adotado. Assim, no caso de sistemas independentes, a ocupação dos volumes de espera dos reservatórios fica caracterizada quando os volumes vazios disponíveis são inferiores aos volumes de espera previamente

estabelecidos. Por sua vez, nos sistemas interdependentes, a ocupação dos volumes de espera dos reservatórios fica caracterizada quando os tempos de recorrência proporcionados pelos volumes vazios disponíveis são inferiores aos tempos de recorrência pré-estabelecidos.

Indicativo ou ocorrência de violação de restrições de Q_{max} : é estabelecido de acordo com o estado de armazenamento dos reservatórios em relação aos volumes de espera e tempos de recorrência pré-estabelecidos, avaliados para as condições presentes e futuras.

Tabela 3. 1. Classificação da situação da operação nos reservatórios do SIN.

Situação	Caracterização			
	Cheia na bacia	Ocupação de volume espera	Indicativo de violação de restrições Q_{max}	Ocorrência de violação de restrições Q_{max}
Normal	Não	Não	Não	Não
Atenção	Pode existir	Pode existir	Não	Não
Alerta	Sim	Sim	Sim	Não
Emergência	Sim	Sim	Sim	Sim

Diferentes modelos de otimização e simulação têm sido utilizados para definir as regras de operação de reservatórios. Nesse trabalho serão utilizados modelos de simulação e, em consequência, nos itens seguintes são apresentadas as principais características desses modelos.

3.2- Modelos de simulação da operação de reservatórios com base na previsão

A previsão de vazão de afluência a reservatórios se apresenta como uma ferramenta para conciliar os conflitos na operação de reservatórios com usos múltiplos. Porém, os benefícios da previsão dependem da eficiência dos modelos de previsão e da forma em que a informação da previsão é apresentada e usada pelo modelo de simulação da operação (Yao e Georgakakos, 2001).

Os primeiros modelos de simulação da operação de um reservatório com base na previsão de vazão eram simples. Estes modelos eram baseados num balanço hídrico simplificado do reservatório, onde a vazão efluente era definida com o objetivo de atender uma demanda específica constante no tempo, por exemplo: água para abastecimento, como em Mishalani e Palmer (1988). A demanda podia não ser atendida em algum intervalo de tempo se apresentado um déficit, e em consequência, perdas econômicas.

Os modelos apresentados em Yeh et al. (1982) e Mishalani e Palmer (1988) possuem um intervalo de tempo mensal e consideram previsões de longo prazo, com diferentes horizontes (de um mês até um ano). Nesses modelos, em cada intervalo de tempo são recebidos dados de previsão, em função dos quais se estabelece uma previsão de operação, ao longo do horizonte de previsão, com uma regra simples: 1) operação normal: vazão efluente igual à demanda; 2) operação otimizada: a vazão efluente é inferior à demanda em algum intervalo de tempo dentro do horizonte de previsão, porém as vazões efluentes adotadas minimizam as perdas econômicas decorrentes dos déficits. Posteriormente, o balanço hídrico real do reservatório utiliza o valor da vazão efluente no primeiro intervalo de tempo da previsão de operação e a vazão afluente observada.

Recentemente, outros pesquisadores preferiram uma abordagem alternativa para incorporar as previsões de vazão na operação de reservatórios através de modelos de simulação. Assim, Hamlet et al. (2002) e Maurer e Lettenmaier (2004) flexibilizaram as regras de operação de reservatórios nas bacias do rio Columbia e do rio Missouri, respectivamente, em função da previsão de vazão afluente. Ambos os trabalhos avaliaram, da mesma forma que nos casos anteriores, o benefício das previsões de longo prazo considerando uma simulação da operação com intervalo de tempo mensal.

Nesses trabalhos, as regras fixas de operação, que alocavam um volume do reservatório para atingir um determinado objetivo em função de eventos críticos da série histórica, foram substituídas por uma alocação dinâmica em função da informação de previsão. Outros trabalhos (por exemplo: Silveira, 1996 e Mine, 1998) se focaram, especificamente, em incorporar a previsão de vazão em modelos de simulação da operação de reservatórios com o objetivo de conciliar os conflitos entre a geração de energia e o controle de cheias. Como a utilização de um intervalo de tempo mensal nos modelos de simulação da operação de reservatórios não é apropriada para eventos como as cheias (Yeh et al., 1982), nesses trabalhos foram utilizados um intervalo de tempo diário (Silveira, 1996) e de 2 horas (Mine, 1998). As previsões de vazão utilizadas por esses autores apresentaram uma

freqüência de um dia e horizontes de 7, 10 e 20 dias (Silveira, 1996) e freqüências de 2 e 4 horas e horizontes de 12, 24, 36 e 48 horas (Mine, 1998).

O modelo de simulação da operação do reservatório desenvolvido por Silveira (1996) visa manter o reservatório sempre no nível máximo operacional, e em consequência, no ótimo da geração de energia. Nesse modelo, em cada intervalo de tempo (diário) são recebidos dados de previsão, em função dos quais se estabelece uma previsão de operação, ao longo do horizonte de previsão, com base na seguinte regra: 1) Se o volume do reservatório não supera o volume máximo operacional em nenhum intervalo de tempo dentro do horizonte de previsão, a vazão de vertimento é nula; 2) Se o volume do reservatório é igual ao volume máximo operacional, as vazões efluentes são iguais às vazões afluentes; 3) Se o volume do reservatório supera o volume máximo operacional em algum intervalo de tempo dentro do horizonte de previsão, é alocado um volume de espera. O modelo foi aplicado na operação do reservatório de Sobradinho, na bacia do rio São Francisco.

Os resultados obtidos foram comparados com os correspondentes da utilização de metodologias mais simplificadas, como o método da curva volume-duração, apresentando bons resultados do ponto de vista da geração de energia, como era esperado. Porém, os volumes de espera alocados de forma dinâmica, através desse modelo, não foram suficientes para minimizar as quebras de restrição nas diferentes cheias avaliadas. Em todos os casos avaliados, o modelo apresentou um desempenho inferior no controle de cheias, inclusive com horizonte de previsão de 20 dias.

Mine (1998) se baseou numa abordagem similar à anterior na simulação da operação com base na previsão do reservatório de Foz de Areia, localizado na bacia do rio Iguaçu. Embora essa autora utilizasse o modelo desenvolvido por Silveira (1996), ela incorporou uma divisão em zonas do volume útil do reservatório com diferentes políticas de operação.

Os resultados obtidos foram comparados com as operações reais desse reservatório. Os resultados se mostraram melhores em quase todas as avaliações realizadas, existindo benefícios na geração de energia nos sete eventos estudados. Porém, a operação real levou, em alguns eventos, a um deplecionamento do nível da água do reservatório não justificado pelo controle de cheias e que poderia ter influenciado nos resultados encontrados.

A análise dos resultados desse trabalho do ponto de vista do controle de cheias é mais difícil porque foram avaliados apenas dois eventos. Assim, no evento mais crítico, a operação com base na previsão apresentou um menor número de intervalos de tempo com níveis da água no reservatório superiores ao nível máximo operacional, o que pode ser considerado como um benefício da previsão.

É importante ressaltar uma diferença entre os problemas abordados por esses dois autores. A vazão afluente ao reservatório de Foz de Areia não possui uma sazonalidade bem definida, com cheias tanto na época de inverno como de verão. Em consequência, a alocação de volumes de espera apresenta uma grande incerteza na ausência de boas previsões de vazão. Assim, mesmo com previsões de curto prazo como as utilizadas por essa autora, a consideração de boas previsões de vazão pode trazer benefícios nesses casos.

Por fim, Bravo et al. (2008a) apresentaram um modelo de simulação da operação de um reservatório com base na previsão de vazão, denominado AMANDA, e que será utilizado nesse trabalho.

3.3- O modelo AMANDA

O modelo AMANDA (Bravo et al., 2008a) foi desenvolvido para a simulação da operação em tempo real de um reservatório com base na previsão de vazão. O AMANDA utiliza os dados das características do reservatório, demandas, restrições e as previsões de vazão.

A operação definida por esse modelo é baseada em uma curva-guia que é flexibilizada com base na informação das previsões de vazão. Esse modelo foi aplicado aos dados do reservatório de Três Marias, na bacia do rio São Francisco, permitindo estimar os benefícios da previsão, com diferentes frequências e horizontes, em um problema simplificado no qual foi considerado que o reservatório possuía apenas dois usos, o controle de cheias e a geração de energia.

O AMANDA é integrado por: (1) o modelo de balanço hídrico do reservatório, (2) o módulo de previsão de operação e (3) o módulo de operação real.

O modelo de balanço hídrico resolve a equação de continuidade, a cada intervalo de tempo, utilizando um método explícito. Dessa forma, são definidos os volumes do reservatório, vazões turbinadas e vazões de vertimento, a cada intervalo de tempo.

O módulo de previsão de operação recebe as previsões de vazão afluente para todos os intervalos de tempo do horizonte de previsão e realiza o balanço hídrico do reservatório. A função do módulo de previsão de operação é definir as vazões defluentes (turbinadas e vertidas), no dia em que são recebidos os dados de previsão para todos os intervalos de tempo dentro do horizonte de previsão. Isto é feito através de uma série de passos nos quais é verificada a possível flexibilização das regras de operação. Nesse sentido, a flexibilização é

interpretada como a alteração das decisões que seriam tomadas sem o uso da previsão, de forma de aumentar os benefícios a serem obtidos. Assim, por exemplo, no caso de reservatórios onde a geração de energia e o controle de cheias são os usos principais, a flexibilização esta associada à diminuição ou ao aumento dos volumes de espera, em função das informações da previsão.

Por fim, no módulo de operação real é realizado o balanço hídrico do reservatório com as vazões afluentes reais (observadas) e com as vazões defluentes (totais) definidas no módulo de previsão de operação. Uma descrição detalhada desse modelo é apresentada no Anexo 1 e em Bravo et al., (2008a) e em Bravo (2006).

A aplicação desse modelo permite ainda a avaliação dos benefícios incrementais do uso de previsões de vazão como subsidio à tomada de decisão na operação de reservatórios, ao comparar os benefícios econômicos da operação de reservatórios com e sem o uso das informações das previsões.

3.4- Benefícios da previsão de vazão

A previsão de vazão é a estimativa de valores de vazão para um ou mais intervalos de tempo específicos no futuro. A incorporação da previsão de vazão no processo de tomada de decisão na operação de reservatórios permite minimizar os conflitos entre os diferentes usuários d'água no reservatório. Entre os benefícios que poderiam ser obtidos considerando previsões de vazão na operação de reservatórios se encontram: (1) o incremento da geração de energia pelo aumento da queda e da minimização dos vertimentos; (2) a mitigação dos racionamentos provocados pelas secas, iniciando o reservatório com níveis superiores nos períodos de recessão; (3) a diminuição dos danos provocados pelas cheias evitando os vertimentos acima dos limites permitidos, favorecendo uma melhor definição dos volumes de espera.

O cálculo dos benefícios da previsão resulta uma tarefa complexa, pois muitas variáveis influenciam os resultados, entre elas podem ser destacadas: (1) o tamanho dos reservatórios e sua capacidade de regularização; (2) a configuração espacial e natureza das demandas em relação à hidrologia da região; (3) as características da previsão, entre elas o horizonte (antecedência), frequência (período de tempo no qual são emitidos novos dados de

previsão) e qualidade. Assim, os benefícios da previsão de vazão na operação de reservatórios podem variar de valores relativamente desprezíveis a importantes quantidades de dinheiro.

As principais dificuldades no gerenciamento dos recursos hidroenergéticos são decorrentes da incerteza nas vazões e da interdependência hidráulica entre as unidades geradoras situadas numa mesma bacia hidrográfica. As decisões de operação devem estabelecer um compromisso entre a geração hidrelétrica no momento da decisão e a disponibilidade de água nos intervalos de tempo posteriores, levando ao chamado dilema do operador (Figura 3. 2). O operador de um reservatório tem, no intervalo de tempo atual, duas opções: (1) utilizar a água ou (2) armazenar a água. Ainda, dois cenários de afluências podem se apresentar no intervalo de tempo posterior: (a) afluências altas e (b) afluências baixas. Tomada a decisão (1) e acontecendo o cenário de afluências (a), o resultado será uma operação econômica, dado que seriam evitados possíveis vertimentos. Porém, no caso de ter sido tomada a decisão (1) e acontecer o cenário de afluências (b), o resultado seria um déficit no atendimento da demanda. Por sua vez, tomada a decisão (2) e acontecendo o cenário de afluências (b), o resultado também será uma operação econômica, dado que seria evitado um possível déficit no atendimento de demandas. Porém, no caso de ter sido tomada a decisão (2) e acontecer o cenário de afluências (a), como resultado seriam obtidos vertimentos. Em todos os casos, boas previsões das vazões de afluências seriam de utilidade para auxiliar a tomada de decisão do operador.

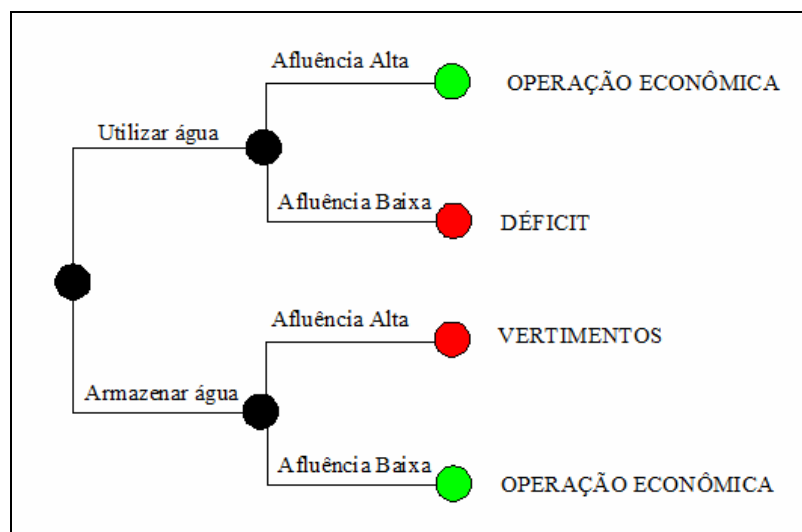


Figura 3. 2. Representação esquemática do dilema do operador.

Considerando a importância do assunto, diferentes pesquisadores têm efetuado estudos de avaliação dos benefícios econômicos da utilização da previsão de vazão na operação de

reservatórios (por exemplo, Sivapragasam et al., 2007; Bravo et al., 2007b; Bravo et al., 2008b; Maurer e Lettenmaier, 2004; Hamlet et al., 2002; Yao e Georgakakos, 2001; Faber e Stedinger 2001; Georgakakos et al., 1998; Kim e Palmer, 1997; Georgakakos, 1989; Mishalani e Palmer, 1988; Yeh et al., 1982).

A partir da década de 80 foram iniciadas, embora esporadicamente, diversas pesquisas que tentaram avaliar os benefícios da previsão de vazão afluente na operação de reservatórios. Assim, Yeh et al. (1982) foram os pioneiros em tentar dar uma resposta às perguntas: 1) qual é o valor econômico da informação de previsão para a operação de reservatórios? 2) quais devem ser os graus de precisão das previsões para obter esses benefícios? Estes autores estabeleceram as bases das análises que seriam feitas posteriormente, e avaliaram os benefícios das previsões de longo prazo com diferentes horizontes e graus de incerteza, considerando um intervalo de tempo mensal na simulação. Yeh et al. (1982), assim como Mishalani e Palmer (1988), demonstraram que os benefícios da previsão perfeita de vazão na operação de reservatórios dependem dos horizontes de previsão, isto é, maiores benefícios são obtidos para maiores horizontes de previsão. Recentemente, Bravo et al. (2008b) confirmaram os resultados previamente obtidos e ainda mostraram que os benefícios da previsão perfeita de vazão na operação de reservatórios dependem também da frequência de previsão, isto é, para um mesmo horizonte são obtidos maiores benefícios quando utilizadas previsões com menores frequências (Figura 3. 3). Ainda, a influência da frequência de previsão nos benefícios obtidos é maior para as previsões de curto prazo.




Figura 3. 3. Influência da frequência e do horizonte de previsão nos benefícios do uso de previsões de vazão. Fonte: Bravo et al., (2008b).

Outros aspectos também influenciam o benefício potencial das previsões de vazão na operação de reservatórios. Maurer e Lettenmaier (2004) analisaram os benefícios da previsão perfeita de vazão na operação de reservatórios com diferentes capacidades de regularização, e resumiram as avaliações dos benefícios da consideração da previsão de longo prazo na operação de reservatórios através de um gráfico reproduzido na Figura 3. 4. Os autores utilizaram o quociente entre o volume útil do sistema e o volume afluente médio anual para caracterizar os diferentes reservatórios ou sistemas de reservatórios. Os resultados obtidos mostraram que o benefício do uso da previsão perfeita de vazão de longo prazo na operação de reservatórios tende a aumentar na medida em que as dimensões do sistema de reservatórios (ou de um único reservatório) diminuem. Esses resultados foram ainda confirmados por Bravo et al. (2007b) para o caso de um único reservatório e são apresentados na Figura 3. 4.

Aparentemente a tendência indicada nessa figura deve se inverter, em algum momento, para reservatórios muito pequenos (volume do sistema / volume afluente próximo de zero), porque para reservatórios a fio d'água pouco benefício pode ser esperado. Nos reservatórios pequenos a operação é limitada, havendo poucas oportunidades de tomada de decisão entre utilizar/verter a água no presente ou no futuro, o que limita os benefícios da previsão.

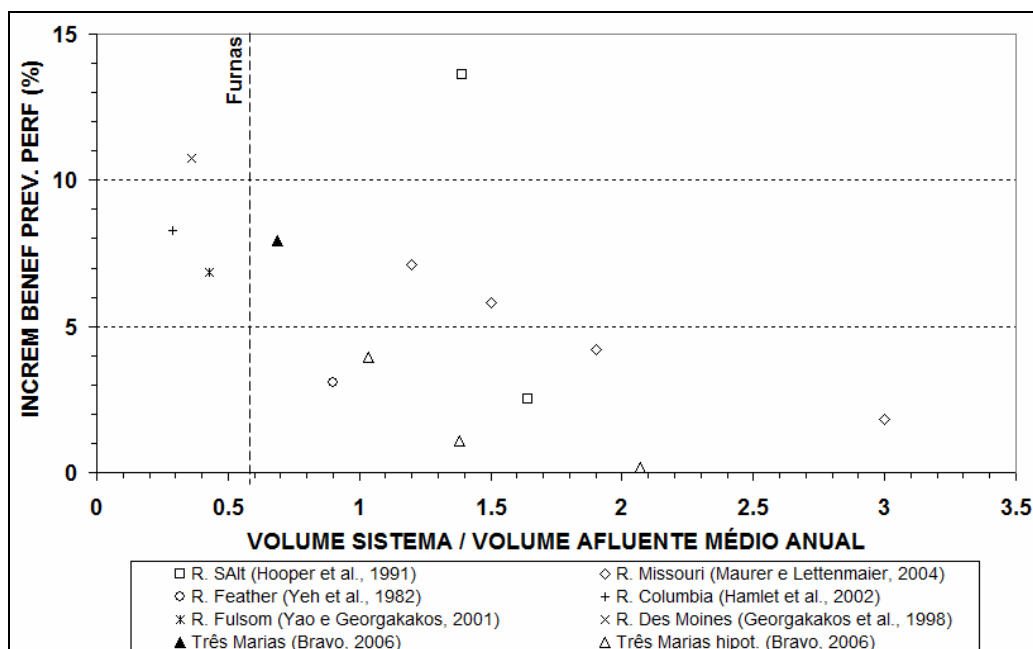


Figura 3. 4. Benefícios da previsão perfeita de longo prazo em função do quociente: volume do sistema e volume afluente médio anual (Adaptado de Bravo et al., 2007b).

Reservatórios ou sistema de reservatórios muito grandes também têm pouco benefício a ser obtido a partir de boas previsões de vazão, uma vez que são capazes de regularizar completamente um valor muito próximo à vazão média do rio. Aparentemente, os reservatórios que têm maior benefício a obter se a sua operação for baseada em boas previsões de vazão são os reservatórios cuja relação entre volume útil e volume afluente médio anual se encontra entre 0,25 e 0,5. Porém, é evidente que esta análise é dependente de outras características do sistema, bem como do tipo de previsão (longo prazo, curto prazo).

3.5- Resumo do capítulo

Nesse capítulo são apresentados as regras tradicionais de operação de um reservatório e de sistemas de reservatórios, e os modelos de simulação da operação de reservatórios com base na previsão de vazão.

No começo desse capítulo são apresentados os conceitos fundamentais das regras de operação denominadas curvas-guia, que dividem o volume útil do reservatório em diferentes “zonas” que possuem políticas de descargas específicas. Posteriormente, os fundamentos das principais regras de operação de sistemas de reservatórios são apresentados, junto com uma breve descrição de regras de operação como a *Pack rule*, *Hedging rule*, *NYC rule* e *Space rule*, entre outras. Por fim, são expostas as características do Sistema Interligado Nacional (SIN), o principal sistema de geração e transmissão de energia elétrica do Brasil. Os usos principais dos reservatórios de grande porte do SIN são a geração de energia e o controle de cheias. Os reservatórios do SIN podem ser classificados como interdependentes (quando tem uma operação integrada, como parte de um sistema de reservatórios) ou independentes (operação isolada). Conforme a metodologia utilizada no SIN, a situação de operação pode ser classificada em Normal, Atenção, Alerta e Emergência, em função de três elementos: (1) a caracterização de cheia na bacia hidrográfica; (2) a ocupação de volumes de espera dos reservatórios e (3) o indicativo ou a ocorrência de violação das restrições hidráulicas de vazões máximas na bacia hidrográfica.

Os modelos de simulação da operação de reservatórios com base na previsão são descritos, incluindo os modelos mais antigos e simples, baseados em um balanço hídrico simplificado do reservatório, até os mais complexos, que incluem a flexibilização de regras de operação de reservatórios. Uma breve descrição do modelo AMANDA, que permite a

flexibilização de regras de operação com base na informação de previsão, é apresentada. O AMANDA possui três componentes principais: o modelo de balanço hídrico do reservatório, o módulo de previsão de operação e o módulo de operação real. Esse modelo é utilizado durante esse trabalho.

Por fim, são discutidos os principais elementos que influenciam os potenciais benefícios do uso da previsão na operação de reservatórios. Considerando previsões perfeitas de vazão (previsões sem erro), foi demonstrado que os benefícios da previsão dependem do horizonte, sendo obtidos maiores benefícios para os maiores horizontes. Os benefícios da previsão também dependem da frequência da previsão, isto é, para um mesmo horizonte são obtidos maiores benefícios quando utilizadas previsões com menores frequências. Finalmente, as características dos reservatórios também se mostraram como determinantes nos benefícios a serem obtidos com o uso de previsões para subsidiar a tomada de decisão. Diversos autores têm mostrado que os reservatórios que têm maior benefício a obter se a sua operação for baseada em boas previsões de vazão são os reservatórios cuja relação entre volume útil e volume afluente médio anual se encontra entre 0,25 e 0,5.

Eu não preciso ver para onde vou, simplesmente saber por onde andei.

Mater – filme Cars

4- Medidas de desempenho das previsões

Resulta de vital importância, para o tomador de decisões, conhecer o desempenho dos modelos de previsão ao estimar as variáveis hidrológicas. Com esse fim, diferentes medidas de desempenho das previsões podem ser utilizadas, sendo apresentado nesse capítulo as mais conhecidas.

Diversos autores tentaram definir o que representa uma “boa previsão” ou, que elementos devem ser considerados para saber se as previsões são boas ou ruins. Nesse sentido, Murphy (1993) é, talvez, quem melhor tem definido esses elementos, se transformando no texto de referência para a maioria dos trabalhos posteriores.

Esse autor define três diferentes formas em que as previsões podem ser boas ou ruins: (1) Consistência, (2) Qualidade e (3) Utilidade.

A consistência leva em conta a correspondência entre as previsões e o juízo de quem faz as previsões. A qualidade mede o grau de aproximação entre valores observados e previstos. Assim, previsões de boa qualidade apresentam uma adequada correspondência entre valores previstos e observados. Por fim, a utilidade considera os benefícios incrementais do uso das previsões durante o processo de tomada de decisão. Murphy (1993) ressalta que as previsões não possuem valor intrínseco, elas adquirem valor através de sua capacidade de influenciar as decisões dos usuários das previsões.

Esse capítulo apresenta uma descrição dessas duas últimas formas de avaliar as previsões: qualidade e utilidade.

4.1- Medidas de desempenho tradicionais

As medidas de desempenho tradicionalmente utilizadas para avaliar a qualidade das previsões de vazão são baseadas no erro entre os valores previstos e observados (Casati et al.,

2008; Murphy, 1993). Assim, qualquer dessas medidas de desempenho compara uma série de pares de valores (previstos e observados) e pondera as diferenças de uma forma particular. Exmplos desse tipo de medidas de desempenho são o Coeficiente de Nash-Sutcliffe ou coeficiente de eficiência (CE); o Erro padrão da previsão (EP); o Erro médio absoluto (EMA) e o Erro médio relativo (EMR). As equações dessas medidas de desempenho foram previamente apresentadas no item 2.3.5 (veja as equações 2.11 a 2.14).

No caso do EP, EMA e EMR, os modelos de previsão que apresentem valores menores nestas medidas de desempenho serão considerados melhores, sendo o valor obtido com previsão perfeita (previsão hipotética que não apresenta erros) igual a zero, em qualquer dessas medidas de desempenho. Já no caso do CE, quanto mais próximo de um se encontrar esse valor, melhores serão os modelos de previsão. Utilizando previsões perfeitas o valor do CE é igual a um.

Quando diferentes modelos de previsão são aplicados a um estudo de caso, o desempenho desses modelos é, normalmente, avaliado em função da qualidade das previsões. Algumas dessas medidas de desempenho foram recentemente utilizadas no Brasil para comparar a qualidade das previsões de vazão de afluência a reservatórios do SIN, obtidas com diferentes modelos, conforme apresentado em Guilhon et al. (2007).

Além das medidas de desempenho tradicionais, existem outras medidas de desempenho que foram utilizadas em menor grau pela comunidade científica, mas que são também de grande utilidade quando comparados modelos com diferentes números de parâmetros, conforme apresentado a seguir.

4.2- Medidas de desempenho e número de parâmetros do modelo

As medidas de desempenho apresentadas tradicionais, não levam em conta o número de parâmetros existentes nos diferentes modelos. As medidas de desempenho apresentadas nesse item procuram identificar os modelos mais parcimoniosos, isto é, aqueles modelos que apresentam um desempenho aceitável com o menor número de parâmetros. Dawson e Wilby (2001) apresentam uma série de medidas de desempenho que podem ser utilizadas nesses casos, se destacando o *Akaike's information criterion* - AIC (Akaike, 1974) e o *Bayesian information criterion* - BIC (Schwarz, 1978), conforme as equações a seguir:

$$AIC = n \ln(EP) + 2par \quad (4.1)$$

$$BIC = n \ln(EP) + par \ln(n) \quad (4.2)$$

onde n é o número de dados no período analisado; par é o número de parâmetros do modelo de previsão e EP é o erro padrão da previsão.

Em ambos os casos, os modelos que apresentarem os menores valores dessas medidas de desempenho serão considerados os melhores. Observa-se, ainda, na equação 4.5 e na equação 4.6 que ambas medidas de desempenho são funções crescentes do erro padrão da previsão e do número de parâmetros do modelo. Assim, para modelos com o mesmo valor do erro padrão da previsão, aqueles modelos que possuem um maior número de parâmetros são penalizados por essas medidas de desempenho.

A Figura 4. 1 e a Figura 4. 2 apresentam o comportamento típico dessas medidas de desempenho, para diferentes valores do número de dados (n) e do número de parâmetros (par). Nessas figuras é apresentado o quociente entre o valor da medida de desempenho (AIC ou BIC) e o valor da medida de desempenho obtido com um modelo com apenas um parâmetro (AIC_{p1} ou BIC_{p1}).

Observa-se nessas figuras que o valor da penalidade por cada parâmetro adicional é maior no caso do BIC, se comparado ao AIC (veja e compare os eixos de ordenadas em ambas figuras). Além disso, essas figuras mostram que quanto menor o tamanho do número de dados, maior é o incremento no valor absoluto da penalidade para cada parâmetro adicional do modelo.

Uma metodologia alternativa, que também considera a parcimônia do modelo nas medidas de desempenho tradicionais, foi proposta por Clarke (2008). Nesse caso, o autor introduz o termo que leva em conta o número de parâmetros, conforme apresentado a seguir, na equação 4.3:

$$EPM = \left[\frac{1}{n - par} \sum_{i=1}^N (Qp_i - Qo_i)^2 \right]^{1/2} \quad (4.3)$$

onde EPM é o erro padrão modificado da previsão.

A Figura 4. 3 apresenta o comportamento típico dessa medida de desempenho, para diferentes valores do número de dados (n) e do número de parâmetros (par). Nessa figura é apresentado o quociente entre o valor do erro padrão modificado e do erro padrão da previsão,

observando-se que o incremento devido ao aumento do número de parâmetros segue uma lei exponencial, diferentemente das medidas de desempenho AIC e BIC, que resultava uma relação linear.




Figura 4. 1. Quociente AIC / AIC_{p1} , para um erro padrão igual $100 \text{ m}^3 \cdot \text{s}^{-1}$, em função do número de parâmetros e para diferentes valores do número de dados (n).




Figura 4. 2. Quociente BIC / BIC_{p1} , para um erro padrão igual $100 \text{ m}^3 \cdot \text{s}^{-1}$, em função do número de parâmetros e para diferentes valores do número de dados (n).




Figura 4. 3. Quociente EPm / EP, para um erro padrão igual $100 \text{ m}^3 \cdot \text{s}^{-1}$, em função do número de parâmetros e para diferentes valores do número de dados (n).

O uso de medidas de desempenho modificadas se apresentou como uma alternativa viável no auxílio da obtenção de modelos parcimoniosos durante o treinamento de modelos de redes neurais, conforme apresentado por Bravo et al. (2008a). Esses autores fizeram uma avaliação da melhoria nas previsões de vazão utilizando modelos de redes neurais artificiais, à medida que era aumentado o número de neurônios na camada intermediária do modelo (aumentando o número de parâmetros). Um índice baseado em quatro medidas de desempenho, modificadas conforme Clarke (2008), foi calculado para identificar a arquitetura do modelo que apresentava a melhor relação entre desempenho e parcimônia.

4.3- Medidas de desempenho baseadas em tabelas de contingência

Quando o evento a ser previsto apresenta apenas dois resultados possíveis (evento dicotômico), por exemplo, a vazão superará um certo valor ou não, acontecerá uma cheia ou não, outro grupo de medidas de desempenho pode ser utilizado. Nesse caso, as medidas de desempenho podem ser obtidas a partir da informação resumida em tabelas de contingência.

Uma tabela de contingência 2x2 (Figura 4. 4) apresenta o arranjo das quatro possíveis combinações de pares previsão/evento que podem acontecer em um evento dicótomos (Wilks, 2006). Em função do exemplo apresentado na Figura 4. 4, o evento foi corretamente previsto (acertos ou *hits*) “a” vezes de um total de n previsões. Por sua vez, “b” vezes o evento foi previsto, mas não aconteceu (alarme falso ou *false alarm*). Ainda, “c” vezes o evento aconteceu, mas não foi previsto (erro ou *misses*). Por fim, “d” vezes a previsão indicou que o evento não aconteceria e o evento não aconteceu (rejeição correta ou *correct rejection*).

(i)		Observado	
		Sim	Não
P r e v i s t o	Sim	a	b
	Não	c	d

(ii)		Observado	
		Sim	Não
P r e v i s t o	Sim	f_{1,1} = a/n	f_{1,2} = b/n
	Não	f_{2,1} = c/n	f_{2,2} = d/n

Figura 4. 4. Tabela de contingência de um evento dicótomos em termos de: (i) frequência absoluta e (ii) frequência relativa.

Dois medidas de desempenho, estimadas com base na informação apresentada na tabela de contingência, são frequentemente utilizadas para caracterizar a qualidade das previsões (Wilks, 2006): (1) a Taxa de acertos (TA) e (2) a Taxa de alarme falso (TAF). A Taxa de acertos (equação 4.4) representa a proporção dos eventos que aconteceram, que foram corretamente previstos. Por sua vez, a Taxa de alarme falso (equação 4.5) representa a proporção dos eventos que não aconteceram, que foram previstos que aconteceriam.

$$TA = \frac{a}{a + c} \tag{4.4}$$

$$TAF = \frac{b}{b + d} \tag{4.5}$$

Outras medidas de desempenho podem ser estimadas a partir de tabelas de contingência, conforme apresentado por diferentes autores (por exemplo, Wilks, 2006; Ebert, 2008; Göber et al., 2004; Seaman et al., 1996; Stephenson et al., 2008).

Nos casos em que o evento a ser previsto possui três ou mais resultados possíveis, Gandin e Murphy (1992) e Gerrity (1992) sugeriram uma medida de desempenho das previsões chamada de *Gandin-Murphy skill score* (GMSS). Essa medida de desempenho permite levar em conta a distância (dada pelo número de linhas ou colunas da tabela de contingência) no erro da previsão quando três ou mais eventos que possuem um ordenamento natural são previstos. Assim, na estimativa dessa medida de desempenho, uma previsão que erra múltiplas categorias é considerada pior que uma previsão que erra uma única categoria.

O *Gandin-Murphy skill score* (equação 4.6) é baseado nas freqüências de ocorrência das combinações possíveis do evento analisado, que são ponderadas por pesos que tendem a dar maior importância a previsões corretas de eventos raros, e menor importância a previsões corretas de eventos comuns:

$$GMSS = \sum_{i=1}^I \sum_{j=1}^J (f_{i,j} \cdot w_{i,j}) \quad (4.6)$$

onde $f_{i,j}$ é a freqüência relativa de ocorrência da combinação previsão do evento i e ocorrência do evento j e $w_{i,j}$ é o peso correspondente à combinação de eventos i,j , dado por Gerrity (1992).

Os valores dos pesos são estimados em função da equação 4.7 à equação 4.9 (Gerrity, 1992), apresentadas a seguir:

$$D_j = \frac{1 - \sum_{r=1}^j f_r}{\sum_{r=1}^j f_r} \quad ; \quad j = 1, \dots, J-1 \quad (4.7)$$

$$w_{j,j} = \frac{1}{J-1} \left[\sum_{r=1}^{j-1} \frac{1}{D_r} + \sum_{r=j}^{J-1} D_r \right] \quad j = 1, \dots, J \quad (4.8)$$

$$w_{i,j} = \frac{1}{J-1} \left[\sum_{r=1}^{i-1} \frac{1}{D_r} + \sum_{r=j}^{J-1} D_r - (j-i) \right] \quad ; \quad 1 \leq i \leq j \leq J \quad (4.9)$$

Dessa forma, a equação 4.8 define os pesos das freqüências de previsões corretas, enquanto que a equação 4.9 define os pesos das freqüências de previsões incorretas. Uma

medida de desempenho baseada no *Gandin-Murphy skill score* é desenvolvida nesse trabalho, conforme apresentado adiante no texto.

As medidas de desempenho apresentadas até aqui medem o grau de aproximação entre valores observados e previstos e, em consequência, mostram a qualidade das previsões. No entanto, a utilidade das previsões considera os benefícios incrementais do uso das previsões durante o processo de tomada de decisão. Nos dois próximos itens é apresentada uma discussão sobre as qualidades e as utilidades das previsões na operação de reservatórios.

4.4- Problema da relação custo/perda

A abordagem do problema da relação custo/perda (*cost/loss ratio problem*) é baseada em um modelo simplificado de tomada de decisão. Essa abordagem tem sido tipicamente utilizada apesar de sua simplicidade, devido a que consegue aproximar, de forma razoável, um grande número de problemas reais, simples, de tomada de decisão (Roebber e Bosart, 1996).

Esse problema considera a existência de um tomador de decisão para o qual um evento adverso pode ou não acontecer (evento dicotômico) e que tem a opção de se proteger ou não, contra a possibilidade de ocorrência do evento adverso (Wilks, 2001).

Para tornar mais fácil a explicação dessa abordagem, um exemplo do problema da relação custo/perda é apresentado a seguir de forma similar ao dilema do operador apresentado no capítulo anterior. Nesse sentido, o tomador de decisões é o operador de um reservatório cujos usos principais são o controle de cheias e a geração de energia. Por sua vez, o evento é uma cheia. Conforme essa abordagem, podem acontecer dois eventos: cheia ou não cheia, e o tomador de decisões tem duas opções, criar um volume de espera ou não criar um volume de espera no reservatório.

Se o operador do reservatório decide se proteger, criando um volume de espera, conseguirá, nesse problema hipotético, evitar qualquer quebra de restrição de vazões máximas a jusante ou do nível máximo do reservatório, mas essa decisão terá um custo C , devido à diminuição da geração de energia atual ou futura. Dessa forma, quando tomada a decisão de se proteger, o custo C associado é independente da ocorrência ou não do evento de cheia.

Se o evento da cheia acontecer e não foram criados volumes de espera, o operador do reservatório sofre uma perda L ($L > C$), como consequência das quebras das restrições

previamente apresentadas. Por sua vez, no caso que não tenham sido criados volumes de espera e o evento da cheia não acontecer, as perdas são iguais a zero.

A decisão ótima de criar ou não volumes de espera é aquela que gera o menor custo esperado. A informação disponibilizada ao operador do reservatório é que o evento cheia ocorrerá com uma probabilidade p . Se a criação de volumes de espera é sempre selecionada, o custo C será cometido com probabilidade igual a um. Caso contrário, uma perda L será sofrida com probabilidade p . Assim, a criação de volumes de espera é ótima sempre que:

$$C < p \cdot L \Rightarrow \frac{C}{L} < p \quad (4.10)$$

Isto é, a criação de volumes de espera é ótima, quando a relação C/L é menor que a probabilidade de ocorrência de cheias.

A abordagem previamente apresentada permite, além de definir as decisões ótimas, estimar os custos esperados associados a previsões com diferentes características. Assim, por exemplo, se o operador do reservatório teria acesso a previsões perfeitas do evento da cheia, os volumes de espera no reservatório seriam criados apenas nos eventos de cheias e, em consequência, o custo esperado seria igual a:

$$CE_{perf} = C \cdot \varphi \quad (4.11)$$

onde: CE_{perf} é o custo esperado da previsão perfeita; φ é igual à probabilidade de ocorrência de cheias.

O custo esperado das decisões custo/perda baseadas em previsões com modelos (previsões com erros) depende das características dessas previsões. Um conjunto de previsões probabilísticas de um evento dicótomio pode ser caracterizado por uma distribuição de probabilidades conjunta (Figura 4. 5). O operador do reservatório, com base nessas previsões probabilísticas, possui um limiar de decisão ótimo “D”, correspondente à relação C/L . Isto é, o limiar de decisão D é o valor do índice i correspondente à menor probabilidade f_i que é maior que C/L . O operador do reservatório transforma as previsões probabilísticas em previsões categóricas do evento dicótomio, cheia ou não cheia, da seguinte forma: as probabilidades f_i para as quais i é maior ou igual a D são transformadas em previsões de cheias, enquanto que as probabilidades f_i para as quais $i < D$ são transformadas em previsões de não cheias (Wilks, 2006).

Combinando os elementos de ambas tabelas apresentadas na Figura 4. 5, o custo esperado associado às previsões caracterizadas pela distribuição de probabilidades conjunta $p(f_i, o_j)$ é dado pela equação 4.12:

$$CE_f = (p_{1,1} + p_{1,0}) \cdot C + p_{0,1} \cdot L \quad (4.12)$$

Observa-se que o custo esperado depende da natureza do tomador de decisões através da relação C/L que define o limiar de decisão D e da qualidade das previsões probabilísticas disponibilizadas.

(a)		Cheia	
		Sim	Não
Cria Volume espera	Sim	C	C
	Não	L	0

(b)		Evento Observado	
		Sim	Não
Previsão do evento	Sim	$p_{11} = \sum_{i \geq D} p(f_i, o_1)$	$p_{10} = \sum_{i \geq D} p(f_i, o_0)$
	Não	$p_{01} = \sum_{i < D} p(f_i, o_1)$	$p_{00} = \sum_{i < D} p(f_i, o_0)$

Figura 4. 5. (a) Função de perda para a relação custo/perda; (b) Tabela correspondente obtida a partir de previsões probabilísticas caracterizadas pela distribuição de probabilidade conjunta $p(f_i, o_j)$ transformada em previsões categóricas através da relação custo/perda.

Esse tipo de abordagem tem sido aplicado em um grande número de estudos, como por exemplo apresentados em Wilks (2001); Thornes e Stephenson (2001); Richardson (2000) e Roulin (2007). Em todos os casos são utilizadas previsões probabilísticas ou transformações a esse tipo de previsões.

4.5- Qualidade vs utilidade das previsões

No caso da operação de reservatórios com usos conflitantes como, por exemplo, o controle de cheias e a geração de energia, um exemplo prático pode deixar mais clara a diferença entre as utilidades das previsões e a qualidade das previsões definidas com base nas medidas de desempenho previamente apresentadas.

IPH (2005) apresentou os resultados de dois modelos hipotéticos de previsão de vazão, cujas previsões são chamadas de “ingênuo” e “esperto” (Figura 4. 6). Ambos os modelos prevêem o valor observado quando esse é menor que o valor médio da série histórica. Por sua vez, quando o valor observado é maior que o valor médio, os modelos apresentam um comportamento diferente: (1) o modelo que gera a previsão ingênuo prevê sempre o valor médio da série histórica; (2) o modelo que gera a previsão esperto prevê sempre o valor observado mais a diferença entre o valor observado e a previsão ingênuo. As equações 4.13 a 4.15 definem as previsões ingênuo e esperto.




Figura 4. 6. Previsões hipotéticas de vazão (Adaptado de IPH,2005).

se $Q_o^i \leq Q_m$, então

$$Q_{pI}^i = Q_{pE}^i = Q_o^i \quad (4.13)$$

se $Q_o^i > Q_m$, então

$$Q_{pI}^i = Q_m \quad (4.14)$$

$$Q_{pE}^i = Q_o^i + (Q_o^i - Q_{pI}^i) \quad (4.15)$$

onde Q_{PI}^i é o valor da previsão ingênua no intervalo de tempo i , Q_{PE}^i é o valor da previsão esperta no intervalo de tempo i , Q_o^i é a vazão observada no intervalo de tempo i e Q_m é a vazão média da série histórica.

A maioria das medidas de desempenho, baseadas no erro da previsão, quando aplicadas às previsões ingênua e esperta, apresentariam valores iguais para as duas previsões, dado que a previsão ingênua subestima as vazões na mesma quantidade que a previsão esperta as superestima.

É evidente que o uso de uma ou outra previsão terá impactos diferentes nos resultados da operação de reservatórios. Do ponto de vista do controle de cheias, a previsão esperta teria uma maior utilidade, dado que ao superestimar os eventos observados, certamente seriam criados maiores volumes de espera, evitando-se inundações a jusante do reservatório, embora isto também estaria associado com uma perda de geração. Entretanto, a previsão ingênua teria uma utilidade praticamente nula, já que nenhum evento de cheia é previsto, sempre prevendo o valor médio da série. Por sua vez, desde o ponto de vista da geração de energia, a previsão esperta teria pouca utilidade em razão do possível aumento dos volumes de espera, para alocar as cheias previstas que posteriormente não acontecem. Já a previsão ingênua teria uma maior utilidade desde o ponto de vista da geração de energia, dado que os volumes de espera poderia ter sido reduzido, por se esperar cheias menores às de projeto, embora isto possa incorrer em inundações a jusante e quebras de restrições do controle de cheias.

4.6- Resumo do capítulo

Nesse capítulo são apresentados os principais conceitos associados às medidas de desempenho das previsões e à forma como as previsões podem ser avaliadas, sendo o foco do texto a qualidade e a utilidade das previsões.

A qualidade das previsões mede o grau de aproximação entre valores observados e previstos. Por sua vez, a utilidade considera os benefícios incrementais do uso das previsões durante o processo de tomada de decisão. Neste caso admite-se que as previsões não possuem valor intrínseco, adquirindo valor através de sua capacidade de influenciar as decisões dos usuários.

As medidas de desempenho tradicionalmente utilizadas para avaliar a qualidade das previsões de vazão são baseadas no erro entre os valores previstos e observados. Um grande

número de medidas de desempenho pertence a esse grupo, como por exemplo, o Coeficiente de Nash-Sutcliffe, o Erro padrão da previsão, o Erro médio absoluto ou o Erro médio relativo. Outras medidas de desempenho alternativas levam também em conta o número de parâmetros dos modelos de previsão, procurando favorecer aos modelos mais parcimoniosos.

Posteriormente são apresentadas as medidas de desempenho baseadas em tabelas de contingência. No seu formato mais simples, uma tabela de contingência 2x2 apresenta o arranjo das quatro possíveis combinações de pares previsão/evento que podem acontecer em um evento dicotômico. A partir da informação resumida nessas tabelas, diferentes medidas de desempenho podem ser calculadas, sendo as mais conhecidas a Taxa de acertos e a Taxa de alarme falso.

O problema da relação custo/perda é ainda descrito nesse capítulo. Trata-se de uma abordagem baseada em um modelo simplificado de tomada de decisão, que apresenta um tomador de decisão para o qual um evento adverso pode ou não acontecer (evento dicotômico) e que tem a opção de se proteger ou não, contra a possibilidade de ocorrência do evento adverso. A partir dessa representação podem ser obtidas as decisões ótimas enquanto a operação de reservatórios. Ainda, podem ser estimados os custos esperados associados a previsões probabilísticas com diferentes características em aplicações simplificadas.

Por fim, um exemplo prático é apresentado com o objetivo de deixar mais clara a diferença entre a utilidade das previsões e a sua qualidade. Assim, através do uso de previsões hipotéticas, denominadas esperta e ingênua, que se caracterizam por apresentar o mesmo valor das maiorias das medidas de desempenhos baseadas no erro da previsão, é comprovada a diferença nas utilidades durante a operação de um reservatório com dois usos principais, a geração de energia e o controle de cheias.

I have not lost my mind, it's backed up on disk somewhere.

Anônimo, na geladeira da Kirsten - Lund

5- Metodologia

A metodologia utilizada nesse trabalho para produzir subsídios à tomada de decisão na operação de reservatórios com base na previsão de variáveis hidrológicas é composta por três processos apresentados a seguir, cada um deles descrito separadamente no texto:

- 1) Previsão de vazão de curto prazo.
- 2) Previsão de precipitação de longo prazo
- 3) Medida de desempenho das previsões com base na utilidade.

5.1- Previsões de vazão de curto prazo

Dois procedimentos são utilizados, neste trabalho, para definir as previsões de vazão de curto prazo. No primeiro procedimento são obtidas previsões de vazão com base em modelos de redes neurais artificiais. No segundo procedimento são obtidas previsões hipotéticas de vazão, agregando em forma estocástica um erro, com estatísticas predefinidas, aos valores observados.

5.1.1- Previsões com modelos

Para a obtenção de previsões de vazão de curto prazo com base em modelos de redes neurais artificiais foi utilizada a metodologia apresentada a seguir, e sintetizada na Figura 5. 1.

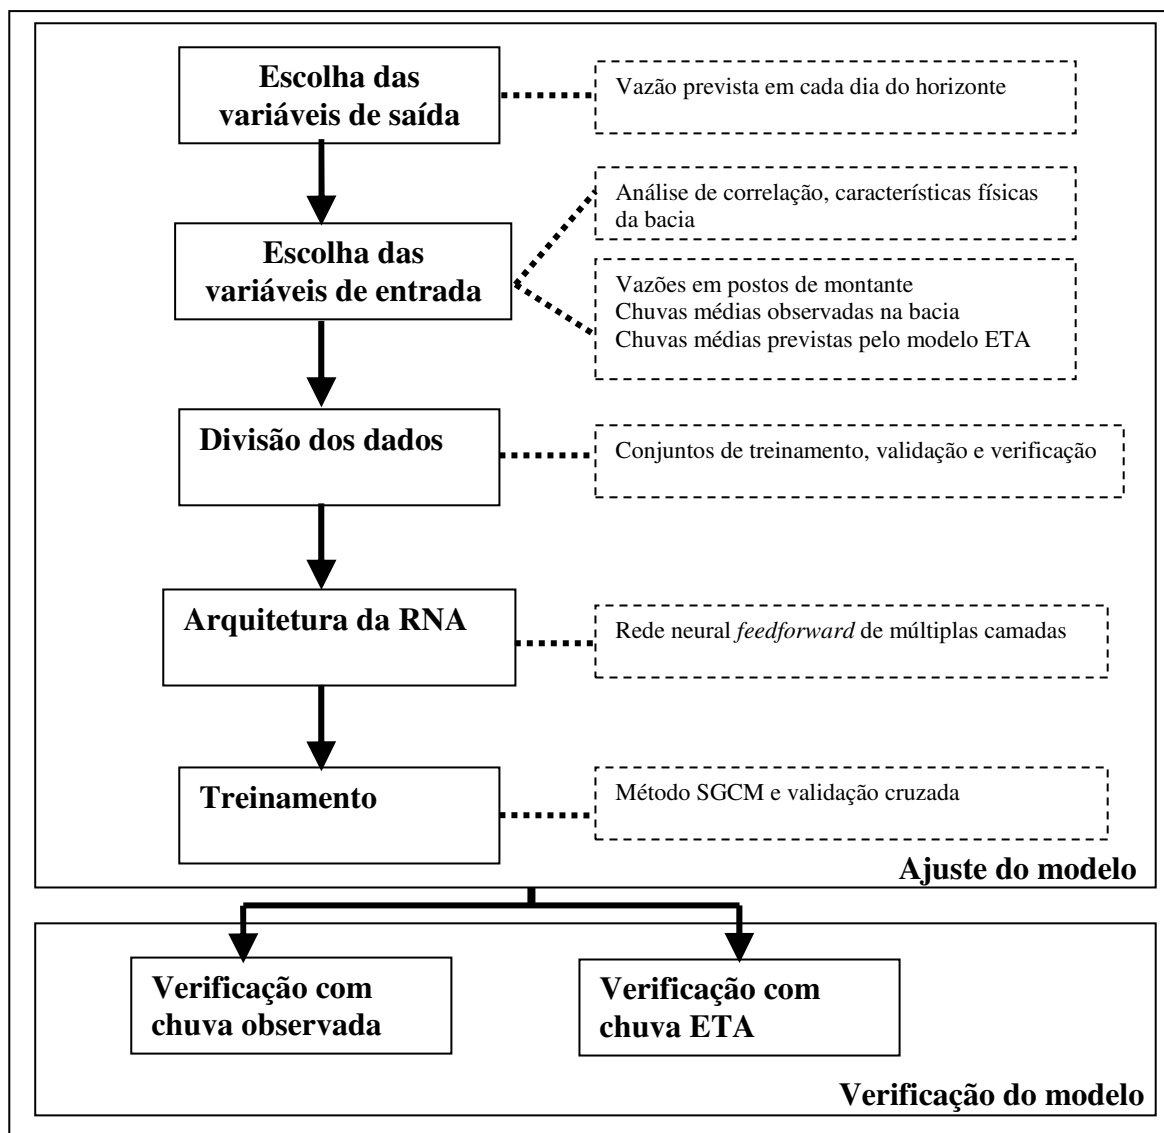


Figura 5. 1. Estrutura metodológica para a geração de previsões de vazão de curto prazo com modelos.

As variáveis de entrada são definidas em função de uma análise de correlação entre o conjunto de variáveis de entrada candidatas e a vazão média diária do local de interesse. Ainda são levadas em conta, durante o processo de definição das variáveis de entrada, as características físicas da bacia hidrográfica de contribuição ao local de interesse.

Uma das variáveis de entrada é baseada na precipitação. Para diminuir o número de parâmetros do modelo, e assim obter um modelo mais parcimonioso, a variável de entrada baseada na precipitação leva em conta a informação da precipitação antecedente (observada) e da previsão quantitativa de chuva. Assim, por exemplo, a Figura 5. 2 ilustra como uma variável de entrada baseada na precipitação, a precipitação acumulada de doze dias ($P_{ma12}(t)$) é definida conforme o intervalo de tempo dentro do horizonte de previsão para o

qual está sendo efetuada a previsão de vazão. Cada linha dessa figura mostra como é estimado o valor dessa variável para cada dia do horizonte de previsão de 12 dias.

Essa variável de entrada tem valores diferentes, conforme o intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão. Por exemplo, quando é feita a previsão para o dia $t+1$, são considerados os valores de precipitação média (na bacia) diária acumulada entre os dias $t-11$ e t . Nesse caso são utilizados somente valores observados de precipitação. Entretanto, no caso da previsão feita para o dia $t+2$, por exemplo, são considerados os valores de precipitação média (na bacia) diária acumulada entre os dias $t-10$ e $t+1$. Nesse caso são utilizados valores de precipitação observada entre os dias $t-10$ e t e o valor de precipitação prevista no dia $t+1$ (Figura 5. 2).



Figura 5. 2. Cálculo da variável precipitação média na bacia diária acumulada ($P_{ma12}(t)$) em função do intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão (o primeiro dia da previsão é $t+1$).

As variáveis de saída dos modelos são as vazões previstas em cada dia até o horizonte de previsão. Na metodologia utilizada, cada modelo de rede neural artificial prevê a vazão para um dia dentro do horizonte de previsão. Dessa forma, cada modelo possui um único neurônio na camada de saída, correspondente ao valor da vazão prevista em um determinado dia do horizonte da previsão.

As redes neurais artificiais utilizadas possuem uma arquitetura do tipo progressiva de três camadas (uma camada de entrada, uma camada intermediária e uma camada de saída, Figura 5. 3).

O número de neurônios na camada de entrada é igual ao número de variáveis de entrada, previamente definidas. Por sua vez, os modelos apresentam um único neurônio na camada de saída, o qual corresponde ao valor da vazão prevista em um determinado intervalo de tempo dentro do horizonte de previsão.

Por fim, o número de neurônios da camada intermediária é determinado independentemente para cada modelo através de um procedimento de experimentação

sistemática com busca de melhores resultados. Inicia-se o procedimento com um número considerado grande de neurônios, sendo retirado, sucessivamente, um neurônio a cada treinamento e avaliação de desempenho, até a obtenção de uma configuração com desempenho ainda satisfatório, com o menor número de neurônios na camada intermediária (Figura 5. 4).




Figura 5. 3. Arquitetura de uma rede neural artificial progressiva de três camadas.




Figura 5. 4. Procedimento de experimentação sistemática para estimativa da arquitetura de uma rede neural artificial progressiva de três camadas.

Apesar de utilizar uma variável de entrada que incorpora previsões quantitativas de chuva, durante o treinamento são utilizados apenas valores observados das variáveis (por exemplo, da precipitação). Isto é, nos conjuntos de treinamento e validação do modelo é utilizada chuva observada como previsão, e, em consequência, uma informação de previsão quantitativa de chuva que não apresenta erros. As informações de variáveis previstas são utilizadas apenas durante a verificação do desempenho do modelo. Isto tem duas grandes vantagens: (1) poderia ser utilizado um maior número de dados já que o período das séries de

dados observados é tipicamente muito superior ao período em que existem previsões quantitativas de chuva e (2) o treinamento do modelo desenvolvido não fica prejudicado pelas diferentes versões do modelo de previsão de chuva ao longo do tempo.

Por sua vez, a validação cruzada é utilizada como critério de parada do treinamento. Nesse sentido, é feita a divisão dos dados em três conjuntos: treinamento, validação e verificação. A divisão dos dados para treinamento e validação é feita de forma a obter conjuntos com média e desvio padrão similares nas diferentes variáveis de entrada.

Os modelos de redes neurais artificiais são treinados com o *scaled conjugate gradient method* (SCGM - Moller, 1993), utilizando como função-objetivo, para avaliar o desempenho da rede neural, o erro padrão de previsão.

Nessa etapa do trabalho, os modelos de redes neurais artificiais são projetados e treinados utilizando as funções do *Neural Network Toolbox* (Demuth et al., 2006) do software MATLAB.

A verificação do desempenho da rede é feita para cada dia do horizonte de previsão utilizando o Erro padrão de previsão (EP); o Erro médio absoluto (EMA); o Erro médio relativo (EMR); o Coeficiente de eficiência ou coeficiente de Nash-Sutcliffe (CE). Ainda são calculadas duas medidas de desempenho alternativas: (1) o Erro médio relativo da previsão no quarto dia da previsão (EMR_j , $j = 4$) e (2) o Erro médio relativo da média dos valores previstos, entre o quarto e o décimo dia do horizonte de previsão (EMR_{4-10}). Essas medidas de desempenho são tradicionalmente utilizadas pelo ONS para avaliar o desempenho de diferentes modelos de previsão.

5.1.2- Previsões hipotéticas

Para a obtenção de um maior número de previsões de vazão de curto prazo, cujo desempenho como subsídio à tomada de decisão na operação de reservatórios possa ser avaliado, é utilizada uma metodologia simplificada para a geração de previsões hipotéticas de vazão. Essas previsões hipotéticas de vazão apresentam um comportamento típico, a partir da introdução de erros aos valores observados.

É importante ressaltar que existe um grande número de modelos que podem ser utilizados nessa etapa, cada um definido em função de um comportamento particular. Nesse trabalho foram utilizados os cinco modelos descritos a seguir no texto. Versões mais

simplificadas de alguns desses modelos foram utilizados previamente, por exemplo, em Yeh et al. (1982).

Os modelos que geram previsões hipotéticas de vazão, desenvolvidos nesse trabalho, são apresentados a seguir:

Previsões ingênua e esperta

Essas previsões têm um comportamento particular: a ingênua sempre subestima as vazões superiores à vazão média, enquanto que a previsão esperta sempre superestima essas vazões. As previsões ingênua e esperta são definidas com base na equação 4.13 à equação 4.15, apresentadas no item 4.5.

Previsões com defasagem

Essas previsões apresentam uma defasagem se comparadas aos valores observados das vazões (antecipam ou atrasam).

$$Q_{pD}^i = Q_o^{i+\Delta} \quad (5.1)$$

onde Q_{pD}^i é o valor da previsão com defasagem no intervalo de tempo i , Δ é o número de intervalos de tempo de defasagem; $Q_o^{i+\Delta}$ é a vazão observada no intervalo de tempo $i+\Delta$.

Previsões com erro segundo uma distribuição estatística

Essas previsões apresentam um erro que segue uma distribuição estatística pré-especificada. Esse erro é então agregado aos valores observados de vazão. Dessa forma, diferentes graus de incerteza podem ser representados. Nesse tipo de previsões hipotéticas são apresentados dois modelos. O primeiro gera previsões com erros segundo uma distribuição normal, com e sem tendência crescente no valor médio e no desvio padrão dos erros (equação 5.2). Por sua vez, o segundo modelo gera previsões com erros segundo uma distribuição uniforme, com e sem tendência crescente no valor médio e nos extremos do intervalo dos erros (equação 5.5).

As equações que produzem as previsões com erros segundo uma distribuição normal são apresentadas a seguir:

$$Q_{pEn}^i = Q_o^i + Q_o^i \cdot (\mu + \varepsilon_0^1 \cdot \sigma) \quad (5.2)$$

onde Q_{pEn}^i é o valor da previsão com erro segundo uma distribuição normal com média μ e desvio padrão σ , assumido padronizado em função de Q_o^i , no intervalo de tempo i ; Q_o^i é a vazão observada no intervalo de tempo i ; ε_0^1 é um número aleatório com distribuição normal com média zero e desvio padrão igual a 1.

Quando as previsões têm um horizonte superior a um intervalo de tempo, a média e o desvio padrão do erro podem crescer linearmente, em função da seguinte equação:

$$\mu = \mu_0 + tend^\mu \quad (5.3)$$

$$\sigma = \sigma_0 + tend^\sigma \quad (5.4)$$

onde μ_0 é o valor da média do erro no primeiro intervalo de tempo da previsão e $tend^\mu$ é o valor da tendência na qual será incrementado o valor da média do erro durante os próximos intervalos de tempo da previsão; σ_0 é o valor do desvio padrão do erro, assumido padronizado em função de Q_o^i , no primeiro intervalo de tempo da previsão e $tend^\sigma$ é o valor da tendência na qual será incrementado o valor do desvio padrão do erro durante os próximos intervalos de tempo da previsão.

As equações que definem as previsões com erros segundo uma distribuição uniforme são apresentadas a seguir:

$$Q_{pEu}^i = Q_o^i \cdot (1 + \mu) \cdot (1 - Lim + 2 \cdot Lim \cdot \eta_0^1) \quad (5.5)$$

onde Q_{pEu}^i é o valor da previsão com erro segundo uma distribuição uniforme entre $\mu-Lim$ e $\mu+Lim$, no intervalo de tempo i , sendo μ o ponto central do intervalo de variação do erro e Lim os extremos, assumido padronizado em função de Q_o^i ; Q_o^i é a vazão observada no intervalo de tempo i ; η_0^1 é um número aleatório com distribuição uniforme entre zero e um.

Quando as previsões têm um horizonte superior a um intervalo de tempo, os extremos e ponto central do intervalo do erro podem crescer linearmente, em função da seguinte equação:

$$\mu = \mu_0 + tend^\mu \quad (5.6)$$

$$Lim = Lim_0 + tend^{Lim} \quad (5.7)$$

onde μ_0 é o valor do ponto central do intervalo de variação no primeiro intervalo de tempo da previsão e $tend^\mu$ é o valor da tendência na qual será incrementado o valor do ponto central do intervalo de variação; Lim_0 é o valor do extremo do intervalo de variação do erro, assumido padronizado em função de Q_o^i , no primeiro intervalo de tempo da previsão e $tend^{Lim}$ é o valor da tendência na qual será incrementado o valor do extremo do intervalo de variação do erro durante os próximos intervalos de tempo da previsão.

Previsões de persistência

Essas previsões correspondem ao último valor observado da vazão, independentemente de qual seja o intervalo de tempo dentro do horizonte de previsão.

$$Q_{pP}^{i+j} = Q_o^i \quad j=1, Horiz \quad (5.8)$$

onde Q_{pP}^{i+j} é o valor da previsão de persistência no intervalo de tempo $i+j$, Q_o^i é a vazão observada no intervalo de tempo i .

Por fim, a previsão perfeita de vazão (vazões observadas como previsão) é ainda utilizada para estimar os patamares superiores dos benefícios que podem ser alcançados.

Todos os modelos foram desenvolvidos para estimar previsões com qualquer frequência e horizonte utilizando a plataforma do software Fortran 90.

5.2- Previsões de longo prazo de chuva

Para a obtenção de previsões de precipitação de longo prazo com base nos índices climáticos através de um modelo de rede neural artificial, é utilizada uma metodologia apresentada a seguir no texto e sintetizada na Figura 5. 5.

As variáveis de entrada são definidas em função de uma análise de correlação entre os índices climáticos e a precipitação. No entanto, a validade física dos fenômenos representados resulta de vital importância e, em consequência, uma busca exaustiva de combinações de variáveis de entrada que apresentem um sustento físico é ainda efetuada.

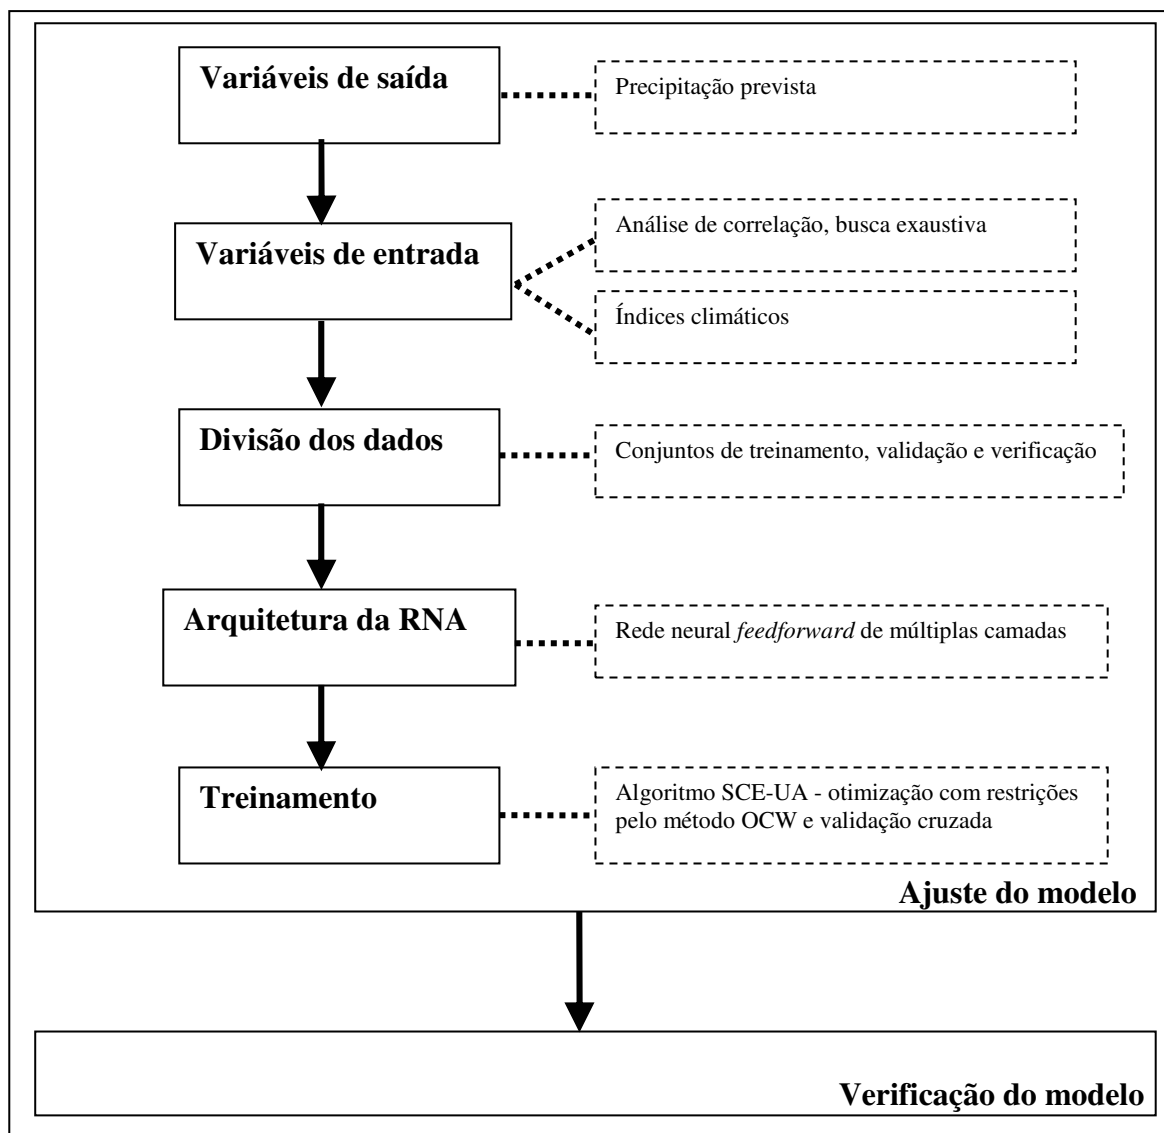


Figura 5. 5. Estrutura metodológica para a geração de previsões de precipitação de longo prazo.

A variável de saída do modelo são as precipitações previstas para uma estação do ano, por exemplo, a estação chuvosa. Dessa forma, o modelo possui um único neurônio na camada de saída, correspondente ao valor da precipitação prevista.

Da mesma forma que nos modelos de previsão de vazão de curto prazo, é utilizada uma rede neural com arquitetura do tipo progressiva de três camadas (uma camada de entrada, uma camada intermediária e uma camada de saída).

O número de neurônios na camada de entrada é igual ao número de índices climáticos utilizados, previamente identificado. Por sua vez, o número de neurônios da camada intermediária é determinado através de um procedimento de experimentação sistemática com

busca de melhores resultados, conforme previamente apresentado no modelo de previsão de vazão de curto prazo.

Dado que, neste caso, tipicamente se trabalha com séries temporais de muito poucos dados, é aplicado um procedimento particular de treinamento da rede neural artificial. Nesse caso é ainda utilizada a validação cruzada como critério de parada do treinamento e a distribuição dos dados nos três conjuntos, o de treinamento, o de validação e o de verificação. Porém, o treinamento do modelo de rede neural artificial é baseado no uso do algoritmo evolucionário SCE-UA (*Shuffled Complex Evolution – University of Arizona*), desenvolvido por Duan et al. (1992), e a teoria de estabelecimento dos valores dos pesos com sustento físico, estabelecido por Olden e Jackson (2002).

Vários métodos têm sido propostos para determinar quanto contribui uma variável de entrada no valor dado por modelos empíricos à variável de saída (Kingston et al., 2005; Sarle, 2000). Nesse trabalho é utilizada uma versão modificada do *Overall Connection Weight (OCW) Approach* (Olden e Jackson, 2002), apresentado por Kingston et al. (2005), que permite determinar a contribuição de cada variável de entrada, nesse caso, a contribuição de cada índice climático, ao valor da variável de saída.

Durante o processo de treinamento, com base nessa metodologia, o problema de otimização é definido como, por exemplo, apresentado a seguir:

$$\text{Min: FO} = 1 - \text{CE} + \text{Pen} \quad (5.9)$$

$$\text{s.t. ROCWX}_i > 0 \text{ ou } < 0 ; \quad (5.10)$$

onde FO é a função-objetivo; CE é o coeficiente de eficiência ou de Nash-Sutcliffe; Pen é uma penalidade, cujo valor depende da verificação de restrições; ROCWX_i é a contribuição relativa da variável de entrada X_i . O valor da penalidade é igual a zero quando as restrições são atendidas. No caso contrário, a penalidade apresenta um valor maior que zero.

Todos os modelos desenvolvidos nessa etapa foram programados utilizando a plataforma do software Fortran 90.

5.3- Medida de desempenho com base na utilidade da previsão

A medida de desempenho baseada na utilidade da previsão desenvolvida nesse trabalho é estimada a partir do *Gandin-Murphy skill score* aplicado, porém, aos resultados do

uso de previsões de curto prazo (operação do reservatório) e não à combinação de valores previstos e observados das variáveis hidrológicas, como tipicamente é utilizado.

Nesse sentido, é necessário o uso de um modelo de operação de reservatórios que permita a flexibilização das regras de operação, com base na informação da previsão das variáveis hidrológicas. Para melhor entender esse conceito, a seguir é apresentado um exemplo, mostrando em que consiste a flexibilização de regras de operação em reservatórios com dois usos conflitantes, como o controle de cheias e a geração de energia.

Para atender a estes objetivos, o controle de cheias e a geração de energia, o nível d'água no reservatório é reduzido no início e durante o período chuvoso, para permitir amortecer vazões afluentes altas. Em função disto, ocorre uma redução da produção energética potencial, se comparada ao cenário de maximização do nível d'água no reservatório que representaria a operação otimizada, sob o ponto de vista da geração de energia. O volume criado no reservatório pelo rebaixamento do nível é denominado de volume de espera. A curva definida pela relação entre o nível d'água necessário para garantir um determinado volume de espera e a época do ano é chamada de curva-guia para controle de cheias.

Essa curva representa uma regra de operação simples para controle de cheias, que pode ser expressa como: se o nível d'água no reservatório estiver acima da curva-guia é necessário verter; se estiver abaixo não é necessário verter. Um exemplo simples de curva-guia é apresentado na Figura 5. 6.




Figura 5. 6. Exemplo de curva-guia para controle de cheias com volume de espera variável durante o ano.

Geralmente, essas curvas-guia são definidas em função de eventos de projeto com uma determinada recorrência pré-estabelecida como, por exemplo, apresentado em Kelman (1987)

e no capítulo 3 desse trabalho. Porém, o evento que acontece durante o período analisado pode ter uma recorrência maior, sendo necessário um maior volume de espera, para evitar a quebra de restrições do controle de cheias. Ainda, pode-se apresentar um evento de menor recorrência, podendo os volumes de espera serem reduzidos para maximizar a geração de energia e a probabilidade de enchimento do reservatório no final do período chuvoso. É, nesses casos, que a flexibilização da curva-guia para controle de cheias, com base nas informações da previsão de vazão, pode se transformar em um elemento que valorize a utilidade da previsão para os operadores de reservatórios.

A Figura 5. 7 apresenta os possíveis resultados que poderiam ser obtidos com a flexibilização de uma regra de operação (nesse exemplo, uma curva-guia para controle de cheias) com base no uso de previsões de vazão obtidas com diferentes modelos. Na Figura 5. 7(A) são apresentados os resultados do uso de previsões perfeitas de vazão, quando se apresenta um evento menor que os implicitamente considerados como de projeto (na cor verde), e quando se apresenta um evento maior que os implicitamente considerados como de projeto (na cor vermelha). A curva-guia na cor preta corresponde àquela que seria obtida com base em eventos de projeto de recorrência pré-estabelecida. Dessa forma, em ambos os casos são evitadas as quebras de restrições do controle de cheias sendo maximizada ainda, a geração de energia. Observa-se, também, que no caso do evento menor àqueles implicitamente considerados como de projeto, existiu uma flexibilização (-) associada a uma diminuição dos volumes de espera (menor número de vertimentos), se comparada à regra de operação de projeto. Por sua vez, no caso do evento maior aos implicitamente considerados como de projeto, existiu uma flexibilização (+) associada a um aumento dos volumes de espera (e a um maior número de vertimentos). Em ambos os casos, esses resultados seriam ideais, já que estariam sendo utilizadas previsões de vazão que não apresentam erros.

No caso de previsões de vazão obtidas com modelos, a Figura 5. 7(B) apresenta os resultados que poderiam ser obtidos (na cor azul), no caso do evento ser menor aos implicitamente considerados como de projeto. Observa-se, nesse caso, que os resultados da flexibilização não seguem sempre o comportamento da curva-guia flexibilizada com base no uso da previsão perfeita de vazão (apresentada na cor verde na Figura 5. 7(B)), devido aos erros nas previsões.

É importante ressaltar, também, que os resultados das flexibilizações de regras de operação dependem do horizonte e frequência da previsão, além das características do reservatório.




Figura 5. 7. Exemplo de flexibilizações de curva-guia para controle de cheias com base na previsão de vazão, (A) com previsão perfeita para um evento menor (na cor verde) ou maior (na cor vermelha) que o de projeto (na cor preta); (B) com previsão com modelos durante um evento menor ao de projeto.

A metodologia utilizada para a definição da medida de desempenho com base na utilidade da previsão é apresentada a seguir e sintetizada na Figura 5. 8.

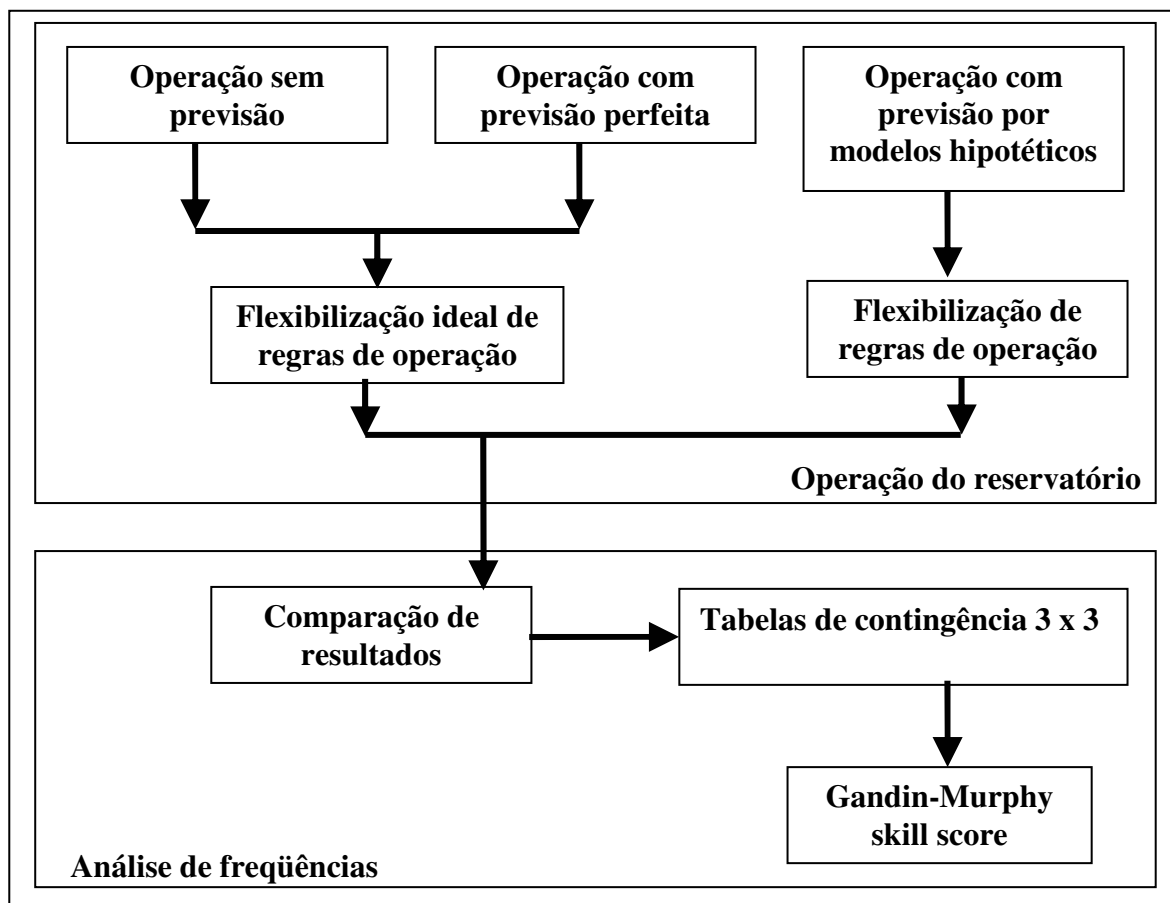


Figura 5. 8. Estrutura metodológica para definição da medida de desempenho com base na utilidade das previsões.

Em uma primeira etapa da estimativa da medida de desempenho baseada na utilidade, proposta neste trabalho, é feita a operação do reservatório sem previsão. Isto é, a operação segue a curva-guia de projeto, obtendo-se como resultado a série de níveis do reservatório ($NS_i, i=1,N$) e vertimentos ($VS_i, i=1,N$) ao longo do período de simulação (N) (Figura 5. 9(a))

Posteriormente, é feita a operação do reservatório com base na previsão perfeita de vazão, determinando a seqüência de flexibilizações mais conveniente das regras de operação (flexibilização (+) indicaria o aumento dos volumes de espera e o maior número de vertimentos; flexibilização (-) indicaria a diminuição dos volumes de espera e o menor número de vertimentos e, por último, poderia não existir flexibilização (volumes de espera e vertimentos definidos pela própria curva-guia de projeto)). Nessa etapa é obtida como resultado, a série de níveis do reservatório ($NP_i, i=1,N$) e vertimentos ($VP_i, i=1,N$) ao longo do período de simulação sob uma operação ideal (Figura 5. 9(b)), na qual as previsões não apresentam erro.

Na seqüência, é feita a operação do reservatório com base em previsões de vazão obtidas por modelos cujos desempenhos estão sendo avaliados e, estimada a série de flexibilizações decorrentes do uso de cada um desses conjuntos de previsões. Assim, uma nova série de níveis do reservatório ($NM_i, i=1,N$) e vertimentos ($VM_i, i=1,N$) ao longo do período de simulação é obtida, em função do uso das previsões de cada modelo (Figura 5. 9(c)).

(a) Sem previsão		(b) Previsão perfeita		(c) Previsão com modelos	
NS_1	VS_1	NP_1	VP_1	NM_1	VM_1
NS_2	VS_2	NP_2	VP_2	NM_2	VM_2
NS_3	VS_3	NP_3	VP_3	NM_3	VM_3
...
...
...
NS_i	VS_i	NP_i	VP_i	NM_i	VM_i
NS_{i+1}	VS_{i+1}	NP_{i+1}	VP_{i+1}	NM_{i+1}	VM_{i+1}
...
...
NS_{N-1}	VS_{N-1}	NP_{N-1}	VP_{N-1}	NM_{N-1}	VM_{N-1}
NS_N	VS_N	NP_N	VP_N	NM_N	VM_N

Figura 5. 9. Resultados da operação de um reservatório: (a) sem o uso de previsões de vazão de curto prazo; (b) utilizando previsões perfeitas de vazão e (c) utilizando previsões de vazão obtidas com modelos.

Por fim, uma tabela de contingência 3x3 é calculada com base nos resultados da operação, identificando as frequências de ocorrências da combinação de eventos indicados na Figura 5. 10, para cada um dos modelos de previsão. Observa-se, nessa figura, que está sendo comparado o resultado do uso da previsão, dado pelo conceito de uma correta flexibilização das regras de operação de reservatórios. A flexibilização das regras de operação pode ser avaliada pela comparação dos níveis do reservatório ou dos vertimentos obtidos pelo uso das previsões de vazão com os modelos e os correspondentes valores obtidos durante a operação com previsão perfeita de vazão.

A tabela de contingência apresentada na Figura 5. 10 mostra as frequências relativas de ocorrência dos eventos apresentados a seguir (célula – linha,coluna):

- **célula 1,1:** uso de previsão perfeita leva à flexibilização (+) das regras de operação e uso de previsão com modelos leva à flexibilização (+) das regras de operação.
- **célula 1,2:** uso de previsão perfeita não flexibiliza as regras de operação e uso de previsão com modelos leva à flexibilização (+) das regras de operação.
- **célula 1,3:** uso de previsão perfeita leva à flexibilização (-) das regras de operação e uso de previsão com modelos leva à flexibilização (+) das regras de operação.
- **célula 2,1:** uso de previsão perfeita leva à flexibilização (+) das regras de operação e uso de previsão com modelos não flexibiliza as regras de operação.
- **célula 2,2:** uso de previsão perfeita não flexibiliza as regras de operação e uso de previsão com modelos não flexibiliza as regras de operação.
- **célula 2,3:** uso de previsão perfeita leva à flexibilização (-) das regras de operação e uso de previsão com modelos não flexibiliza as regras de operação.
- **célula 3,1:** uso de previsão perfeita leva à flexibilização (+) das regras de operação e uso de previsão com modelos leva à flexibilização (-) das regras de operação.
- **célula 3,2:** uso de previsão perfeita não flexibiliza as regras de operação e uso de previsão com modelos leva à flexibilização (-) das regras de operação.
- **célula 3,3:** uso de previsão perfeita leva à flexibilização (-) das regras de operação e uso de previsão com modelos leva à flexibilização (-) das regras de operação.

		Previsão perfeita		
		Flexib. (+)	Sem flexib.	Flexib. (-)
P r e v i s t o r i o s	Flexib. (+)	$f_{1,1}$	$f_{1,2}$	$f_{1,3}$
	Sem flexib.	$f_{2,1}$	$f_{2,2}$	$f_{2,3}$
	Flexib. (-)	$f_{3,1}$	$f_{3,2}$	$f_{3,3}$
		$f_1 = \sum f_{i,1}$	$f_2 = \sum f_{i,2}$	$f_3 = \sum f_{i,3}$

Figura 5. 10. Tabela de contingência para a definição da medida de desempenho com base na utilidade.

A partir dos resultados dessa tabela é estimada a medida de desempenho proposta utilizando-se o *Gandin-Murphy skill score* (equações 4.6 a 4.9 no item 4.3).

Nessa etapa são ainda estimados os benefícios da previsão de vazão em função dos resultados obtidos com operação do reservatório com base na curva-guia sem uso de previsões e com o uso das previsões. Os benefícios são estimados em termos relativos, para diminuir a influência de qualquer simplificação adotada.

Todos os modelos desenvolvidos nessa etapa foram programados utilizando a plataforma do software Fortran 90.

5.4- Resumo da metodologia

A metodologia utilizada na estimativa de subsídios à tomada de decisão na operação de reservatórios com base na previsão de variáveis hidrológicas é composta por três processos: a previsão de vazão de curto prazo, a previsão de precipitação de longo prazo e uma medida de desempenho com base na utilidade das previsões.

Dois procedimentos são utilizados para definir as previsões de vazão de curto prazo. No primeiro procedimento são obtidas previsões de vazão com base em modelos empíricos de redes neurais artificiais utilizando ainda previsões quantitativas de chuva. Apesar de utilizar

uma variável de entrada que incorpora previsões quantitativas de chuva, durante o treinamento são utilizados apenas valores observados das variáveis (por exemplo, da precipitação). Isto é, nos conjuntos de treinamento e validação do modelo é utilizada chuva observada como previsão, e, em consequência, uma informação de previsão quantitativa de chuva que não apresenta erros. As informações de variáveis previstas são utilizadas apenas durante a verificação do desempenho do modelo. Isto tem duas grandes vantagens: (1) poderia ser utilizado um maior número de dados já que o período das séries de dados observados é tipicamente muito superior ao período em que existem previsões quantitativas de chuva e (2) o treinamento do modelo desenvolvido não fica prejudicado pelas diferentes versões do modelo de previsão de chuva ao longo do tempo. No segundo procedimento são obtidas previsões hipotéticas de vazão, agregando em forma estocástica um erro, com estatísticas predefinidas, aos valores observados. Os modelos que geram previsões hipotéticas de vazão, desenvolvidos nesse trabalho, são: previsões ingênua e esperta, previsões com defasagem, previsões com erro segundo uma distribuição estatística, previsões de persistência e previsões perfeitas.

As previsões de precipitação de longo prazo são obtidas com base no uso de índices climáticos como variáveis de entrada a um modelo de rede neural artificial. No sentido de assegurar o sustento físico do modelo desenvolvido, um processo de otimização com restrições é feito baseado no uso do algoritmo evolucionário SCE-UA e do *Overall Connection Weight Approach*, que permite determinar a contribuição de cada variável de entrada.

Por fim, a medida de desempenho baseada na utilidade da previsão é estimada a partir do *Gandin-Murphy skill score* aplicado, porém, aos resultados do uso de previsões de curto prazo (operação do reservatório, níveis ou vertimentos) e não à combinação de valores previstos e observados das variáveis hidrológicas. Nesse sentido, é utilizado um modelo de operação de reservatórios que permite a flexibilização das regras de operação, com base na informação da previsão das variáveis hidrológicas.

Às vezes é preciso parar e olhar para longe, para podermos enxergar o que está diante de nós.

John Kennedy

6- Aplicação da metodologia

Dois estudos de casos foram selecionados, conforme apresentado a seguir. O primeiro estudo de caso foi utilizado na aplicação da metodologia completa, isto é, foram geradas previsões de vazão de curto prazo, previsões de precipitação de longo prazo e avaliada a medida de desempenho com base na utilidade das previsões na operação de reservatórios. O segundo estudo de caso foi utilizado apenas na avaliação da medida de desempenho com base na utilidade das previsões.

6.1- O estudo de caso 1

O reservatório de Furnas foi selecionado como estudo de caso devido, principalmente, à disponibilidade de previsões quantitativas de chuva de curto prazo para a região, desenvolvidas no âmbito do projeto FAURGS-FINEP 40.04.0094.00 (IPH, 2005), e pela importância desse reservatório na região analisada e no SIN.

O reservatório de Furnas localiza-se na bacia do Rio Grande, em Minas Gerais, Brasil. A bacia contribuinte ao reservatório de Furnas compreende uma área de 51.900 km², equivalente praticamente à terceira parte da área da bacia do Rio Grande (Figura 6. 1).

Na Figura 6. 1(c) apresenta-se a bacia afluente ao reservatório de Furnas, cujos dados são utilizados nesse trabalho. Essa bacia é integrada por cinco sub-bacias: Ibituruna, Camargos, Porto dos Buenos, Caruaçu e incremental de Furnas. Os círculos pretos identificam os postos fluviométricos ou usinas localizadas nos exutórios das sub-bacias. No caso das usinas, os dados de vazão se referem à vazão natural reconstituída fornecida pelo próprio ONS.

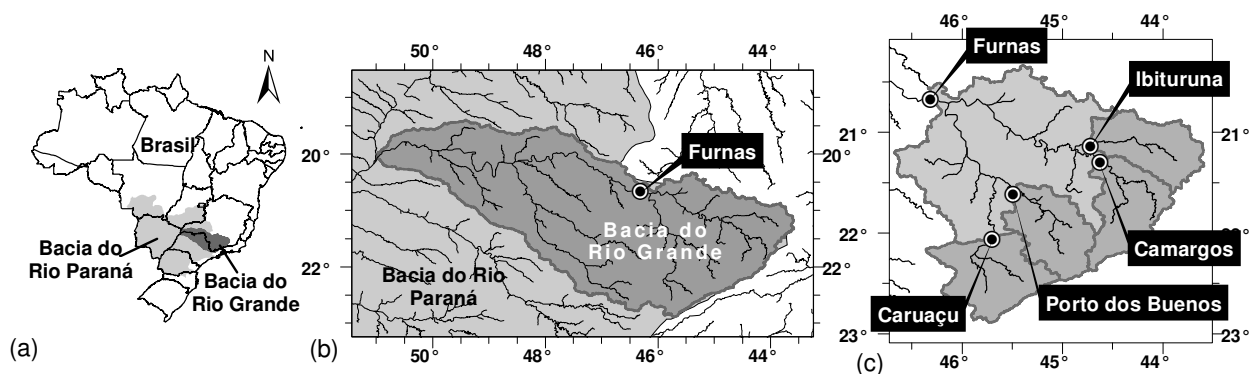


Figura 6. 1. Localização da área de estudo.

A bacia do Rio Grande tem grande importância no contexto da geração hidrelétrica brasileira, com uma capacidade instalada de 7.722MW, representando 10,2% da capacidade instalada nas usinas hidrelétricas do país (BIG-ANEEL, 2010). Além de Furnas, destacam-se na bacia as usinas hidrelétricas de Marimbondo, Água Vermelha e Estreito, cada uma com potência instalada superior a 1.000 MW (Figura 6. 2). Nessa região também predomina a agricultura, com grandes áreas destinadas à produção de cana de açúcar. As pastagens e a produção de frutos são também realizadas, mas em menor grau.

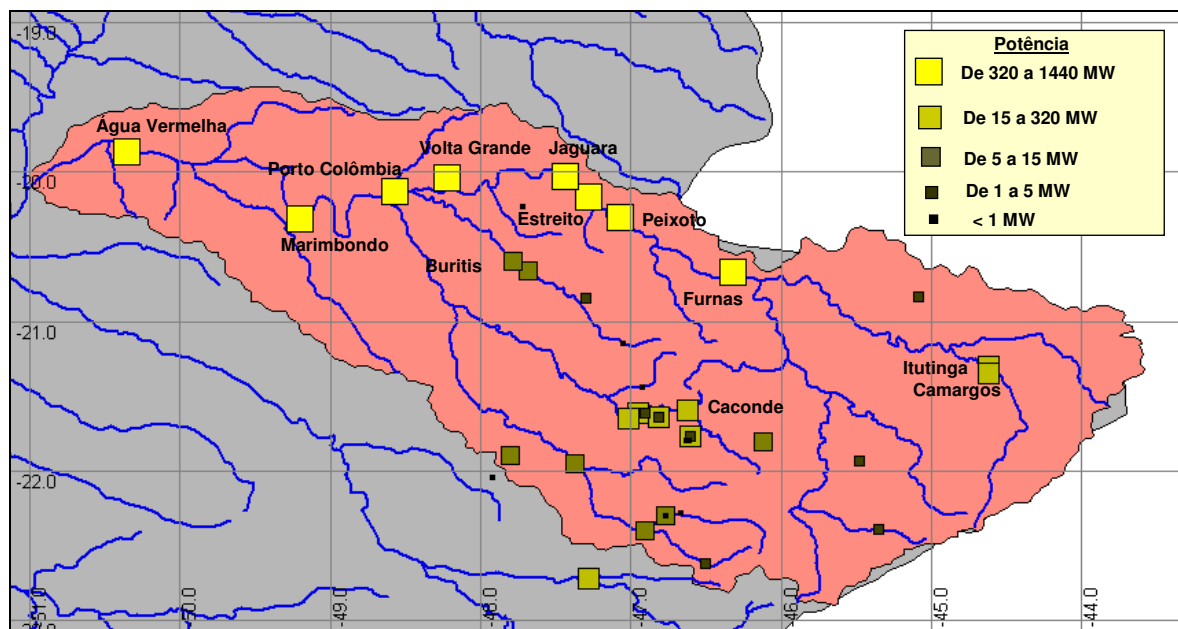


Figura 6. 2. Localização dos principais aproveitamentos hidroelétricos na bacia do Rio Grande classificados pela potência de geração de energia (Fonte: IPH, 2005).

A vazão do Rio Grande afluente a Furnas tem uma forte variação sazonal, como resultado do inverno seco e do verão chuvoso. A vazão afluente varia entre valores próximos

a $350 \text{ m}^3 \cdot \text{s}^{-1}$, no período de estiagem, e valores tipicamente superiores a $2000 \text{ m}^3 \cdot \text{s}^{-1}$ no período de verão, com algumas cheias superiores a $4000 \text{ m}^3 \cdot \text{s}^{-1}$.

6.2- O estudo de caso 2

Os reservatórios operados para atender demandas de água para abastecimento, irrigação e geração de energia são, normalmente, mantidos em níveis tão altos como possível para garantir uma reserva de água que será utilizada durante os períodos críticos de estiagem. Por sua vez, reservatórios operados com o objetivo de reduzir inundações a jusante da barragem são mantidos em níveis mínimos para que as cheias possam ser absorvidas e as vazões máximas reduzidas. Quando um mesmo reservatório é operado para atender os dois tipos de objetivos surgem conflitos.

Um exemplo é o caso do reservatório de Três Marias, no rio São Francisco, em Minas Gerais. Este reservatório é operado de forma a evitar vazões superiores ao limite que provoca inundações na cidade de Pirapora, localizada a jusante, como mostra o esquema da Figura 6. 3. Também é necessário evitar que o nível da água no reservatório supere uma cota máxima a partir da qual começam a ocorrer inundações na cidade de Morada Nova de Minas localizada a montante. Assim, embora seja possível verter uma vazão muito alta (vazão de projeto do vertedor), na operação normal existem restrições de jusante.

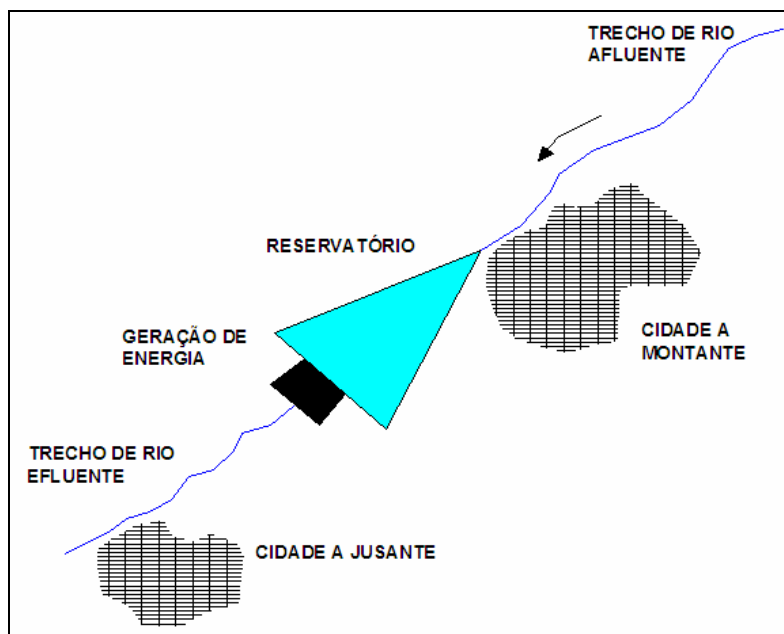


Figura 6. 3. Esquema da configuração espacial do sistema analisado.

6.3- Dados dos estudos de caso

6.3.1- Dados utilizados nas previsões de vazão de curto prazo

Nesse trabalho são estimadas previsões de curto prazo de vazão de afluência ao reservatório de Furnas com base em previsões quantitativas de chuvas.

Dados de precipitação diária foram obtidos de 274 postos pluviométricos (Figura 6. 4) a partir do banco de dados da Agência Nacional de Águas (ANA) e do sistema de informações do gerenciamento dos recursos hídricos da cidade de São Paulo. Esses postos pluviométricos se encontram uniformemente distribuídos ao longo da bacia do Rio Grande e apresentam dados no período de 1950 a 2003. Nesse trabalho, foram utilizados os dados de 101 postos pluviométricos localizados no interior e nas proximidades da bacia hidrográfica de Furnas.

Os dados utilizados na estimativa das previsões de curto prazo de vazão de afluência ao reservatório de Furnas são: (1) vazões diárias em Furnas e nos exutórios das sub-bacias de montante (Ibituruna, Camargos, Porto dos Buenos e Caruaçu - Figura 6. 5); (2) precipitações diárias médias observadas sobre a área de cada sub-bacia e na bacia de contribuição ao reservatório de Furnas; (3) precipitações diárias médias previstas pelo modelo ETA sobre cada sub-bacia e na bacia.




Figura 6. 4. Localização da bacia do rio Grande, com destaque na bacia de contribuição ao reservatório de Furnas, e postos pluviométricos com dados disponibilizados.

As séries de precipitações médias diárias sobre as diferentes sub-bacias e sobre a bacia de contribuição ao reservatório de Furnas são apresentadas no Anexo 2. As séries históricas

de vazão nos postos fluviométricos de Porto dos Buenos e Caruaçu foram obtidas do site Hidroweb da Agência Nacional de Águas. Por sua vez, as séries de vazão nos exutórios das sub-bacias Ibituruna, Camargos e Furnas correspondem a vazões naturais reconstituídas e foram obtidas do site do ONS. Essas séries apresentam dados no período de 1970 a 2001 e são ainda reproduzidas no Anexo 2.

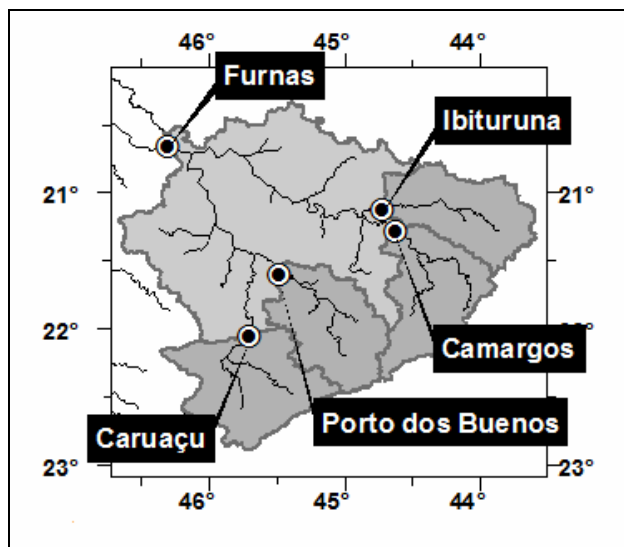


Figura 6. 5. Exutórios das sub-bacias.

As precipitações apresentam uma sazonalidade bem definida na região como pode ser observada pela Figura 6. 6, onde são apresentados os valores médios mensais nas diferentes sub-bacias e sobre a bacia de contribuição ao reservatório de Furnas. Observa-se nessa figura que os valores de precipitação mensal possuem um mesmo comportamento e uma clara sazonalidade, com um período mais chuvoso começando no mês de outubro e se estendendo até o mês de março. Os meses de dezembro, janeiro e fevereiro são, em média, os meses mais chuvosos na região.

A Figura 6. 7 apresenta a série de precipitações totais anuais adimensionalizadas com relação a sua média, nas sub-bacias e na bacia de contribuição ao reservatório de Furnas. Não se observam períodos anômalos nos dados. Apenas dois anos de eventos extremos se destacam nessa figura. O primeiro evento extremo corresponde a um ano relativamente seco, o ano 1963, onde a precipitação total foi inferior ao 50% da precipitação média anual em todas as sub-bacias e na bacia de contribuição ao reservatório de Furnas. O segundo evento extremo corresponde a um ano relativamente úmido (ano de 1983), onde a precipitação total superou em 60% a 80% a precipitação média anual, dependendo da sub-bacia.




Figura 6. 6. Precipitação mensal média nas sub-bacias e na bacia de contribuição ao reservatório de Furnas.




Figura 6. 7. Precipitações totais anuais adimensionalizadas com relação a sua média, nas sub-bacias e na bacia de contribuição ao reservatório de Furnas.

As principais características associadas com a pluviometria média mensal (valores médios, mínimos e máximos de cada mês) e sazonalidade das precipitações em cada sub-bacia e na bacia de contribuição ao reservatório de Furnas são apresentadas na Figura 6. 8.

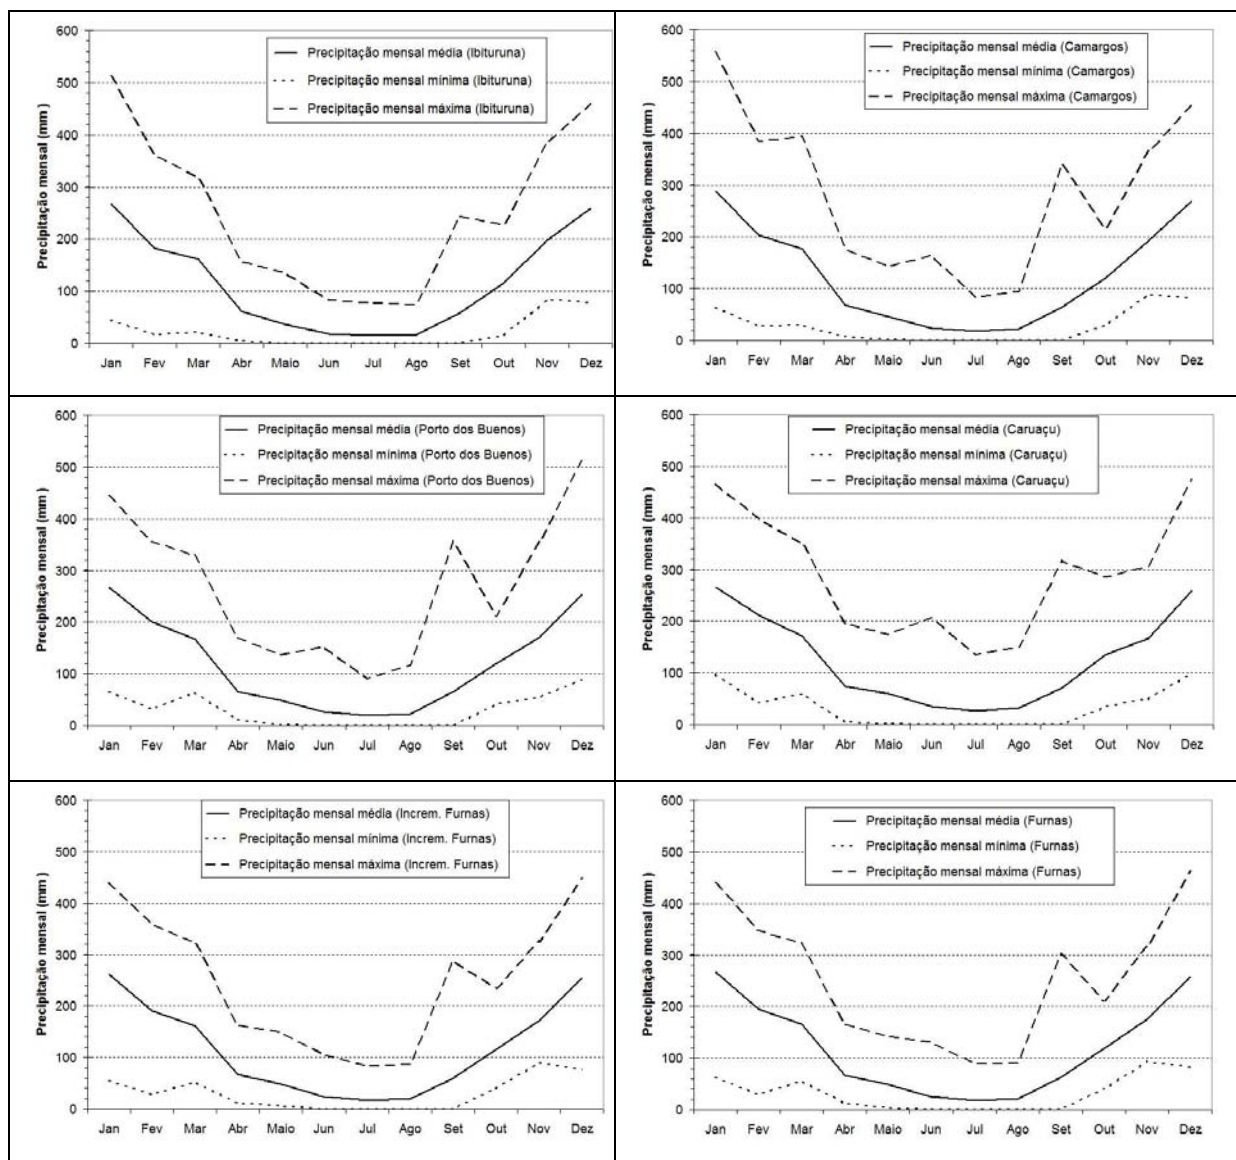


Figura 6. 8. Características da precipitação média mensal nas sub-bacias e na bacia de contribuição ao reservatório de Furnas.

Da mesma forma que as precipitações, as vazões apresentam uma sazonalidade bem definida na região como pode ser observada na Figura 6. 9, onde são apresentados os valores médios mensais adimensionalizadas com relação à média de longo período, nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas. Observa-se nessa figura que os valores de vazões médias mensais possuem um mesmo comportamento e uma clara sazonalidade, com um período de vazões maiores começando no mês de dezembro e se estendendo até o mês de abril.

A Figura 6. 10 apresenta a série de vazões médias anuais adimensionalizadas com relação à média de longo período, nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas. Não se apresentam períodos

anômalos nos dados. Apenas um evento extremo se destaca nessa figura, correspondente a um ano relativamente úmido (ano de 1983), onde a vazão média anual superou o dobro do valor da média de longo período nos diferentes locais.




Figura 6. 9. Características da vazão média mensal adimensionalizadas com relação à média de longo período, nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas.




Figura 6. 10. Vazões médias anuais adimensionalizadas com relação à média de longo período, nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas.

As principais características associadas com a fluviometria média mensal (valores médios, mínimos e máximos de cada mês) e sazonalidade das vazões nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas são apresentadas na Figura 6. 11.

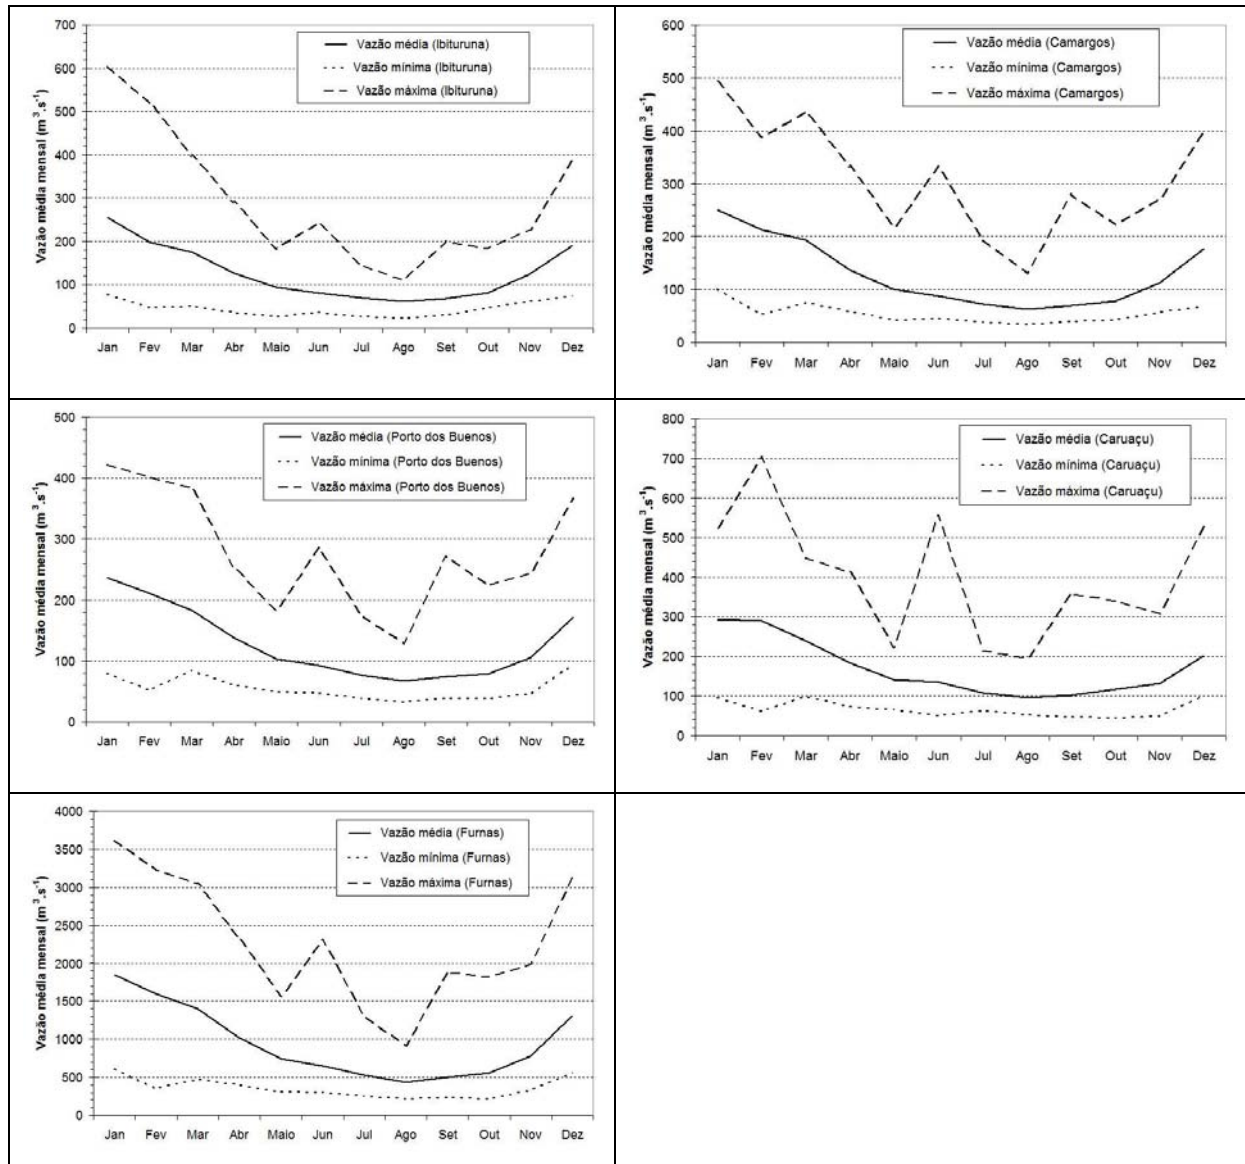


Figura 6. 11. Características da vazão média mensal nos postos fluviométricos de Porto dos Buenos e Caruaçu e nos exutórios das sub-bacias Ibituruna, Camargos e Furnas.

As previsões quantitativas de chuvas utilizadas no presente trabalho foram geradas pelo modelo regional ETA rodado operacionalmente pelo CPTEC (Chou, 1996; IPH, 2005). As previsões disponibilizadas possuem um horizonte de dez dias, uma frequência de sete dias

(começam sempre às quartas-feiras), um intervalo de tempo diário e se estendem de janeiro de 1996 até dezembro de 2000.

As previsões disponibilizadas do modelo ETA possuem uma resolução espacial de aproximadamente 40 km. A localização dos pontos da grade do modelo ETA sobre a região da bacia do Rio Grande é apresentada na Figura 6. 12. Os dados de precipitação prevista foram acumulados das 12:00 Z (em relação ao meridiano de Greenwich) de um dia até às 12:00 Z do dia seguinte, o que corresponde ao intervalo das 9h de um dia às 9h do dia seguinte no horário do Brasil, período coincidente com o horário de leitura dos pluviômetros no Brasil.




Figura 6. 12. Malha do modelo ETA-40km sobre a região da bacia do Rio Grande. Fonte: IPH (2005).

Nos gráficos da Figura 6. 13 e da Figura 6. 14 são apresentadas as chuvas observadas e previstas acumuladas para o período dos primeiros sete dias do horizonte da previsão, considerando valores médios sobre as áreas das sub-bacias Camargos e incremental de Furnas.

Observa-se nessas duas figuras uma boa representação dos eventos de precipitação observados pelas previsões do modelo regional ETA. Apenas no período de verão de 1998 as previsões parecem piorar, com superestimativas em ambas as sub-bacias apresentadas. Observa-se ainda que o modelo consegue representar bem tanto os períodos mais chuvosos

como os períodos de menores precipitações, assim como os primeiros eventos chuvosos no final do período seco e os últimos eventos chuvosos no final do período úmido.




Figura 6. 13. Chuva diária acumulada para o horizonte de 7 dias, observada e prevista pelo modelo ETA, no período de jan/96 a out/99 – valores médios sobre a sub-bacia de Camargos. Fonte: IPH (2005).




Figura 6. 14. Chuva diária acumulada para o horizonte de 7 dias, observada e prevista pelo modelo ETA, no período de jan/96 a out/99 – valores médios sobre a sub-bacia Incremental de Furnas. Fonte:IPH(2005).

A Figura 6. 15 apresenta a variação do coeficiente de correlação entre os valores observados e previstos de precipitação acumulada para diferentes horizontes, ou seja, acumulando a previsão de chuva para 1, 2 ... 10 dias. Observa-se nessa figura que a correlação aumenta com o aumento do intervalo de acumulação, mas atingindo um máximo em torno dos 6 ou 7 dias, diminuindo a seguir gradativamente, até os 10 dias de acumulação. Esse comportamento aparenta ser uma incoerência, pois aumentando a antecedência melhoram os resultados. Porém, a medida que os valores são acumulados, os erros individuais de cada dia são minimizados pela soma de todos os dias em um dado período. Observa-se ainda nessa figura que o maior valor de correlação é obtido para as precipitações sobre toda a área da bacia de contribuição ao reservatório de Furnas (na cor azul na Figura 6. 15).




Figura 6. 15. Avaliação da qualidade da previsão de precipitação do modelo ETA-40km na região analisada: coeficiente de correlação em função do período de acumulação da precipitação.

Os gráficos da Figura 6. 16 e da Figura 6. 17 apresentam uma comparação entre os valores observados de precipitação acumulada na sub-bacia incremental de Furnas, considerando diferentes períodos de acumulação (1 a 6 dias, na Figura 6. 16, e de 7 a 10 dias, na Figura 6. 17) e os valores previstos pelo modelo regional ETA.

Observa-se nessas figuras que o modelo regional ETA apresenta uma tendência a superestimar as precipitações acumuladas, que fica mais evidente a partir do quarto dia de acumulação. Entretanto, de maneira geral, os gráficos mostram que os valores acumulados reduzem a dispersão em relação à previsão perfeita (linha a 45°) até o sétimo dia de acumulação e, a partir do oitavo dia de acumulação, a dispersão volta a aumentar.

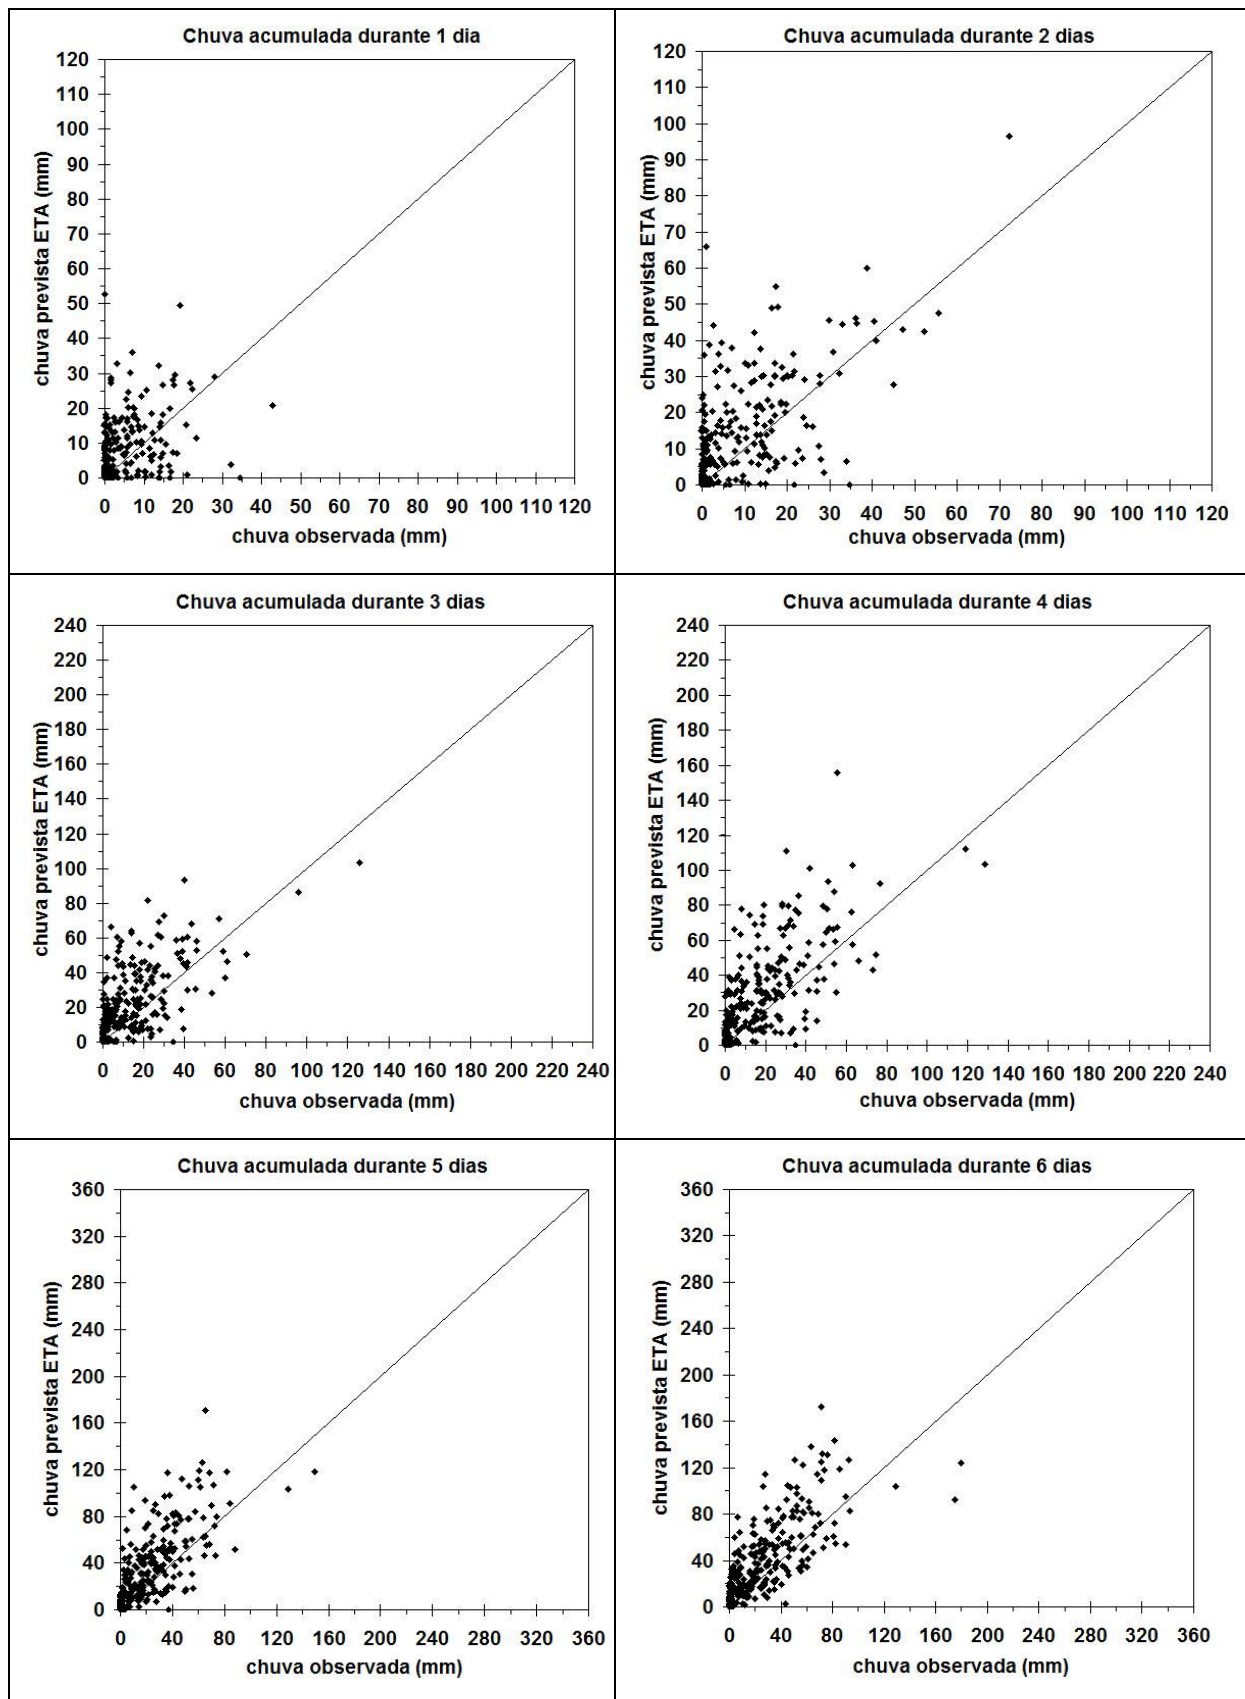


Figura 6. 16. Precipitação observada vs. precipitação prevista pelo modelo ETA na sub-bacia incremental de Furnas, considerando diferentes períodos de acumulação (1 a 6 dias).

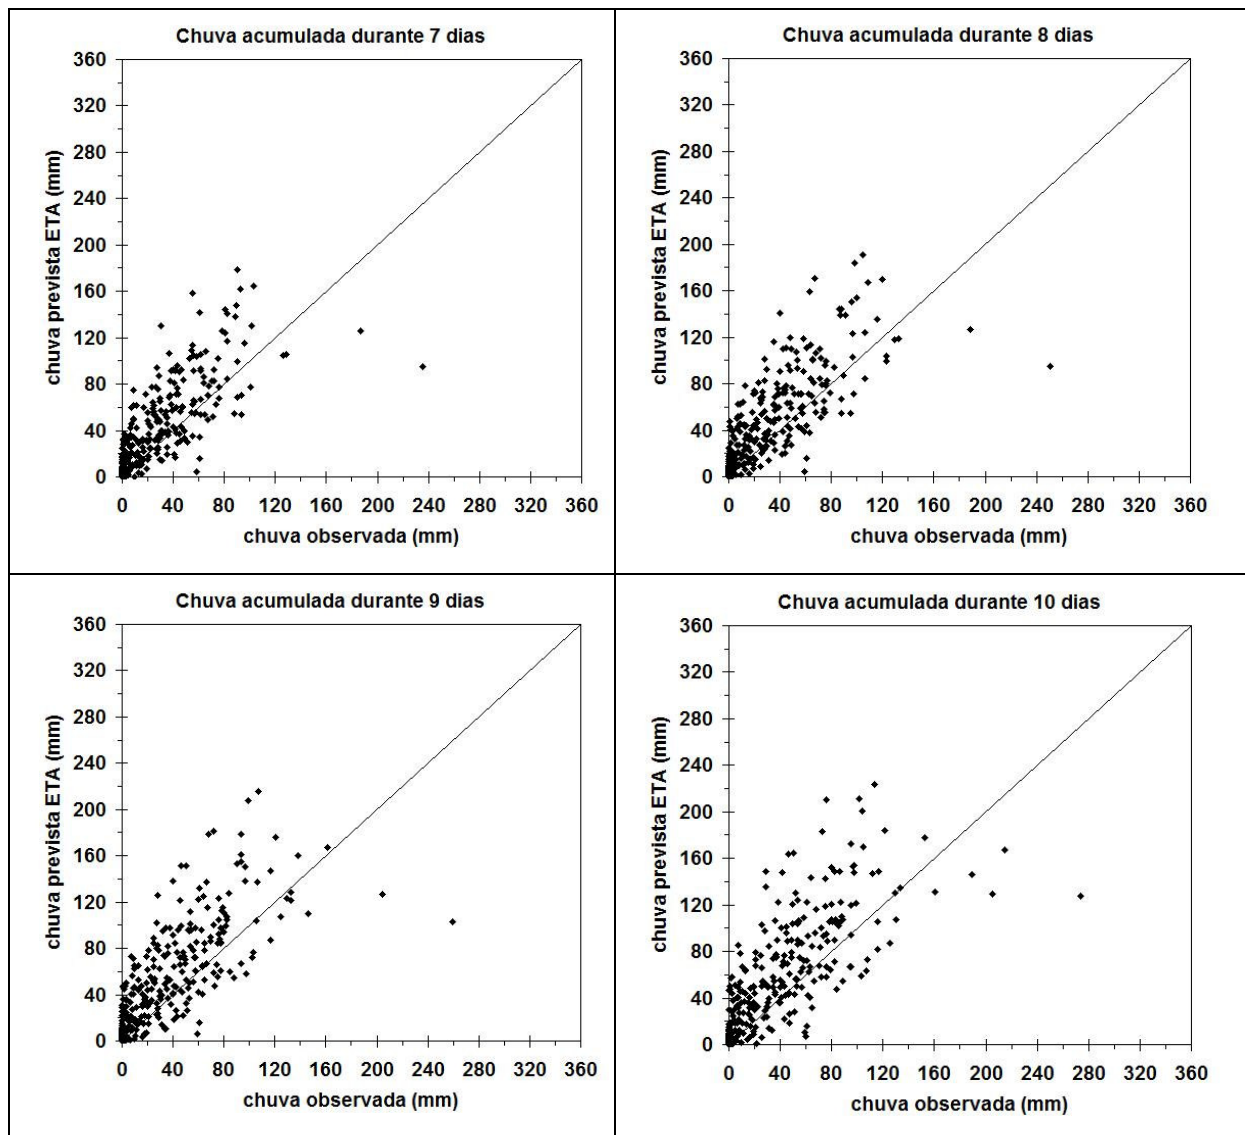


Figura 6. 17. Precipitação observada vs. precipitação prevista pelo modelo ETA na sub-bacia incremental de Furnas, considerando diferentes períodos de acumulação (7 a 10 dias).

6.3.2- Dados utilizados nas previsões de chuva de longo prazo

Nesse trabalho são estimadas previsões de longo prazo de precipitação, mais particularmente, é prevista, no mês de novembro, a precipitação acumulada do trimestre Dezembro, Janeiro e Fevereiro (DJF), o período mais chuvoso durante o ano na bacia hidrográfica de contribuição ao reservatório de Furnas.

Como variáveis predictoras são utilizados apenas os índices climáticos. Os índices climáticos são representativos da intensidade, ao longo do tempo, dos modos de variabilidade

atmosférica e fenômenos climáticos. Os índices climáticos relacionados ao ENSO, NAO, PDO e SAM foram selecionados como potenciais preditores.

O ENSO é representado pelo índice El Niño 3.4, que mede a intensidade das anomalias da temperatura da superfície do mar no oceano Pacífico tropical central. No que diz respeito à NAO, o índice escolhido foi o NAOI, definido como a diferença normalizada entre a pressão no nível do mar em Stykkisholmur (Islândia) e Ponta Delgada (Açores).

O SAM é representado pelo índice SAMI, definido como a diferença no valor médio zonal normalizado da pressão no nível do mar entre as latitudes 40°S e 70°S e disponível em <http://jisao.washington.edu/data/aaoslp/>.

Por sua vez, no caso do PDO, foi selecionado o índice PDOI, definido como as anomalias da temperatura da superfície do mar na região central do oceano Pacífico norte.

Séries mensais dos índices NAOI, PDOI e El Niño 3.4 são disponibilizadas no site do Centro de Previsão do Clima dos Estados Unidos (<http://www.cpc.noaa.gov/>) para o período de 1950 a 2003.

A Figura 6. 18 e a Figura 6. 19 apresentam as séries temporais padronizadas dos valores médios trimestrais (DJF, MAM, SON e JJA) de cada índice climático e dos totais precipitados, estimadas a partir dos dados mensais disponibilizados. A padronização foi feita descontando o valor médio e dividindo pelo desvio padrão.

Como já mencionado, as precipitações apresentam uma sazonalidade bem definida na região. Na Figura 6. 20 são apresentados as precipitações mensais na bacia de contribuição ao reservatório de Furnas de cada mês do ano, organizados por ano da série histórica. Ainda são apresentados nessa figura os valores médios, mínimos e máximos de cada mês. O período mais chuvoso ocorre nos meses de verão, começando em novembro e se estendendo até o mês de março. Os meses de dezembro, janeiro e fevereiro são, na média, os meses mais chuvosos na região.




Figura 6. 18. Séries padronizadas: (a) Precipitação acumulada por trimestre; (b) NAOI médio trimestral; (c) SAMI médio trimestral.




Figura 6. 19. Séries padronizadas: (a) El Niño 3.4 médio trimestral e (b) PDOI médio trimestral.




Figura 6. 20. Precipitação mensal na bacia de contribuição ao reservatório de Furnas em cada ano da série histórica e valores médios, mínimos e máximos.

Por fim, a série de precipitação acumulada no trimestre DJF na bacia de contribuição ao reservatório de Furnas é apresentada na Figura 6. 21. Observa-se nessa figura que a precipitação DJF apresenta valores típicos entre 600mm e 800mm. Alguns anos onde ocorrem eventos extremos, a precipitação apresenta valores superiores a 1000mm e inferiores a 500mm.

As séries temporais padronizadas dos valores médios trimestrais (DJF, MAM, SON e JJA), em cada trimestre, de cada índice climático e dos totais precipitados são apresentadas no Anexo 3.




Figura 6. 21. Precipitação acumulada no trimestre DJF na bacia de contribuição ao reservatório de Furnas.

6.3.3- Dados disponíveis para operação de reservatórios

O estudo de caso corresponde ao reservatório e à bacia hidrográfica de Furnas, conforme foi apresentado nos itens anteriores. A seguir, no item 6.3.3.1 são apresentados os dados de características físicas do reservatório de Furnas utilizados nesse trabalho.

Além disso, foi selecionado, para a estimativa da medida de desempenho com base na utilidade das previsões, um segundo local de estudo: o reservatório de Três Marias. Esse

reservatório está localizado no rio São Francisco, em Minas Gerais e os dados de suas características físicas, utilizados nesse trabalho, são apresentados no item 6.3.3.2.

Para simplificar a análise, de forma que os resultados pudessem ser mais facilmente interpretados e que o benefício e a utilidade das previsões de vazão na operação se tornasse claro, a metodologia foi aplicada, em ambos os estudos de caso, como se o reservatório operasse de forma isolada. Assim, os reservatórios atendem as restrições hidráulicas do trecho imediatamente a jusante e a geração de energia é feita em função do nível d'água no reservatório.

Isto representa uma simplificação, já que as usinas hidrelétricas e os reservatórios são parte do SIN, e as decisões de operação levam em conta a situação do conjunto de reservatórios. Entretanto, para um aproveitamento de cabeceira, como o reservatório de Três Marias e de Furnas, a operação para controle de cheias pode ser considerada razoavelmente independente (ONS, 2001), de forma que, para esses casos a análise é relativamente realista.

Nesse problema simplificado foi considerado que o reservatório possui apenas, dois usos: a geração de energia e o controle de cheias.

6.3.3.1- Reservatório de Furnas

A relação Cota-Área-Volume do reservatório de Furnas é apresentada na Tabela 6. 1. Nesse trabalho considerou-se que o volume útil do reservatório está compreendido entre as cotas de 750m e 768m, representando um volume de 17.217 milhões de m³. O volume útil desse reservatório representa aproximadamente 0,575 vezes o volume afluente médio durante um ano.

Tabela 6. 1. Relação Cota-Área-Volume do reservatório de Furnas.

Cota (m)	Área (km ²)	Volume (hm ³)
750	530	5733
755,12	755,2	9000
761	1044	14268
766	1320	20183
768	1442	22950

O vertedor do reservatório de Furnas possui sete comportas e a sua cota de soleira é igual a 750,7m, correspondendo a um volume do reservatório igual a 6.173 hm³. A

capacidade máxima total de vertimento é igual a $13.000 \text{ m}^3 \cdot \text{s}^{-1}$ (SIPOT, 2005). Nesse trabalho foi considerado que a capacidade máxima de vertimentos possui uma relação linear com o volume ou nível d'água no reservatório, sendo igual a zero para cota da soleira e igual ao valor máximo total para o nível máximo d'água no reservatório (volume igual a 22.950 hm^3).

A potência efetiva do conjunto de turbinas da usina hidrelétrica de Furnas é de 1.216MW. Na operação real, a vazão turbinada em Furnas depende das decisões tomadas pelo ONS, que dependem, entre outras variáveis, da época do ano, do nível da água no reservatório, da previsão da demanda e da situação de outros reservatórios do sistema interligado. Assim, para um mesmo nível da água no reservatório podem ser turbinadas diferentes vazões em função das decisões tomadas pelo ONS.

Para simplificar a representação da vazão turbinada adotou-se neste trabalho uma relação unívoca entre o nível da água no reservatório e a vazão turbinada. A relação entre o nível da água no reservatório e a vazão turbinada adotada é linear, sendo igual a $200 \text{ m}^3 \cdot \text{s}^{-1}$ para a cota 750m e igual a $821 \text{ m}^3 \cdot \text{s}^{-1}$ para a cota do nível máximo d'água no reservatório (768m).

É evidente que outros resultados seriam encontrados se for utilizada outra relação definida com base num critério diferente. Porém, para reduzir a influência da escolha desta relação, os resultados deste trabalho serão obtidos em termos relativos, isto é, percentagem de benefício em relação à operação sem previsão do mesmo sistema simplificado.

No caso analisado nesse trabalho foram consideradas duas restrições de operação no reservatório de Furnas. A primeira refere-se ao valor máximo da vazão efluente total (Q_{lim}), limitado a $4000 \text{ m}^3 \cdot \text{s}^{-1}$. Além disso, a vazão efluente deve respeitar uma restrição que limita a sua variação de um dia para o próximo. Assim, o máximo incremento ou decréscimo da vazão efluente entre um dia e o próximo é de $2000 \text{ m}^3 \cdot \text{s}^{-1}$. Todos esses valores refletem, de forma muito aproximada, as restrições de operação existentes no reservatório de Furnas.

A regra de operação utilizada no reservatório de Furnas é apresentada na Figura 6. 22. Trata-se de uma curva-guia para controle de cheias, definida conforme a metodologia do ONS (ONS, 2009b), e que possui um período de recorrência de 30 anos.




Figura 6. 22. Regras de operação (curva-guia para controle de cheias) adotadas no reservatório de Furnas.

Os dados de evaporação líquida média mensal do reservatório Furnas foram obtidos de ONS (2004) e são apresentados na Tabela 6. 2.

Tabela 6. 2. Evaporação líquida média mensal do reservatório Furnas (ONS, 2004).

Mês	Evaporação (mm/mês)	Mês	Evaporação (mm/mês)
Janeiro	2	Julho	50
Fevereiro	0	Agosto	42
Março	22	Setembro	57
Abril	40	Outubro	48
Maiο	51	Novembro	23
Junho	55	Dezembro	29

6.3.3.2- Reservatório de Três Marias

A relação Cota-Área-Volume do reservatório de Três Marias é apresentada na Tabela 6. 3. Nesse trabalho considerou-se que o volume útil do reservatório está compreendido entre as cotas de 549,2m e 572,5m, representando um volume de 15.278 milhões de m³. O volume útil desse reservatório representa aproximadamente 0,7 vezes o volume afluente médio durante um ano, configurando um reservatório com grande capacidade de regularização de vazão.

Tabela 6. 3. Relação Cota-Área-Volume do reservatório de Três Marias.

Cota (m)	Área (km ²)	Volume (hm ³)
549,20	315,75	4250
549,96	416,92	6300
556,90	593,42	10100
562,86	788,38	14500
572,50	1009,32	19528

A curva de descarga do vertedor é apresentada na Figura 6. 23, para a condição de uma comporta aberta, com valores máximos próximos a 850 m³.s⁻¹. O vertedor tem seis comportas, o que significa que teria capacidade de verter vazões de aproximadamente 5100 m³.s⁻¹.




Figura 6. 23. Curva de descarga do vertedor considerando apenas uma comporta com diferentes aberturas (a envoltória superior representa a condição da comporta completamente aberta).

A potência efetiva do conjunto de turbinas da usina hidrelétrica de Três Marias é de 396 MW, e o engolimento máximo das turbinas é de 227 m³.s⁻¹.

Na operação real a vazão turbinada em Três Marias depende também das decisões tomadas pelo ONS, que dependem, entre outras variáveis, da época do ano, do nível da água no reservatório, da previsão da demanda e da situação de outros reservatórios do sistema

interligado. Assim, para um mesmo nível da água no reservatório podem ser turbinadas diferentes vazões em função das decisões tomadas pelo ONS.

Para simplificar a representação da vazão turbinada adotou-se neste trabalho uma relação unívoca entre o nível da água no reservatório e a vazão turbinada. A relação entre o nível da água no reservatório e a vazão turbinada adotada é apresentada na Tabela 6. 4. Esta relação foi baseada nos dados de potência máxima, queda, número de turbinas e vazão máxima de engolimento.

É evidente que outros resultados seriam encontrados se for utilizada outra relação definida com base num critério diferente. Porém, para reduzir a influência da escolha desta relação, os resultados deste trabalho serão obtidos em termos relativos, isto é, percentagem de benefício em relação à operação sem previsão do mesmo sistema simplificado.

Tabela 6. 4. Relação entre nível da água no reservatório e vazão turbinada no reservatório de Três Marias, adotada neste trabalho.

H_t (m)	Vazão turbinada QT_t ($m^3 \cdot s^{-1}$)
$H_t < 549,20$	0
$549,2 < H_t < 555$	$215,00 + 3,2328 \times (H_t - 549,2)$
$555 < H_t < 556$	$233,75 + 122,50 \times (H_t - 555)$
$556 < H_t < 560$	$356,25 + 4,6875 \times (H_t - 556)$
$560 < H_t < 561$	$375,00 + 130,00 \times (H_t - 560)$
$561 < H_t < 565$	$505,00 + 5,6250 \times (H_t - 561)$
$565 < H_t < 566$	$527,50 + 138,13 \times (H_t - 565)$
$566 < H_t < 569$	$665,63 + 7,2917 \times (H_t - 566)$
$569 < H_t < 570$	$687,50 + 145,0 \times (H_t - 569)$
$570 < H_t < 572,5$	$832,50 + 7,50 \times (H_t - 570)$
$H > 572,5$	851,25

No caso analisado neste trabalho foram consideradas três restrições de operação no reservatório de Três Marias. A primeira refere-se ao nível da água no reservatório a partir do qual começam as inundações na cidade de montante, limitado a 572,50 m. A segunda restrição refere-se ao valor máximo da vazão efluente total (Q_{lim}), limitado a $3000 m^3 \cdot s^{-1}$. Além disso, a vazão efluente deve respeitar uma restrição que limita a sua variação de um dia para o próximo. Assim, por exemplo, para vazões inferiores a $2500 m^3 \cdot s^{-1}$, o máximo incremento ou decréscimo da vazão efluente entre um dia e o próximo é de $500 m^3 \cdot s^{-1}$; e para

vazões entre $2500 \text{ m}^3.\text{s}^{-1}$ e $4000 \text{ m}^3.\text{s}^{-1}$, o máximo incremento ou decréscimo da vazão efluente entre um dia e o próximo é de $700 \text{ m}^3.\text{s}^{-1}$. Todos esses valores refletem, de forma muito aproximada, as restrições hidráulicas existentes no reservatório de Três Marias.

A regra de operação utilizada no reservatório de Três Marias é apresentada na Figura 6. 24. Trata-se de uma curva-guia para controle de cheias, definida em um trabalho prévio (Bravo, 2006), e que possui um período de recorrência próximo aos 50 anos, conforme a metodologia do ONS (ONS, 2009a).




Figura 6. 24. Regras de operação (curva-guia para controle de cheias) adotadas no reservatório de Três Marias.

Por fim, os dados de evaporação líquida média mensal do reservatório Três Marias foram obtidos de Brandão (2004) e são apresentados na Tabela 6. 5.

Tabela 6. 5. Evaporação líquida média mensal do reservatório Três Marias (Brandão, 2004).

Mês	Evaporação (mm/mês)	Mês	Evaporação (mm/mês)
Janeiro	2	Julho	50
Fevereiro	0	Agosto	42
Março	22	Setembro	57
Abril	40	Outubro	48
Maiο	51	Novembro	23
Junho	55	Dezembro	29

6.4- Previsões de curto prazo de vazão de afluência ao reservatório de Furnas

Nesse trabalho são estimadas previsões de curto prazo de vazão de afluência ao reservatório de Furnas. Estas previsões possuem horizonte de doze dias com intervalo diário de previsão. Na nomenclatura utilizada, t representa o dia no qual é realizada a previsão, $t+1$ é o primeiro dia da previsão e $t+12$ o último dia da previsão.

Foram desenvolvidos doze modelos usando redes neurais artificiais (RNAs). Cada modelo realiza a previsão de vazão afluente ao reservatório de Furnas para um dia do horizonte de previsão. Dessa forma, a camada de saída de cada modelo possui um único neurônio.

6.4.1- Variáveis de entrada

Tendo em mente o processo físico representado e os dados disponíveis, pode-se assumir que é fundamental alimentar a rede com três tipos de informação: precipitação na bacia contribuinte; vazão nos exutórios das sub-bacias contribuintes e vazão no local de previsão. A definição das variáveis de entrada à rede foi realizada com base em análises de correlação entre os dados disponíveis e a saída da rede (vazão afluente ao reservatório de Furnas) no período de 01/01/1970 a 31/12/1980.

A respeito da informação da precipitação na área de contribuição, inicialmente as precipitações médias diárias de cada sub-bacia (Ibituruna, Portos dos Buenos, Camargo, Caruaçu e Incremental de Furnas) e da bacia total a montante de Furnas foram correlacionadas com a vazão afluente ao reservatório de Furnas considerando defasagens de um a doze dias (Figura 6. 25). A maior correlação foi obtida para a variável precipitação média sobre a bacia total contribuinte a Furnas, embora relativamente baixa ($< 0,60$).

Na tentativa de obter variáveis baseadas nos dados de precipitação com maior grau de correlação com a vazão em Furnas, foram geradas séries de precipitação acumulada em diferentes períodos de tempo a partir das precipitações médias diárias sobre a bacia total contribuinte a Furnas. Isto é, foram criadas novas séries de precipitação acumulada de dois dias (por exemplo, dos dias t e $t-1$), de três dias (por exemplo, dos dias t , $t-1$ e $t-2$), e assim por diante. Posteriormente, essas variáveis foram correlacionadas com a vazão afluente ao reservatório de Furnas com defasagem de um dia (vazão observada em $t+1$). Os resultados são apresentados na Figura 6. 26. Nesse caso as chuvas guardam grande correlação serial entre si.




Figura 6. 25. Coeficiente de correlação (de Pearson) entre diferentes variáveis (precipitação média diária nas sub-bacias e na bacia de montante de Furnas) e a vazão afluente ao reservatório de Furnas com defasagens de um a doze dias.




Figura 6. 26. Coeficiente de correlação (de Pearson) entre diferentes variáveis (precipitação média diária, na bacia, acumulada em diferentes períodos de tempo) e a vazão afluente ao reservatório de Furnas com defasagem de um dia.

Como ilustrado na Figura 6. 26, a correlação entre a precipitação média (na bacia) diária acumulada e a vazão afluente ao reservatório de Furnas em $t+1$ aumenta com o aumento do período de acumulação. Essa tendência se mantém até um período de acumulação de doze dias anteriores ao instante $t+1$, quando atinge um valor máximo de correlação igual a

0,82, diminuindo, a seguir, gradativamente. Dessa forma, a precipitação média (na bacia) diária acumulada de doze dias ($P_{ma12}(t)$) foi adotada como variável de entrada à RNA.

Como a previsão de chuva disponível do modelo ETA possui um horizonte de dez dias (até $t+10$), foi considerada nula a previsão de chuva referente ao dia $t+11$ ao realizar a previsão de vazão para $t+12$.

Na análise das informações referentes às vazões nas sub-bacias contribuintes a Furnas, foram correlacionadas as vazões diárias nos exutórios de cada uma das sub-bacias (Ibituruna, Portos dos Buenos, Camargo e Caruaçu) e a média delas com a vazão afluente ao reservatório de Furnas, considerando defasagens de um a doze dias. Maiores valores de correlação com a vazão em Furnas foram obtidos tomando o valor médio diário das quatro vazões de montante ($QM4(t)$), como ilustra a Figura 6. 27. Tal variável e o seu valor incremental ($\Delta QM4(t)=QM4(t)-QM4(t-1)$) foram adotados como variáveis de entrada para a RNA representando as informações das vazões de contribuição de montante. A inclusão da vazão incremental $\Delta QM4(t)$ como variável de entrada à RNA tem o objetivo de facilitar a distinção entre períodos de subida e descida do hidrograma (cheia ou recessão).




Figura 6. 27. Coeficiente de correlação (de Pearson) entre diferentes variáveis de entrada (vazão nos exutórios das sub-bacias de montante e valor médio diário $QM4(t)$) e a vazão afluente ao reservatório de Furnas com defasagens de um a doze dias.

Por fim, quanto à informação de vazão no próprio local de previsão (Furnas), foram adotadas duas variáveis para entrada à rede: a vazão afluente a Furnas no período t ($QF(t)$); e

o valor incremental $\Delta QF(t) = QF(t) - QF(t-1)$, também com o intuito de facilitar a distinção entre subida e descida do hidrograma pela rede.

Os modelos de RNAs desenvolvidos neste trabalho para prever a vazão em Furnas são alimentados, portanto, com cinco variáveis de entrada. Quatro dessas variáveis são definidas com base nos dados de vazão: média diária das vazões nos exutórios das sub-bacias de montante no dia t ($QM4(t)$) e seu valor incremental entre os dias $t-1$ e t ($\Delta QM4(t)$); vazão em Furnas no dia t ($QF(t)$) e o valor incremental entre os dias $t-1$ e t ($\Delta QF(t)$). Os valores dessas variáveis são os mesmos para uma previsão que inicia no dia t , independentemente do intervalo de tempo dentro do horizonte de previsão. A quinta variável de entrada é definida com base nos valores de precipitação média diária (na bacia) acumulada de doze dias ($Pma12(t)$) e apresenta valores diferentes conforme o intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão.

6.4.2- Escolha do tipo de rede neural

Foram propostos doze modelos de redes neurais artificiais. Cada modelo realiza a previsão de vazão afluente ao reservatório de Furnas para um dia do horizonte de previsão. As redes neurais progressivas de múltiplas camadas (RNPMCs), com três camadas (uma de entrada, uma intermediária e uma camada de saída) foram utilizadas nesse trabalho. Cada uma das RNPMC desenvolvidas possui cinco neurônios na camada de entrada (cada neurônio corresponde a uma variável de entrada) e um único neurônio (correspondente ao valor previsto de vazão num dia do horizonte de previsão) na camada de saída.

O número de neurônios da camada intermediária da RNPMC foi determinado independentemente para cada modelo desenvolvido.

As funções de ativação utilizadas são, respectivamente, a log-sigmóide unipolar, para a camada intermediária, e a linear, para a camada de saída.

6.4.3- Divisão e pré-processamento dos dados

Definidas as variáveis de entrada e o tipo de RNA, foi feita a divisão dos dados em três conjuntos: treinamento, validação e verificação.

As previsões de precipitação do modelo ETA disponíveis para esse trabalho totalizam cerca de 260 semanas. Isto significa que, se fossem utilizados somente esses dados, existiriam

apenas 260 pares de dados (dados de entrada e saída) para serem divididos entre os três conjuntos citados. Isto definiria um número relativamente reduzido de pares de dados nos diferentes conjuntos, o que poderia provocar a falta de representatividade dos resultados obtidos.

Com o objetivo de superar esse problema, nesse trabalho foi proposta uma metodologia alternativa que é a de se treinar a RNA utilizando previsões perfeitas de chuvas. Isto é, utilizam-se as chuvas observadas como previsão de chuva durante a etapa de treinamento e validação da rede e as previsões reais de chuva na etapa de verificação.

As estatísticas média (μ) e desvio padrão (σ) das variáveis nos conjuntos de treinamento e validação são apresentados na Tabela 6. 6.

Tabela 6. 6. Estatísticas das cinco variáveis de entrada nos conjuntos de treinamento e de validação.

Variáveis	Treinamento		Validação	
	μ	σ	μ	σ
Pm12(t)	47,93	42,52	43,73	42,35
QF(t)	886,53	595,29	859,46	546,87
Δ QF(t)	0,42	98,98	-0,129	90,74
QM4(t)	127,63	80,00	123,76	71,24
Δ QM4(t)	0,079	17,10	-0,007	14,68

Dessa forma, o período da série histórica 1970-1980 foi dividido em dois conjuntos: treinamento e validação. O conjunto de treinamento é composto de dados dos períodos 12/01/1970 a 17/07/1974 e 13/10/1978 a 31/12/1980, totalizando 2.461 pares de dados (frequência diária). O conjunto de validação se estende de 18/07/1974 a 12/10/1978, totalizando 1.548 pares de dados (frequência diária). Todos esses períodos são de chuva prevista perfeita (chuva observada tomada como previsão).

Para avaliar o desempenho da rede foram utilizados dois conjuntos de verificação, sendo ambos compostos de dados de 12/01/1996 a 31/12/2000, totalizando 260 pares de dados (frequência semanal). No primeiro conjunto de verificação, as previsões de precipitação correspondem às obtidas pelo modelo ETA e no segundo conjunto de verificação são utilizadas previsões perfeitas de chuvas.

Posteriormente, o pré-processamento das variáveis de entrada e saída da rede foi feito segundo Maier e Dandy (2000). Os valores das variáveis são padronizados, utilizando-se a equação 6.1:

$$x_{novo} = 0,1 + \left(\frac{x_{orig} - x_{min}}{x_{max} - x_{min}} \right) \times 0,8 \quad (6.1)$$

onde x_{novo} é o valor da variável padronizada no intervalo [0,10 ; 0,90]; x_{orig} é o valor original da variável na sua respectiva unidade; x_{min} é o valor mínimo da variável original (considerando os conjuntos de treinamento e validação) na sua respectiva unidade; x_{max} é o valor máximo da variável original na sua respectiva unidade.

Esse processo é repetido em todas as variáveis previamente à sua utilização.

6.4.4- Treinamento da rede neural

As RNPMCs foram treinadas nessa etapa do trabalho com o *scaled conjugate gradient method* (SCGM) (Moller, 1993). Trata-se de um método de treinamento supervisionado que pertence à família dos métodos dos gradientes conjugados. A função utilizada para avaliar o desempenho da rede neural no treinamento foi o erro padrão de previsão (com N igual ao número de valores no conjunto de treinamento). Por sua vez, a validação cruzada foi utilizada como critério de parada do treinamento.

Do processo de experimentação sistemática com busca de melhores resultados resultou que as RNPMCs para os primeiros sete dias do horizonte de previsão possuem dois neurônios na camada intermediária, isto é, RNPMCs(5-2-1) (Figura 6. 28), e as RNPMCs para os dias 8 a 12 do horizonte de previsão possuem três neurônios na camada intermediária, isto é, RNPMCs(5-3-1).

Os modelos de previsão de vazão de curto prazo, baseados em RNAs, foram projetados e treinados utilizando o *Neural Network Toolbox* (Demuth et al., 2006) do software MATLAB. No treinamento das RNPMCs(5-2-1) foram necessários em torno de 1300 ciclos. Entretanto, 1800 ciclos, na média, foram necessários no treinamento das RNPMCs(5-3-1).




Figura 6. 28. Arquitetura da RNPMC para previsão de vazão de afluência ao reservatório de Furnas nos primeiros sete dias do horizonte de previsão.

6.5- Previsões de longo prazo de chuva na bacia de Furnas

Nessa etapa do trabalho foram estimadas previsões de precipitação média sobre a bacia de contribuição ao reservatório de Furnas. As previsões foram desenvolvidas no início do período chuvoso e abrangem os meses de dezembro, janeiro e fevereiro (DJF). Assim, no final do mês de novembro é estimado o valor médio de precipitação acumulada para os próximos três meses.

Foi desenvolvido um único modelo usando redes neurais artificiais (RNAs), o qual prevê a precipitação DJF utilizando como variáveis de entrada os índices climáticos.

6.5.1- Variáveis de entrada e escolha da rede neural

Foi utilizada nessa etapa do trabalho uma RNPMC com três camadas (uma de entrada, uma intermediária e uma camada de saída). Devido à curta extensão das séries de dados, foi adotado o menor número possível de neurônios na camada intermediária, procurando o modelo mais parcimonioso. Nesse sentido, após diferentes tentativas, foi adotada uma

arquitetura RNPMC(4-4-1), isto é, o modelo desenvolvido possui quatro neurônios na camada de entrada (cada neurônio corresponde a um índice climático), quatro neurônios na camada intermediária e um único neurônio (correspondente ao valor previsto da precipitação DJF) na camada de saída (Figura 6. 29).




Figura 6. 29. Arquitetura da RNPMC para previsão de precipitação na bacia de contribuição ao reservatório de Furnas.

A função de ativação tangente hiperbólica sigmóide foi adotada na camada intermediária, enquanto a função de ativação linear foi usada na camada de saída.

As variáveis de entrada potenciais a serem utilizadas para prever a precipitação no trimestre de DJF são os valores médios trimestrais dos quatro índices climáticos selecionados (SAMI, NAOI, El Niño 3.4, PDOI), que medem a intensidade dos modos de variabilidade climática e dos fenômenos climáticos, com possível incidência na região de análise, conforme foi apresentado no item 2.2.1.2.

Mesmo que apenas as variáveis fisicamente relacionadas à precipitação na região de estudo sejam selecionadas, várias variáveis de entrada candidatas podem ser identificadas. Particularmente, é importante identificar a defasagem mais adequada para cada variável de entrada. Nesse sentido, uma análise independente foi realizada para verificar a defasagem em cada variável de entrada com a qual são obtidos os melhores resultados.

A Figura 6. 30 apresenta o coeficiente de correlação entre os valores médios trimestrais dos índices climáticos, com defasagens de um a oito trimestres, e a precipitação DJF a montante de Furnas. Isto é, o lag-1 indicado nessa figura, mostra os resultados de

correlação entre os valores médios dos índices no trimestre SON e a precipitação DJF. Por sua vez, o lag-2 mostra os resultados correspondentes aos valores médios dos índices no trimestre JJA e a precipitação DJF.

Observa-se nessa figura que o coeficiente de correlação é significativamente diferente (ao nível de significância de 0,05) de zero no índice SAMI com defasagem de quatro, cinco e oito trimestres e no índice PDOI com defasagem de sete e oito trimestres. Embora não sejam significativamente diferentes de zero (ao nível de significância de 0,05), a maior correlação entre o índice El Niño 3.4 e a precipitação DJF, acontece com uma defasagem de oito trimestres e, no caso do NAOI, com uma defasagem de quatro trimestres.

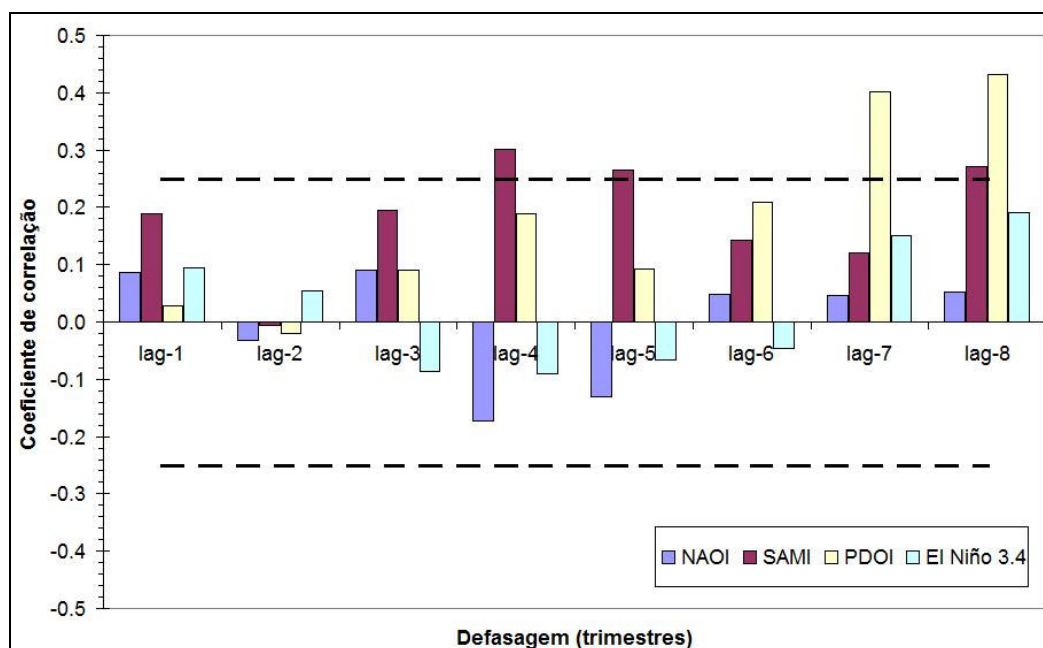


Figura 6. 30. Coeficiente de correlação r (de Pearson) entre diferentes variáveis (índices climáticos) e a precipitação DJF a montante de Furnas com defasagens de um a oito trimestres (as linhas tracejadas indicam o r_{crit} usando o teste t ($H_0: r=0$), para um nível de significância de 0,05).

Os sinais dos máximos valores de correlação de cada índice climático, positivo para os índices SAMI, PDOI e El Niño 3.4 e negativo para o NAOI, seguem o comportamento esperado com base na física dos fenômenos climáticos afetando o SMSA, conforme apresentado no item 2.2.1.2. Porém, para a defasagem existente, de um e dois anos (defasagens de quatro e oito trimestres) resulta difícil justificar a sua real influência sobre a variável de interesse.

Dois modelos de previsão de precipitação foram desenvolvidos em função de diferentes conjuntos de variáveis de entradas. Em primeiro lugar foram escolhidas as variáveis

de entrada que maior correlação apresentaram com a precipitação DJF a montante de Furnas. Isto é, as variáveis de entrada no modelo são os índices climáticos SAMI(DJF-1); NAOI(DJF-1); PDOI(DJF-2) e El Niño 3.4(DJF-2), onde $-x$ representa a defasagem em anos. Dessa forma, a antecedência das previsões utilizando esse modelo é de nove meses.

No segundo conjunto de variáveis de entrada foi feita uma busca exaustiva entre as candidatas, limitadas, porém, a uma defasagem de dois trimestres. Assim, as variáveis de entrada teriam um maior sustento físico. Dessa forma, diferentes conjuntos de variáveis de entradas com base nos índices climáticos, restringidas aos trimestres SON e JJA, foram avaliados. A antecedência das previsões utilizando esse modelo é de três meses.

6.5.2- Divisão e pré-processamento dos dados

A divisão de dados em três conjuntos foi realizada com o objetivo de distribuir eventos de precipitação de todas as intensidades ao longo deles. Entre as 53 amostras do conjunto de dados disponíveis, 35 amostras (66%) foram selecionadas como o conjunto de treinamento, oito amostras (15%) foram considerados como o conjunto de validação e as outras dez amostras (19%) como o conjunto de verificação (Figura 6. 31). A precipitação média é de 704mm, 761mm e 732mm nos conjuntos de treinamento, validação e verificação, respectivamente, enquanto que o desvio padrão é 125mm, 128mm e 139mm, respectivamente. Todos os dados de entrada e saída foram padronizados, subtraindo o valor médio e dividindo o resultado pelo desvio padrão.




Figura 6. 31. Divisão dos dados em conjuntos de treinamento, validação e verificação.

6.5.3- Treinamento da rede neural e otimização com restrições

Para cada configuração das RNAs, o processo de treinamento foi realizado através do algoritmo evolucionário SCE-UA acoplado à e a teoria de estabelecimento dos valores dos pesos com sustento físico (ROCW)

Durante a aplicação da metodologia, o problema de otimização no processo de treinamento foi definido como:

$$\text{Min: } FO = 1 - CE + \text{Pen} \quad (6.2)$$

$$\text{s.t. } ROCW_{SAM} > 0 \quad (6.3)$$

$$ROCW_{NIÑO} > 0 \quad (6.4)$$

$$ROCW_{PDO} > 0 \quad (6.5)$$

$$ROCW_{NAO} < 0 \quad (6.6)$$

onde FO é a função-objetivo, CE é o coeficiente de eficiência de Nash-Sutcliffe; Pen é uma penalidade que depende da verificação de restrições, $ROCW_{SAM}$, $ROCW_{NIÑO}$, $ROCW_{PDO}$ e $ROCW_{NAO}$ são as contribuições relativas das variáveis de entrada SAMI, El Niño 3.4, PDOI e NAOI, respectivamente.

Neste trabalho, foi adotado um valor relativamente grande na penalidade ($\text{Pen} = 1$) quando qualquer uma das restrições não é satisfeita (isso significa que os parâmetros estão localizados em uma região inviável do espaço de busca), enquanto que o valor da penalidade é zero quando as restrições são satisfeitas.

As restrições (equações 6.3 a 6.6) foram definidas de acordo com as intensidades conhecidas dos padrões de circulação atmosférica e teleconexões identificados como possivelmente relacionados com a precipitação sobre a bacia hidrográfica das Furnas, conforme anteriormente mencionado no item 2.2.1.2 e no item 6.5.1.

6.6- Medidas de desempenho das previsões

Para a estimativa da medida de desempenho baseada na utilidade das previsões foram utilizados modelos que geram previsões hipotéticas de vazão de afluência aos reservatórios e um modelo de operação de reservatórios.

Nessa etapa foram utilizadas as informações dos dois reservatórios, adotados como estudo de caso, isto é, o reservatório de Furnas e o reservatório de Três Marias.

O período de análise no caso do reservatório de Furnas é 01/01/1970 a 31/12/2001, totalizando 32 anos de dados. Por sua vez, no caso do reservatório de Três Marias, o período de análise é 01/01/1931 a 12/09/1964, totalizando 34 anos de dados aproximadamente.

Para cada um desses períodos foram gerados vários conjuntos de previsões hipotéticas, chamadas de previsões com modelos, para auxiliar na análise. Cada conjunto representa comportamentos típicos das previsões de vazões de curto prazo, entre eles foram considerados:

- (1) Previsões ingênuas e espertas, sendo a vazão média (Q_m) estimada em função do período analisado em cada estudo de caso. Foram desenvolvidos, em consequência, dois modelos.
- (2) Previsões que apresentam uma defasagem se comparadas aos valores observados (antecipam ou atrasam) de um a dez dias, ou seja, o valor de Δ variou de -10 a +10, excluindo o valor Δ igual a zero (que corresponderia à previsão perfeita de vazão). Foram desenvolvidos nesse tipo, vinte modelos.
- (3) Previsões com erro segundo uma distribuição normal com e sem tendência crescente. Foram criados quatro modelos de previsões, cada um deles gerando 100 conjuntos de previsões a partir de diferentes sementes aleatórias. Os conjuntos de modelos se diferenciam entre si pelos valores adotados em seus parâmetros. O primeiro conjunto de previsões foi gerado considerando: $\mu_0 = 0$; $tend^\mu = 0$; $\sigma_0 = 0,3$; $tend^\sigma = 0$. O segundo conjunto de previsões apresenta: $\mu_0 = 0$; $tend^\mu = 0,05$; $\sigma_0 = 0,05$; $tend^\sigma = 0,05$. O terceiro conjunto de previsões foi gerado considerando: $\mu_0 = 0,05$; $tend^\mu = 0,05$; $\sigma_0 = 0,3$; $tend^\sigma = 0,05$. Finalmente, o último conjunto de previsões possui: $\mu_0 = 0$; $tend^\mu = 0,01$; $\sigma_0 = 0,4$; $tend^\sigma = 0,01$.
- (4) Previsões com erro segundo uma distribuição uniforme com e sem tendência crescente. Foram criados quatro modelos de previsões, cada um deles gerando 100 conjuntos de previsões a partir de diferentes sementes aleatórias. Os conjuntos de modelos se diferenciam entre si pelos valores adotados em seus parâmetros. O primeiro conjunto de previsões foi gerado considerando: $\mu_0 = 0$; $tend^\mu = 0$; $Lim_0 = 0,3$; $tend^{Lim} = 0$. O segundo conjunto de previsões apresenta: $\mu_0 = 0$;

$tend^{\mu} = 0,05$; $Lim_0 = 0,05$; $tend^{Lim} = 0,05$. O terceiro conjunto de previsões foi gerado considerando: $\mu_0 = 0,05$; $tend^{\mu} = 0,05$; $Lim_0 = 0,3$; $tend^{Lim} = 0,05$. Finalmente, o último conjunto de previsões possui: $\mu_0 = 0$; $tend^{\mu} = 0,01$; $Lim_0 = 0,4$; $tend^{Lim} = 0,01$.

(5) Previsões que correspondem ao último valor observado (persistência). Foi desenvolvido um único modelo.

Dessa forma, foram gerados 823 conjuntos de previsões em função dos dados de vazões de afluência a cada reservatório do estudo de caso. Por último, foram geradas previsões perfeitas de vazão, isto é, previsões que não apresentam erro.

Em todos os casos foram desenvolvidas previsões com frequência de sete dias e horizonte de 12 dias ao longo do período de simulação.

Para cada um desses conjuntos de previsões, que se estendem ao longo de todo o período de simulação dos estudos de caso, foi calculado o coeficiente de Nash-Sutcliffe. Dessa forma é obtida uma estimativa da qualidade das previsões existentes em cada conjunto, mostrando como as medidas de desempenho baseadas no erro da previsão são influenciadas pelos diferentes comportamentos típicos representados.

Na seqüência, foram efetuadas as simulações de operação de reservatório com base nas regras de operação de projeto. Esse procedimento foi repetido em cada um dos reservatórios dos estudos de caso, considerando suas respectivas restrições hidráulicas e curvas-guias.

Inicialmente, foi feita a operação do reservatório segundo as curvas-guias de projeto e sem flexibilizações, não levando em conta as informações das previsões. Posteriormente foi utilizado o modelo AMANDA para estimar a seqüência de flexibilizações das regras de operação do reservatório com base nos conjuntos de previsões obtidas na etapa anterior.

Em uma primeira fase das simulações da operação do reservatório com base nas previsões de vazão foram utilizadas as previsões perfeitas de vazão, determinando a seqüência de flexibilizações mais conveniente das regras de operação. Nessa etapa é obtido como resultado, a série de níveis do reservatório e vertimentos ao longo do período de simulação sob uma operação ideal, na qual as previsões de vazão de afluência não apresentam erro.

Na segunda fase foi feita a operação do reservatório, com cada um dos 823 conjuntos de previsões previamente apresentadas, e estimada, em cada caso, a série de flexibilizações decorrentes do uso dessas previsões.

Ao chegar nesse ponto, existem: (1) uma série de vertimentos e níveis d'água no reservatório obtidas da simulação da operação do reservatório ao longo do período de simulação sem levar em conta as previsões de vazão de afluência e segundo uma curva-guia utilizada como regra de operação; (2) uma série de vertimentos e níveis d'água no reservatório obtida da simulação da operação do reservatório utilizando previsões perfeitas de vazão, em função de flexibilizações ideais das regras de operação e (3) um conjunto de 823 séries de vertimentos e níveis d'água no reservatório obtidas da simulação da operação do reservatório utilizando as previsões com modelo, em função das flexibilizações recomendadas pelo uso dessas previsões.

Na seqüência, 823 tabelas de contingência 3x3 foram estimadas com base nos resultados da operação, identificando as freqüências de ocorrências da combinação de eventos definidos na metodologia. A Figura 6. 32 à Figura 6. 35 apresentam as tabelas de contingência para as previsões de quatro diferentes modelos de previsão.

Modelo 19		Previsão perfeita		
		Flexib. (+)	Sem flexib.	Flexib. (-)
P r e v i s i o e s	Flexib. (+)	0,0635	0,0009	0,0124
	Sem flexib.	0,0020	0,8093	0,0412
	Flexib. (-)	0,0123	0,0159	0,0426

Figura 6. 32. Tabela de contingência de freqüências de ocorrência de vertimentos menores, iguais ou maiores aos definidos utilizando previsões perfeitas de vazão, modelo número 19 (modelo que atrasa em nove dias as previsões de vazão). Estudo de caso: reservatório de Furnas.

Finalmente, nessa etapa foram ainda estimados os benefícios incrementais em termos de aumento de geração pelo uso das previsões definidas pelos modelos de previsão. Esses benefícios foram estimados, comparando-se a geração total de energia durante a operação do reservatório sem previsão e com base na previsão e expressos como percentagens.

Modelo 221		Previsão perfeita		
		Flexib. (+)	Sem flexib.	Flexib. (-)
P r e v c o m o d e l o s	Flexib. (+)	0,0608	0,0004	0,0091
	Sem flexib.	0,0034	0,8153	0,0383
	Flexib. (-)	0,0135	0,0104	0,0488

Figura 6. 33. Tabela de contingência de frequências de ocorrência de vertimentos menores, iguais ou maiores aos definidos utilizando previsões perfeitas de vazão, modelo número 221 (previsões por persistência). Estudo de caso: reservatório de Furnas.

Modelo 100		Previsão perfeita		
		Flexib. (+)	Sem flexib.	Flexib. (-)
P r e v c o m o d e l o s	Flexib. (+)	0,0624	0,0007	0,0087
	Sem flexib.	0,0012	0,8140	0,0409
	Flexib. (-)	0,0141	0,0114	0,0466

Figura 6. 34. Tabela de contingência de frequências de ocorrência de vertimentos menores, iguais ou maiores aos definidos utilizando previsões perfeitas de vazão, modelo número 100 (modelo com erros segundo uma distribuição normal). Estudo de caso: reservatório de Furnas.

Modelo 1		Previsão perfeita		
		Flexib. (+)	Sem flexib.	Flexib. (-)
P r e v c o m o d e l o s	Flexib. (+)	0,0594	0,0005	0,0102
	Sem flexib.	0,0032	0,8129	0,0446
	Flexib. (-)	0,0151	0,0126	0,0413

Figura 6. 35. Tabela de contingência de frequências de ocorrência de vertimentos menores, iguais ou maiores aos definidos utilizando previsões perfeitas de vazão, modelo número 1 (modelo que antecipa em dez dias as previsões de vazão). Estudo de caso: reservatório de Furnas.

6.7- Resumo da aplicação da metodologia

O problema abordado nesse trabalho é avaliar diferentes elementos que subsidiam a tomada de decisão na operação de reservatório. Nesse sentido são estimadas previsões de vazão de curto prazo utilizando previsões quantitativas de precipitação do modelo ETA, previsões de precipitação de longo prazo através de índices climáticos e uma medida de desempenho com base na utilidade das previsões.

A região do estudo de caso é a bacia hidrográfica de contribuição ao reservatório de Furnas, localizada na bacia do Rio Grande (MG).

As previsões de vazão de afluência de curto prazo são calculadas utilizando doze modelos de redes neurais artificiais. Cada modelo realiza a previsão de vazão afluente ao reservatório de Furnas para um dia do horizonte de previsão. Essas previsões têm as seguintes características:

- período: janeiro de 1996 a dezembro de 2000;
- frequência: uma previsão a cada 7 dias;
- horizonte: 12 dias (baseado em previsões de chuva de 10 dias obtidas com o modelo atmosférico regional ETA);

Na seqüência são estimadas previsões de precipitação de longo prazo, mais particularmente, é prevista, no mês de novembro, a precipitação acumulada do trimestre Dezembro, Janeiro e Fevereiro (DJF), o período tipicamente mais chuvoso durante o ano na bacia hidrográfica de contribuição ao reservatório de Furnas. Como variáveis preditoras são utilizados apenas índices climáticos relacionados ao ENSO, NAO, PDO e SAM. Os índices climáticos são representativos da intensidade, ao longo do tempo, dos modos de variabilidade atmosférica e fenômenos climáticos com incidência na bacia hidrográfica analisada.

Na estimativa da medida de desempenho baseada na utilidade das previsões de vazão de afluência a reservatórios são considerados dois estudos de caso: o reservatório de Furnas e o reservatório de Três Marias, localizado no rio São Francisco (MG). Em ambos casos, durante o cálculo da medida de desempenho baseada na utilidade das previsões, é empregado um processo de simulação da operação do reservatório simplificado, com o objetivo de tornar claros os resultados. Nesse problema simplificado foi considerado que os reservatórios possuem apenas, dois usos: a geração de energia e o controle de cheias. O problema considera

ainda as restrições na operação do reservatório que refletem de forma muito aproximadas às restrições de operação existentes no reservatório de Três Marias e no reservatório de Furnas.

Na estimativa da medida de desempenho baseada na utilidade das previsões de vazão de afluência a reservatórios são utilizados diferentes conjuntos de previsões de vazão, apresentando comportamentos particulares. Os resultados da operação do reservatório utilizando essas previsões são posteriormente comparados aos resultados da operação com previsões perfeitas de vazão (previsões sem erros) e aos resultados da operação sem levar em conta as informações da previsão, obtendo-se tabelas de contingência em função das frequências de ocorrência das diferentes flexibilizações das regras de operação.

Se eu soubesse o que eu estava fazendo, não seria chamada pesquisa.

Albert Einstein

7- Resultados e discussão

7.1- Previsões de vazão de curto prazo

7.1.1- Resultados com a metodologia proposta

A metodologia proposta foi aplicada, em uma primeira etapa, no desenvolvimento de modelos empíricos de previsão de vazão de afluência de curto prazo ao reservatório de Furnas. Os modelos empíricos utilizados foram as redes neurais artificiais (RNAs).

Os doze modelos de RNAs desenvolvidos para prever a vazão em Furnas foram alimentados com cinco variáveis de entrada, sendo que cada modelo prevê a vazão para um dia do horizonte (horizonte das previsões de 12 dias). Quatro das variáveis de entrada foram definidas com base nos dados de vazão: média diária das vazões nos exutórios das sub-bacias de montante no dia t ($QM4(t)$) e seu valor incremental entre os dias $t-1$ e t ($\Delta QM4(t)$); vazão em Furnas no dia t ($QF(t)$) e o valor incremental entre os dias $t-1$ e t ($\Delta QF(t)$). Os valores dessas variáveis são os mesmos para uma previsão que inicia no dia t , independentemente do intervalo de tempo dentro do horizonte de previsão. A quinta variável de entrada é definida com base nos valores de precipitação média diária (na bacia) acumulada de doze dias ($Pma12(t)$) e apresenta valores diferentes conforme o intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão.

Para avaliar o desempenho da rede foram utilizados dois conjuntos de verificação, sendo ambos compostos de dados de 12/01/1996 a 31/12/2000, totalizando 260 pares de dados (frequência de previsão semanal). No primeiro conjunto de verificação, as previsões de precipitação correspondem às obtidas pelo modelo ETA e no segundo conjunto de verificação são utilizadas previsões perfeitas de chuvas (valores observados).

Os valores de quatro medidas de desempenho (o Coeficiente de Nash-Sutcliffe - CE, o Erro médio absoluto – EMA, o Erro médio relativo – EMR e o Erro padrão - EP) da previsão de vazão afluente ao reservatório de Furnas, com um horizonte de doze dias, no período de verificação (01/1996–12/2000), são apresentados na Figura 7. 1.

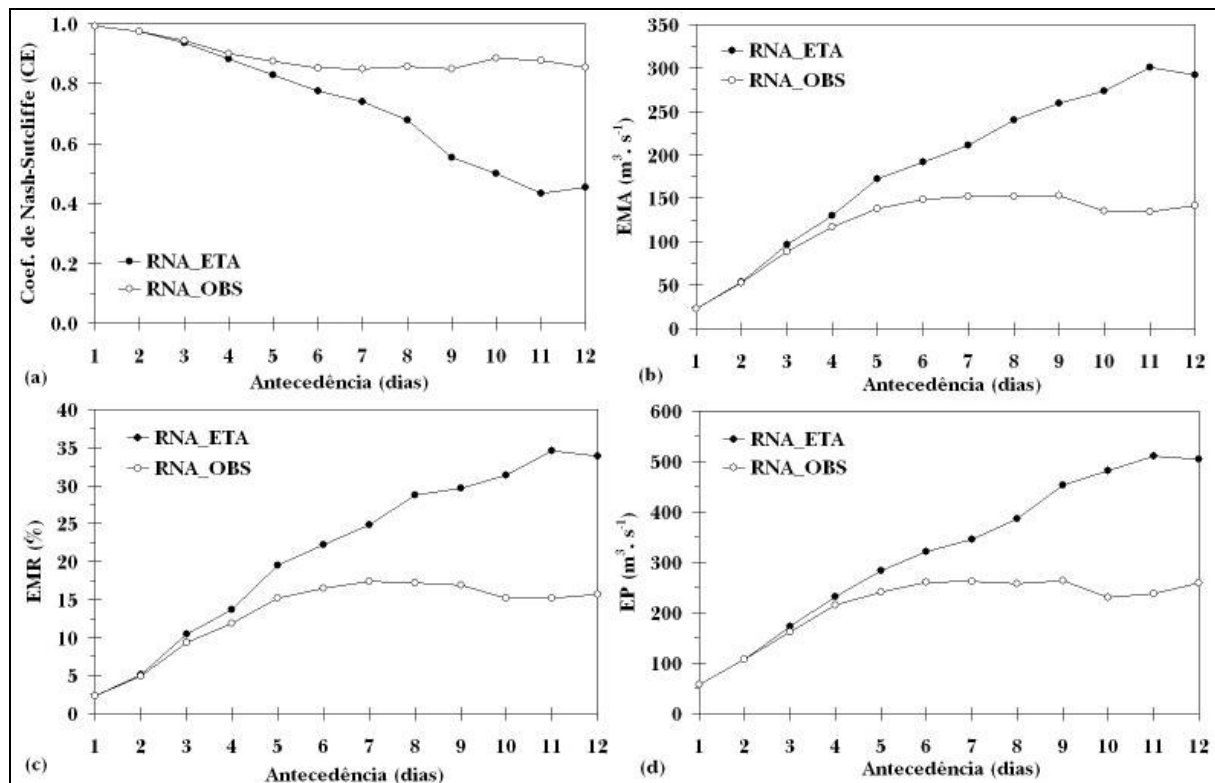


Figura 7. 1. Valores das medidas de desempenho para os diferentes dias do horizonte de previsão (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)): a) Coeficiente de Nash-Sutcliffe (CE); b) Erro médio absoluto (EMA); c) Erro médio relativo (EMR); d) Erro padrão de previsão (EP).

Observa-se que o erro nas previsões de vazão afluente ao reservatório de Furnas tende a aumentar conforme aumenta o horizonte de previsão. Entretanto, esse erro na previsão de vazão aumenta em maior medida quando utilizadas as previsões do modelo ETA se comparado aos erros obtidos considerando chuva prevista perfeita (chuva observada como previsão). Isso mostra como os erros na previsão de chuva influenciam os resultados obtidos na previsão de vazão e deixa em evidência o quanto a previsão de vazão afluente ao reservatório de Furnas poderia ser beneficiada com o aprimoramento das previsões de chuva.

Ainda pode-se destacar que os resultados obtidos com previsão perfeita de chuva e considerando a chuva do modelo ETA são similares até o quinto dia do horizonte de previsão. A partir do sexto dia da previsão de vazão, o desempenho da rede neural utilizando previsões

quantitativas de chuva do modelo ETA diminui, em comparação a se considerar previsão perfeita de chuva.

A seqüência de gráficos ilustrados na Figura 7. 2 à Figura 7. 5 apresenta as previsões contínuas de vazão, realizadas semanalmente, durante o período 30/10/1996 a 4/12/1996, utilizando previsões de chuva do modelo ETA e previsões perfeitas de chuva (chuva observada). Observa-se que as previsões de vazão apresentam bons resultados em termos gerais no período analisado. Para os primeiros dias do horizonte de previsão os resultados são similares utilizando chuva prevista pelo modelo ETA ou previsão perfeita de chuva. Entretanto, conforme aumenta o intervalo de tempo dentro do horizonte de previsão, o desempenho do modelo que utiliza as previsões de chuva do modelo ETA diminui, sub-estimando as vazões previstas devido a sub-estimativas na previsão de chuva.




Figura 7. 2. Previsões contínuas de vazão afluente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996. Data da previsão: 29/10/1996.

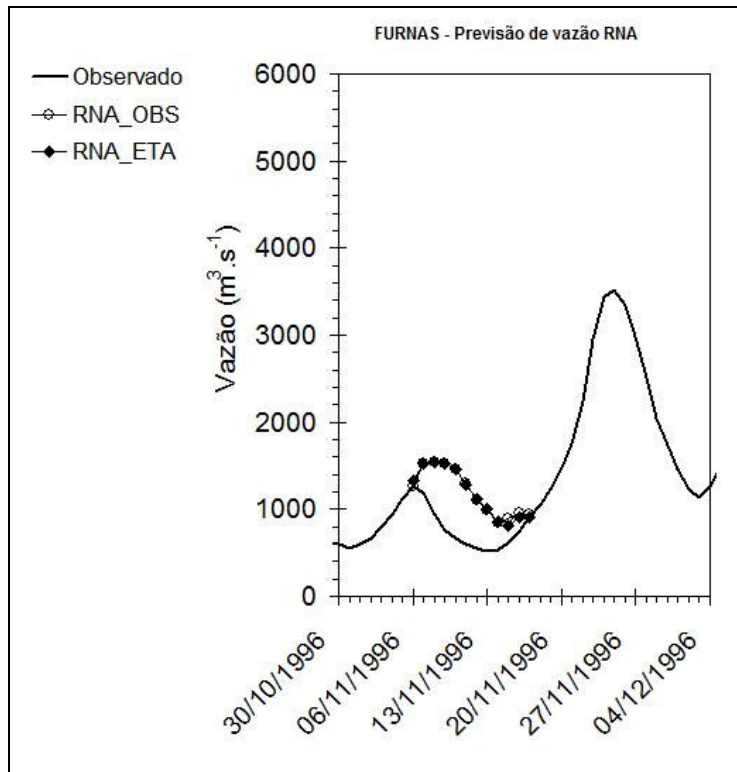


Figura 7. 3. Previsões contínuas de vazão afluyente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996. Data da previsão: 5/11/1996.




Figura 7. 4. Previsões contínuas de vazão afluyente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996. Data da previsão: 12/11/1996.




Figura 7. 5. Previsões contínuas de vazão afluyente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996. Data da previsão: 19/11/1996.

A seqüência de gráficos ilustrados na Figura 7. 6 e na Figura 7. 7 apresentam uma comparação entre os valores observados das vazões de afluência ao reservatório de Furnas e os valores previstos utilizando as chuvas do modelo regional ETA, considerando as diferentes antecedências (1 a 6 dias, na Figura 7. 6, e de 7 a 12 dias, na Figura 7. 7). Esses gráficos mostram que até uma antecedência de três dias, os resultados são muito bons, sendo a vazão prevista muito próxima à vazão observada. A partir de uma antecedência de quatro dias se apresenta uma maior dispersão dos resultados para vazões maiores a $1000 \text{ m}^3 \cdot \text{s}^{-1}$, e as vazões previstas possuem uma leve tendência a superestimar os valores observados até uma antecedência de seis dias. Em antecedências de sete a 12 dias fica mais evidente a tendência do modelo a superestimar as vazões, se apresentando ainda uma maior dispersão dos valores previstos em relação à previsão perfeita (linha a 45°).

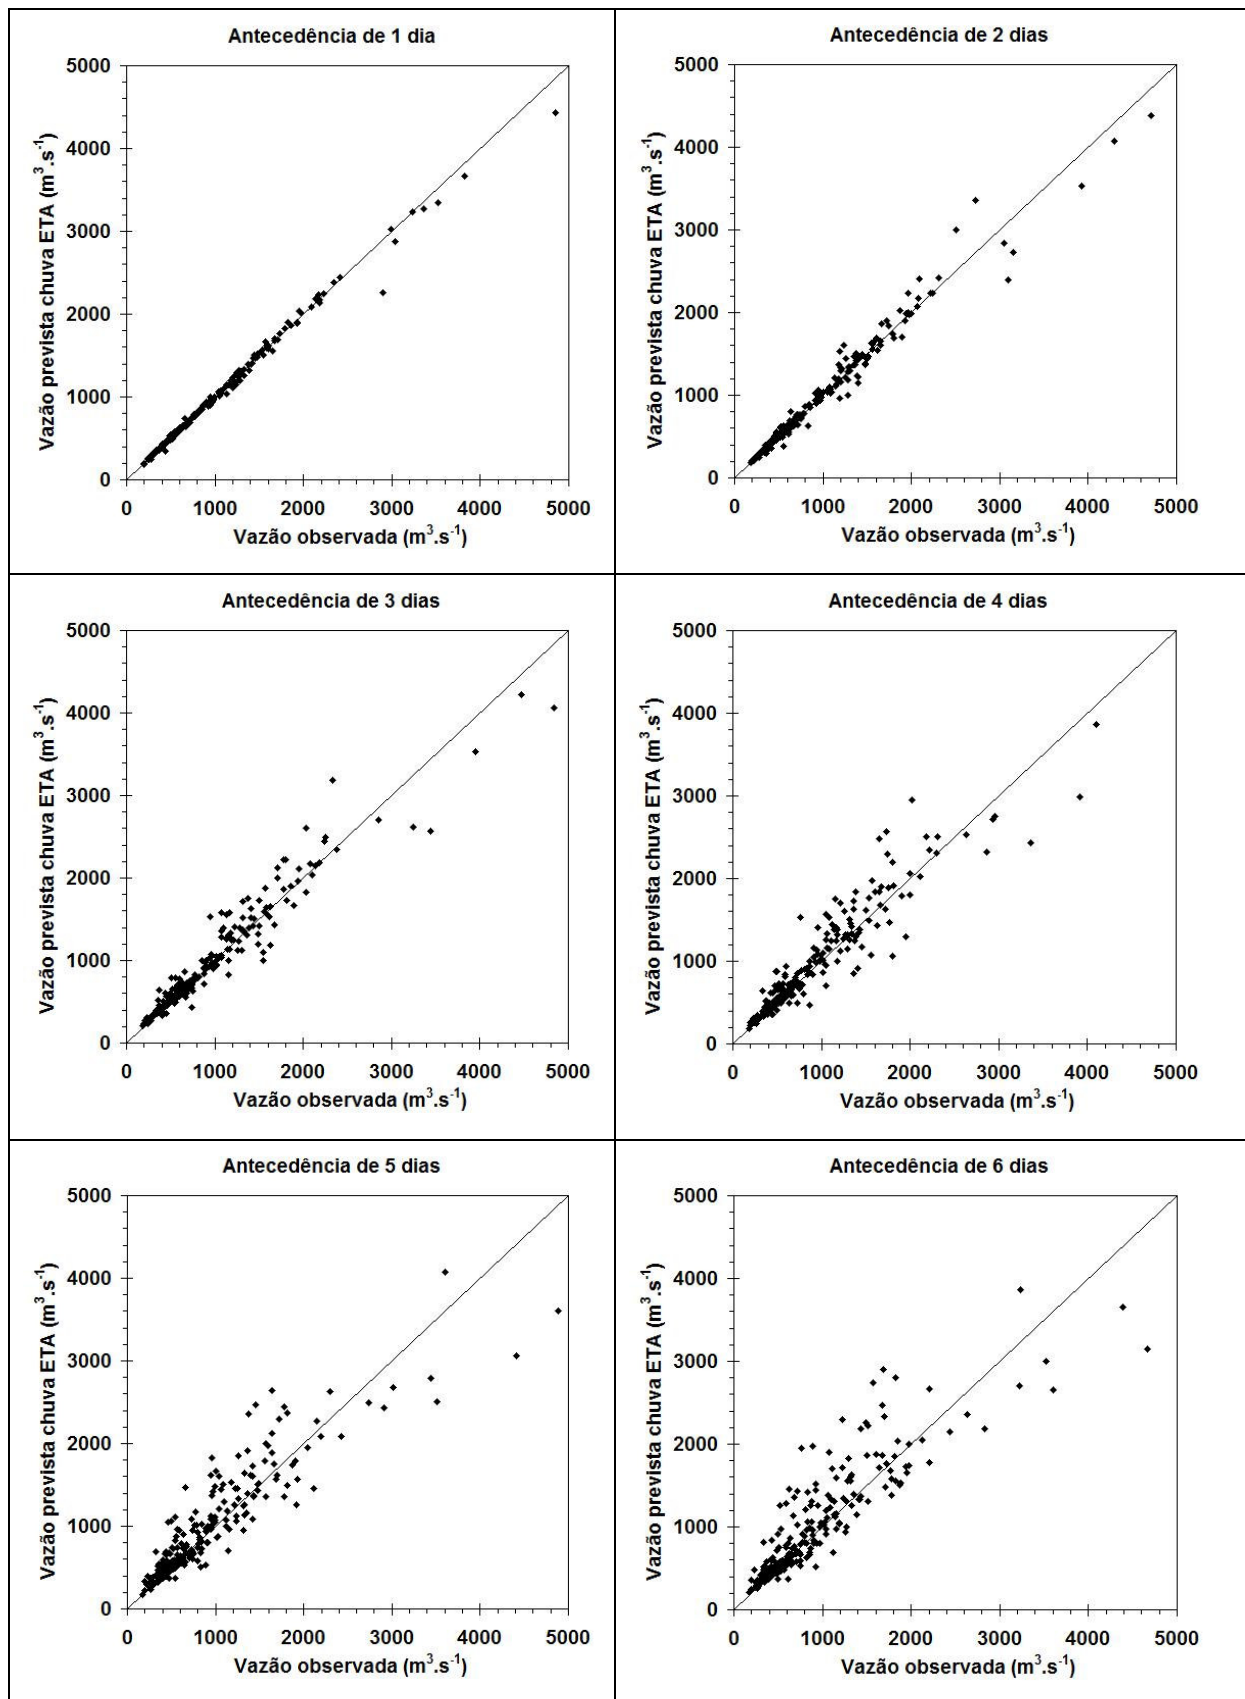


Figura 7. 6. Vazão de afluência ao reservatório de Furnas observada vs. Vazão prevista com chuvas do modelo ETA, com antecedências de 1 a 6 dias.

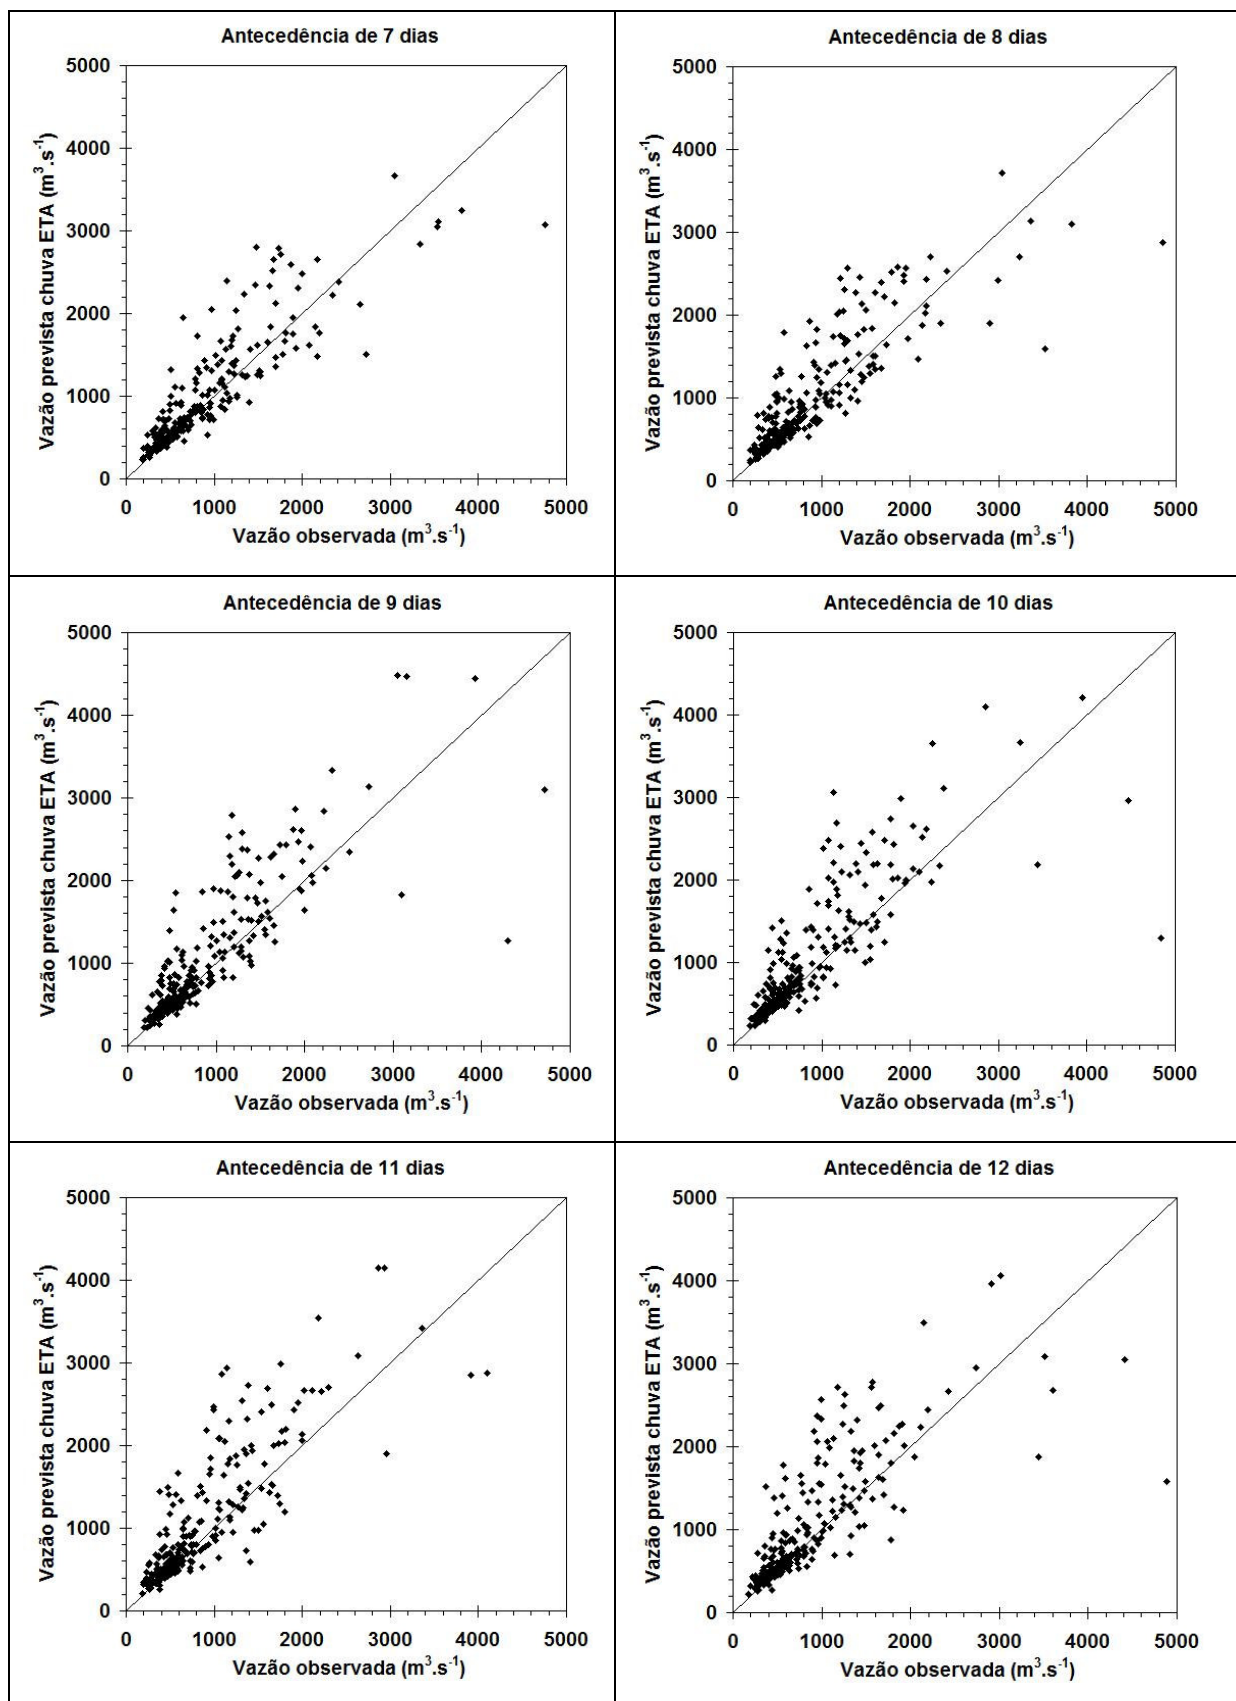


Figura 7. 7. Vazão de afluência ao reservatório de Furnas observada vs. Vazão prevista com chuvas do modelo ETA, com antecedências de 7 a 12 dias.

Estimativas do desempenho do modelo de previsão de vazão de afluência ao reservatório de Furnas, atualmente utilizado pelo ONS e que não utiliza previsão de chuva, foram disponibilizadas por Guilhon et al. (2007). Valores de EMR4 e EMR4-10 em torno de 22% e 28%, respectivamente, são obtidos empregando a metodologia atual. Os valores dessas estimativas representam valores típicos de desempenho desse modelo na área de estudo

Os valores das medidas de desempenho obtidos com a rede neural desenvolvida no presente trabalho se apresentam melhores, em todos os casos, que os obtidos pelo modelo atualmente utilizado pelo ONS no período analisado. Considerando o uso de chuva prevista pelo modelo ETA como entrada, o EMR4 diminui de 22% para 13,7% e o EMR4-10 diminui de 28% para 22%.

Melhores resultados são obtidos quando utilizada a previsão perfeita de chuva (chuva observada), com valores de EMR4 e EMR4-10 iguais a 11,9% e 13,8%, respectivamente.

Embora a previsão perfeita de chuva seja hipotética (não possui erros), seu uso indica os patamares dos benefícios que poderiam ser obtidos com o aprimoramento das previsões de chuva. A diminuição do EMR4 foi similar utilizando previsão de chuva do modelo ETA e previsão perfeita de chuva. Entretanto, a redução do EMR4-10 quando utilizada a previsão perfeita de chuva pode ser considerada importante, com um valor superior a 50% (de 28% para 13,8%).

7.1.2- Comparação de resultados com modelos conceituais

Na seqüência foi feita uma comparação dos resultados da metodologia proposta com os resultados obtidos com o modelo hidrológico MGB-IPH (Collischonn et al., 2007a; Collischonn et al., 2007b) ajustado por IPH (2005) para gerar previsões de vazão de afluência ao reservatório de Furnas.

O modelo MGB-IPH é um modelo hidrológico distribuído e conceitual, aplicado em um grande número de bacias na modelagem do processo chuva-vazão e na estimativa de previsões de vazão. É importante ressaltar que o modelo MGB-IPH foi quem apresentou os melhores resultados nas diferentes comparações do desempenho do conjunto de modelos de previsão avaliados por Guilhon et al. (2007).

Uma comparação dos resultados obtidos no período de verificação com a metodologia proposta e com o modelo MGB-IPH é apresentada na Figura 7. 8. Observa-se nessa figura que quando previsões perfeitas de chuva são utilizadas (chuva observada como previsão), os resultados mostram que o modelo baseado em RNAs apresenta um melhor desempenho até o

terceiro dia da previsão, porém, para horizontes maiores, o modelo hidrológico apresenta melhores resultados. Como consequência da defasagem entre a precipitação e a vazão, a previsão de vazão para os primeiros três dias do horizonte é fortemente dependente da quantidade d'água já existente na bacia, como por exemplo dada pela vazão atual observada no local de interesse. Nessa situação, os modelos baseados em RNAs possuem bom desempenho na previsão de vazão, como apresentado por diferentes estudos prévios. Entretanto, para os maiores horizontes, o processo de transformação chuva-vazão e o armazenamento da água na bacia adquirem maior importância, fazendo que o modelo hidrológico conceitual apresente melhores resultados que o modelo empírico baseado em RNAs.

A diferença entre os desempenhos do MGB-IPH e das RNAs muda com o uso das previsões quantitativas de chuvas dadas pelo modelo ETA. Melhores previsões foram obtidas com as RNAs até o sétimo dia da previsão, enquanto que o modelo hidrológico apresenta melhores resultados nos últimos cinco dias da previsão. Esses resultados parecem indicar que as RNAs são menos sensíveis aos erros das previsões de precipitação, se comparadas ao modelo hidrológico para o local analisado.

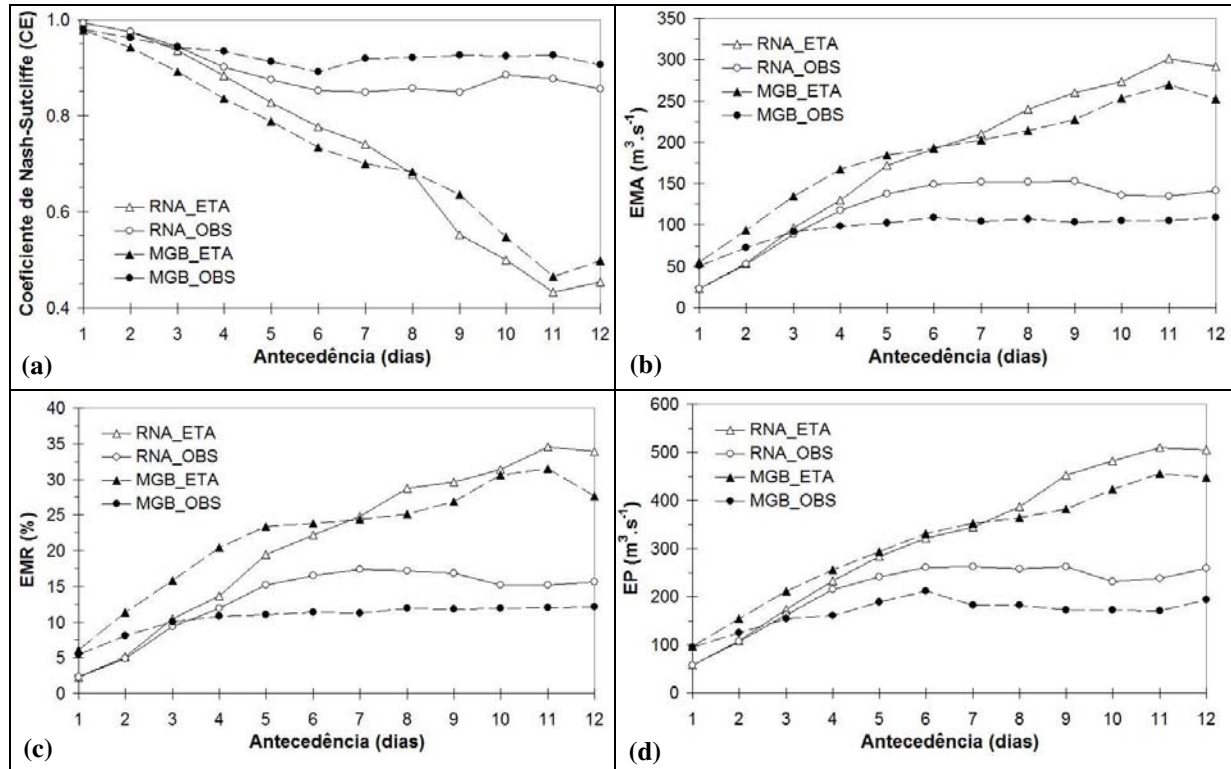


Figura 7. 8. Valores das medidas de desempenho para os diferentes dias do horizonte de previsão: a) Coeficiente de Nash-Sutcliffe (CE); b) Erro médio absoluto (EMA); c) Erro médio relativo (EMR); d) Erro padrão de previsão (EP).

A Figura 7. 9 e a Figura 7. 10 apresentam um exemplo de previsões contínuas de vazão de afluência ao reservatório de Furnas utilizando os modelos empíricos baseados em redes neurais artificiais e o modelo hidrológico conceitual MGB-IPH, respectivamente, no período de 11/12/1996 a 26/01/1997. Em ambas figuras existem seis gráficos mostrando a previsão calculada em semanas sucessivas.




Figura 7. 9. Previsões contínuas de vazão afluente ao reservatório de Furnas utilizando os modelos baseados em RNAs com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 11/12/1996 a 26/01/1997.

Observa-se nessas figuras que ambos modelos apresentam bons resultados no período mostrado. É importante ressaltar que essas figuras mostram, claramente, como a qualidade das previsões de vazão depende das previsões quantitativas de chuva utilizadas. Assim, por exemplo, a previsão de vazão emitida no dia 18/12/1996 (veja o gráfico superior central de cada figura) tem antecipado e superestimado a vazão de pico quando utilizadas as previsões

quantitativas de chuva do ETA, enquanto que com o uso de previsões perfeitas de precipitação são obtidas previsões de vazão muito próximas aos valores observados.




Figura 7. 10. Previsões contínuas de vazão afluente ao reservatório de Furnas utilizando o modelo conceitual MGB-IPH com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 11/12/1996 a 26/01/1997.

A seqüência de gráficos ilustrados na Figura 7. 11 e na Figura 7. 12 apresentam uma comparação entre os valores observados das vazões de afluência ao reservatório de Furnas e os valores previstos utilizando as chuva do modelo regional ETA utilizando o modelo empírico (RNA) e o modelo conceitual (MGB-IPH), considerando as diferentes antecedências. Esses gráficos mostram que até uma antecedência de sete dias, os resultados do modelo RNAs apresentam uma menor dispersão dos valores previstos em relação ao modelo conceitual MGB-IPH. Para antecedências maiores, a dispersão em ambos modelos aumenta, mas o modelo conceitual apresenta os melhores resultados.

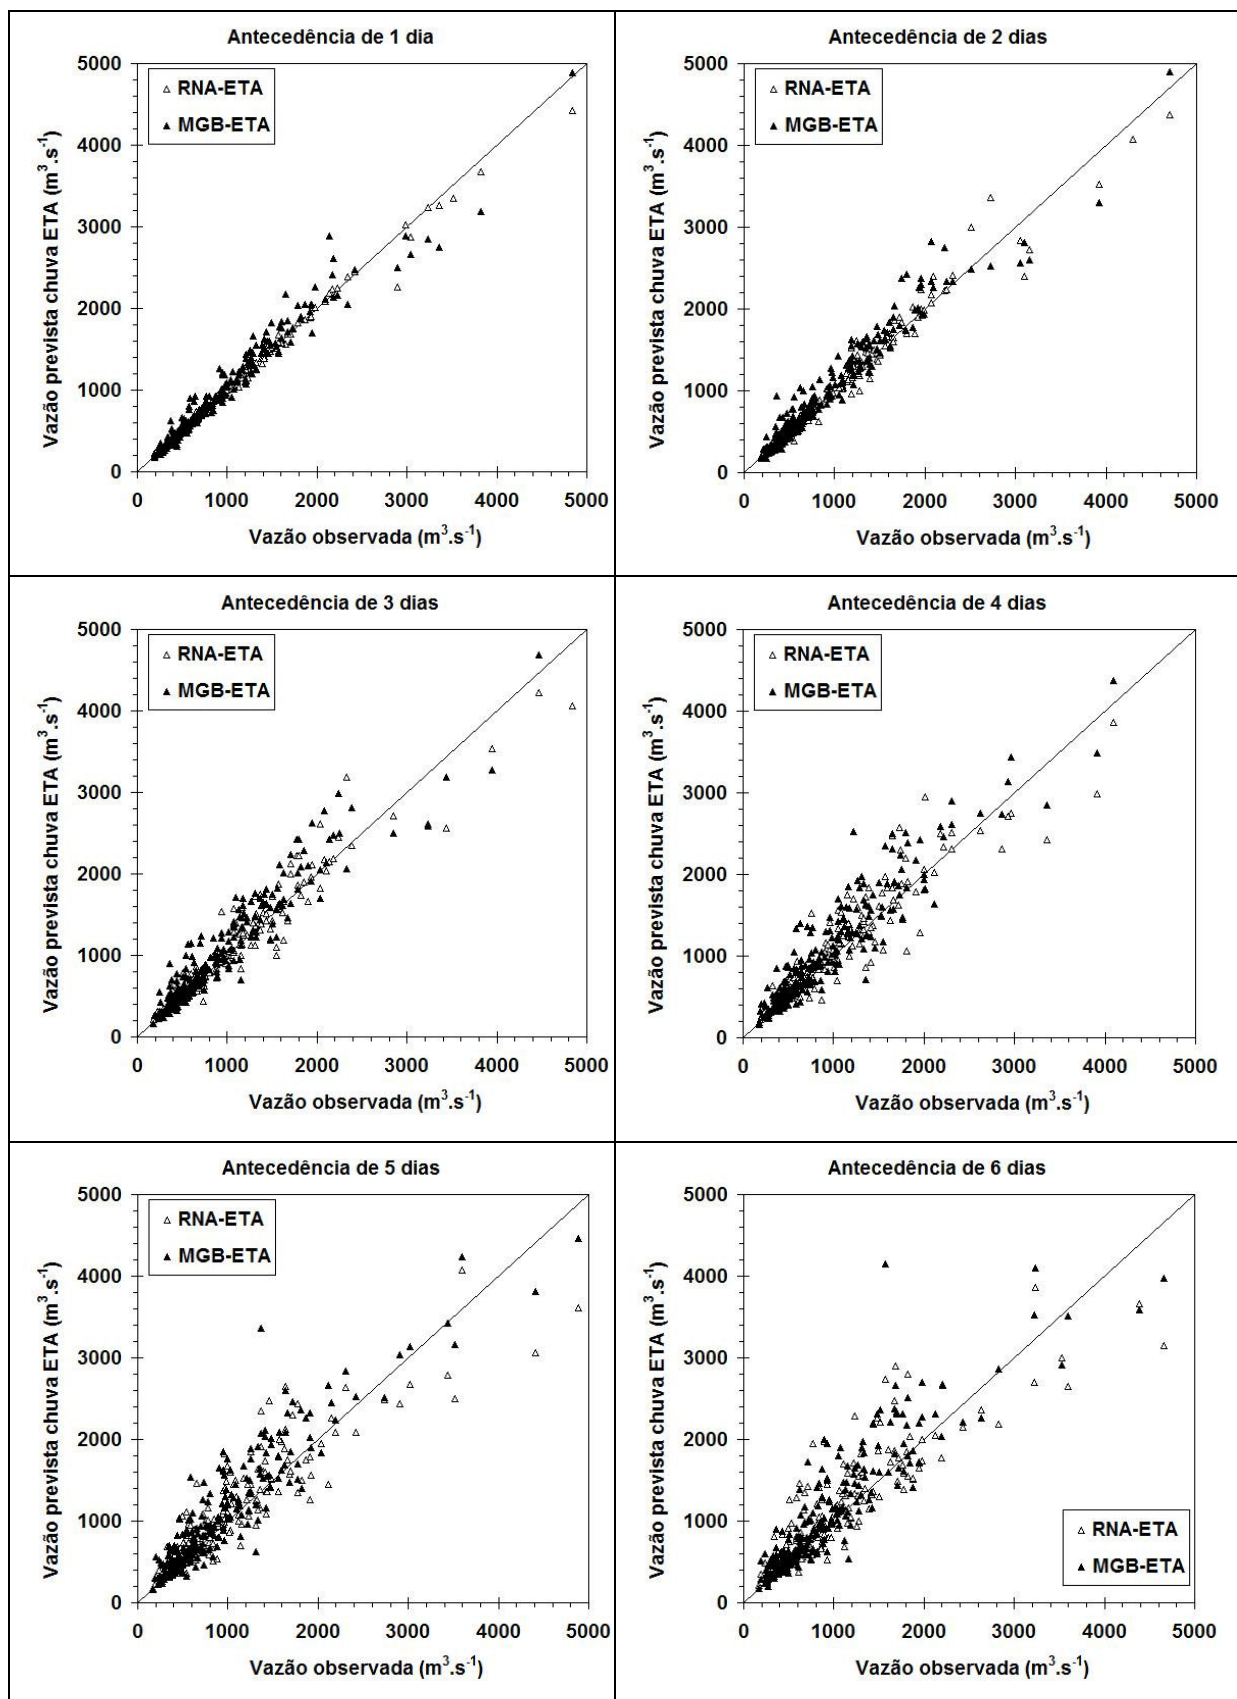


Figura 7. 11. Comparação entre Vazões de afluência ao reservatório de Furnas observadas vs. Vazão prevista com chuvas do modelo ETA utilizando o modelo empírico (RNA) e o modelo conceitual (MGB), com antecedências de 1 a 6 dias.

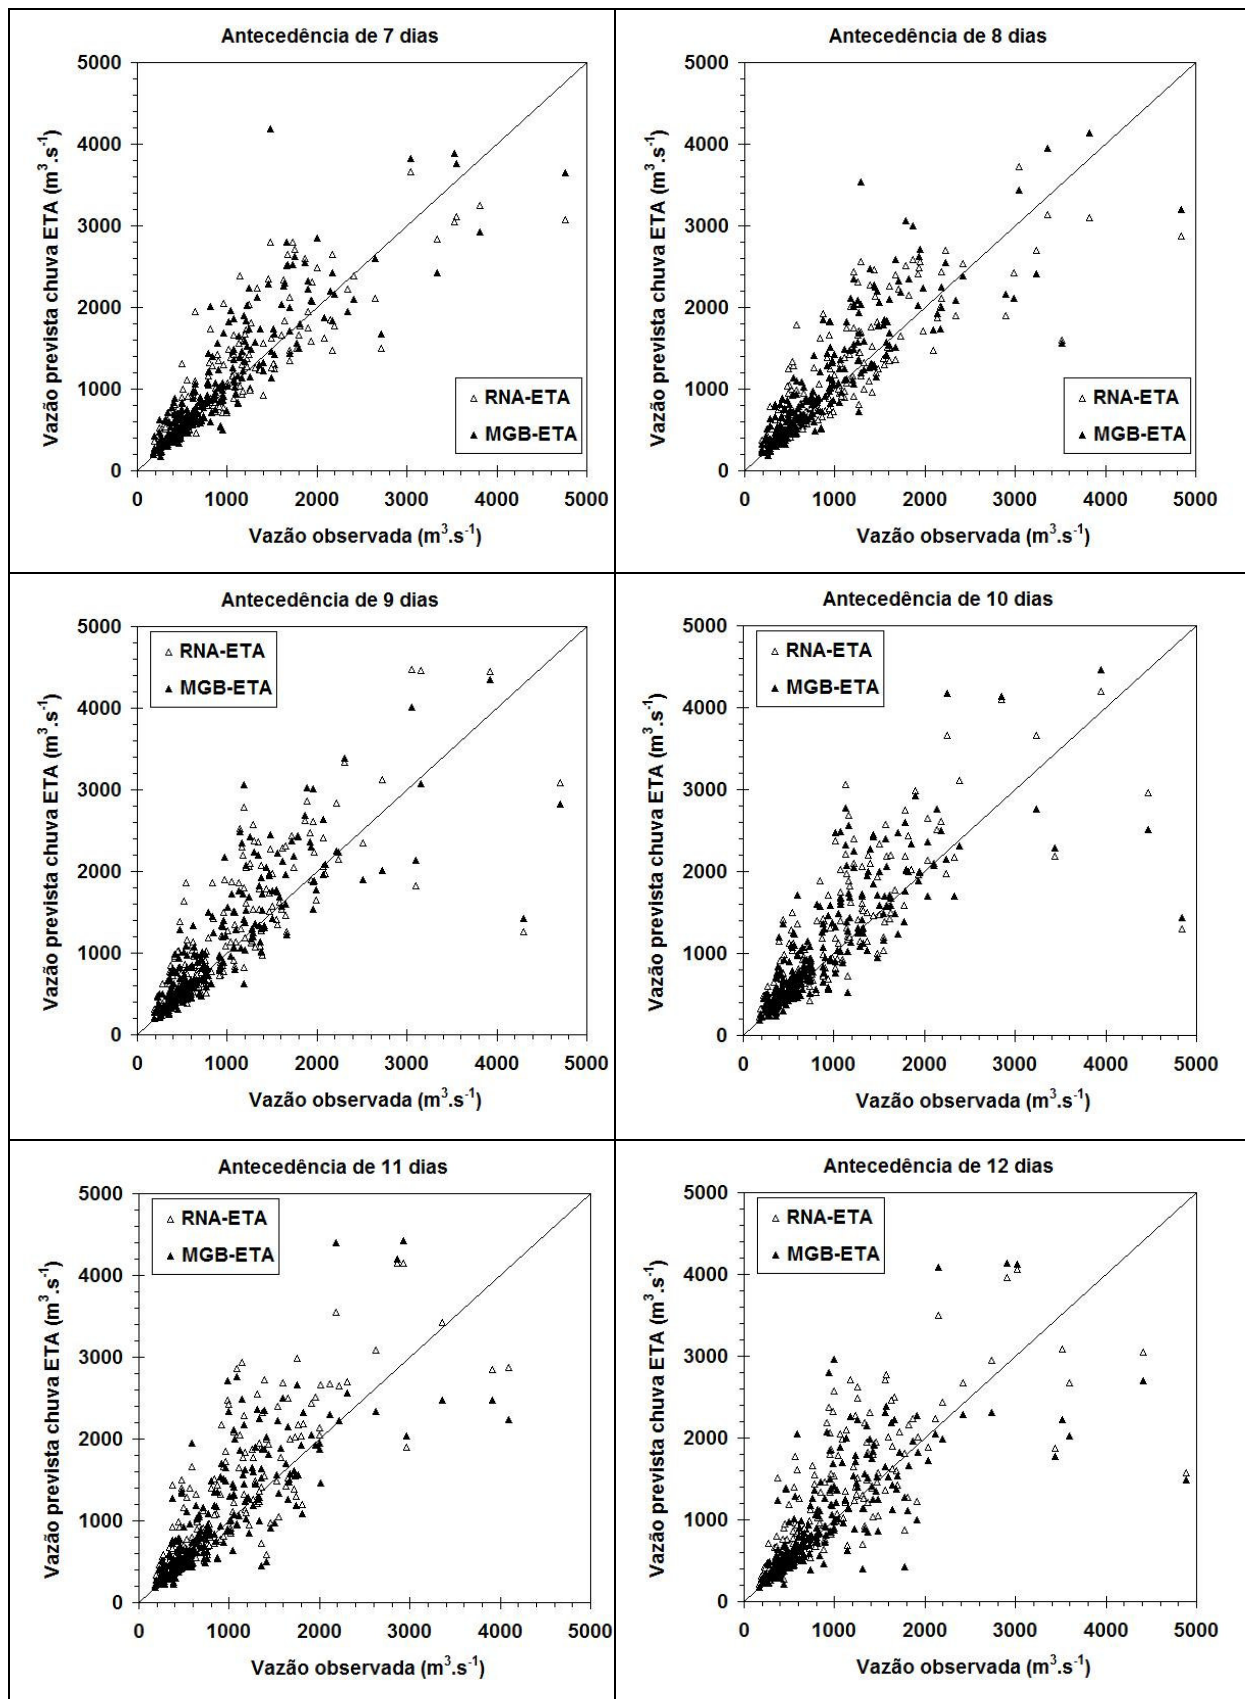


Figura 7. 12. Comparação entre Vazões de afluência ao reservatório de Furnas observadas vs. Vazão prevista com chuvas do modelo ETA utilizando o modelo empírico (RNA) e o modelo conceitual (MGB), com antecedências de 7 a 12 dias.

Por fim, uma comparação dos resultados de todos os modelos (rede neural artificial, MGB-IPH e atual utilizado pelo ONS), em termos das medidas de desempenho tipicamente utilizadas pelos ONS, é apresentado na Tabela 7. 1. EMR4 é o erro médio relativo da previsão no quarto dia da previsão e EMR4-10 o erro médio relativo da média dos valores previstos, entre o quarto e décimo dia do horizonte de previsão. É importante ressaltar que os períodos de referência do cálculo dessas medidas de desempenho não são os mesmos. Enquanto que no caso do modelo do ONS correspondem a valores típicos das medidas de desempenho na região, no caso do modelo baseado em redes neurais artificiais e no modelo MGB-IPH, correspondem aos valores das medidas de desempenho no período de verificação, de 1996 a 2001.

Tabela 7. 1. Medidas de desempenho das previsões obtidas com a metodologia proposta, o modelo conceitual MGB-IPH e com os modelos atualmente utilizados pelo ONS.

Modelo	EMR4 (%)	EMR4-10 (%)
Atual ONS	22,0	27,9
RNA_ETA	13,7	22,0
MGB_ETA	20,4	22,7
RNA_OBS	11,9	13,8
MGB_OBS	10,8	9,8

7.1.3- Eficiência e eficácia em comparação à RNA tradicional

Na seqüência foi feita uma comparação dos resultados da metodologia proposta com os resultados obtidos com o método tradicional, tipicamente utilizado, no uso de modelos de redes neurais artificiais para prever vazão com base em previsões quantitativas de chuvas.

Na aplicação do método tradicional para o desenvolvimento de modelos de previsão de vazão com base em previsões quantitativas de chuva, o período no qual as previsões quantitativas de chuva estão disponíveis é dividido nos conjuntos de treinamento, validação e verificação. Assim, a rede é treinada utilizando as previsões quantitativas de chuva.

Duas grandes diferenças se apresentam com o método proposto nesse trabalho. A primeira é que no método tradicional o número de amostra resulta muito menor, dado que apenas é utilizado o período com informações de previsões quantitativas de chuva. A segunda

diferença reside em que o método proposto nesse trabalho utiliza as precipitações observadas como previsão durante o treinamento da rede neural artificial, e apenas utiliza as previsões quantitativas de chuva na verificação. Dessa forma o treinamento do modelo desenvolvido não fica prejudicado pelas diferentes versões do modelo de previsão de chuva ao longo do tempo, o que sim acontece com o método tradicional.

A comparação dos resultados obtidos no período de verificação com a metodologia proposta e com o método tradicional é apresentado na Figura 7. 13 e na Figura 7. 14. Observa-se nessas figuras que quando utilizadas previsões quantitativas de chuva do modelo regional ETA, os modelos desenvolvidos com base na metodologia proposta nesse trabalho apresentaram melhores resultados para os primeiros oito dias do horizonte de previsão. No entanto, para horizontes maiores, os modelos baseados no método tradicional apresentam o maior desempenho.

Embora as previsões quantitativas de chuva do modelo regional ETA sejam uma tentativa de reproduzir as precipitações observadas, elas são diferentes, e essa diferença aumenta justamente com o passar do número de dias da previsão. Ao utilizar a metodologia proposta nesse trabalho, treinando os modelos de RNAs com precipitações observadas como previsão e fazendo previsões de vazão com base nas previsões quantitativas de chuva do ETA, os modelos apresentam bom desempenho nos primeiros dias do horizonte porque as previsões quantitativas de chuva são mais semelhantes às precipitações observadas. Entretanto, para os últimos dias do horizonte de previsão, as previsões quantitativas de chuva do ETA apresentam maiores erros e a qualidade da previsão de vazão diminui. Assim, para os últimos dias do horizonte, a rede treinada com o método tradicional apresenta melhores resultados.




Figura 7. 13. Coeficiente de Nash-Sutcliffe para os diferentes dias do horizonte de previsão.




Figura 7. 14. Erro médio relativo (%) para os diferentes dias do horizonte de previsão.

Observa-se ainda na Figura 7. 13 e na Figura 7. 14. que quando previsões perfeitas de chuva são utilizadas (chuva observada como previsão), os resultados mostram que os modelos baseados no método proposto nesse trabalho apresentam sempre os melhores desempenhos. Isto era um resultado esperado, dado que ao fazer as previsões de vazão usando as previsões perfeitas de chuva com os modelos de redes neurais treinados com esse tipo de previsões de chuva, está sendo dado aos modelos o mesmo padrão dessa variável de entrada.

Na análise dos resultados utilizando previsões perfeitas de chuva, é importante ressaltar o que aconteceu no nono dia do horizonte da previsão (Figura 7. 13), usando o método tradicional foi obtido um maior coeficiente de Nash-Sutcliffe utilizando previsões quantitativas de chuva do modelo ETA que utilizando as previsões perfeitas de chuva.

Finalmente, a Figura 7. 15 e a Figura 7. 16 apresentam as curvas de permanência dos erros da previsão em cada dia do horizonte da previsão, tanto para os modelos baseados na metodologia proposta nesse trabalho como aqueles baseados no método tradicional. Observa-se nessa figura que, em quase todos os dias do horizonte, a metodologia proposta nesse trabalho apresenta os menores valores de erro da previsão de vazão, para as maiores permanências.

Finalmente, foi verificada a eficiência da metodologia proposta nesse trabalho. Para cada um dos doze modelos de previsão de vazão de afluência ao reservatório de Furnas foram iniciados 20 processos de treinamento, e estimado o número de vezes em que os valores otimizados dos parâmetros foram achados. Esse procedimento foi repetido tanto no metodologia proposta nesse trabalho como no método tradicional, e os resultados são

apresentados na Figura 7. 17. É importante ressaltar que em ambos casos o algoritmo de treinamento é o mesmo (SCGM), porém os conjuntos de treinamento e validação são diferentes.




Figura 7. 15. Curvas de permanência do erro da previsão nos seis primeiros dias do horizonte de previsão.

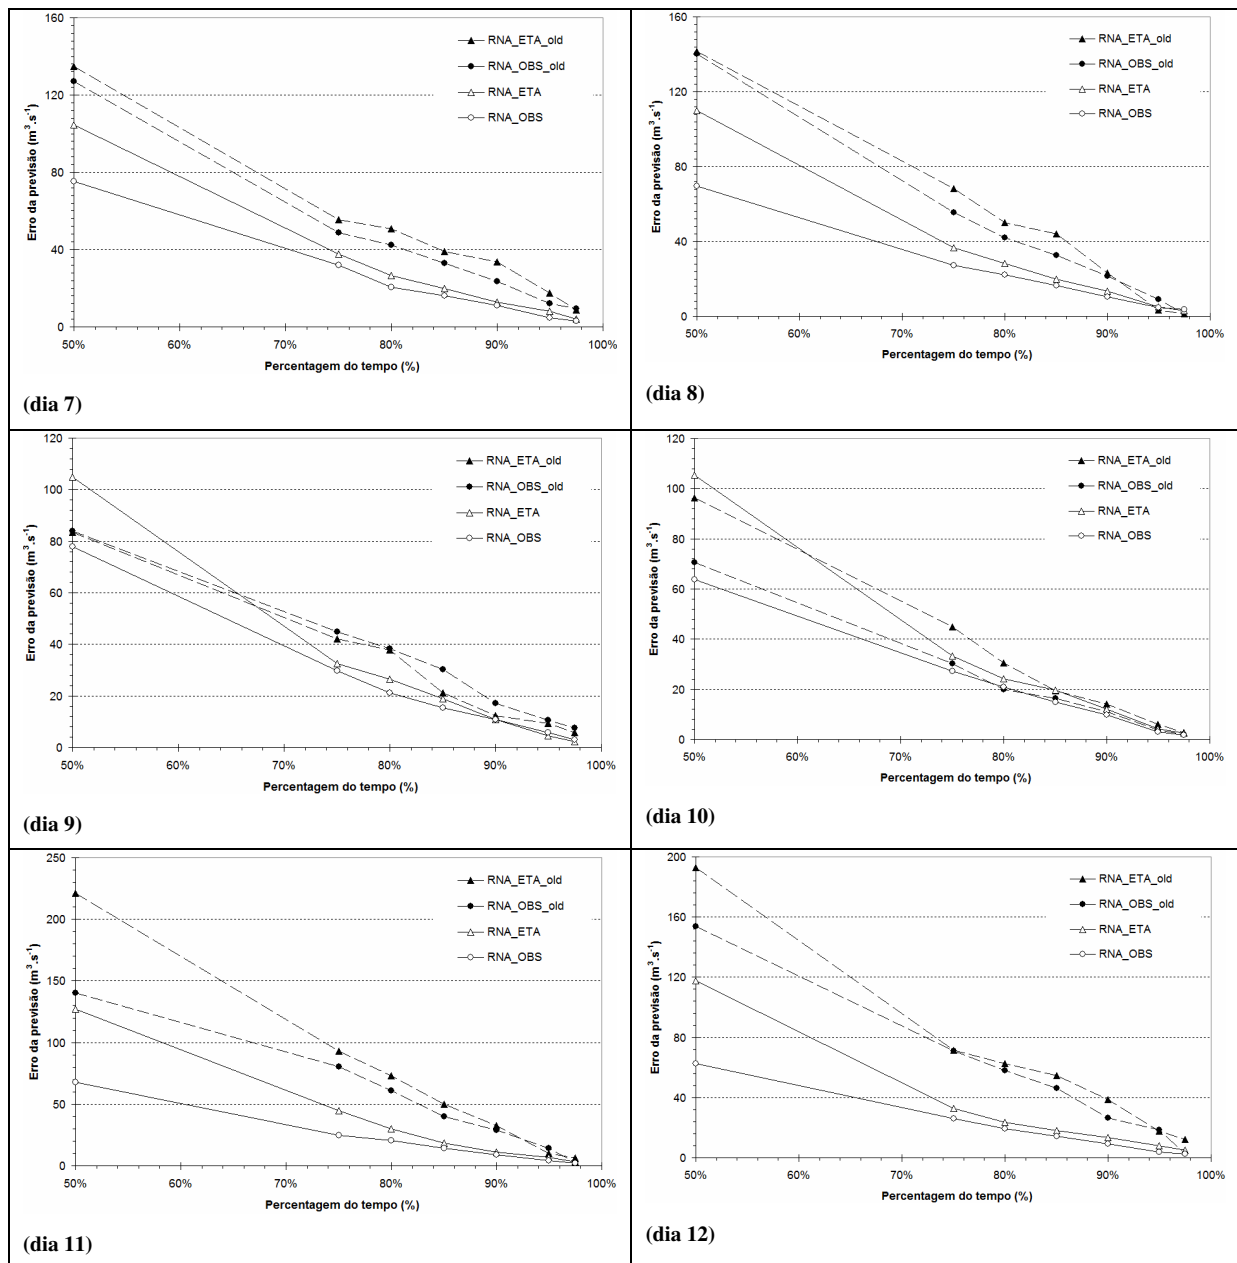


Figura 7. 16. Curvas de permanência do erro da previsão nos últimos seis dias do horizonte de previsão.

Observa-se nessa figura que aplicando a metodologia proposta nesse trabalho, em 5 a 7 vezes de cada 20 processos de treinamento foram achados os verdadeiros valores otimizados dos parâmetros, sendo que os outros resultados foram parecidos, mas com conjuntos de parâmetros diferentes. Por sua vez, com a metodologia tradicional foram obtidos resultados semelhantes, sendo achados os parâmetros otimizados em 3 a 5 vezes de cada 20 processos de treinamento.




Figura 7. 17. Estimativa de eficiência do método desenvolvido nesse trabalho (RNA) e do método tradicional (RNA_old) em 20 processos de treinamento.

Assim, apesar da metodologia proposta trabalhar com um conjunto de dados maior no processo de treinamento e validação, a partir do qual se esperava uma maior facilidade para encontrar os parâmetros otimizados da relação entre as variáveis de entrada e saída do modelo, o aumento da eficiência do processo de otimização com a metodologia proposta foi relativamente pequeno.

7.2- Previsões de longo prazo de precipitação

A metodologia proposta foi aplicada no desenvolvimento de modelos empíricos baseados em redes neurais artificiais para prever a precipitação média sobre a bacia de contribuição ao reservatório de Furnas. As previsões são desenvolvidas no início do período chuvoso e abrangem os meses de dezembro, janeiro e fevereiro (DJF). Assim, no final do mês de novembro é estimado o valor médio de precipitação acumulada para os próximos três meses.

Foram desenvolvidos dois modelos, em ambos os casos utilizando quatro índices climáticos como variável de entrada. As variáveis de entrada do primeiro modelo são aquelas que possuem a maior correlação com a precipitação DJF. Por sua vez, as variáveis de entrada do segundo modelo foram obtidas após uma busca exaustiva, limitada aos dois trimestres anteriores ao da emissão da previsão.

7.2.1- Resultados com variáveis de entrada em função de correlação

Como resultado da aplicação da metodologia desenvolvida nesse trabalho, o modelo de rede neural RNPMC para prever a precipitação acumulada de DJF na bacia de contribuição ao reservatório de Furnas foi projetado com quatro neurônios na camada intermediária, ou seja, com 25 parâmetros (20 pesos e cinco “bias”). Os índices climáticos SAMI(DJF-1), NAOI (DJF-1), El Niño3.4(DJF-2) e PDOI(DJF-2) são as variáveis de entradas do modelo (-x representa uma defasagem de x anos), ou seja, as variáveis correspondem aos valores médios dos índices no mesmo trimestre do ano, mas com defasagem de um e dois anos.

Diferentes processos de treinamento e validação foram realizados para a configuração adotada, fundamentalmente devido à escassez de dados. Os resultados obtidos são apresentados na Figura 7. 18 à Figura 7. 20. Essas figuras apresentam uma comparação entre os valores observados da precipitação DJF na bacia de contribuição ao reservatório de Furnas e os valores previstos com a metodologia utilizada nesse trabalho. Nessas figuras é ainda apresentado o valor da precipitação DJF média de longo período.

Observa-se nessas figuras que o modelo conseguiu representar bem o comportamento da precipitação DJF ao longo dos diferentes conjuntos de treinamento, validação e verificação, esse último conjunto não utilizado durante a calibração do modelo.




Figura 7. 18. Precipitação DJF observada e calculada no conjunto de verificação (a linha tracejada representa o valor da precipitação DJF média de longo período).

O modelo consegue prever corretamente precipitações acima ou embaixo do valor médio de longo período. Isto acontece em todos os conjuntos, sendo que o modelo acerta que a precipitação estará acima ou embaixo do valor médio em sete das dez amostras no conjunto de verificação, em seis das oito amostras no conjunto de validação e em 26 das 33 amostras do conjunto de treinamento.

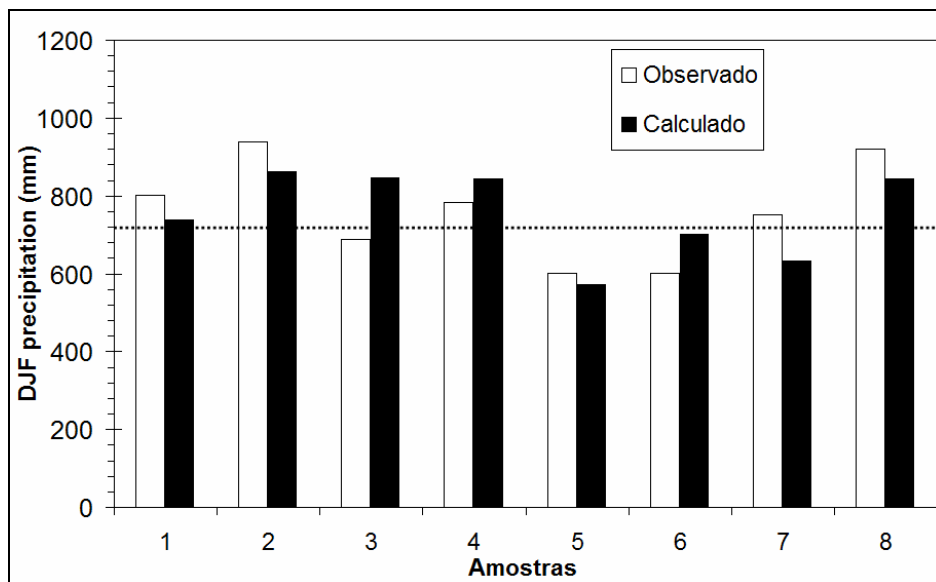


Figura 7. 19. Precipitação DJF observada e calculada no conjunto de validação (a linha tracejada representa o valor da precipitação DJF média de longo período).




Figura 7. 20. Precipitação DJF observada e calculada no conjunto de treinamento (a linha tracejada representa o valor da precipitação DJF média de longo período).

É importante ressaltar ainda, observando a Figura 7. 18 à Figura 7. 20, que o modelo consegue prever melhor os períodos de secas extremas que os períodos muito úmidos. A exceção da amostra 15 (ano 1970), o menor valor da série histórica, todos os restantes eventos de seca extrema foram muito bem representados.

Para melhor avaliar o desempenho do modelo, um gráfico de correlação das precipitações de DJF observadas e calculadas é apresentado na Figura 7. 21. Os resultados apresentados nessa figura deixam em evidência o bom comportamento geral do modelo na previsão da precipitação DJF na bacia de contribuição ao reservatório de Furnas.

Foi calculada a medida de desempenho REMQ, igual à razão entre o Erro médio quadrático obtido com o modelo de redes neurais e o Erro médio quadrático ao utilizar o valor médio de longo período como previsão. Assim, quanto menor o valor de REMQ, melhor o desempenho do modelo, sendo que a previsão perfeita da precipitação DJF (previsão sem erros) teria REMQ igual a zero.

Os valores obtidos para o conjunto de treinamento, validação e verificação foram: $REMQ = 0,42$; $REMQ = 0,33$ e $REMQ = 0,52$; respectivamente. Observa-se que valores muito parecidos de REMQ foram obtidos nos três conjuntos, treinamento, validação e verificação, o que pode ser considerado como uma boa indicação da capacidade de generalização do modelo.




Figura 7. 21. Precipitação DJF observada vs precipitação DJF calculada, nos conjuntos de treinamento, validação e verificação (a linha tracejada corresponde a previsão perfeita).

Esse primeiro modelo foi desenvolvido utilizando como variáveis de entrada os índices climáticos com defasagens definidas em função de uma análise de correlação. No entanto, essas variáveis possuem defasagem de um e dois anos com relação à variável sendo prevista, a precipitação DJF na bacia de contribuição ao reservatório de Furnas. Embora um modelo empírico não precisa representar o comportamento físico dos processos, resulta mais conveniente assegurar a viabilidade das variáveis de entrada ainda fisicamente. Assim, no segundo modelo desenvolvido, a defasagem das variáveis de entrada foi limitada aos dois trimestres prévios ao de emissão das previsões.

7.2.2- Resultados com variáveis de entrada limitadas aos dois trimestres prévios

Nessa segunda etapa foi feita uma busca exaustiva da melhor defasagem nas quatro variáveis de entrada ao modelo de redes neurais artificiais, limitada aos dois trimestres antecedentes ao da emissão da previsão (SON é o trimestre Setembro-Outubro-Novembro e JJA é o trimestre Junho-Julho-Agosto).

Da mesma forma que no caso anterior, o modelo de rede neural RNPMC para prever a precipitação acumulada de DJF na bacia de contribuição ao reservatório de Furnas foi projetado com quatro neurônios na camada intermediária, ou seja, com 25 parâmetros (20 pesos e cinco “bias”). As variáveis de entrada que melhor desempenho apresentaram, após diferentes processos de treinamento e validação realizados com a configuração adotada, foram os índices climáticos SAMI(SON), NAOI (SON), El Niño3.4(JJA) e PDOI(JJA).

Os resultados obtidos são apresentados na Figura 7. 22 à Figura 7. 24. Essas figuras apresentam uma comparação entre os valores observados da precipitação DJF na bacia de contribuição ao reservatório de Furnas e os valores previstos com a metodologia utilizada nesse trabalho. Nessas figuras é ainda apresentado o valor da precipitação DJF média de longo período.

Observa-se nessas figuras que o modelo conseguiu representar muito bem o comportamento da precipitação DJF ao longo dos diferentes conjuntos de treinamento, validação e verificação, esse último conjunto não utilizado durante a calibração do modelo.

O modelo consegue prever corretamente precipitações acima ou embaixo do valor médio de longo período. Isto acontece em todos os conjuntos, sendo que o modelo acerta que

a precipitação estará acima ou embaixo do valor médio em oito das dez amostras no conjunto de verificação, em sete das oito amostras no conjunto de validação e em 29 das 35 amostras do conjunto de treinamento.




Figura 7. 22. Precipitação DJF observada e calculada no conjunto de verificação (a linha tracejada representa o valor da precipitação DJF média de longo período).




Figura 7. 23. Precipitação DJF observada e calculada no conjunto de validação (a linha tracejada representa o valor da precipitação DJF média de longo período).

É importante ressaltar ainda, observando a Figura 7. 22 à Figura 7. 24, que o modelo consegue prever, da mesma forma que aconteceu com o primeiro modelo, melhor os períodos de secas extremas que os períodos muito úmidos. Nesse caso, o modelo até conseguiu

representar bem o valor extremo do ano 1970 (amostra 15), mas prevendo alguns eventos extremos de seca que não aconteceram, como pode se observar na amostra 27 da Figura 7. 24.




Figura 7. 24. Precipitação DJF observada e calculada no conjunto de treinamento (a linha tracejada representa o valor da precipitação DJF média de longo período).

Para melhor avaliar o desempenho do modelo, um gráfico de correlação das precipitações de DJF observadas e calculadas é apresentado na Figura 7. 25. Os resultados apresentados nessa figura deixam em evidência o bom comportamento geral do modelo na previsão da precipitação DJF na bacia de contribuição ao reservatório de Furnas.




Figura 7. 25. Precipitação DJF observada vs precipitação DJF calculada, nos conjuntos de treinamento, validação e verificação (a linha tracejada corresponde a previsão perfeita).

Valores relativamente idênticos da REMQ foram obtidos nos conjuntos de treinamento, validação e verificação: $REMQ = 0,34$; $REMQ = 0,32$ e $REMQ = 0,25$; respectivamente, no entanto, melhores que os obtidos com o primeiro modelo. Ainda se ressalta que esses resultados são uma boa indicação da capacidade de generalização do modelo.

7.3- Medidas de desempenho das previsões

A metodologia proposta foi aplicada na estimativa de medidas de desempenho com base na utilidade em dois estudos de caso, baseados no reservatório de Furnas e de Três Marias.

Nesse sentido, através de diferentes modelos hipotéticos foram gerados 823 conjuntos de previsões (denominadas de previsões com modelos) com frequência de sete dias e horizonte de 12 dias. Na seqüência, uma medida de desempenho com base na qualidade, o coeficiente de Nash-Sutcliffe, foi calculada para cada um desses conjuntos.

Por fim, a medida de desempenho com base na utilidade foi calculada a partir dos resultados da operação com base nas previsões de vazão de afluência. Dita medida de desempenho foi estimada utilizando o *Gandin-Murphy Skill Score* a partir de tabelas de contingência de frequências de ocorrência de flexibilizações das regras de operação.

Os resultados obtidos são apresentados nos três itens seguintes.

7.3.1- Benefícios vs Qualidade das previsões

Os benefícios econômicos obtidos com o uso das previsões com modelo, em função da qualidade das previsões são apresentados na Figura 7. 26 à Figura 7. 31. As quatro primeiras figuras correspondem ao reservatório de Furnas, enquanto que as últimas duas correspondem ao reservatório de Três Marias. Observa-se nessas figuras diferentes comportamentos que podem ser analisados.

As previsões esperta e ingênua apresentam o mesmo valor do coeficiente de Nash-Sutcliffe, mas os benefícios são completamente diferentes. No caso de Furnas, enquanto a previsão ingênua gera um benefício pelo incremento da geração de energia de,

aproximadamente 0,3%; a previsão esperta apresenta uma perda de 0,2%. No caso de Três Marias os resultados são similares, com ganhos no uso da previsão ingênua e perdas usando a previsão esperta. Como a previsão ingênua prevê sempre a ocorrência da vazão média, quando utilizada pelo modelo de operação, os volumes de espera de projeto são diminuídos, favorecendo a geração de energia. Pelo contrário, a previsão esperta superestima as cheias, fazendo que o modelo de operação aumente os volumes de espera, estes posteriormente não são preenchidos pela não ocorrência da cheia, reduzindo a geração de energia atual e futura. É importante ainda ressaltar que apesar do ganho na produção de energia, o uso da previsão ingênua levou a quebras das restrições hidráulicas e as perdas associadas não estão sendo descontadas dos benefícios na geração de energia, dado a subjetividade desses valores.

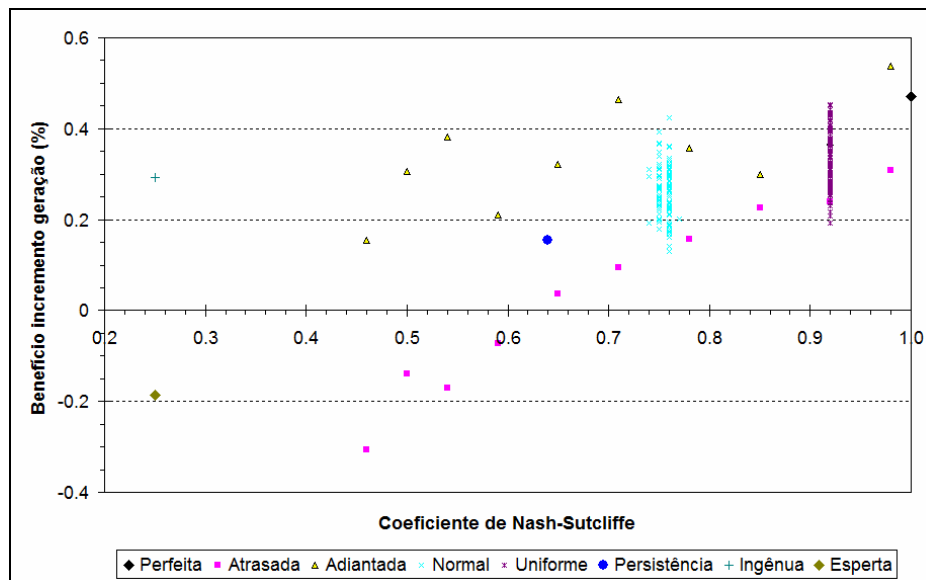


Figura 7. 26. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).

As previsões com defasagem apresentaram o mesmo valor do coeficiente de Nash-Sutcliffe para iguais defasagens, positivas ou negativas. Por exemplo, as previsões que antecipam um dia ($\Delta=+1$) tiveram a mesma qualidade que as previsões que atrasam um dia ($\Delta=-1$). Porém, os resultados em termos de benefícios econômicos foram diferentes. Tanto no reservatório de Furnas como no de Três Marias, as previsões que antecipam tiveram melhores resultados que as previsões que atrasam, em termos econômicos.

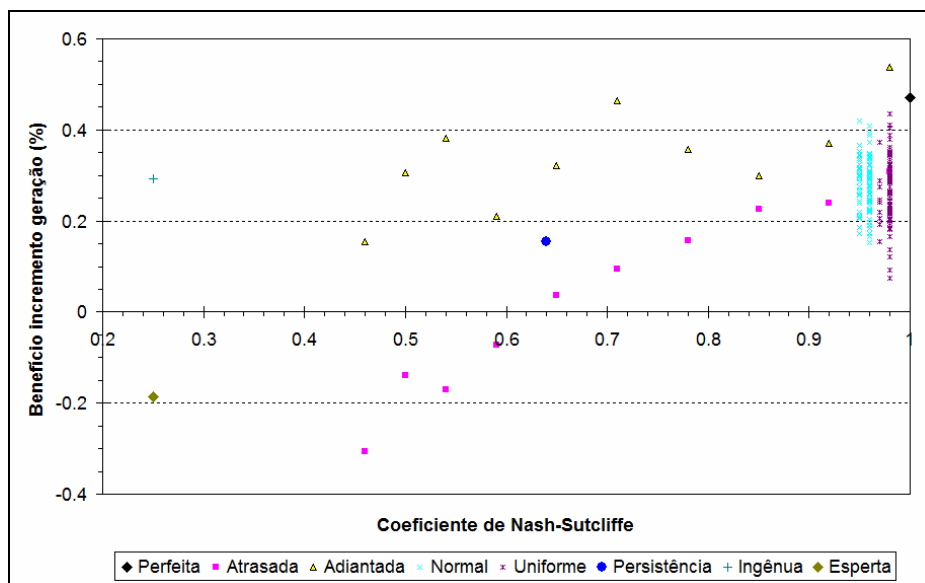


Figura 7. 27. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).




Figura 7. 28. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do terceiro conjunto de parâmetros).

Os maiores benefícios obtidos com as previsões que antecipam estão associados a uma detecção prévia dos eventos de cheias que são menores que os eventos de projeto da curva-guia, e em consequência, podendo antecipadamente, reduzir os volumes de espera. Isto é confirmado, principalmente, no reservatório de Três Marias, no qual o período de simulação apresentou muitos eventos de menor recorrência, sendo que os benefícios com as previsões que antecipam possuem uma tendência a serem maiores, conforme a maior defasagem. Além

disso, esses modelos também antecipam o acabamento do período de cheias, podendo provocar, em alguns casos, quebras das restrições hidráulicas do controle de cheias no final do período chuvoso.




Figura 7. 29. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do quarto conjunto de parâmetros).




Figura 7. 30. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).

Os resultados da utilização dos diferentes conjuntos de previsões com erros segundo uma distribuição estatística pré-definida (normal ou uniforme) são apresentadas na Figura 7. 26 à Figura 7. 31. Cada figura apresenta os resultados para cada um dos quatro conjuntos de parâmetros dos modelos hipotéticos (100 previsões com erros segundo distribuição normal e 100 previsões com erros segundo uma distribuição uniforme).

Observa-se nessas figuras uma concentração de pontos, indicando que todos os modelos apresentam, praticamente, a mesma qualidade. Porém, importantes diferenças existem nos benefícios obtidos com uso dessas previsões. Em quase todos os casos, existe um intervalo de, aproximadamente, 0,2% no caso do reservatório de Furnas, nos benefícios que podem ser obtidos por todos esses modelos.

Por fim, os resultados obtidos com as previsões de persistência apresentaram um coeficiente de Nash-Sutcliffe de 0,64 no caso de estudo baseado no reservatório de Furnas e de 0,68 em Três Marias. Em ambos casos se apresentaram benefícios positivos no uso dessas previsões no subsídio à tomada de decisão na operação do reservatório.




Figura 7. 31. Benefícios da previsão de vazão vs Coeficiente de Nash-Sutcliffe, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).

Analisando todos os resultados em conjunto, não existe uma relação unívoca entre os benefícios na operação do reservatório e a qualidade das previsões. Entretanto, pode se observar que existem diferentes tendências quando a previsão possui um comportamento particular, como por exemplo, as detectadas nos modelos com defasagem.

7.3.2- Benefícios vs Utilidade das previsões

Os benefícios econômicos obtidos com o uso das previsões com modelo, em função da utilidade das previsões são apresentados na Figura 7. 32 à Figura 7. 37. As quatro primeiras figuras correspondem ao reservatório de Furnas, enquanto que as últimas duas correspondem ao reservatório de Três Marias. Da mesma forma que na análise da qualidade das previsões, essas figuras também apresentam diferentes comportamentos que podem ser analisados.

O maior destaque é dado ao conjunto de modelos com erros segundo distribuições estatísticas pré-definidas. Em todos os casos, existe uma melhora na capacidade da medida de desempenho de diferenciar as previsões com modelo, não existindo concentrações de resultados para previsões com características similares nas estatísticas de seus erros. Isto pode ser considerado uma grande virtude da medida de desempenho proposta nesse trabalho, a qual, considerando a utilidade do uso das previsões, consegue distinguir o desempenho de modelos que com o método tradicional não tinha sido possível. Ainda, a medida de desempenho tende a apresentar maiores valores nos modelos que apresentam maiores benefícios, o que fica mais evidente no caso do reservatório de Três Marias.




Figura 7. 32. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).

Os resultados obtidos com as previsões com defasagem em função da medida de desempenho proposta nesse trabalho são diferentes quando as previsões antecipam ou atrasam. Enquanto as previsões que atrasam, uma clara tendência existe entre os benefícios da

previsão e a utilidade estimada em função do *Gandin-Murphy skill score*. No caso das previsões que antecipam, essa relação não é tão evidente, sobretudo no reservatório de Furnas.




Figura 7. 33. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).




Figura 7. 34. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do terceiro conjunto de parâmetros).

As previsões esperta e ingênuo apresentaram um comportamento diferente em função do reservatório analisado. Enquanto no reservatório de Furnas a previsão ingênuo apresenta um maior valor da medida de desempenho com base na utilidade, no reservatório de Três

Marias acontece o contrário. Em ambos casos, os benefícios do uso dessas previsões foi maior utilizando as previsões ingênuas. No caso do reservatório de Três Marias, a medida de desempenho proposta nesse trabalho penalizou as previsões ingênuas em maior grau pela grande diferença na frequência de vertimentos, que começam mais tarde e acabam mais tarde durante eventos superiores aos de projeto.




Figura 7. 35. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do quarto conjunto de parâmetros).




Figura 7. 36. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).




Figura 7. 37. Benefícios da previsão de vazão vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).

7.3.3- Utilidade das previsões vs Qualidade das previsões

Finalmente, nesse último item do trabalho, é apresentada uma comparação entre a utilidade das previsões, estimada com base na medida de desempenho proposta nesse trabalho e a qualidade das previsões, definidas a partir do coeficiente de Nash-Sutcliffe. Os resultados são apresentados na Figura 7. 38 à Figura 7. 43. As quatro primeiras figuras correspondem ao reservatório de Furnas, enquanto que as últimas duas correspondem ao reservatório de Três Marias.

Analisando todos os resultados em conjunto, observa-se nessas figuras que não existe uma relação unívoca entre a utilidade das previsões e a qualidade das previsões. Entretanto, pode se observar que existem diferentes tendências quando a previsão possui um comportamento particular, como por exemplo, as detectadas nos modelos com defasagem. Nesses modelos, a utilidade das previsões tende a crescer na medida que a qualidade das mesmas aumenta.




Figura 7. 38. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).




Figura 7. 39. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).




Figura 7. 40. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do terceiro conjunto de parâmetros).




Figura 7. 41. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Furnas, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do quarto conjunto de parâmetros).




Figura 7. 42. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do primeiro conjunto de parâmetros).




Figura 7. 43. Coeficiente de Nash-Sutcliffe vs Gandin-Murphy Score proposto nesse trabalho, reservatório de Três Marias, resultados de 223 modelos (200 modelos com erros segundo distribuições estatística (normal e uniforme) do segundo conjunto de parâmetros).

8- Conclusões e Recomendações

8.1- Aspectos gerais

Essa pesquisa procurou dar uma resposta a diversos questionamentos que surgem durante a tomada de decisão na operação de reservatórios com base na previsão de variáveis hidrológicas.

Nesse sentido, foram desenvolvidos modelos de previsão de vazão de curto prazo e modelos de previsão de precipitação de longo prazo. Além disso, uma medida de desempenho das previsões com base na utilidade foi apresentada. Todos esses elementos podem subsidiar à tomada de decisão.

A seguir são apresentadas as principais conclusões dessa pesquisa.

8.2- Previsão de vazão de curto prazo

Redes neurais artificiais foram utilizadas no presente trabalho para realizar previsões de vazão diária afluente ao reservatório de Furnas, com horizonte de doze dias, a partir de previsões quantitativas de chuva. Para tanto, foram desenvolvidos doze modelos de redes neurais artificiais onde cada modelo define a previsão de vazão no posto de Furnas para um dia do horizonte de previsão.

Uma metodologia de treinamento e validação da rede foi desenvolvida utilizando-se previsões perfeitas de chuva (considerando a chuva observada como previsão), o que permitiu utilizar um maior número de dados no treinamento.

Dois conjuntos de verificação foram utilizados, o primeiro com chuva prevista pelo modelo regional ETA e o segundo com previsão perfeita de chuva (chuva observada). Embora

essa última previsão seja hipotética, permite conhecer os patamares superiores dos benefícios (avaliados em termos de redução dos erros na previsão de vazão) que poderiam ser obtidos.

Os resultados obtidos mostraram que o erro nas previsões de vazão afluente ao reservatório de Furnas tende a aumentar com o horizonte da previsão e que o erro na previsão de vazão aumenta em maior medida quando utilizadas as previsões do modelo regional ETA se comparadas às obtidas com uso de chuva prevista perfeita. Isto mostra como os erros na previsão de chuva influenciam os resultados obtidos na previsão de vazão e deixa em evidência quanto poderia ser beneficiada a previsão de vazão afluente ao reservatório de Furnas pelo aprimoramento das previsões de chuva.

Deve-se destacar que os resultados obtidos com previsão perfeita de chuva e considerando a chuva do modelo regional ETA são similares até o quinto dia do horizonte de previsão. A partir do sexto dia da previsão o desempenho da rede neural utilizando chuva do modelo regional ETA diminui em comparação ao desempenho quando se faz uso de previsão perfeita de chuva.

Em uma segunda comparação do desempenho da metodologia aplicada, os resultados foram comparados aos obtidos com um modelo hidrológico conceitual. Nesse caso, ambos modelos usaram os mesmos dados de precipitação quantitativa de chuva do modelo regional ETA e os dados observados de precipitação subseqüentemente. Os resultados obtidos mostraram que o desempenho das previsões de vazão foi fortemente dependente da qualidade das previsões quantitativas de precipitação. O modelo empírico de redes neurais artificiais foi menos sensível aos erros na previsão quantitativa de precipitação no período analisado. Por sua vez, o modelo conceitual apresentou o melhor desempenho quando utilizadas as previsões perfeitas de precipitação. Esse modelo foi, ainda, o que mostrou um desempenho melhor para as maiores antecedências, quando a representação do processo de transformação chuva-vazão e o armazenamento na bacia são mais importantes que a propagação ao longo da rede de drenagem.

O ONS usa previsões de vazão de afluência aos principais reservatórios do SIN, definidas até o ano 2008, sem considerar dados de precipitação observada ou prevista como informação de entrada. Os resultados obtidos nesse trabalho, embora limitados a um único reservatório, mostraram que as previsões de vazão utilizando modelos empíricos e conceituais e incorporando previsões quantitativas de precipitação são melhores que a metodologia do ONS que não utiliza essas informações. A redução dos erros de previsão relativos à metodologia do ONS foi de em torno de 20% quando usadas previsões quantitativas de precipitação definidas pelo modelo regional ETA e superiores a 50% quando usadas previsões

perfeitas de precipitação. Embora este último patamar não pode ser atingido, os resultados sugerem que o melhoramento das previsões quantitativas de precipitação levará a melhores previsões de vazão de afluência aos reservatórios.

Em uma terceira etapa foram avaliadas a eficiência e a eficácia de modelos de redes neurais artificiais desenvolvidos com base na metodologia proposta nesse trabalho e na metodologia tradicional. Em termos de eficiência, ambos modelos apresentaram o mesmo desempenho, com uma pequena vantagem a favor da metodologia proposta nesse trabalho. Em termos de eficácia, utilizando as previsões quantitativas do modelo regional ETA, os modelos desenvolvidos com base na metodologia proposta nesse trabalho apresentaram melhores resultados para os primeiros oito dias do horizonte de previsão. No entanto, para horizontes maiores, os modelos baseados no método tradicional apresentaram o maior desempenho. Utilizando previsões perfeitas de chuva, os resultados mostram que os modelos baseados no método proposto nesse trabalho apresentam sempre os melhores desempenhos. Além disso, os modelos baseados no método tradicional apresentaram, em alguns casos, um melhor desempenho utilizando previsões quantitativas de chuva do modelo regional ETA que utilizando as previsões perfeitas de chuva. Dessa forma, o treinamento dos modelos baseados no método tradicional ficaria prejudicado pelas diferentes versões do modelo de previsão de chuva ao longo do tempo.

Isso mostra uma outra virtude dos modelos de redes neurais desenvolvidos com base na metodologia apresentada nesse trabalho, estes possuem um comportamento mais realista, dado que é assegurado, sem necessidade de novos treinamentos, o melhoramento dos resultados do modelo de previsão de vazão quando melhoradas as previsões quantitativas de chuva.

8.3- Previsão de precipitação de longo prazo

Diversas atividades humanas são fortemente dependentes da precipitação e, em consequência, da variabilidade climática, especialmente aquelas relacionadas ao uso da água. A precipitação sazonal governa a necessidade de irrigação na agricultura, as condições de navegação do rio, a operação de reservatórios com múltiplos usos e os recursos hídricos em geral. Assim, o conhecimento antecipado da precipitação na estação mais chuvosa do ano é

uma informação valiosa para esses usuários d'água, justificando o desenvolvimento e aperfeiçoamento de métodos de previsão de precipitação.

Os métodos empíricos são adequados para o desenvolvimento de modelos de previsão de precipitação, uma vez que permitem produzir previsões em locais específicos e têm baixos custos computacionais e de desenvolvimento. Um passo fundamental para o desenvolvimento desses modelos é a seleção das variáveis de entrada. No caso particular das previsões de precipitação de longo prazo, os índices climáticos são potenciais candidatos a variáveis de entrada, dado que representam as intensidades dos modos de variabilidade climática e teleconexões.

Redes neurais artificiais foram utilizadas no presente trabalho para realizar previsões de precipitação de longo prazo. As previsões foram desenvolvidas no início do período chuvoso e abrangem os meses de dezembro, janeiro e fevereiro (DJF). Assim, no final do mês de novembro é estimado o valor médio de precipitação acumulada, na bacia de contribuição ao reservatório de Furnas, para os próximos três meses.

Foram desenvolvidos dois modelos, em ambos os casos utilizando quatro índices climáticos (SAMI, NAOI, PDOI e El Niño 3.4) como variáveis de entrada. As variáveis de entrada do primeiro modelo foram aquelas que apresentam a maior correlação com a precipitação DJF. Por sua vez, as variáveis de entrada do segundo modelo foram obtidas após uma busca exaustiva, limitada aos dois trimestres anteriores ao da emissão da previsão.

Os bons resultados obtidos nesse trabalho com ambos modelos mostram a viabilidade do uso de índices climáticos como variáveis de entrada em modelos de previsão de longo prazo. As reduções dos erros de previsão relativos ao uso apenas da média climatológica como previsão foram importantes, sendo como mínimo de 50% e chegando até um valor próximo a 75% nos diferentes testes efetuados, no período analisado.

A principal questão por trás de um modelo empírico é a determinação da relação entre as variáveis de entrada e as variáveis de saída. Nesse sentido, as redes neurais artificiais se mostraram como uma ferramenta poderosa. Apesar das redes neurais artificiais terem sido aplicadas em diversos problemas relacionados à hidrologia, a aplicação dessas técnicas na previsão de precipitação de longo prazo é ainda rara. No entanto, os resultados obtidos nesse trabalho mostram o grande potencial dos modelos baseados em redes neurais artificiais em prever variáveis hidrológicas. Esta abordagem pode ser usada com sucesso para previsão de precipitação em locais específicos.

8.4- Medida de desempenho com base na utilidade

Enquanto as medidas de desempenho tradicionalmente utilizadas na operação de reservatórios são baseadas nos erros da previsão, medindo o grau de aproximação entre valores previstos e observados da vazão de afluência, o valor, ou utilidade da previsão, depende dos benefícios esperados do uso da previsão por usuários específicos. Ainda, o uso das medidas de desempenho baseadas no erro da previsão não consegue, em alguns casos, distinguir o verdadeiro desempenho de modelos de previsão, sobretudo no caso da operação de reservatórios com usos conflitantes.

Nesse trabalho foi proposta e avaliada uma medida de desempenho baseada na utilidade da previsão de vazão de afluência a reservatórios com usos conflitantes, como a geração de energia e o controle de cheias. Essa medida de desempenho foi estimada em função dos resultados da operação do reservatório com base na previsão de vazão de afluência, usando o *Gandin-Murphy Skill Score* a partir de tabelas de contingência de frequências de ocorrência de flexibilizações das regras de operação. Dessa forma, foi obtida uma medida de desempenho da utilidade das previsões contínuas de vazão, sem a necessidade de estas serem probabilísticas.

Um total de 823 conjuntos de previsões foi avaliado em dois estudos de caso baseados nas informações do reservatório de Furnas e de Três Marias. Na comparação dos resultados ficou evidente, nos testes realizados nesse trabalho, que não existe uma relação unívoca entre a qualidade das previsões e a utilidade das previsões. No entanto, em função de comportamentos particulares das previsões, tendências foram encontradas, como por exemplo nos modelos com defasagem. Nesses modelos, a utilidade das previsões tende a crescer na medida que a qualidade das mesmas aumenta.

Uma das grandes virtudes da medida de desempenho desenvolvida nesse trabalho foi sua capacidade de distinguir o desempenho de modelos que apresentaram a mesma qualidade. Ainda, a medida de desempenho tendeu a apresentar maiores valores nos modelos que apresentam maiores benefícios, o que ficou mais evidente no caso do reservatório de Três Marias.

Enquanto às características dos erros das previsões, as previsões de cinco modelos hipotéticos foram avaliadas. Esses modelos geram previsões espertas e ingênuas, previsões com defasagem, previsões com erros segundo uma distribuição estatística pré-definida (normal ou uniforme) e previsões de persistência. As previsões esperta e ingênuas apresentaram a mesma qualidade, mas os benefícios foram completamente diferentes, se

apresentando ganhos no uso da previsão ingênua e perdas no uso da previsão esperta. As previsões com defasagem apresentaram também a mesma qualidade para iguais defasagens. Porém, os resultados em termos de benefícios econômicos foram diferentes. Tanto no reservatório de Furnas como no de Três Marias, as previsões que antecipam tiveram melhores resultados que as previsões que atrasam. Por fim, no caso das previsões de persistência, em ambos estudos de caso se apresentaram benefícios positivos no seu uso para subsidiar à tomada de decisão na operação do reservatório.

Conforme apresentado, um grande esforço foi feito nessa pesquisa para quantificar a utilidade das previsões de vazão de afluência a reservatórios e ainda compreender como as características particulares das previsões influenciam nos benefícios da previsão.

8.5- Recomendações

Todas as análises efetuadas nesse trabalho são dependentes dos períodos de dados disponibilizados. Assim, os resultados obtidos aqui, devem ser complementados com novas análises, cobrindo outros períodos de tempo, incluindo novos dados que sejam disponibilizados no futuro. Ainda as metodologias apresentadas nessa pesquisa podem ser validadas em outras regiões climáticas do país.

É necessário ressaltar que uma série de simplificações foi feita para obter resultados de fácil interpretação, destacando de forma clara a influência da previsão de vazão na operação de reservatórios. O ONS tem feito diversos estudos no quais um conjunto de modelos tem sido aplicado a um local de estudo na estimativa de previsões de vazão de afluência a reservatórios. No entanto, nesse trabalho se optou por modelos hipotéticos ante a falta dessas informações. A disponibilidade dos resultados desses modelos permitiria a avaliação da medida de desempenho baseada na utilidade da previsão em um caso real.

Quanto melhor o desempenho do modelo regional ETA em reproduzir as precipitações observadas, menos aparentes deverão ser as diferenças entre a metodologia proposta nesse trabalho e a metodologia tradicional de desenvolvimento de modelos de redes neurais artificiais. Assim, ambas metodologias poderiam ser testadas em regiões onde os resultados do modelo regional ETA possuem diferentes qualidades e comparadas a eficiência e a eficácia de cada uma. Isto poderá mostrar as vantagens de usar previsões perfeitas de chuva durante o

treinamento, já que existe a tendência a serem disponibilizadas séries longas de dados observados, se comparadas aos períodos com dados de chuva prevista por modelos.

A operacionalização do sistema de previsões de curto prazo baseado em modelos de redes neurais é relativamente simples, dado que uma vez treinado o modelo, este pode rodar em uma planilha de Excel. No entanto, seria necessária a transmissão contínua das informações que integram as variáveis de entrada ao modelo, isto é, as vazões observadas até o dia da previsão nos exutórios das sub-bacias e no reservatório de Furnas; as precipitações registradas nos pluviômetros na bacia e as previsões quantitativas de chuva do modelo regional ETA.

As previsões de chuva acumulada no trimestre DJF desenvolvidas nesse trabalho podem ainda serem utilizadas como entradas a modelos hidrológicos para gerar previsões de longo prazo de vazões de afluência ao reservatório de Furnas. Nesse sentido, técnicas de *downscaling* da precipitação deverão ser utilizadas, de forma que a discretização espacial da chuva coincida com aquela utilizada pelo modelo hidrológico. Ainda técnicas de desagregação temporal da precipitação deverão ser utilizadas para atender a discretização temporal dos modelos hidrológicos.

O sistema de previsões de precipitação de longo prazo pode ainda ser operacionalizado de forma que os próprios usuários, por exemplo, na agricultura, tivessem suas próprias estimativas conforme apresentado em Paz et al. (2010).

Na estimativa da medida de desempenho com base na utilidade das previsões, os eventos cujas frequências são avaliadas não levam em conta o grau de acerto na flexibilização da regra de operação, apenas consideram se o sentido da flexibilização foi o correto. Isto é, se em um intervalo de tempo a flexibilização com modelos foi positiva e com previsão perfeita foi também positiva, soma uma unidade na frequência absoluta, independentemente da proximidade no valor da flexibilização. Assim, a consideração dessas diferenças no conteio das frequências da tabela de contingência poderia permitir uma melhor diferenciação das utilidades das previsões de diferentes modelos.

Resulta ainda de interesse, expandir a análise apresentada neste trabalho à operação de um conjunto de reservatórios ou mesmo, a um subsistema do sistema interligado brasileiro. Nesse caso, a medida de desempenho com base na utilidade das previsões levaria em conta os resultados da operação de um conjunto de reservatórios.

Referências bibliográficas

- Akaike, H. (1974). "A new look at the statistical model identification". *IEEE Transactions on Automatic Control*, 19(6), p. 716–723.
- Allasia, DG. (2007). Avaliação da previsão hidro-climática no Alto Paraguai. Tese de doutorado, Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Porto Alegre, Brasil, 208 p.
- Alvim, AC; Martinez, CB; Silva, SR; Caminhas, WM; Versiani, BR; Quintão, CMF. (2005). "Utilização de redes neo-fuzzy-neuron para predição de vazões". *Revista Brasileira de Recursos hídricos*, v. 10(1), p. 61-77.
- Andreolli, I. (2003). "Previsão de Vazão em Tempo Real no Rio Uruguai com Base na Previsão Meteorológica". Porto Alegre: UFRGS. Dissertação. Mestrado em Recursos Hídricos e Saneamento Ambiental, Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul. 182p.
- ANEEL. Agência Nacional de Energia Elétrica. (2008). Atlas de energia elétrica do Brasil 3ed. Brasília, ANEEL, 236 p.
- ASCE (Task Committee on Application of Artificial Neural Networks in Hydrology). (2000a). "Artificial neural networks in hydrology. I: Preliminary concepts". *Journal of Hydrologic Engineering*, v. 5(2), p. 115-123.
- ASCE (Task Committee on Application of Artificial Neural Networks in Hydrology). (2000b). "Artificial neural networks in hydrology. II: Hydrologic applications". *Journal of Hydrologic Engineering*, v. 5(2), p. 124-137.
- Ash, A; McIntosh, P; Cullen, B; Carberry, P; Smith, MS. (2007). "Constraints and opportunities in applying seasonal climate forecasts in agriculture". *Australian Journal of Agricultural Research*, v. 58, p. 952-965.
- Bessler, LT; Savic, DA; Walters, GA. (2003). "Water reservoir control with data mining". *Journal of Water Resources Planning and Management*, v. 129(1), p. 26-34.
- BIG-ANEEL. (2010). Banco de Informações de Geração - Agência Nacional de Energia Elétrica ANEEL. <http://www.aneel.gov.br/area.cfm?idArea=15&idPerfil=2>. Acesso em 15/04/2010.
- Birikundavyi, S; Labib, R; Trung, HT; Rouselle, J. (2002). "Performance of neural networks in daily streamflow forecasting". *Journal of Hydrologic Engineering*, v. 7(5), p. 392-398.
- Bishop, CM. (1995). "Neural networks for pattern recognition". Clarendon Press, Oxford, Inglaterra.
- Bowden, GJ; Dandy, GC; Maier, HR. (2005). "Input determination for neural network models in water resources applications. Part 1 – background and methodology". *Journal of Hydrology*, v. 301, p. 75–92.

- Brandão, JLB. (2004). “Modelo para operação de sistemas de reservatórios com usos múltiplos”. Tese (Doutorado em Engenharia) - Escola Politécnica, Universidade de São Paulo. São Paulo, 160 p.
- Bravo, JM. (2006). “Otimização da operação de um reservatório para controle de cheias com base na previsão de vazão”. Porto Alegre: UFRGS. Dissertação. Mestrado em Recursos Hídricos e Saneamento Ambiental, Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul. 155p.
- Bravo, JM; Collischonn, W; Pilar, JV; Silva, BC; Tucci, CEM. (2005). “Operação de um reservatório com múltiplos usos com base na previsão de curto prazo de vazão”. *Revista Brasileira de Energia*, v. 11(2), p. 85-110.
- Bravo, JM; Collischonn, W; Pilar, JV; Tucci, CEM. (2007b). “Influência da capacidade de regularização de reservatórios nos benefícios da previsão de vazão de longo prazo”. *Anais do XVII Simpósio Brasileiro de Recursos Hídricos*, São Paulo, SP, 1 CD.
- Bravo, JM; Collischonn, W; Pilar, JV; Tucci, CEM. (2008b). “Otimização de regras de operação de reservatórios com incorporação da previsão de vazão”. *Revista Brasileira de Recursos Hídricos*, v. 13(1), p.181-196.
- Bravo, JM; Collischonn, W; Pilar, JV; Tucci, CEM. (2008c). “Avaliação dos benefícios de previsões de vazão na operação de reservatórios”. *Revista Brasileira de Recursos Hídricos*, v. 13(1), p. 197-216.
- Bravo, JM; Collischonn, W; Silva, BC; Tucci, CEM. (2006). “Avaliação de Benefícios de Previsão Meteorológica na Operação de Reservatórios com Usos Múltiplos”. IPH-UFRGS, 71 pp, Porto Alegre.
- Bravo, JM; Collischonn, W; Uvo, CB. (2007a). “River flow forecast based on previous precipitation and streamflow information using artificial neural networks”. *Geophysical Research Abstracts*, v. 9, p. 9670-9671.
- Bravo, JM; Collischonn, W; Uvo, CB. (2008a). “Improvements on river flow forecast by additional predictors using artificial neural networks”. *Geophysical Research Abstracts*, v. 10, p. 282.
- Bravo, JM; Paz, AR; Collischonn, W; Uvo, CB; Pedrollo, OC; Chou, S. (2009). “Incorporating forecasts of rainfall in two hydrologic models used for medium-range streamflow forecasting”. *Journal of Hydrologic Engineering*, v 14(5), p. 435-445.
- Bretherton, CS; Smith, C; Wallace, JM. (1992). “An intercomparison of methods for finding coupled patterns on climate data”. *Journal of Climate*, v. 5, p. 541-560.
- Bruen, M; Yang, J. (2005). “Functional networks in real-time flood forecasting: a novel application”. *Advances in Water Resources*, v. 28, p. 899-909.
- Carvalho, F; Silva, DA; Santos, JPL; Lima, VCGR. (2005). “Aplicação de redes neurais artificiais na previsão de precipitação na bacia do rio Mundaú – Alagoas”. In: *Simpósio Brasileiro De Recursos Hídricos*, 16, João Pessoa PA. Anais 1 CD.
- Casati, B; Wilson, LJ; Stephenson, DB; Nurmi, P; Ghelli, A; Pocerlich, M; Damrath, U; Ebert, EE; Brown, BG; Mason, S. (2008). “Forecast verification: current status and future directions”. *Meteorol. Appl.*, v. 15, p. 3-18.
- Changnon, SA; Vonnahme, DR. (2003). “Impact of spring 2000 drought forecast on Midwestern water management”. *Journal of Water Resources Planning and Management*, v 129(1), p. 18-25.
- Chattopadhyay S. (2007). “Feed-forward artificial neural network model to predict the average summer-monsoon rainfall in India”. *Geophysica Acta* v. 55(3), p. 369-382.
- Chau, KW. (2006). “Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River”. *Journal of Hydrology*, v. 329, p. 363– 367.
- Chiew, FHS; Zhou, SL; McMahon, TA. (2003). “Use of seasonal streamflow forecasts in water resources management”. *Journal of Hydrology* 270, p. 135-144.

- Chou, S. (1996). "O modelo regional ETA". Climanálise. Edição Especial. INPE.
- Chow, TWS; Cho, SY. (1997). "Development of a Recurrent Sigma-Pi Neural Network Rainfall Forecasting System in Hong Kong". *Neural Computing and Applications*, v. 5, p. 66-75.
- Cicogna, M; Kadowaki, M; Ballini, R; Soares, S. (2003). "Previsão de Vazões Médias Mensais: Uma Aplicação para as Usinas do Rio Paranapanema". *Anais do II CITENEL (Hidrologia)*, p. 440-444.
- Cicogna, MA. (2002). "Análise de sensibilidade da otimização energética de sistemas hidrotérmicos". Encontro de pesquisadores em sistemas de potência, II SisPot, Campinas.
- Clarke, RT. (2008). "Issues of experimental design for comparing the performance of hydrologic models". *Water Resources Research*, 44, W01409.
- Coelho, LSF. (2003). "Notas em matemática aplicada 2. Fundamentos, potencialidade e aplicações dos algoritmos evolutivos". SBMAC, 99 p.
- Collischonn, W; Allasia, D; Silva, BC; Tucci, CEM. (2007a). "The MGB-IPH model for large scale rainfall runoff modeling". *Hydrological Sciences Journal*, v. 52(5), p. 878-895.
- Collischonn, W; Tucci, CEM; Clarke, RT; Chou, SC; Guilhon, LG; Cataldi, M; Allasia, D. (2007b). "Medium-range reservoir inflow predictions based on quantitative precipitation forecasts". *Journal of Hydrology*, v. 344, p. 112-122.
- Collischonn, W; Haas, R; Andreolli, I; Tucci, CEM. (2005). "Forecasting River Uruguay flow using rainfall forecasts from a regional weather-prediction model". *Journal of Hydrology*. V. 305, p. 87-98.
- Costa Lima, HV; Melo Lima, LCT; Ribeiro Lima, CH. (2005). "Modelagens hidrológica conceitual e por redes neurais artificiais aplicadas ao processo chuva-vazão: uma análise comparativa". In: Simpósio Brasileiro De Recursos Hídricos, 16, João Pessoa, Anais, 1 CD.
- Costa Rohn, M; Mine, MRM. (2005). "Uma aplicação das redes neurais artificiais à previsão de chuvas de curtíssimo prazo". In: Simpósio Brasileiro De Recursos Hídricos, 16, 2005, João Pessoa PA. Anais: 1 CD.
- Costa Rohn, M; Müller, II; Rosa, PJAL. (2006). "Modelos de previsão de vazão para o planejamento energético de curto prazo e operação em tempo real". In: Simpósio De Recursos Hídricos Do Sul-Sudeste, 1, 2006, Curitiba PR. Anais, 1 CD.
- Coulibaly, P; Anctil, F; Bobee, B. (2000a). "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach". *Journal of Hydrology*, v. 230, p. 244-257.
- Coulibaly, P; Anctil, F; Rasmussen, P; Bobée, B. (2000b). "A recurrent neural networks approach using indices of low-frequency climatic variability to forecast regional annual runoff". *Hydrological Processes*, v. 14, p. 2755-2777.
- CPTEC – Centro de Previsão de Tempo e Estudos Climáticos. El Niño e La Niña. <http://www.cptec.inpe.br/enos>. Acesso em: junho, 2009.
- Czaja, AP; van der Vaart; Marshall, J. (2002). "A diagnostic study of the role of remote forcing in tropical Atlantic variability". *Journal of Climate*, v. 15, p. 3280-3290.
- Dawson, CW; Harpham, C; Wilby, RL; Chen, Y. (2002). "Evaluation of artificial neural network techniques for flow forecasting in the River Yangtze, China". *Hydrol. and Earth System Sci.*, v. 6(4), p. 619-926.
- Dawson, CW; Wilby, RL. (2001). "Hydrological modelling using artificial neural networks". *Progress in Physical Geography*, v. 25(1), p. 80-108.
- Demuth, H; Beale, M; Hagan, M. (2006). "Neural network toolbox user's guide". The MathWorks. 848 p.

- Diniz, LS. (1999). "Calibração de modelos hidrológicos". In: Galvão, CO; Valença, MJS. *Sistemas inteligentes: aplicações a recursos hídricos e sistemas ambientais*. Editorial da Universidade/UFRGS/ABRH. Porto Alegre, capítulo 4.
- Dornelles, F. (2007). "Previsão contínua de níveis fluviais com redes neurais utilizando previsão de precipitação : investigação metodológica da técnica". Porto Alegre: UFRGS. Dissertação. Mestrado em Recursos Hídricos e Saneamento Ambiental, Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul. 99p.
- Dornelles, F; Pedrollo, OC; Goldenfun, JA. (2006). "Análise comparativa da aplicação de redes neurais e sistemas de inferência difusa na previsão de nível do rio Quarai utilizando previsão de chuva". In: Simpósio De Recursos Hídricos Do Sul-Sudeste, 1, Curitiba PR. Anais 1 CD.
- Duan, Q; Sorooshian, S; Gupta, V. (1992). "Effective and efficient global optimization for conceptual rainfall-runoff models". *Water Resources Research*, v. 28(4), p.1015-1031.
- Ebert, EE. (2008). "Fuzzy verification of high-resolution gridded forecast: a review and proposed framework". *Meteorol. Appl.*, v. 15, p. 51-64.
- Faber, BA; Stedinger, JR. (2001). "Reservoir optimization using sampling SDP with ensemble streamflow prediction (ESP) forecasts". *Journal of Hydrology*, v. 249, p. 113-133.
- Fall, S; Niyogi, D; Mohanty, UC; Kumar, A. (2007). "Application of weather prediction models for hazard mitigation planning: a case study of heavy off-season rains in Senegal". *Natural Hazards*, v. 41, p. 227-243.
- Figueiredo, K; Barbosa, CR; Cruz, AVA; Vellasco, M. (2007). "Modelo de previsão de vazão com informação de precipitação utilizando redes neurais". *Revista Brasileira de Recursos Hídricos*, v. 12(3), p. 69-82.
- Forsund, FR. (2007). "Hydropower economics". Springer Science+Business Média, Norway, 261 p.
- Freitas, MAS; Gondim, JGC. (2005). "Modelos de previsão de cheias na bacia amazônica". In: Simpósio Brasileiro De Recursos Hídricos, 16, João Pessoa PA. Anais: 1 CD.
- French, MN; Krajewski, WF; Cuykendall, RR. (1992). "Rainfall forecasting in space and time using a neural network". *Journal of Hydrology*, v. 137, p. 1-31.
- Galacgac, ES; Balisacan, CM. (2009). "Traditional weather forecasting for sustainable agroforestry practices in Ilocos Norte Province, Philippines". *Forest Ecology and Management*, v. 257, p. 2044-2053.
- Galvão, CO. (1999). *Aplicabilidade em recursos hídricos da previsão de precipitação de longo prazo no nordeste do Brasil*. Tese de doutorado, Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Porto Alegre, Brasil, 153 p.
- Gandin, LS; Murphy, AH. (1992). "Equitable skill scores for categorical forecasts". *Monthly weather review*, v. 120, p. 361-370.
- Garcia-Moya, JAZ. (2010). "Los modelos numéricos de predicción del tiempo". TETHYS, *Revista de Meteorología*, <http://www.tethys.cat/antics/num02/articles/art0205esp.htm>.
- Georgakakos, KP; Krzysztofowicz, R. (2001). "Probabilistic and ensemble forecasting". *Journal of Hydrology*, v. 249, pp 1.
- Georgakakos, A; Yao, H; Mullusky, MG; Georgakakos, KP. (1998). "Impacts of climate variability on the operational forecast and management of the upper Des Moines River basin". *Water Resources Research*, v. 34(4), p. 799-821.
- Georgakakos, AP. (1989). "The value of streamflow forecasting in reservoir operation". *Water Resource Bulletin*, v. 25(4), p. 789-800.
- Gerrity, JP. (1992). "A note on Gandin and Murphy's equitable skill score". *Monthly weather review*, v. 120, p. 2709-2712.

- Göber, M; Wilson, CA; Milton, SF; Stephenson, DB. (2004). "Fairplay in the verification of operational quantitative precipitation forecasts". *Journal of hydrology*, v. 288, p. 225-236.
- Goddard, L; Mason, SJ; Zebiak, SE; Ropelewski, CF; Basher, R; Cane, MA. (2001). "Current approaches to seasonal-to-interannual climate predictions". *International Journal of Climatology*, v. 21, p. 1111-1152.
- Goldberg, DE. (1989). "Genetic algorithms in search, optimization and machine learning". Editorial Addison Wesley Longman, Inc. 412 p.
- Gong, D; Wang, S. (1999). "Definition of Antarctic Oscillation index". *Geophysical Research Letters*, v. 26, p. 459-462.
- Grimm, AM; Pal, JS; Giorgi, F. (2007). "Connection between Spring Conditions and Peak Summer Monsoon Rainfall in South America: Role of Soil Moisture, Surface Temperature, and Topography in Eastern Brazil". *Journal of Climate*, v. 20(24), p. 5929–5945.
- Guilhon, LGF; Rocha, VF; Moreira, JC. (2007). "Comparação de métodos de previsão de vazões naturais afluentes a aproveitamentos hidroelétricos". *Revista Brasileira de Recursos Hídricos*, v. 12(3), p. 13-20.
- Guilhon, LGF. (2002). "Modelo heurístico de previsão de vazões naturais médias semanais aplicado à usina de Foz do Areia". Dissertação de mestrado. Universidade Federal do Rio de Janeiro. Rio de Janeiro.
- Hamlet, AF; Huppert, D; Lettenmaier, DP. (2002). "Economic values of long-lead streamflow forecasts for Columbia River hydropower". *Journal of the Water Resources Planning and Management*, v. 128(2), p. 91-101.
- Hansen, JW. (2002). "Realizing the potential benefits of climate prediction to agriculture: issues, approaches, challenges". *Agricultural Systems*, v. 74, p. 309-330.
- Hansen, JW; Mishra, A; Rao, KPC; Indeje, M; Ngugi, RK. (2009). "Potential value of GCM-based seasonal rainfall forecasts for maize management in semi-arid Kenya". *Agricultural Systems*, v. 101, p. 80-90.
- Hare, SR; Mantua, NJ. (2000). "Empirical evidence for North Pacific regime shifts in 1977 and 1989". *Prog. Oceanogr.*, v. 47, p. 103-145.
- Hastenrath, S. (1991). "Climate Dynamics of the Tropics". The Netherlands: Kluwer Academic Publishers.
- Hay, LE; Clark, MP. (2003). "Use of statistically and dynamically downscaled atmospheric model output for hydrologic simulations in three mountainous basins in the western United States". *Journal of Hydrology*, v. 282, p. 56-75.
- Hsieh, WW; Yuval, LJ; Shabbar, A; Smith, S. (2003). "Seasonal prediction with error estimation of Columbia River streamflow in British Columbia". *Journal of water Resources Planning and Management*, v. 129(2), p. 146-149.
- Hsu, MH; Fu, JC; Liu, WC. (2003). "Flood routing with real-time stage correction method for flash flood forecasting in the Tanshui River, Taiwan". *Journal of Hydrology*, v. 283, p. 267-280.
- Hsu, KL; Gupta, HV; Sorooshian, S. (1995). "Artificial neural network modeling of the rainfall-runoff process". *Water Resources Research*, v. 31(10), p. 2517–2530.
- Hu, TS; Lam, KC; Thomas, NG. (2005). "A modified neural network for improving river flow prediction". *Hydrological Sciences*, v. 50(2), p. 959-972.
- Hurrell, JW; Kushnir, Y; Visbeck, M; Ottersen, G. (2003). "An overview of the North Atlantic Oscillation". In: JW Hurrell; Y Kushnir; G Ottersen; M Visbeck (Eds), *The North Atlantic Oscillation: Climate Significance and Environmental Impacts* (pp. 1-35), *Geophysical Monograph Series*, 134. Washington, D.C.: American Geophysical Union.

- Hurrell, JW. (1995). "Decadal trends in the North Atlantic Oscillation: regional temperatures and precipitation". *Science*, v. 269, p. 676-679.
- Imrie, CE; Durucan, S; Korre, A. (2000). "River flow prediction using artificial neural networks: generalisation beyond the calibration range". *Journal of Hydrology*, v. 233, p. 138-153.
- IPH. (2005). "Previsão de afluência a reservatórios hidrelétricos – Módulo 1 (PREVHIDRO)". Projeto FAURGS/FINEP 40.04.0094.00, Relatório Técnico.
- Jeong, DI; Kim, YO. (2005). "Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction". *Hydrological Processes*, v. 19, p. 3819-3835.
- Jones, C; Carvalho, LMV. (2002). "Active and break phases in the South American Monsoon System". *Journal of Climate*, v. 15, p. 905-914.
- Jones, JW; Hansen, JW; Royce, FS; Messina, CD. (2000). "Potential benefits of climate forecasting to agriculture". *Agriculture, Ecosystems and Environment*, v. 82, p. 169-184.
- Karamouz, M; Razavi, S; Araghinejad, A. (2008). "Long-lead seasonal rainfall forecasting using time-delay recurrent neural networks: a case study". *Hydrological Processes*, v. 22, p. 229-241.
- Kayano, MT; Andreoli, RV. (2004). "Decadal variability of northern northeast Brazil rainfall and its relation to tropical sea surface temperature and global sea level pressure anomalies". *Journal Geophys. Res.*, v. 109, p. 21-32.
- Kelman, J. (1987). "Controle de cheias e aproveitamentos hidrelétricos". Rio de Janeiro, ABRH/RBE, 175 p.
- Kelman, J; Damazio, JM; Marien, JL; Costa, JP. (1989). "The determination of flood control volumes in a multireservoir system". *Water resources research*, v. 25(3), p. 337-344.
- Kerr, RA. (2004). "Storm-in-a-Box Forecasting". *Science*, v. 304, p. 946-948.
- Kim, Y-O; Palmer, RN. (1997). "Value of seasonal flow forecast in Bayesian stochastic programming". *Journal of the Water Resource Planning and Management*, v. 123(6), p. 327-335.
- Kimura, R. (2002). "Numerical weather prediction". *Journal of Wind Engineering and Industrial Aerodynamics*, v. 90, p. 1403-1414.
- Kingston, GB; Maier, HR; Lambert, MF. (2005). "Calibration and validation of neural networks to ensure physically plausible hydrological modeling". *Journal of Hydrology*, v. 314, p. 158-176.
- Koussis, AD; Lagouvardos, K; Mazi, K; Kotroni, V; Sitzmann, D; Lang, J; Zaiss, H; Buzzi, A; Malguzzi, P. (2003). "Flood Forecasts for Urban Basin with Integrated Hydro-Meteorological Model". *Journal of Hydrologic Engineering*, v. 8(1), p. 1-11.
- Koutsoyiannis, D; Efstratiadis, A; Namassis, N; Christofides, A. (2008). "On the credibility of climate predictions". *Hydrological Sciences Journal*, v. 53(4), p. 671-684.
- Koutsoyiannis, D; Economou, A. (2003). "Evaluation of the parametrization-simulation-optimization approach for the control of reservoir systems". *Water Resources Research*, v. 39(6), 2.
- Koutsoyiannis, D; Efstratiadis, A; Karavokiros, G. (2002). "A decision support tool for the management of multi-reservoir systems". *Journal of the American Water Resources Association*, v. 38(4), p. 945-958.
- Lacerda, EGM; Carvalho, ACPLF. (1999). "Introdução aos algoritmos genéticos". In: Galvão, C.O.; Valença, M.J.S. *Sistemas inteligentes: aplicações a recursos hídricos e sistemas ambientais*. Editorial da Universidade/UFRGS/ABRH. Porto Alegre, 1999, capítulo 3.
- Lettenmaier, DP; Wood, EF. (1993). "Hydrologic Forecasting". In: Maidment, D., *Handbook of Hydrology*. McGraw-Hill, Chapter 26.

- Liebmann, B; Camargo, SJ; Seth, A; Marengo, JÁ; Carvalho, LMA; Allured, D; Fu, R; Vera, CS. (2007). "Onset and end of the rainy season in South America in observations and the ECHAM 4.5 atmospheric general circulation model". *Journal of Climate*, v. 20, p. 2037-2050.
- Liebmann, B; Kiladis, GN; Marengo, JA; Ambrizzi, T; Glick, JD. (1999). "Submonthly convective variability over South America and the South Atlantic Convergence Zone". *Journal of Climate*, v. 12(7), p. 1877–1891.
- Loucks, DP; Stedinger, JR; Haith, DA. (1981). "Water resource systems planning and analysis". Editorial Prentice-Hall, Inc. New Jersey. 559 p.
- Luk, KC; Ball, JE; Sharma, A. (2001). "An application of Artificial Neural Networks for rainfall forecasting". *Mathematical and Computer Modelling*, v. 33, p. 683-693.
- Lund, JR; Guzman, J. (1999). "Some derived operating rules for reservoirs in series or in parallel". *Journal of Water Resources Planning and Management*, v. 125(3), p. 143-153.
- Maceira, MEP; Damázio, JM. (2005). "Periodic auto-regressive streamflow models applied to operation planning for the Brazilian hydroelectric system. Regional hydrological impacts of climatic change – Impact assessment and decision making". IAHS Publication, 295.
- Maier, HR; Dandy, GC. (1997). "Modelling cyanobacteria (blue-green algae) in the River Murray using artificial neural networks". *Math. and Comp. in Simulation*, v. 43, p. 377-386.
- Maier, HR; Dandy, GC. (2000). "Neural networks for the predictions and forecasting of water resources variables: a review of modeling issues and applications". *Environm. Model. and Software*, v. 15, p. 101-124.
- Mantua, NJ; Hare, SR; Zhang, Y; Wallace, JM; Francis, RC. (1997). "A pacific decadal climate oscillation with impacts on salmon". *Bulletin of the American Meteorological Society*, v. 78, p. 1069-1079.
- Marengo, JA; Soares, WR; Saulo, C; Nicolini, M. (2004). "Climatology of the low-level jet east of the Andes as derived from NCEP-NCAR reanalyses - characteristics and temporal variability". *Journal of Climate*, v. 17(12), p. 2261-2280.
- Marinho, MHN; Ballini, R; Soares, S. (2005). "Previsão de vazões afluentes vários passos à frente utilizando redes neurais via agregação de vazões". In: *Simpósio Brasileiro De Recursos Hídricos*, 16, 2005, João Pessoa PA. Anais: 1 CD.
- Maurer, EP; Lettenmaier, DP. (2003). "Predictability of seasonal runoff in the Mississippi River basin". *Journal of Geophysical Research*, v. 108(16), p. 1-13.
- Maurer, EP; Lettenmaier, DP. (2004). "Potential effects of long-lead hydrologic predictability on Missouri River main-stem reservoirs". *Journal of Climate*, v. 17, p. 174-186.
- Mays, LW; Tung, Y-K. (1992). "Hydrosystems engineering and management". Editorial McGraw-Hill, Inc. New York. 530p.
- Mcguffie, K; Henderson-Seller, A. (1997). "A Climate Modelling Primer". England: John Wiley & Sons. 253 p.
- McIntosh, PC; Pook, MJ; Risbey, JS; Lisson, SN; Rebbeck, M. (2007). "Seasonal climate forecasts for agriculture: towards better understanding and value". *Field Crops Research*, v. 104, p. 130-138.
- Mine, MRM. (1998). "Método determinístico para minimizar o conflito entre gerar energia e controlar cheias". 146 p. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) - Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul. Porto Alegre.
- Minns, AW; Hall, MJ. (1996). "Artificial Neural Networks as rainfall-runoff models". *Hydrological Sciences Journal*, v. 41(3), p. 399-417.

- Minobe, S. (1999). "Resonance in bidecadal and pentadecadal climate oscillations over the North Pacific: Role in climatic shifts". *Geophysical Research Letters*, v. 26, p. 855-858.
- Mishalani, NR; Palmer, RN. (1988). "Forecast uncertainty in water supply reservoir operation". *Water Resources Bulletin*, v. 24(6), p. 1237-1245.
- Moller, MS. (1993). "A scaled conjugate gradient algorithm for fast supervised learning". *Neural Networks*, v. 6(4), p. 525-534.
- Moore, RJ; Bell, VA; Jones, DA. (2005). "Forecasting for flood warning". *Computes Rendus Geoscience*, v. 337, p. 203-217.
- Morid, S; Smakhtin, V; Bagherzadeh, K. (2007). "Drought forecasting using artificial neural networks and time series of drought indices". *International Journal of Climatology*, v. 27, p. 2103-2111.
- Muluye, GY; Coulibaly, P. (2007). "Seasonal reservoir inflow forecasting with low-frequency climatic indices: a comparison of data-driven methods". *Hydrological Sciences Journal* 52(3): 508-522.
- Murphy, AH. (1993). "What is a good forecast? An essay on the nature of goodness in weather forecasting". *Weather and forecasting*, v. 10, p. 281-293.
- Namias, J. (1972). "Influence of Northern hemisphere Circulation on Drought in Northeast Brazil". *Tellus*, v. 24, p. 336-342.
- Nan, S; Li, J. (2003). "The relationship between summer precipitation in the Yangtze River valley and the previous Southern Hemisphere Annular Mode". *Geophysical Research Letters*, v. 30(24), 2266.
- Nash, JE; Sutcliffe, JV. (1970). "River flow forecasting through conceptual models part I: A discussion of principles". *Journal of Hydrology*, v. 10(3), p. 282-290.
- Nasrallah, HA; Balling, RC; Selover, NJ; Vose, RS. (2001). "Development of a seasonal forecast model for Kuwait winter precipitation". *Journal of Arid Environments*, v. 48, p. 233-242.
- Neal, EG; Walter, MT; Coffeen, C. (2002). "Linking the Pacific oscillation to seasonal stream discharge patterns in Southeast Alaska". *Journal of Hydrology*, v. 263, p. 188-197.
- Nelder, JA; Mead, R. (1965). "A simplex method for function minimization". *Computer Journal*, v.7, p. 308-313.
- Nguyen, TD; Uvo, CB; Rosbjerg, D. (2007). "Relationship between tropical Pacific and Indian Ocean sea surface temperature and monthly precipitation over the central highland, Vietnam". *International Journal of Climatology*, v. 27(11), p. 1439-1454.
- Nilsson, P; Uvo, CB; Berndtsson, R. (2006). "Monthly runoff simulation: comparison of a conceptual model, neural networks and a combination of them". *Journal of Hydrology*, v. 321, p. 344-363.
- Nilsson, P; Uvo, CB; Landman, WA; Nguyen, TD. (2008). "Downscaling of GCM forecasts to streamflow over Scandinavia". *Hydrology Research*, v. 39(1), p. 17-26.
- Nobre, P; Shukla, J. (1996). "Variations of sea surface temperature, wind stress and rainfall over the tropical Atlantic and South America". *Journal of climate*, v. 10(4), p. 2464-2479.
- Nogués-Paegle, J; Mo, KC. (1997). "Alternating wet and dry conditions over South America during summer". *Monthly Weather Review*, v. 125, p. 279-291.
- Nogués-Paegle, J; co-authors. (2002). "Progress in Pan American CLIVAR research: Understanding the South American Monsoon". *Meteorologica* 27, p. 3-30.
- Ogallo, LA; Boulahya, MS; Keane, T. (2000). "Applications of seasonal to interannual climate prediction in agricultural planning and operations". *Agricultural and Forest Meteorology*, v. 103, p. 159-166.

- Olden, JD; Jackson, DA. (2002). "Illuminating the "black box": a randomization approach for understanding variable contributions in artificial neural networks". *Ecological Modelling*, v. 154, p. 135–150.
- Olden, JD; Joy, MK; Death, RG. (2004). "An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data". *Ecological Modelling*, v. 178, p. 389–397.
- Oliveira, R; Loucks, DP. (1997). "Operating rules for multireservoir systems". *Water Resources Research*, v. 33(4), p. 839-852.
- Olsson, J; Uvo, CB; Jinno, K; Kawamura, A; Nishiyama, K; Koreeda, N; Nakashima, T; Morita, O. (2004). "Neural Networks for rainfall forecasting by atmospheric downscaling". *Journal of Hydrologic Engineering*, v. 9(1), p. 1-12.
- ONS, Operador Nacional do Sistema. (2001). "Plano Anual de Prevenção de Cheias – Ciclo 2000/2001". Rio de Janeiro, 110 p.
- ONS, Operador Nacional do Sistema. (2004). "Evaporações Líquidas nas usinas hidrelétricas". Rio de Janeiro, 61 p.
- ONS, Operador Nacional do Sistema. (2008). "Relatório anual de avaliação de previsões de vazões – 2008". Rio de Janeiro, 60 p.
- ONS, Operador Nacional do Sistema. (2009a). "Plano Anual de Prevenção de Cheias – Ciclo 2009/2010". Rio de Janeiro, 154 p.
- ONS, Operador Nacional do Sistema. (2009b). "Diretrizes para as regras de operação de controle de cheias - bacia do rio Paraná até porto São José (ciclo 2009-2010)". Rio de Janeiro, 191 p.
- Paz, AR; Uvo, CB; Bravo, JM; Collischonn, W; Rocha, HR. (2010). "Seasonal precipitation forecast based on artificial neural networks", capítulo x, *Computational Methods Applied to Agricultural Research: Advances and Applications*. Editores: Prado, HA; Luiz, AJB; Chaib, H, 26 p.
- Pedrollo, OC. (2005). "Previsão de níveis fluviais com redes neurais aplicação para Rosário do sul – RS". In: *Simpósio Recursos Hídricos Do Sul, Santa Maria RS. Anais*, 1 CD.
- Ramírez, MCV; Velho, HFC; Ferreira, NJ. (2005). "Artificial neural network technique for rainfall forecasting applied to the São Paulo region". *Journal of Hydrology*, v. 301, p. 146-162.
- Rasmusson, EM; Carpenter, TH. (1982). "Variations in tropical sea surface temperature and surface wind fields associated with the Southern Oscillation/El Niño". *Monthly Weather Review*, v. 110(5), p. 354-384.
- Rauscher, SA; Seth, A; Liebmann, B; Qian, J-H; Camargo, SJ. (2007). "Regional Climate Model–Simulated Timing and Character of Seasonal Rains in South America". *Monthly Weather Review*, v. 135(7), p. 2642–2657.
- Reboita, MS; Ambrizzi, T; Rocha, RP. (2009). "Relationship between the Southern Annular Mode and Southern Hemisphere Atmospheric Systems". *Revista Brasileira de Meteorologia*, v. 24, p. 48-55.
- Richardson, D. (2000). "Skill and economic value of the ECMWF ensemble prediction system". *Q. J. R. Meteorol. Soc.*, v. 126, p. 649–668.
- Roads, J; Chen, SC; Kanamitsu, M. (2003). "U.S. regional climate simulations and seasonal forecasts". *Journal of Geophysical Research*, v. 108(16), p. 1-17.
- Robertson, AW; Mechoso, CR. (1998). "Interannual and decadal cycles in river flows of Southeastern South America". *Journal of Climate*, v. 11, p. 2570-2581.
- Roebber, PJ.; Bosart, LF. (1996). "The Complex Relationship between Forecast Skill and Forecast Value: A Real-World Analysis". *Weather and Forecasting*, v. 11, p. 544-559.
- Roulin, E. (2007). "Skill and relative economic value of medium-range hydrological ensemble prediction". *Hydrologic Earth Systems Science*, v. 11, p. 725-737.

- Saldanha, CB. (2009). Previsão de longo prazo da umidade do solo na bacia do rio Uruguai. Tese de doutorado, Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Porto Alegre, Brasil, 161 p.
- Sarle, WS. (2000). "How to measure the importance of inputs?" SAS Institute Inc., Cary, NC. <ftp://ftp.sas.com/pub/neural/importance.html>. Acesso em agosto 2009.
- Sarmento, FJ. (1996). "Modelagem de séries hidrológicas através de redes de neurônios". Revista Brasileira de Recursos Hídricos, ABRH, v. 1(2), p. 19-31.
- Schwarz, GE. (1978). "Estimating the dimension of a model". Annals of Statistics 6(2), p. 461-464.
- Seaman, R; Mason, I; Woodcock, F. (1996). "Confidence intervals for some performance measures of yes-no forecast". Aus. Met. Mag., v. 45, p. 49-53.
- Serra Costa, F; Maceira, MEP; Damázio, JM. (2007). "Modelos de Previsão Hidrológica Aplicados ao Planejamento da Operação do Sistema Elétrico Brasileiro". Revista Brasileira de Recursos Hídricos, v. 12(3), p. 21-30.
- Silva, CB. (2005). "Previsão hidroclimática de vazão para a bacia do rio são Francisco". Porto Alegre: UFRGS. Tese. Doutorado em Recursos Hídricos e Saneamento Ambiental, Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul. 279p.
- Silveira, CAC. (1996). "Previsão de volumes de espera em tempo-real para usina hidrelétrica de Sobradinho". 129 p. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) - Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul. Porto Alegre.
- Silverman, D; Dracup, JA. (2000). "Artificial Neural Networks and long-range precipitation prediction in California". Journal of Applied Meteorology, v. 39, p. 57-66.
- Silvestri, GE; Vera, CS. (2003). "Antarctic Oscillation signal on precipitation anomalies over southeastern South America". Geophysical Research Letters, v. 30(21), 4 p.
- SIPOT, Sistema de Informações do Potencial Hidrelétrico Brasileiro. (2005). "Características dos reservatórios do SIN". Eletrobras, programa computacional de banco de dados.
- Sivapragasam, C; Vasudevan, G; Vincent, P. (2007). "Effect of inflow forecast accuracy and operating time horizon in optimizing irrigation releases". Water Resource Management, v. 21, p. 933-945.
- Sorooshian, S; Gupta, VK. (1995). "Model calibration". In: Singh, VJ. (editor) Computer models of watershed hydrology. Water Resources Publications, Highlands Ranch, chapter 2.
- Stephenson, DB; Casati, B; Ferro, CAT; Wilson, CA. (2008). "The extreme dependency score: a non-vanishing measure for forecasts of rare events". Meteorol. Appl., v. 15, p. 41-50
- Stokelj, T; Paravan, D; Golob, R. (2002). "Enhanced artificial neural network inflow forecasting algorithm for run-of-river hydropower plants". J. Water Resour. Plann. Manag., v. 128(6), p. 415-423.
- Tantane, S; Patamatamakul, S; Oki, T; Sriboonlue, V; Prempre, T. (2005). "Downscaled rainfall prediction model (DRPM) using a unit disaggregation curve (UDC)". Hydrology and Earth System Sciences Discussions, v. 2, p. 543-568.
- Tchaban, T; Taylor, MJ; Griffin, JP. (1998). "Establishing Impacts of the Inputs in a Feedforward Neural Network". Neural Comp. and Applications, v. 7, p. 309-317.
- Thirumalaiah, K; Deo, MC. (2000). "Hydrological forecasting using neural networks". Journal of Hydrologic Engineering, v. 5(2), p. 180-189.
- Thompson, DWJ; Wallace, JM. (2000). "Annular modes in the extratropical circulation. Part I: Month-to-month variability". Journal of Climate, v. 13, p. 1000-1016.

- Thornes, JE; Stephenson, DB. (2001). "How to judge the quality and value of weather forecast products". *Meteorology Applied*, v. 8, p. 307-314
- Tokar, AS; Johnson, PA (1999). "Rainfall-runoff modeling using artificial neural networks". *Journal of Hydrologic Engineering*, v. 4(3), p. 232-239.
- Trenberth, KE. (1990). "Recent observed interdecadal climate changes in the northern hemisphere". *Bulletin of the American Meteorological Society*, v. 71, p. 988-993.
- Trenberth, KE; Hurrell, JW. (1994). "Decadal atmosphere-ocean variations in the Pacific". *Climate Dynamics*, v. 9, p. 303-319.
- Tucci, CEM. (2005). "Modelos Hidrológicos". Editora ABRH/UFRGS, 678.
- Tucci, CEM; Collischonn, W. (2003). "Previsão de Vazão". In: Tucci, C.E.M.; Braga, B. (Orgs.) *Clima e Recursos Hídricos no Brasil*. Porto Alegre: ABRH, p. 281-348.
- Uvo, CB; Graham, NE. (1998). "Seasonal runoff forecast for the northern South America: a statistical model". *Water Resource Research*, v. 34(12), p. 3515-3524.
- Vera, C; Higgins, W; Amador, J; Ambrizzi, T; Garreaud, R; Gochis, D; Gutzler, D; Lettenmaier, D; Marengo, J; Mechoso, CR. (2006). "Toward a unified view of the American Monsoon Systems". *Journal of Climate*, v. 19(20), p. 4977-5000.
- Wang, WC; Chau, KW; Cheng, CT; Qiu, L. (2009). "A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series". *Journal of Hydrology*, v. 374, p. 294-306.
- Watterson, IG. (2009). "Components of precipitation and temperature anomalies and change associated with modes of the Southern Hemisphere". *Hydrological Processes*, v. 29, p. 809-826.
- WCD, World Commissions on Dams. (2000). "Dams and development. A new framework for decision-making". Earthscan Publications Ltd, London, 404 p.
- Wernstedt, K.; Hersh, R. (2002). "Climate forecast in flood planning: Promise and ambiguity". *Journal of the American Water Resource Association*, v 38(6), p. 1703-1713.
- Wilby, RL; Wedgbrow, CS; Fox, HR. (2004). "Seasonal predictability of the summer hydrometeorology of the River Thames, UK". *Journal of Hydrology*, v. 295, p. 1-16.
- Wilks, DS. (2001). "A skill score based on economic value for probability forecast". *Meteorol. Appl.*, v. 8, p. 209-219.
- Wilks, DS. (2006). "Statistical methods in the atmospheric sciences. Burlington, Massachusetts: Academic Press, Elsevier, 627 p.
- Wu, CL; Chau, KW; Li, YS. (2009). "Methods to improve neural network performance in daily flows prediction". *Journal of Hydrology*, v. 372, p. 90-93
- Wurbs, RA. (1996). "Modeling and analysis of reservoir system operations". Editorial Prentice-Hall, Inc. 356 p.
- Yao, H; Georgakakos, A. (2001). "Assessment of Folsom Lake response to historical and potential future climate scenarios 2. Reservoir management". *Journal of Hydrology*, v. 249, p. 176-196.
- Yeh, W; Becker, L; Zettlemoyer, R. (1982). "Worth of inflow forecast for reservoir operation". *Journal of the Water Resources Planning and Management Division*, v. 108(WR3), p. 257-259.
- Zealand, CM; Burn, DH; Simonovic, SP. (1999). "Short term streamflow forecasting using artificial neural networks". *Journal of Hydrology*, v. 214, p. 32-48.
- Zhang, Y; Wallace, JM; Battisti, DS. (1997). "ENSO-like interdecadal variability: 1900-93". *Journal of Climate*, v. 10, p. 1004-1020.
- Zwiers, FW; von Storch, H. (2004). "On the role of statistics in climate research". *International Journal of Climatology*, v. 24, p. 665-680.

Anexos

Anexo 1: Modelo AMANDA

O modelo AMANDA apresenta as seguintes características principais, quando utilizado na operação de um reservatório com base na previsão de vazão, sendo os usos principais do reservatório a geração de energia e o controle de cheias:

- 1) Aplica-se a sistemas independentes ou reservatórios com características de aproveitamento de cabeceira com operação isolada de controle de cheias.
- 2) A operação do reservatório é feita com base numa curva-guia para controle de cheias e na previsão de vazão afluente.
- 3) O intervalo de tempo utilizado na simulação é tipicamente, o diário, porém pode ser utilizado qualquer intervalo de tempo menor.
- 4) Utiliza previsões de vazão afluente com um horizonte e frequência pré-definidos para cada simulação. Estes valores podem ser mudados para diferentes simulações. O modelo pode ser utilizado para a operação com base em previsões com qualquer combinação de horizonte e frequência, desde que o horizonte seja igual ou maior do que a frequência.

O AMANDA é integrado pelo modelo de balanço hídrico do reservatório e os módulos de previsão de operação e operação real, apresentados a seguir:

A.1.1. Modelo de balanço hídrico do reservatório

A Figura A. 1 apresenta as principais variáveis intervenientes na operação de um reservatório.




Figura A. 1. Principais variáveis intervenientes na operação de um reservatório.

O modelo de balanço hídrico do reservatório utiliza, em cada intervalo de tempo, uma expressão discretizada da equação de continuidade (equação A.1).

$$V_t = V_{t-1} + \left(\frac{QA_{t-1} + QA_t}{2} \right) \times \frac{\Delta t}{10^6} - \left(\frac{QE_{t-1} + QE_t}{2} \right) \times \frac{\Delta t}{10^6} - \frac{E_t \times A_{t-1}}{10^3} \quad (\text{A.1})$$

Nesta equação t-1 indica o intervalo de tempo anterior; t indica o intervalo de tempo atual; V_t é o volume do reservatório em t (hm^3); V_{t-1} é o volume do reservatório em t-1 (hm^3); QA_{t-1} é a vazão afluyente em t-1 ($\text{m}^3 \cdot \text{s}^{-1}$); QA_t é a vazão afluyente em t ($\text{m}^3 \cdot \text{s}^{-1}$); QE_{t-1} é a vazão defluyente em t-1 ($\text{m}^3 \cdot \text{s}^{-1}$); QE_t é a vazão defluyente em t ($\text{m}^3 \cdot \text{s}^{-1}$); Δt é o intervalo de tempo (s); E_t é a evaporação líquida diária no tempo t (mm); A_{t-1} é a área do reservatório (km^2) para um volume V_{t-1} .

A cada intervalo de tempo essa equação é resolvida para o termo V_t , considerando conhecidas as vazões afluentes (QA) nos tempos t-1 e t, e a existência de uma relação direta entre a vazão defluyente e o volume armazenado (ou o nível d'água no reservatório). Assim, o volume V_t define a vazão defluyente QE_{t+1} e a vazão defluyente QE_t é definida pelo volume armazenado no intervalo anterior (V_{t-1}).

Trata-se, portanto, de um método explícito de solução da equação de balanço hídrico. Considerou-se esta simplificação na forma de resolver a equação válida porque foi utilizado

um intervalo de tempo diário, que é relativamente pequeno considerando o volume útil do reservatório para o qual foi feita a aplicação.

A vazão defluente total é dada pela soma da vazão turbinada e vertida (equação A.2):

$$QE_t = QT_t + QV_t \quad (A.2)$$

onde QE_t é a vazão defluente em t ($m^3.s^{-1}$); QV_t é vazão vertida em t ($m^3.s^{-1}$) função da cota do reservatório em t-1; QT_t é a vazão turbinada em t ($m^3.s^{-1}$). Considera-se, de forma simplificada, que a vazão turbinada é uma função unívoca da cota ou do volume do reservatório no tempo t-1.

A aplicação da equação A.1 recursivamente ao longo de toda a série de vazões afluentes observadas resulta em uma série de volumes e níveis d'água (H_t) correspondentes. Entretanto, uma das seguintes situações pode ocorrer no final de um intervalo de tempo: 1) o volume calculado V_t resulta em H_t igual ou inferior ao da curva-guia; 2) H_t é superior ao indicado pela curva-guia.

No caso 1, a vazão de vertimento QV_t do próximo intervalo de tempo é igual a zero. No caso 2, a vazão de vertimento no próximo intervalo de tempo é tal que ao final do balanço o nível d'água é exatamente igual ao nível definido pela curva-guia. Para isto, o valor da vazão vertida é calculado de acordo com equação A.3:

$$QV_{t+1} = 2 \times \frac{10^6}{\Delta t} \times \left(V_t - V_{reg_{t+1}} - \frac{E_{t+1} \times A_t}{10^3} \right) + QA_t + QA_{t+1} - QE_t - QT_{t+1} \quad (A.3)$$

onde QV_{t+1} é a vazão vertida em t+1; V_t é o volume do reservatório em t; QA_t é a vazão afluente em t; QA_{t+1} é a vazão afluente em t+1; QE_t é a vazão defluente em t; Δt é o intervalo de tempo; E_{t+1} é a evaporação líquida diária em t+1; A_t é a área do reservatório para um volume V_t ; QT_{t+1} é a vazão turbinada em t+1; $V_{reg_{t+1}}$ é o volume indicado pela curva-guia em t+1 (hm^3).

São consideradas duas restrições operacionais com o objetivo de evitar inundações a jusante do reservatório. Essas restrições são: 1) limites no valor máximo da vazão defluente (Q_{lim}) e 2) limites no valor dos incrementos e decrementos da vazão defluente (QR_t) de um intervalo de tempo para o seguinte. Assim, nos intervalos de tempo em que a vazão vertida

calculada pela equação A.3, somada à vazão turbinada resulta em uma vazão defluente superior aos limites impostos por essas restrições, a vazão de vertimento é recalculada, limitando-se o seu valor para que a vazão defluente $Q_{E_{t+1}}$ atenda essas restrições, como expresso por exemplo, pela equação A.4.

$$QV_{t+1} = Q_{\text{lim}} - QT_{t+1} \quad (\text{A.4})$$

Nesse caso o nível d'água no reservatório pode ficar superior ao nível definido pela curva-guia, mas são respeitadas as restrições sobre a vazão defluente evitando inundações a jusante do reservatório.

A.1.2. Módulo de previsão da operação

O módulo de previsão de operação recebe as previsões de vazão afluente para todos os intervalos de tempo do horizonte de previsão e realiza o balanço hídrico do reservatório segundo as equações A.1 a A.4. A função do módulo de previsão de operação é definir as vazões defluentes (turbinadas e vertidas), no dia em que são recebidos os dados de previsão para todos os intervalos de tempo dentro do horizonte de previsão. Isto é feito através de 1 a 3 passos, conforme o texto que segue:

- Passo 1: As vazões vertidas e turbinadas são definidas de acordo com a curva-guia e é feita a simulação do balanço hídrico do reservatório até o final do horizonte de previsão.
- Passo 2: Se necessário, corrigem-se as vazões defluentes definidas no passo 1, buscando diminuir as vazões vertidas definidas pela curva-guia.
- Passo 3: Se necessário, corrigem-se as vazões defluentes definidas no passo 1, buscando aumentar as vazões vertidas definidas pela curva-guia.

Numa primeira aproximação (passo 1), as vazões vertidas são definidas pela curva-guia e as vazões turbinadas são definidas considerando que há uma relação direta entre a vazão turbinada e o nível do reservatório. Ao final desta primeira aproximação, de acordo com a variação do nível d'água no interior do reservatório ao longo do horizonte de previsão, ocorrem diferentes situações, que podem ser agrupadas em três casos típicos, descritos pelas figuras e pelo texto que seguem:

- Caso A: o nível d'água não supera a cota definida pela curva-guia em nenhum intervalo de tempo ao longo do horizonte de previsão (Figura A. 2(A)).
- Caso B: o nível d'água supera a cota definida pela curva-guia em um ou mais intervalos de tempo ao longo do horizonte de previsão, mas fica abaixo da curva-guia no último intervalo do horizonte de previsão (Figura A. 2(B)).
- Caso C: o nível d'água supera a cota definida pela curva-guia no último intervalo do horizonte de previsão (Figura A. 2(C)).




Figura A. 2. Casos típicos de variações do nível d'água no interior do reservatório ao longo do horizonte de previsão.

Caso A

No caso A (Figura A. 2(A)) as vazões defluentes adotadas no passo 1 são aceitas. Neste caso, não existem vertimentos em todo o horizonte de previsão. A vazão turbinada é definida em função da cota prevista do reservatório considerando que há uma relação direta entre a vazão turbinada e o nível do reservatório. Assim, a vazão defluente é igual à vazão turbinada em cada intervalo de tempo, e os próximos passos não são executados.

Caso B

No caso B (Figura A. 2(B)), a operação do reservatório seguindo a curva-guia exige vertimentos a partir do intervalo de tempo t_{ind} , quando o nível d'água no reservatório passa a ser superior à cota definida pela curva-guia. De acordo com o modelo de balanço hídrico do reservatório, estes vertimentos devem ser os mais altos possíveis, respeitando as restrições de máximo incremento entre dias consecutivos e de máximo valor absoluto.

No caso B constata-se que as vazões vertidas poderiam ter sido menores, de forma a evitar que ao final do horizonte da previsão o nível d'água no reservatório esteja abaixo da curva-guia. Para reduzir as vazões vertidas em situações como a do caso B, é realizado o procedimento iterativo do passo 2.

O passo 2 consiste de uma flexibilização controlada da curva-guia, onde se admitem situações em que o nível d'água do reservatório pode ficar acima da curva-guia sem que existam vertimentos, em função das informações de previsão de vazão.

Admite-se que o nível d'água no reservatório pode ficar acima da cota dada pela curva-guia, desde que o nível d'água não atinja uma região definida aqui como região de proteção (Figura A. 3), dada por $H_{max}-H_{seg}$, onde H_{max} é o valor da restrição que define o nível máximo operacional do reservatório (pode ainda representar o nível máximo para evitar inundações em cidades de montante) e H_{seg} é um parâmetro que reflete o grau de confiança nas previsões. Quando as previsões de vazão são perfeitas, H_{seg} pode ser igual a zero. Quando são utilizadas previsões reais, H_{seg} deve ser maior do que zero, e o seu valor vai depender das características do reservatório e da qualidade das previsões de vazão utilizadas.

O passo 2 pode ser descrito pelas etapas que seguem, onde $freq$ representa a frequência de previsão (período de tempo no qual são emitidos novos dados de previsão):

Para valores de k entre 0 e $t+freq-t_{ind}$;

- a) Reduzir vertimentos entre $t_{ind}+k$ e $t+freq$, isto é, $QV_t = \min\{0;QVR\}$ onde QVR é o valor mínimo dos vertimentos em função de restrições nos decrementos da vazão defluente, em $m^3.s^{-1}$.
- b) Realizar balanço hídrico de todo o horizonte de previsão, usando as vazões vertidas reduzidas entre $t_{ind}+k$ e $t+freq$ e as vazões vertidas definidas pela curva-guia nos intervalos entre $t+freq$ e $t+horiz$, obtendo H_t (valores do nível d'água do reservatório ao longo do horizonte de previsão).

- c) Testar todos os valores de H_t no horizonte de previsão para verificar se são superiores ao limite $H_{\max} - H_{\text{seg}}$. Em caso positivo (Figura A. 3(1)), incrementa o valor de k e volta à etapa a). Em caso negativo (Figura A. 3(2)), assume os novos valores de vazões vertidas e encerra o módulo de previsão de operação.

Se, para todos os k testados sempre ocorre pelo menos um intervalo de tempo em que $H_t > H_{\max} - H_{\text{seg}}$, então segue para o passo 3 (como no caso C).




Figura A. 3. Cotagramas do reservatório operado segundo a curva-guia (linha preta) e com vertimentos reduzidos (linha cinza tracejada). (1) Região de proteção é invadida no horizonte de previsão. (2) Região de proteção não é invadida.

Caso C

No Caso C, apresentado na Figura A. 2(C), quando o nível d'água no último intervalo de tempo do horizonte da previsão é superior ao nível dado pela curva-guia, o módulo secundário busca aumentar e ou antecipar os vertimentos. Os objetivos dessa alteração nos valores dos vertimentos são: 1) que o nível no último intervalo de tempo do horizonte de previsão seja igual ao definido pela curva-guia; 2) que não ocorra nenhum intervalo de tempo com o nível superior ao nível definido pela curva-guia dentro do horizonte de previsão. A metodologia de determinação do aumento e ou antecipação das vazões vertidas é realizada no passo 3.

O passo 3 é um procedimento iterativo que inicia verificando qual o volume total sobre a curva-guia ao longo do horizonte de previsão, de acordo com a operação definida no passo 1. A partir daí, os vertimentos são antecipados e alterados, em relação aos vertimentos

definidos no passo 1, buscando eliminar completamente o volume sobre a curva-guia, resultando em um cotagrama como o apresentado na Figura A. 4(a).




Figura A. 4. a) Exemplos de cotagrama original no reservatório, resultante do passo 1 (linha preta) e cotagrama resultante da operação com vertimentos antecipados e alterados (linha cinza tracejada). (b) Situação em que mesmo antecipando e aumentando os vertimentos ao máximo admitido pelas restrições não é possível evitar que o cotagrama no reservatório supere a curva-guia. (c) Situação em que antecipando e aumentando os vertimentos apenas após o tempo $t+freq$ é possível evitar que o cotagrama no reservatório supere a curva-guia.

Para definir a alteração da operação em relação ao passo 1, a antecipação dos vertimentos é testada iterativamente, desde o intervalo de tempo em que o nível do reservatório excede a cota definida pela curva-guia (t_{ind}), para trás (intervalos de tempo anteriores), até o intervalo de tempo inicial do horizonte de previsão ou até que a antecipação dos vertimentos é suficiente para eliminar o volume sobre a curva-guia.

Nesta etapa inicial, os valores dos vertimentos na antecipação se correspondem aos máximos valores que somados às respectivas vazões turbinadas, satisfazem as restrições na vazão defluente. O intervalo de tempo inicial da antecipação dos vertimentos é chamado t_{ant} (Figura A. 4). Com relação ao tempo t_{ant} podem ocorrer três situações, dependendo do valor de t_{ant} comparado com o tempo t (em que inicia a previsão) e com o tempo $t+freq$ (tempo em que uma nova previsão será realizada).

Se mesmo aumentando os vertimentos e antecipando seu início para o primeiro dia da operação ao longo do horizonte de previsão não é possível eliminar todos os dias em que o nível d'água no reservatório é superior à cota definida na curva-guia, como apresentado na Figura A. 4(b), então a operação define que os vertimentos em cada um dos dias de $t+1$ até $t+freq$ serão os máximos admitidos pelas restrições.

Se t_{ant} for superior a $t+freq$ (Figura A. 4(c)), então os vertimentos deverão ser aumentados apenas na próxima revisão da operação (em $t+freq$), e a operação (vazões vertidas e turbinadas) definida no passo 1 não é alterada.

Finalmente, se t_{ant} for inferior a $t+freq$ e superior ou igual a $t+1$, o cotograma resultante da operação com vertimentos alterados é tipicamente igual ao apresentado na linha cinza tracejada, na Figura A. 4(a). Em geral, esta primeira aproximação resultará em níveis inferiores aos definidos pela curva-guia, o que representa um “desperdício” de água, do ponto de vista da geração de energia.

Nesse caso inicia uma segunda etapa do passo 3, realizada de forma iterativa, que consiste numa correção dos vertimentos alterados visando dois objetivos: 1) que os vertimentos em t_{ant} sejam os mínimos necessários para que o nível d’água do reservatório não exceda à curva-guia em nenhum intervalo de tempo dentro do horizonte de previsão; 2) que o nível d’água do reservatório ao final do horizonte de previsão seja exatamente igual ao definido pela curva-guia (Figura A. 5(b)).




Figura A. 5. (a) Exemplo de cotograma com vertimentos alterados corrigidos (linha cinza tracejada), (b) Exemplo de cotograma com alteração ideal dos vertimentos (linha de traços e pontos).

Para transformar o cotograma alterado da Figura A. 4(a) no cotograma alterado ideal da Figura A. 5(b) (linha de traços e pontos), são necessárias duas etapas:

- 1) O valor do vertimento alterado em t_{ant} , definido na etapa inicial do passo 3 (valor máximo admitido pelas restrições) é diminuído, mantendo os vertimentos no resto do horizonte de previsão iguais aos definidos na referida

etapa. Esse processo é feito de forma iterativa até encontrar um intervalo de tempo, chamado de $t+x$, no qual a cota do reservatório coincide com a definida pela curva-guia e, além disso, não existem outros intervalos de tempo dentro do horizonte de previsão com cota superior à definida pela curva-guia (Figura A. 5(a)).

- 2) Os vertimentos alterados desde $t+x+1$ até o último intervalo de tempo do horizonte de previsão ($t+Horiz$), definidos na etapa inicial do passo 3 (valores máximos admitidos pelas restrições) são diminuídos para que a cota do reservatório no último intervalo de tempo do horizonte de previsão seja exatamente igual ao da curva-guia, como apresentado na Figura A. 5(b).

A.1.3. Módulo de operação real

No módulo de operação real é realizado o balanço hídrico do reservatório com as vazões afluentes reais (observadas) e com as vazões defluentes (totais) definidas no módulo de previsão de operação.

Entretanto, a vazão turbinada definida no módulo de previsão de operação sofre alterações em função dos erros da previsão. A vazão turbinada é definida de acordo com a relação entre nível e vazão, com base nos níveis d'água reais, calculados a partir do balanço hídrico do módulo de operação real, que utiliza as vazões afluentes observadas. Para manter a vazão defluente total igual à definida no módulo de previsão de operação, a vazão vertida é modificada de forma que a soma total (vertida + turbinada) se mantenha igual à originalmente calculada.

O módulo de operação real calcula as condições iniciais reais para a próxima data em que são feitas previsões de operação ($t+freq$).

Anexo 2: Séries diárias de precipitação e vazão

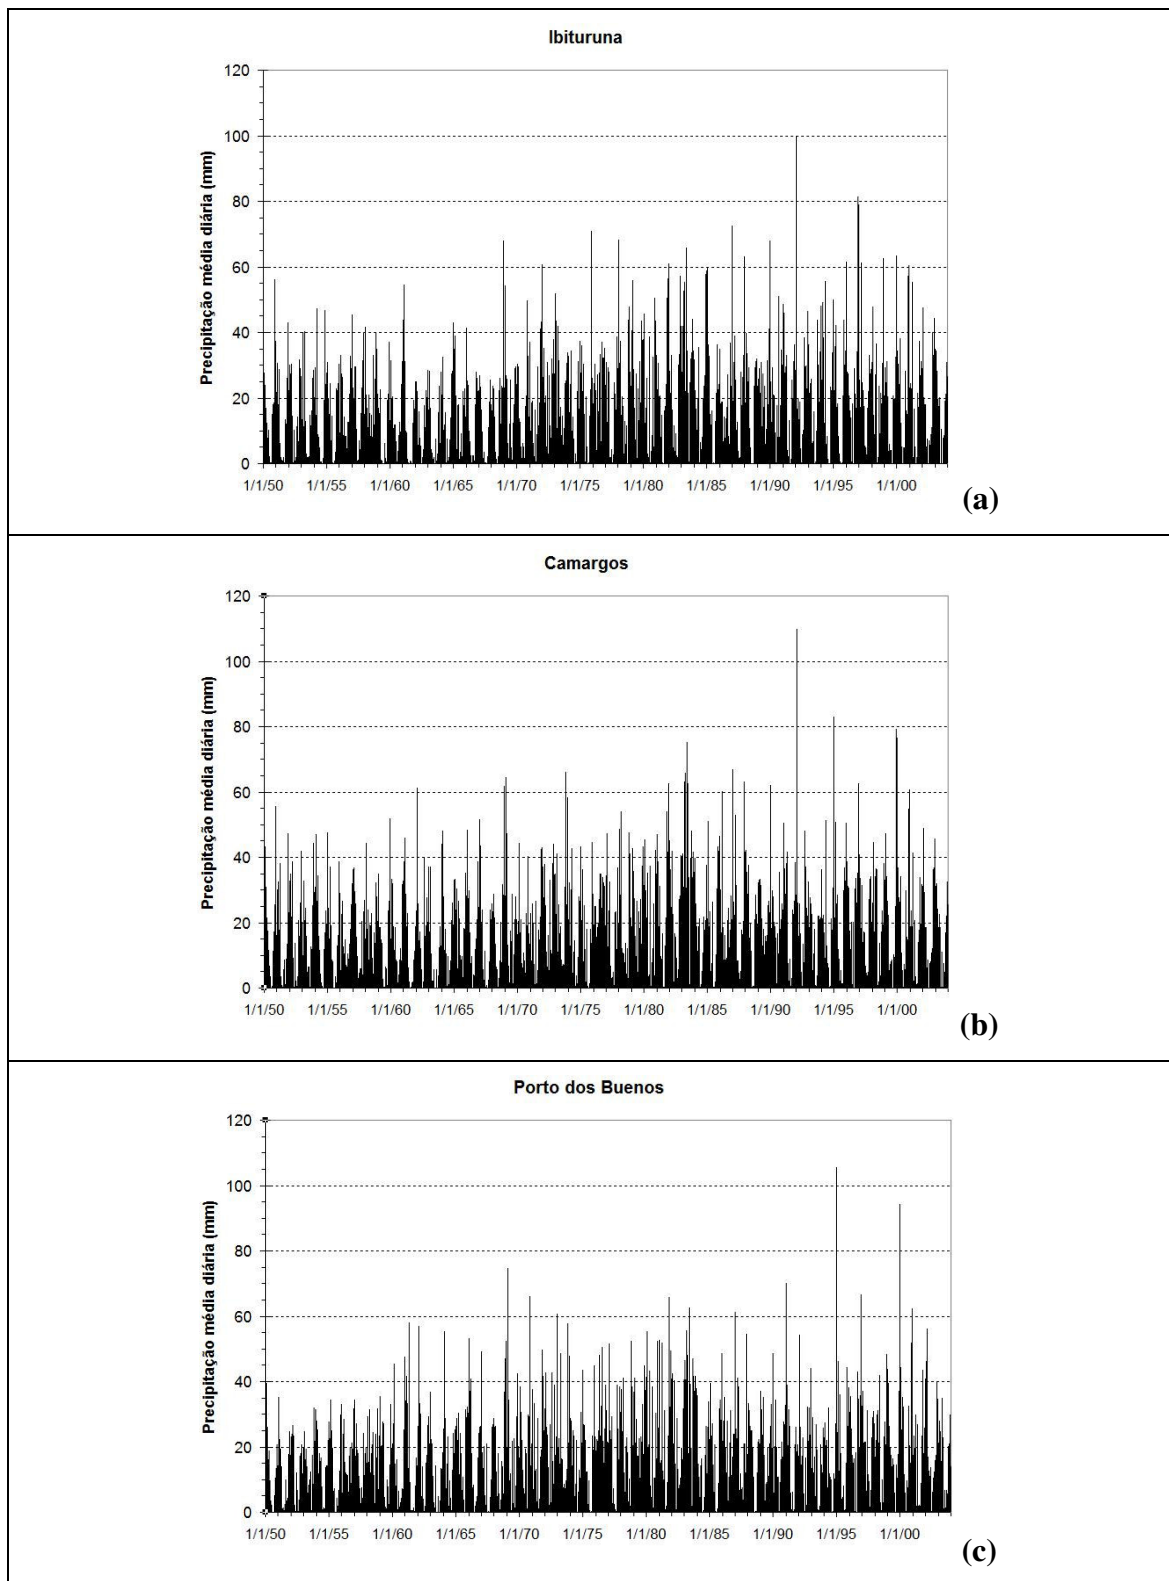


Figura A. 6. . Séries de precipitações médias diárias nas sub-bacias: (a) Ibituruna; (b) Camargos; (c) Porto dos Buenos.

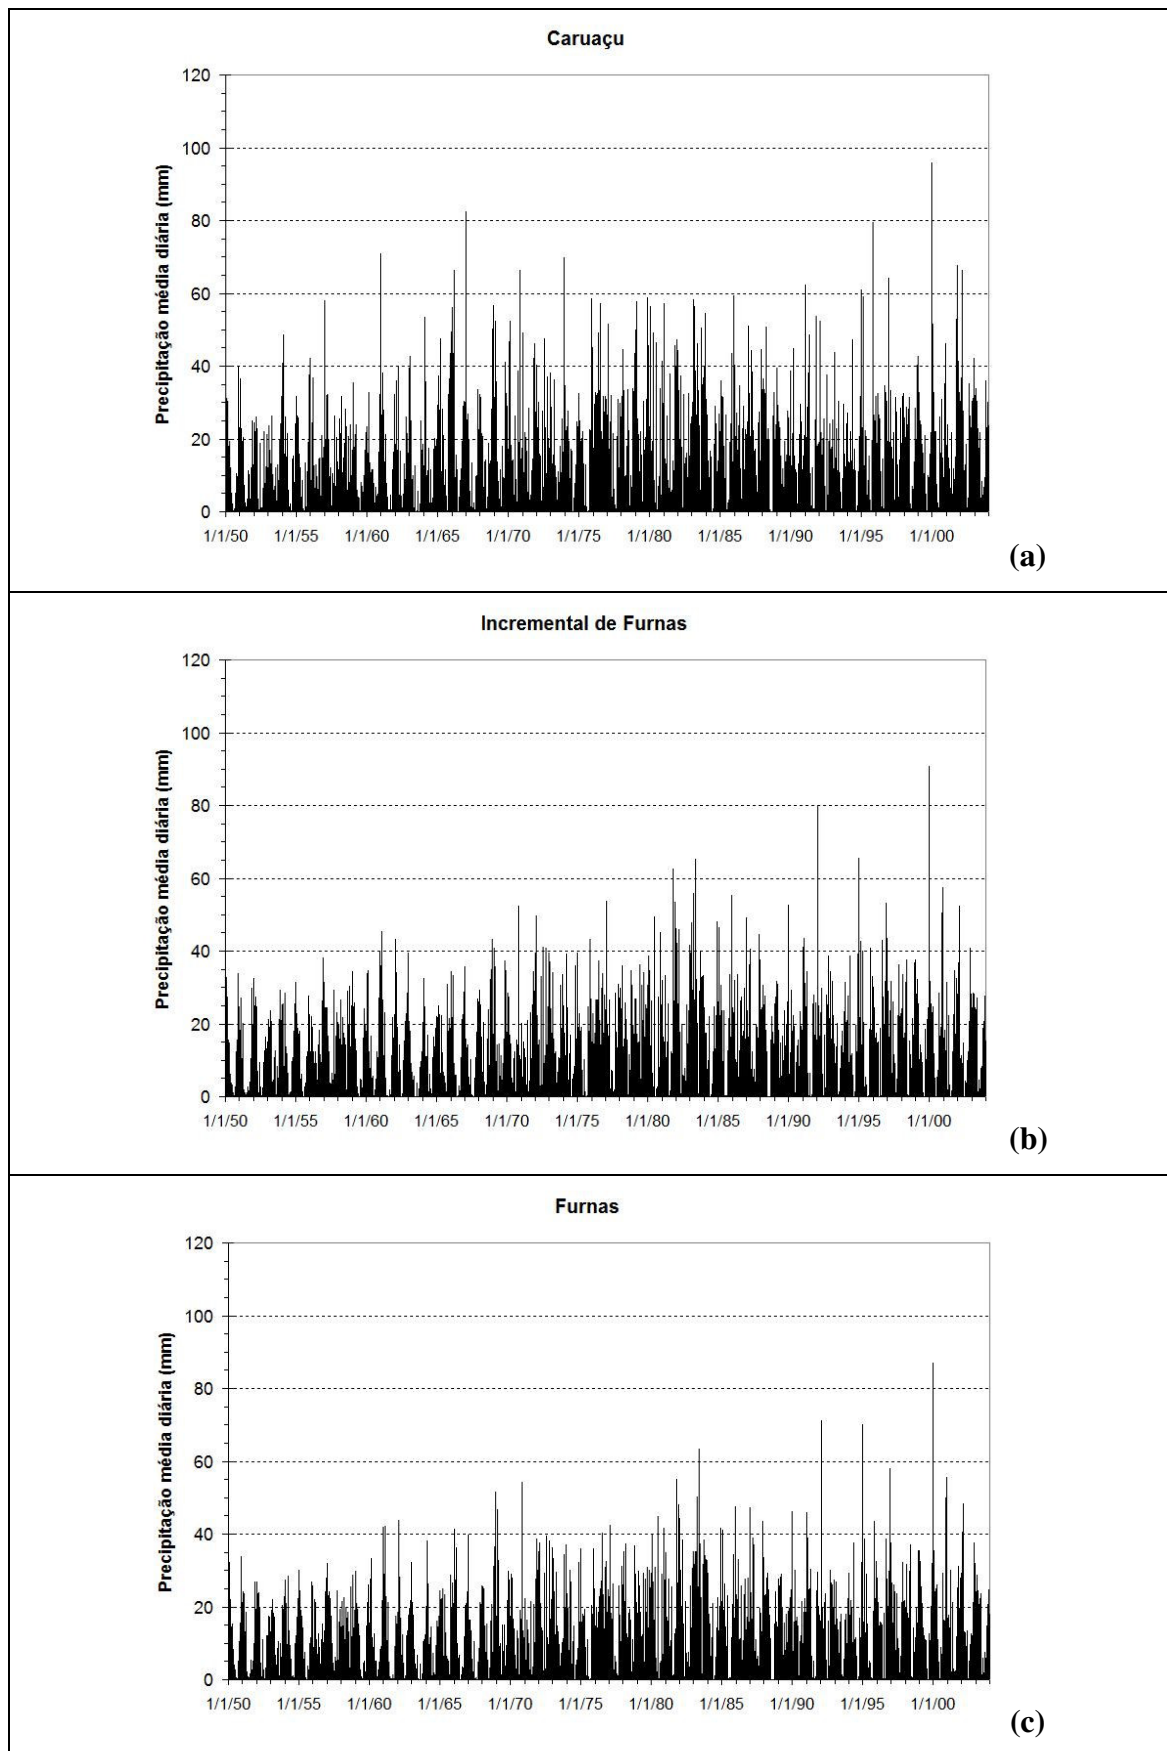


Figura A. 7. Séries de precipitações médias diárias nas sub-bacias: (a) Caruaçu; (b) Incremental de Furnas e (c) na bacia de Furnas.

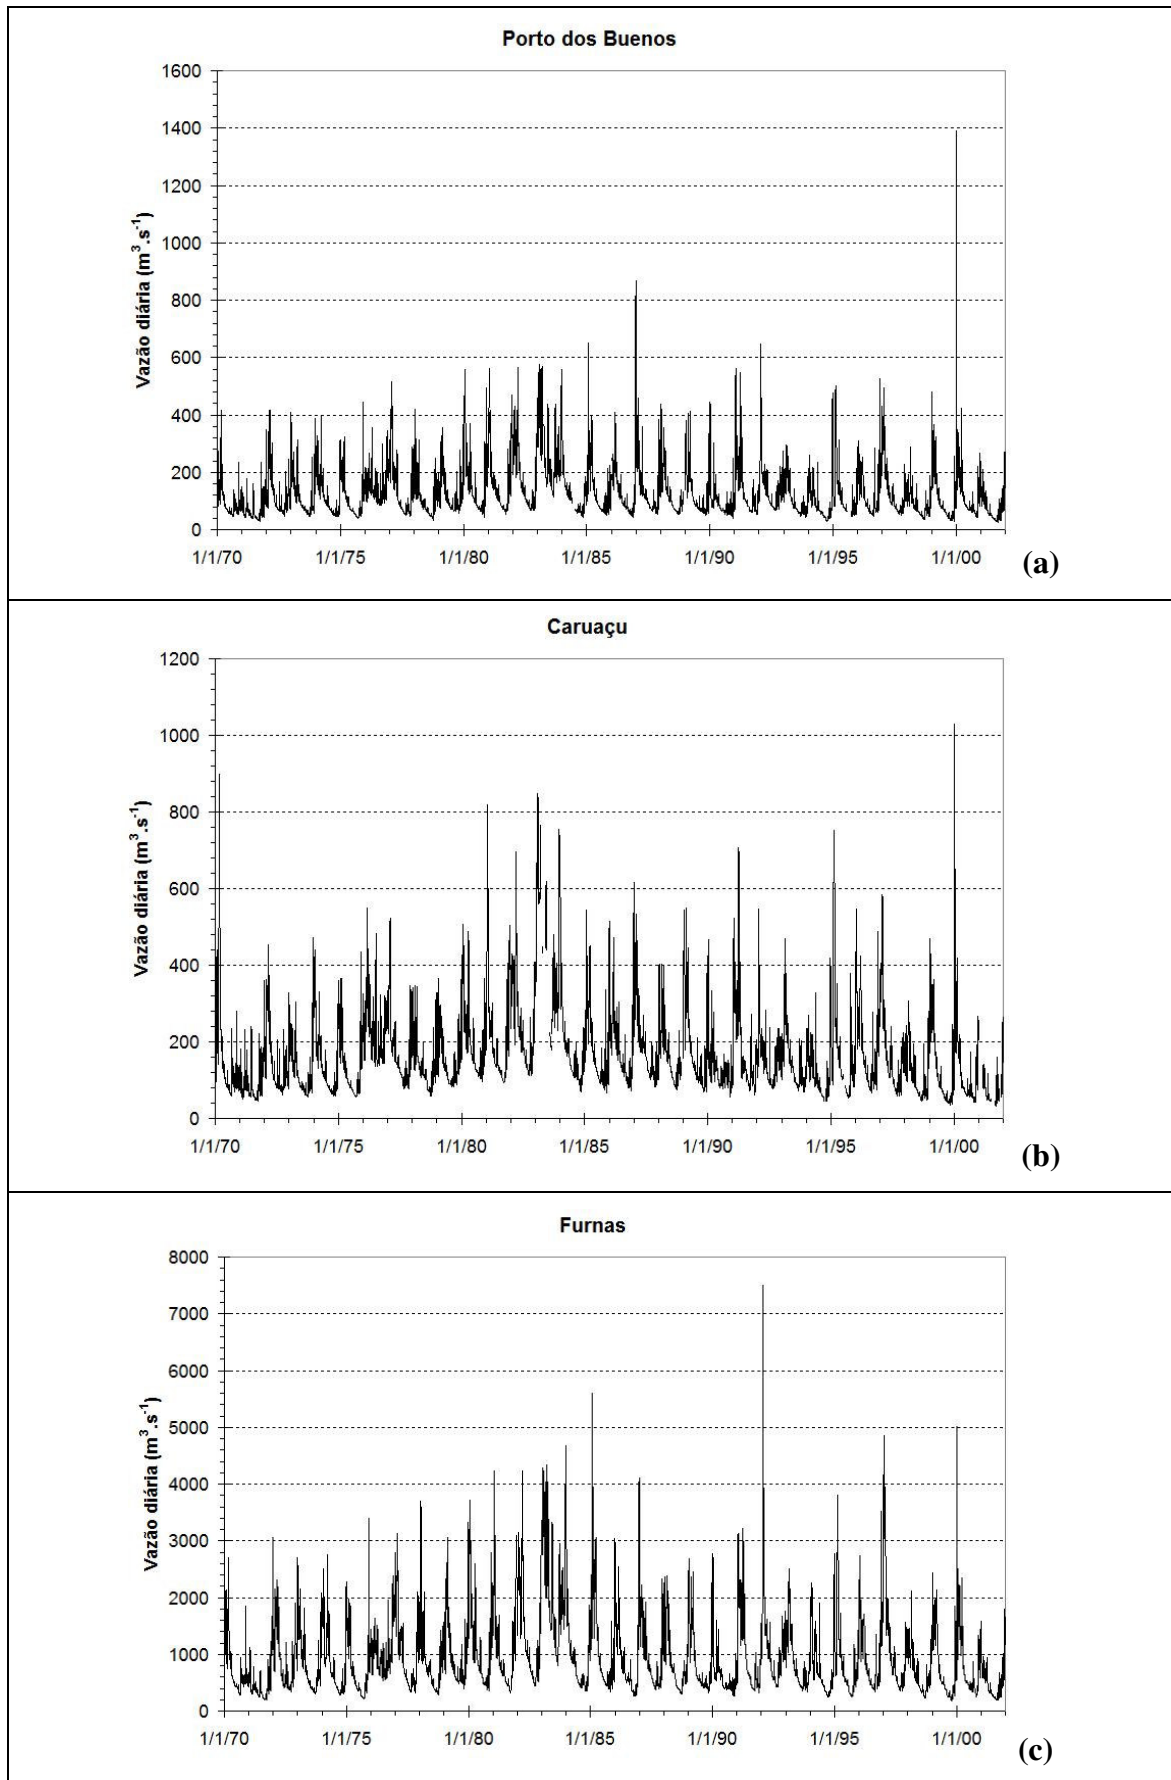


Figura A. 8. Séries de vazões médias diárias nos exutórios das sub-bacias: (a) Porto dos Buenos; (b) Caruaçu e (c) Furnas.

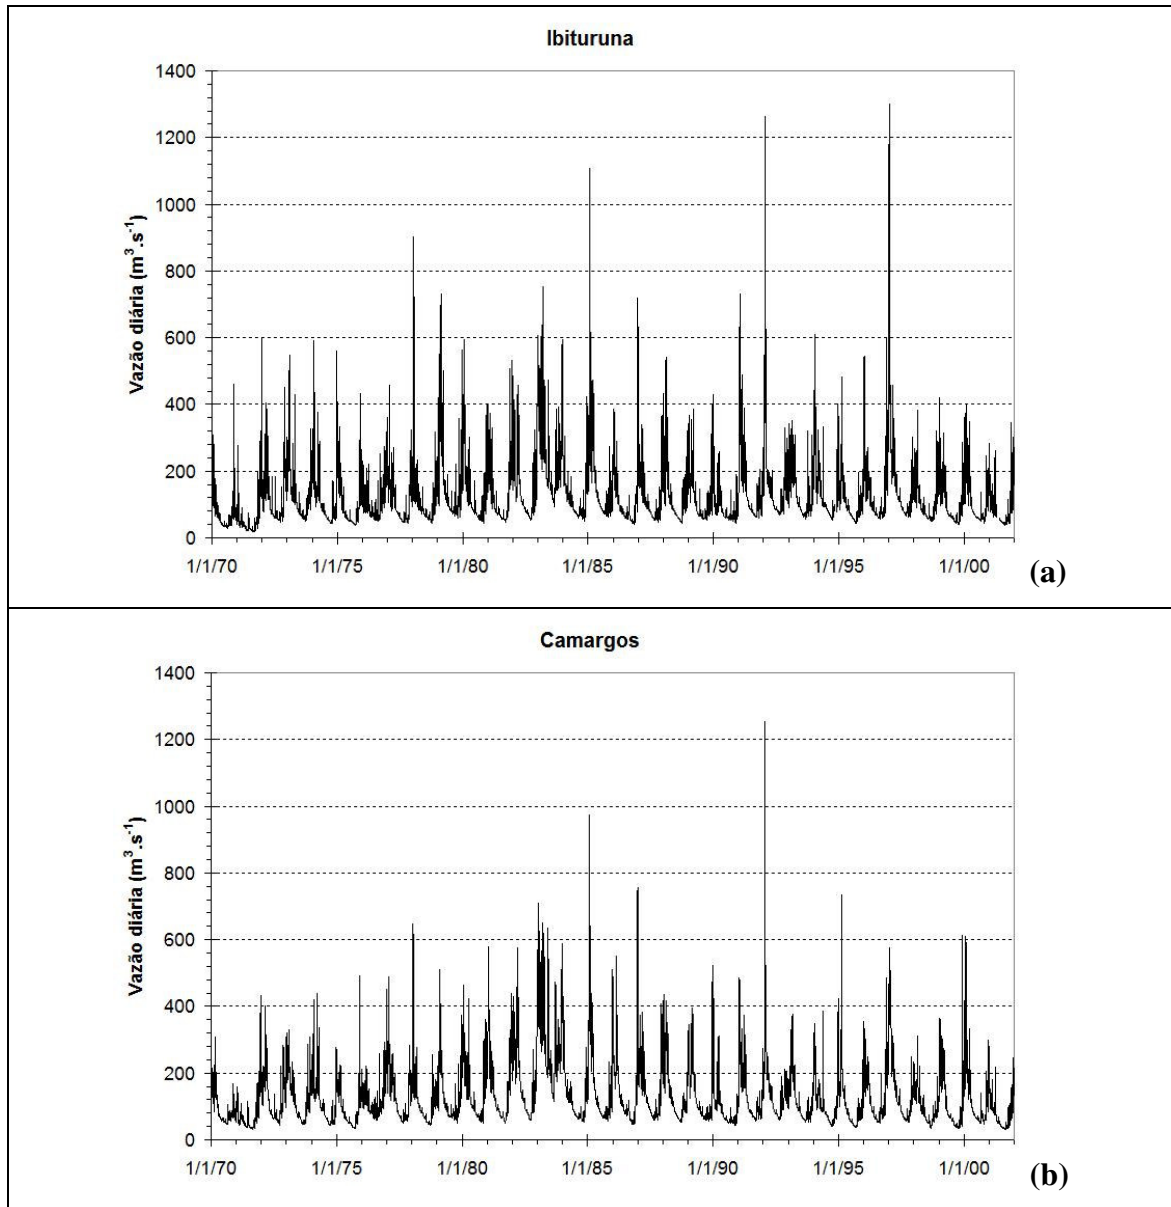


Figura A. 9. Séries de vazões médias diárias nos exutórios das sub-bacias: (a) Ibituruna e (b) Camargos.

Anexo 3: Séries por trimestres de precipitação e índices climáticos

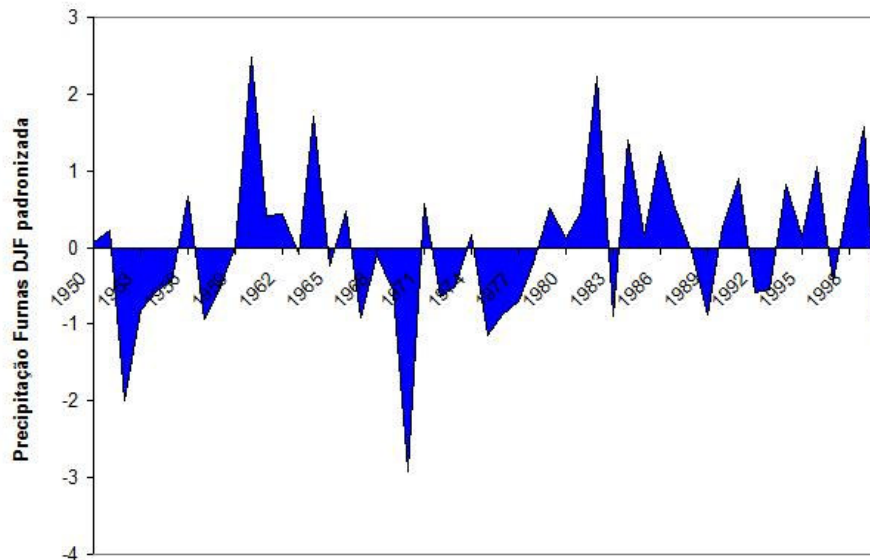


Figura A. 10. Série padronizada da precipitação DJF.




Figura A. 11. Série padronizada dos valores médios do índice NAOI no trimestre DJF.




Figura A. 12. Série padronizada dos valores médios do índice SAMI no trimestre DJF.




Figura A. 13. Série padronizada dos valores médios do índice PDOI no trimestre DJF.




Figura A. 14. Série padronizada dos valores médios do índice El Niño 3.4 no trimestre DJF.




Figura A. 15. Série padronizada da precipitação SON.




Figura A. 16. Série padronizada dos valores médios do índice NAOI no trimestre SON.




Figura A. 17. Série padronizada dos valores médios do índice SAMI no trimestre SON.




Figura A. 18. Série padronizada dos valores médios do índice PDOI no trimestre SON.




Figura A. 19. Série padronizada dos valores médios do índice El Niño 3.4 no trimestre SON.