

Este exemplar corresponde a redação final da tese defendida por MANOEL HENRIQUE DA NÓBREGA MARINHO e aprovada pela Comissão julgada em 11/11/2005
Secundino Soares Filho
Orientador

Universidade Estadual de Campinas

Faculdade de Engenharia Elétrica e de Computação

“Previsão de Vazões Afluentes Vários Passos à Frente Via Agregação de Vazões para o Planejamento Energético da Operação de Sistemas Hidrotérmicos de Potência”

Autor: Manoel Henrique da Nóbrega Marinho

Orientador: Prof. Dr. Secundino Soares Filho

Co-orientadora: Profa. Dra. Rosangela Ballini

Tese de Doutorado apresentada à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: **Energia Elétrica.**

Banca Examinadora

Secundino Soares Filho, Dr. DENSIS/FEEC/UNICAMP
Paulo Sérgio Franco Barbosa, Dr. DRH/FEC/ UNICAMP
Marinho Gomes de Andrade Filho, Dr. ICMC/USP
Takaaki Ohishi, Dr. DENSIS/FEEC/ UNICAMP
Akebo Yamakami, Dr. DT/FEEC/ UNICAMP
Raul Vinhas Ribeiro, Dr. DENSIS/FEEC/ UNICAMP

Campinas, SP.
11 de novembro de 2005

2005.6.04.6.114

BC
 T/UNICAMP
 M 338p
 67109
 123/06
 11.06
 21/3/06
 315 455

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

M338p Marinho, Manoel Henrique da Nóbrega
Previsão de vazões afluentes vários passos à frente via agregação de vazões para o planejamento energético da operação de sistemas hidrotérmicos de potência / Manoel Henrique da Nóbrega Marinho. --Campinas, SP: [s.n.], 2005.

Orientadores: Secundino Soares Filho, Rosangela Ballini
Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Previsão de vazões. 2. Previsão do tempo a longo prazo. 3. Hidrologia - Modelos. 4. Redes neurais (Computação). 5. Sistemas de energia elétrica hidrotérmica. I. Soares Filho, Secundino. II. Ballini, Rosangela. II. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. III. Título.

RMS-BAE

Titulo em Inglês: Multi-step-Ahead streamflow forecasting using aggregation procedure in hydrothermal operation scheduling

Palavras-chave em Inglês: Streamflow forecast, Inflow aggregation, Hydrological modelling, Neural networks, Hydrothermal scheduling

Área de concentração: Energia Elétrica

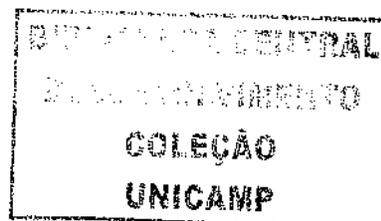
Titulação: Doutor em Engenharia Elétrica

Banca examinadora: Paulo Sérgio Franco Barbosa, Marinho Gomes de Andrade Filho, Takaaki Ohishi, Akebo Yamakami e Raul Vinhas Ribeiro.

Data da defesa: 11/11/2005

Resumo

Modelos de redes neurais artificiais treinados com algoritmos de retropropagação do erro foram desenvolvidos para a previsão de vazões médias mensais vários passos à frente. Essas previsões foram utilizadas em políticas de controle em malha aberta para o planejamento da operação energética de sistemas hidrotérmicos de potência. O posto hidrológico da usina hidrelétrica de Furnas foi selecionado para estudo de caso. Dois métodos foram implementados e testados para a previsão de vazões médias mensais vários passos à frente. O primeiro, denominado Método Direto, utiliza uma rede neural específica para prever cada passo à frente. O segundo, denominado Método Agregado, utiliza inicialmente uma rede neural para prever a soma das vazões vários passos à frente, desagregando posteriormente em valores mensais proporcionalmente aos valores médios do histórico de vazões. Os resultados indicaram que embora o Método Agregado tenha obtido pior desempenho que o Método Direto na comparação dos erros de previsão a cada passo, essa abordagem apresentou melhor desempenho quando comparados os erros de previsão da soma das vazões vários passos à frente. Os dois métodos foram então avaliados através da simulação da operação energética utilizando a política de controle em malha aberta. O resultado indicou um desempenho significativamente melhor para o Método Agregado, proporcionando uma maior geração hidrelétrica e um menor custo operacional.



A origem de tudo,
Manoel Henriques da Silva (in memoriam),

OFEREÇO

Aos meus pais,
Rui Vieira Marinho e
Maria Auxiliadora da Nóbrega Marinho, e irmãos,
Ana Cristina da Nóbrega Marinho,
Alexandre Magno da Nóbrega Marinho, e
Giovanni Guiseppe da Nóbrega Marinho,

DEDICO

AGRADECIMENTOS

A Deus.

À Universidade Estadual de Campinas, através da Faculdade de Engenharia Elétrica e de Computação, do Departamento de Engenharia de Sistemas pela oportunidade oferecida para a realização deste curso.

Ao Prof. Dr. Secundino Soares Filho e a Profa. Dra. Rosangela Ballini pela eficiente e criteriosa orientação bem como pela amizade e incentivo dispensado durante todo este período acadêmico.

À secretária do DENSIS, Márcia Fracaro, pela atenção e colaboração.

À Fundação de Amparo a Pesquisa do Estado de São Paulo - FAPESP, pela concessão da bolsa de estudos.

À apreciação técnica anônima prestada por parte da assessoria científica da FAPESP.

Aos amigos (as) do pensionato, Tiago, Hélcio, Ilton, Maria Amélia, Eudemario, Irênio, Max, Lucas Catão, Ricardo, Lucas Freitas, Alexandre, Roy, Rafael, Bruna, Olivâine, Marcos, Andrielber, Fábio, Paola e Teógenes pela colaboração e estímulo permanentes.

Aos colegas de Pós-Graduação, em especial aos do COSE, Erinaldo, Adriano, Oderson, Thyago, Ricardo, Arce, Marina, Ieda, Ivette, Sandra, Thaís, Mônica, Makoto, Marcos, Marcelo e André, pela convivência e companheirismo.

À Dannielle Venancio pela paciência, compreensão e incentivos.

A eles e a todos aqueles que de alguma forma contribuíram nesta tarefa,

AGRADEÇO

*Sou um ser abençoado,
pela dádiva divina,
minha origem nordestina
sempre tenho conservado;
eu nasci e fui criado
no sol quente abrasador,
foi no meu interior
que comecei a crescer.
Eu tenho orgulho de ser
nordestino, sim senhor.*

*Nasci no Sítio Laranjeiras,
no interior do Estado
da Paraíba, criado
com arroz, feijão e macaxeira,
cuscutz, buchada e pirão,
queijo, tapioca e corredor,
coalhada que tem sabor
do mais natural comer.
Eu tenho orgulho de ser
nordestino, sim senhor.*

*Nasci no alto sertão,
sou nordestino da gema,
conheço todo dilema
da seca na região,
cada fase da estação,
o tempo, o frio, o calor,
o clima, a nuvem, o vapor,
a época que vai chover.
Eu tenho orgulho de ser
nordestino, sim senhor.*

*Conheço todo costume
do nordeste brasileiro,
a bravura do vaqueiro,
os trabalhos de curtume,
da colheita do legume,
do humilde agricultor,
do astuto caçador,
que de tudo quer saber.
Eu tenho orgulho de ser
nordestino, sim senhor.*

*Meu sangue é de nordestino,
que tem a pele queimada
e cada mão calejada,
e lutar no sol a pino,
comecei desde menino
trabalhando com amor,
com coragem e com vigor,
que me faz engrandecer.
Eu tenho orgulho de ser
nordestino, sim senhor.*

*Por tudo que enfrentei,
terra, poeira, sol quente,
sendo firme, resistente,
lutei, venci, superei,
prossegui e melhorei,
me tornando um vencedor;
ao supremo CRIADOR,
quero sempre agradecer.
Eu tenho orgulho de ser
nordestino, sim senhor.*

*O meu sertão tem riqueza,
encanto, graça, abundância,
distinção, exuberância,
destumbramento, beleza,
aconchego, singeleza,
tranqüilidade, esplendor,
panorama acolhedor,
um recanto de lazer.
Eu tenho orgulho de ser
nordestino, sim senhor.*

*Plenamente brasileiro,
nordestino, cordelista,
vate, poeta e artista,
juramentado engenheiro,
destemido, mensageiro,
dinâmico, pesquisador,
apaixonado escritor,
serei isso até morrer.
Eu tenho orgulho de ser
nordestino, sim senhor.*

*Eu tenho orgulho de ser nordestino, sim senhor
Modifiquei de José de Sousa Dantas,
em 30/07/2004*

Conteúdo

Resumo	ii
Abstract	iii
Agradecimentos	v
Conteúdo	vii
Lista de Figuras	ix
Lista de Tabelas	x
Abreviações e Simbologia	xi
1. Introdução	1
1.1 Previsão de Vazões Afluentes	1
1.2 Objetivo e Organização do Trabalho	10
2. Planejamento da Operação Energética	12
2.1 Introdução	12
2.2 Formulação do Problema de Planejamento da Operação Energética	16
2.3 Política de Malha Fechada	18
2.4 Política de Malha Aberta	20
2.5 Previsão de Vazões na Política de Malha Aberta	22
2.6 Síntese do Capítulo	24
3. Redes Neurais Multicamadas	25
3.1 Modelo de Neurônio	25
3.1.1 Tipos de Função de Ativação	27
3.2 Redes Neurais Multicamadas	28
3.3 Aprendizado Supervisionado	30
3.4 O Algoritmo de Retropropagação (<i>Backpropagation</i>)	31
3.5 Síntese do Capítulo	35
4. Previsão de Vazões Vários Passos à Frente	36
4.1 Estrutura da Rede Neural Multicamadas	37
4.2 Método Direto	38
4.3 Método Agregado	38
4.4 Estudo de Caso	41

4.4.1	Resultados do Método Direto	43
4.4.2	Resultados do Método Agregado	45
4.4.3	Resultados da Desagregação e Agregação	46
4.5	Análise dos Resultados	48
4.6	Síntese do Capítulo	51
5.	Desempenho da Previsão de Vazões na Simulação da Operação Energética	54
5.1	Estudo de Caso	55
5.2	Síntese do Capítulo	62
6.	Conclusões	63
6.1	Trabalhos Futuros	65
	Referências Bibliográficas	66
	Índice de Autores	72

Lista de Figuras

Figura 2.1:	Trajectoria Ótima de Volume de Furnas (1950-1960).	22
Figura 2.2:	Trajectoria Ótima de Volume de Furnas (1980-1990).	23
Figura 3.1:	Modelo do Neurônio Artificial.	26
Figura 3.2:	Funções de ativação: (a) função sinal, (b) função linear por partes ($a = 0.5$), (c) função sigmoidal.	28
Figura 3.3:	Redes neurais em camadas: (a) rede com apenas duas camadas de neurônios, (b) rede com uma camada de entradas, uma camada escondida e uma camada de saída.	29
Figura 3.4:	Neurônio de saída j , cujas entradas são as ativações de todos os neurônios da camada imediatamente anterior.	33
Figura 4.1:	Representação do Modelo Direto de previsão para o p -ésimo passo à frente (z^{-l} representa os atrasos no tempo).	38
Figura 4.2:	Comparação dos Métodos Utilizados.	41
Figura 4.3:	Série Histórica de Vazões Afluentes de Furnas.	42
Figura 4.4:	Estatísticas da Série Histórica de Vazões Afluentes de Furnas.	42
Figura 4.5:	EPM para o Posto Hidrológico de Furnas pela Desagregação.	48
Figura 4.6:	EPM para o Posto Hidrológico de Furnas pela Agregação.	49
Figura 4.7:	Comparação das Previsões pela Metodologia de Agregação.	51
Figura 5.1:	Custo Operacional Total dos Estudos.	58
Figura 5.2:	Trajectoria da Geração Hidráulica (1971/1981, 1981/1991, 1991/2001).	60
Figura 5.3:	Trajectoria do Volume de Furnas (1971/1980, 1980/1990, 1990/2001).	61

Lista de Tabelas

Tabela 4.1: Parâmetros do Método Direto.	43
Tabela 4.1: Parâmetros do Método Direto (continuação).	44
Tabela 4.2: Erros de Previsão do Método Direto.	44
Tabela 4.3: Parâmetros do Método Agregado.	45
Tabela 4.4: Erros de Previsão do Método Agregado.	46
Tabela 4.5: Erros de Previsão da MLT para Furnas.	47
Tabela 4.6: Erros de Previsão da Desagregação das Vazões Agregadas pelo Método Agregado.	47
Tabela 4.7: Erros de Previsão da Agregação das Vazões Previstas pelo Método Direto.	47
Tabela 4.8: Resumo dos Erros de Previsão dos Métodos.	52
Tabela 5.1: Característica da Usina Hidrelétrica.	56
Tabela 5.2: Coeficientes dos Polinômios Cota de Montante/Jusante.	56
Tabela 5.3: Produtibilidade Específica e Perda de Carga Média.	56
Tabela 5.4: Geração Hidráulica e Custo Operacional.	57

Abreviações e Simbologia

Abreviações

ANFIS:	Adaptive Network Based Fuzzy Inference System
EAM:	Erro Absoluto Médio
EPM:	Erro Relativo Percentual Médio
EP_{\max} :	Erro Relativo Percentual Máximo
GCOI:	Grupo Coordenador da Operação Interligada
MLP:	Redes Neurais Multicamadas
MLT:	Média de Longo Termo
ONS:	Operador Nacional do Sistema Elétrico
PAR(1):	Modelos Periódicos Auto-regressivos de Ordem 1
PD:	Programação Dinâmica
PDE:	Programação Dinâmica Estocástica
PDED:	Programação Dinâmica Estocástica Dual
POSH:	Planejamento da Operação de Sistemas Hidrotérmicos
REQM:	Raiz do Erro Quadrático Médio
RNN:	Redes Neurais Nebulosas
SAPE:	Sistema de Apoio ao Planejamento Energético
SIN:	Sistema Interligado Nacional

Principais Símbolos

m^3/s :	metro cúbico por segundo
m:	metro
MW:	Mega Watt
GH:	Geração Hidroelétrica
T:	número de estágios do horizonte de planejamento
t:	estágio de planejamento
$\psi_t(\cdot)$:	custo mínimo de geração termoeletrica complementar no estágio t (\$)

- $V(\cdot)$: função custo futuro associado ao estado final do reservatório (\$)
- H_t : função convexa decrescente da geração hidráulica no estágio t
- D_t : mercado a ser atendido no estágio t (MW)
- k_i : produtividade específica da usina i (MW/(m³/s)m)
- $\phi_i(\cdot)$: cota de montante do reservatório i como função do volume armazenado (m)
- $\theta_i(\cdot)$: cota de jusante como uma função do volume de água liberado do reservatório i (m)
- hp_i : perda de carga hidráulica na usina i (m)
- y_{it} : volume de água afluente à usina i no estágio t (hm³)
- Ω_i : conjunto de usinas imediatamente a montante da usina i no estágio t
- x_{it} : volume de água armazenado no reservatório da usina i no início do estágio t (hm³)
- \underline{x}_{it} : volume mínimo de água armazenado no reservatório da usina i no início do estágio t (hm³)
- \bar{x}_{it} : volume máximo de água armazenado no reservatório da usina i no início do estágio t (hm³)
- u_{it} : defluência (vazão descarregada) da usina i no estágio t (m³/s)
- \underline{u}_{it} : defluência mínima (vazão descarregada) da usina i no estágio t (m³/s)
- \bar{u}_{it} : defluência máxima (vazão descarregada) da usina i no estágio t (m³/s)
- q_{it} : turbinagem (vazão que passa pela casa de máquinas) da usina i no estágio t (m³/s)
- \underline{q}_{it} : turbinagem mínima (vazão que passa pela casa de máquinas) da usina i no estágio t (m³/s)
- \bar{q}_{it} : turbinagem máxima (vazão que passa pela casa de máquinas) da usina i no estágio t (m³/s)
- s_{it} : vertimento da usina i no estágio t (m³/s)
- $E_{y_t|y_{t-1}} \{ \cdot \}$: valor esperado com relação ao volume afluente no estágio t
- $F_t(x_t, y_{t-1})$: mínimo custo operacional esperado do estágio t
- $f_t(y_t|y_{t-1})$: função densidade de probabilidade condicional do volume d'água afluente no estágio t
- η : taxa de aprendizagem
- w_{kp} : peso sináptico do neurônio k
- $f(\cdot)$: função de ativação
- y_k : ativação de saída do neurônio k
- v_k : nível de ativação interna ou potencial de ativação do neurônio k
- y_j : valor de vazão real (m³/s)

\hat{y}_j : valor de vazão previsto (m^3/s)

ρ : coeficiente de correlação

p : passos à frente

$v_{i,p}$: volume no p -ésimo passo à frente (m^3/s)

α : termo *momentum*

Ne: neurônios na camada intermediária

E: número de entradas

$k\left(\frac{MW}{m^3 / sm}\right)$: produtibilidade específica

pc : perda de carga média

Capítulo 1

Introdução

A geração de energia no Brasil, depende basicamente da quantidade de água disponível nos grandes reservatórios de acumulação existentes no país. Todo o planejamento da operação, de curto, médio e longo prazo, é feito com base nas previsões de vazões; a segurança dos aproveitamentos e o controle de cheias dependem igualmente de uma boa previsão de vazões, e a adequação do sistema às novas restrições de controle ambiental e uso múltiplo da água também depende de boas previsões de vazões. Enfim, o conhecimento antecipado da quantidade de água que estará disponível no sistema permite ao planejador tomar decisões adequadas para maximização de sua utilização.

Uma condição de fundamental importância para que o atendimento à demanda de energia seja realizado de forma otimizada, é que se disponha de um sistema de previsão de vazões eficientes, uma vez que a capacidade de geração futura do sistema é influenciada pelas futuras vazões afluentes cuja natureza é intrinsecamente estocástica.

Na próxima seção é desenvolvido o estudo sobre a previsão de vazões afluentes.

1.1 Previsão de Vazões Afluentes

Etimologicamente a palavra previsão, *prever, prae e videre*, sugere que se quer ver alguma coisa antes que ela exista. Pode-se definir Previsão como: fornecer, num certo instante de tempo, um valor, ainda que sujeito a erros, para o estado futuro de um certo sistema. Neste sentido, previsão hidrológica consiste em se fornecer valores (e intervalo de confiança) de variáveis hidrológicas (ex.: vazões fluviais, precipitações, níveis de lagos, etc.) com antecedência. A disponibilidade de valores futuros (e de intervalos de confiança) de variáveis hidrológicas, mesmo que sujeitos a erros é ferramenta muito importante no gerenciamento de Recursos Hídricos, portanto as previsões hidrológicas vêm sendo cada vez mais utilizadas em sistemas modernos de Recursos Hídricos.

A previsão de vazões é um desafio hidro-climático utilizado para o gerenciamento dos recursos hídricos numa bacia. A previsão de inundações, da umidade do solo para agricultura, os níveis de navegação de uma via, a disponibilidade hídrica para abastecimento de água, turismo e produção de energia são usos conhecidos para a previsão antecipada da vazão numa bacia hidrográfica. Estes setores se utilizam destas previsões de aflúências para programar suas atividades à luz dos recursos hídricos disponíveis nas diferentes bacias hidrográficas. Sem contar que os rios são importantíssimos recursos viários, não podendo ser esquecido como fator de desenvolvimento econômico, por este motivo. Esta pesquisa foi desenvolvida visando o aumento do conhecimento antecipado das vazões para a utilização nos aproveitamentos hidrelétricos.

A previsão hidrológica pode ser feita principalmente através de dois tipos de modelos: os modelos determinísticos (chuva-vazão) e os modelos estocásticos. Para a realização de previsões hidrológicas são necessárias duas etapas. Na primeira, é estabelecida a série histórica de vazões afluentes, com base em dados observados nos locais de interesse. A segunda etapa consiste na análise destas séries, estimando-se parâmetros que identificam as características estatísticas do regime hidrológico no local, no caso de modelos estocásticos e do processo de transformação de chuva em vazão, no caso de modelos físicos. A partir desses parâmetros, pode-se obter as previsões. Com o conhecimento das previsões, realiza-se uma análise estatística dos erros de previsão e a validação do modelo.

Em VOGEL (1999), verifica-se que quando alguém estuda previsão de vazão na literatura de Recursos Hídricos, observa que existem duas escolas bem distintas: a estocástica e a determinística. É raro encontrar um engenheiro que tenha uma visão balanceada do mundo, que simultaneamente veja os elementos estocásticos e determinísticos na hora de modelar um problema. Esta diferença deriva do sistema educacional, que tende a dar ênfase aos elementos determinísticos.

Os modelos hidrológicos, na tentativa de representar o comportamento dos fenômenos naturais, utilizam como um dos insumos fundamentais para sua perfeita execução as vazões naturais médias diárias, semanais ou mensais, dependendo do horizonte de estudo e da aplicação desejada. Algumas vezes se faz necessário utilizar um histórico de série de vazões naturais e outras vezes se utiliza simplesmente alguns valores previstos para períodos à frente, principalmente para analisar a operação dos reservatórios através de uma simulação ou até mesmo determinar qual deverá ser sua operação

ótima para atender uma determinada condição de armazenamento e demanda para os diferentes usos a partir dessa afluência prevista.

Conforme o uso que se faça das previsões de vazões, trabalha-se com diferentes horizontes e diferentes intervalos de discretização. No Setor Elétrico, há, na verdade, três horizontes de previsões de vazões, a saber: previsões de longo prazo, previsões de médio prazo e previsões de curto prazo.

A previsão de curto prazo, também denominada de previsão em tempo real, é utilizada para estimar a vazão numa seção da bacia com antecedência de horas ou poucos dias, acompanhando a ocorrência do fenômeno que está para atingir ou já atingiu a bacia. Do ponto de vista hidrológico, a previsão de médio prazo envolve a previsão de vazão com antecedência de um a alguns meses e depende fortemente das condições conhecidas de clima e dos oceanos que podem influenciar as vazões futuras na bacia hidrográfica. A previsão de longo prazo é a estimativa, geralmente estatística, de ocorrência de vazões num determinado local, como por exemplo: o risco de inundação numa seção de um rio, a probabilidade de períodos úmidos e secos, entre outros.

No horizonte de previsão de médio prazo, a partir de um histórico de vazões naturais médias semanais e utilizando modelagem estocástica são realizadas estimativas de vazões naturais médias semanais para um horizonte de seis semanas. As previsões de vazões de curto prazo, em nível diário destinam-se à programação diária da operação do Sistema Interligado Nacional - SIN, ao monitoramento e controle de eventos extremos (cheias e secas) e no auxílio à tomada de decisão para promover o uso múltiplo da água (GUILHON, 2002).

Os modelos de previsão de vazões podem ser classificados como estocásticos ao introduzir o conceito de probabilidade de ocorrência das vazões (CHOW, 1964) ou determinísticos caso o modelo não siga a lei das probabilidades (TUCCI, 1998). Podem também ser conceituais, caso suas funções considerem os processos físicos ou empíricos caso sua formulação utilize funções sem nenhuma relação com os processos físicos. Também podem ser caracterizados como modelos concentrados, quando não se leva em conta a variabilidade espacial de seus dados, ou distribuídos, quando as variáveis e parâmetros do modelo dependem do espaço e do tempo.

Atualmente a geração de energia do território brasileiro é baseada majoritariamente em hidrelétricas, pois elas representam a opção mais barata de geração de energia, sendo uma fonte limpa e

renovável. Desta forma, este sistema é fortemente dependente da disponibilidade hídrica de médio e longo prazo para a produção de energia firme e, portanto, da garantia de atendimento do sistema (HAAS, 2003).

No que se refere a previsão de vazões no Brasil, para o horizonte de longo prazo, em base mensal, tradicionalmente era utilizado pela ELETROBRÁS – Centrais Elétricas Brasileiras S.A. e posteriormente pelo Operador Nacional do Sistema Elétrico – ONS, o modelo PREVAZ (ELETROBRÁS, 1980) baseado em modelagem estocástica de séries temporais utilizando técnicas misturando as abordagens tradicionais com modelos auto-regressivos (BOX et al., 1994) e o método de Yevjevich de análise da estrutura periódica da série transformada (YEVJEVICH, 1972).

Até recentemente, a alternativa mais comum aos modelos determinísticos ou hidrológicos na previsão de vazões eram os modelos estocásticos para análise de séries temporais, baseadas principalmente nas metodologias de Box & Jenkins (BOX et al., 1994). Estes modelos tem sido empregados pelo setor elétrico brasileiro, inicialmente no âmbito do Grupo Coordenador da Operação Interligada – GCOI, coordenado pela ELETROBRÁS (GCOI, 1983), e posteriormente no âmbito do Operador Nacional do Sistema Elétrico - ONS.

Redes neurais artificiais, principalmente redes neurais multicamadas (MLP) com algoritmo de retropropagação do erro (RUMELHART et al., 1986), tornaram-se extremamente conhecidas para previsão em diversas áreas, incluindo recursos hídricos (MAIER et al., 2000). Estes modelos apresentam habilidade de aprendizado e capacidade de generalização, destacando a sua capacidade para tratar relações não - lineares de entradas - saídas.

(FRANCELIN et al., 1996) aplicaram redes neurais MLP para previsão de vazões a longo prazo e compararam com os modelos de séries temporais Box & Jenkins. Os resultados mostraram desempenho promissor para a rede neural, apresentando erros percentuais máximos menores que os métodos estatísticos.

(BALLINI, 2000) fez análise e previsão de vazões usando modelos de séries temporais, redes neurais e Redes Neurais Nebulosas (RNN) para previsão um passo à frente e vários passos à frente para dados de postos localizados em diferentes regiões do Brasil. O desempenho dos modelos foi comparado e os resultados mostraram que os modelos propostos apresentaram melhor desempenho que

as outras abordagens tanto para previsão um passo à frente como para previsão com vários passos à frente.

(LACHTERMACHER e FULLER, 1995), descreveram uma metodologia híbrida para a aplicação de redes neurais em análise de séries temporais. A metodologia de Box & Jenkins foi utilizada como um procedimento para explorar importantes relações nos dados da série e estas informações foram usadas para definir uma estrutura inicial para a rede neural reduzindo, assim, os parâmetros a serem estimados e os dados exigidos. Dois tipos de séries foram estudados: séries estacionárias e não estacionárias. Observou-se que o modelo de redes neurais, para maioria das séries testadas, obteve um desempenho igual ou superior quando comparados aos modelos auto-regressivos.

Na previsão de vazões de longo prazo, a partir de um histórico de vazões naturais médias mensais e de diferentes modelagens, geralmente utilizando técnicas de hidrologia estocástica, realizam-se estimativas de vazões naturais médias mensais para os meses seguintes, normalmente abrangendo um horizonte de até um ano à frente. Conhecem-se ainda algumas metodologias, que vêm apresentando resultados promissores, baseadas em tecnologias de RNN, (BALLINI, 2000) ou ainda baseadas em Redes Neurais Construtivas (LUDERMIR e VALENÇA, 2000, 2001), (LUDERMIR et al., 2001).

Uma RNN com estrutura adaptativa foi aplicada para previsão de vazões em (BALLINI et al., 1998, 1999, 2000). Este modelo, proposto por (FIGUEIREDO e GOMIDE, 1997, 1998) apresenta um método de aprendizagem construtivo, onde regras nebulosas são adicionadas à estrutura da rede quando o desempenho desta não é satisfatório. Para avaliar o desempenho do modelo, uma análise comparativa foi realizada com os modelos de redes neurais MLP e PAR. Os resultados mostraram desempenho superior para previsão de vazões um passo à frente usando a RNN.

Em (MARINHO et al., 2003a) um modelo "*Adaptive Network Based Fuzzy Inference System*" (ANFIS) proposto por (JANG, 1993), foi ajustado para previsão de vazões. O desempenho deste modelo foi comparado com uma rede neural MLP, apresentando melhores resultados. No entanto, os resultados não foram satisfatórios em relação aos modelos de RNN, proposto em (BALLINI, 2000). Já em (MARINHO et al., 2003b) os erros foram significativos quando comparados com as metodologias: Modelos Periódicos Auto-regressivos (PAR), redes neurais MLP com algoritmo de retropropagação e RNN.

O modelo SSARR - Streamflow Syntesis and Reservoir Regulation (US ARMY ENGINEER DIVISION, 1972) desenvolvido em 1972 pelo US Army Corps of Engineers, utilizado pela empresa FURNAS – Centrais Elétricas S.A. realiza a previsão de vazões em todos seus aproveitamentos, e que se baseia em três módulos principais, sendo estes, o módulo de precipitação-vazão numa bacia, o módulo de escoamento em rios e reservatórios e o módulo de regularização de reservatórios.

A Companhia de Energia Elétrica do Paraná - COPEL por sua vez utiliza em suas previsões de aflúências os resultados obtidos com o modelo Sacramento Modificado, calibrado pelo Instituto Tecnológico SIMEPAR para União da Vitória, estação localizada a montante da usina hidrelétrica de Foz do Areia, transferindo para o local do aproveitamento por regressão linear simples.

O Operador Nacional do Sistema Elétrico - ONS calibrou para 44 locais de aproveitamentos hidrelétricos o modelo estocástico de previsão de vazões naturais médias diárias PREVIVAZH, desenvolvido em 1999 pelo Centro de Pesquisa de Energia Elétrica - CEPEL (CARVALHO, 2001), baseado em previsões de vazões naturais médias semanais, desagregando-as em vazões diárias utilizando as séries sintéticas de vazões diárias geradas pelo modelo DIANA, apresentado em (KELMAN et al., 1983).

A Companhia Hidroelétrica do São Francisco - CHESF, assim como o ONS, utilizam o modelo CPINS, baseado em rotina de propagação do modelo SSARR, para realizar as previsões de aflúências no trecho incremental entre as usinas hidrelétricas de Três Marias e Sobradinho no rio São Francisco. Além disso, sabe-se que o ONS também vem utilizando experimentalmente a mesma rotina de propagação do modelo SSARR para o curso do rio Tocantins, realizando previsões para os trechos incrementais entre os aproveitamentos de Serra da Mesa, Cana Brava, Lajeado e Tucuruí.

No rio Zaire, utiliza-se modelo estocástico auto-regressivo e periódico de previsão de vazões em base mensal e semanal, com resultados promissores para um mês à frente com erros relativos percentuais médios entre 6% e 9% e para uma semana à frente entre 2% e 4,5%, possuindo este rio uma variação muito suave ao longo do tempo (WANG et al., 1994).

No Canadá, em Vernon – British Columbia, utiliza para previsão das vazões afluentes ao lago de Okanagan também uma modelagem baseada no ESP – Extended Streamflow Prediction Method que utiliza uma variante da clássica regressão linear múltipla. A Hydro Quebec aplica um modelo chuva-vazão para a previsão

de vazões, baseado numa combinação do modelo Stanford (CRAWFORD e LINDSLEY, 1966) com o modelo SSARR. A própria Hydro Quebec aplicou com sucesso, para a bacia do rio St. Maurice uma metodologia de previsão de enchentes baseada em Análise de Correlação Canônica e regressão múltipla de variáveis meteorológicas e hidrológicas (OUARDA, 2000).

Atualmente, é utilizado na Tchecoslováquia o modelo ERM - Empirical Regressive Model, na Dinamarca o modelo chuva-vazão NAMS II e o modelo NAMKAL baseado em filtro de Kalman, na Hungria o modelo chuva-vazão com uso da distribuição gamma denominado GAPI, na Irlanda o modelo chuva-vazão de nome SMAR, na Itália o modelo CLS - Constrained Linear System, na Suíça o modelo chuva vazão que usa previsão de neve denominado SRM - Snowmelt Runoff Model e nos Estados Unidos o modelo SSARR (ROYAL SOCIETY, 2001).

O National Weather Service Ohio utiliza para prever as aflúncias, um modelo físico com uso de previsão de chuva e de neve baseado em previsão de luminosidade, temperatura do ar, uso do solo, urbanização das bacias, previsão de chuva e de evaporação, utilizando para tal o API – Antecedent Precipitation Index. A Hymet Company utiliza para previsão de vazões no rio Columbia, o modelo HMCRF - Hymet Modelo Columbia River Forecast, sendo este baseado em modelagem física baseado em previsão de chuva e temperatura. O USGS - United States Geological Survey aplica o conhecido modelo SSARR para a bacia do rio Puyallup. O Georgia Water Resources Institute aplicou com sucesso o modelo ESP - Extended Streamflow Prediction Method baseado em regressão linear múltipla para previsões em base diária (GEORGAKAKOS e YAO, 2001).

Nos Estados Unidos, dentre outros se aplica o HFAM - Hydrocomp Forecast and Analysis Modeling, modelo que a partir de dados históricos de variáveis meteorológicas gera cenários de previsão de aflúncias futuras diárias e estima funções de distribuição de probabilidade para essas vazões futuras, sendo utilizado pela Minnesota Power and Light Company (MNPOWER, 2002).

Na África do Sul, a cidade de Pretória utiliza dois modelos chuva-vazão conhecidos como SPLASH e KOVACS para realizar as previsões de vazões no rio Orange, em (WRC, 2002).

A seguir, é apresentando um breve resumo da literatura com respeito à agregação e desagregação de dados hidrológicos em diversas escalas de tempo.

A metodologia de desagregação consiste em partir uma vazão anual em parcelas (vazões nos períodos), de modo que a média das parcelas resulte exatamente na média anual, preservando-se as covariâncias entre as vazões dos períodos do ano. (VALENCIA e SCHAAKE, 1972) apresentaram um modelo linear que possui estas propriedades. Posteriormente, (MEJIA e ROUSSELE, 1976) propuseram uma modificação a este modelo de modo a preservar as covariâncias entre os períodos do ano anterior.

(CESP, 1976) desenvolveu um modelo (CEPEL2) com a iniciativa de gerar séries sintéticas de vazões anuais obtidas a partir das vazões mensais e depois desagregá-las em mensais. Em (KELMAN et al., 1979) apresentou-se um modelo (DESAG) com a mesma idéia, mas com métodos diferentes tanto para geração anual como para desagregação. Os modelos DESAG e CEPEL2 diferem quanto à reprodução de períodos secos “semelhantes” ao período crítico da série histórica: DESAG se ajusta bem à curva de regularização histórica enquanto CEPEL2 é “otimista” (baixa probabilidade de secas tão severas quanto a histórica). Em termos de planejamento, a energia garantida de uma dada configuração seria menor quando avaliada por DESAG do que por CEPEL2. Isto implicaria, por exemplo, na antecipação do plano de expansão.

(LIN e LEE, 1992) propuseram uma metodologia fornecendo uma ligação entre as abordagens de agregação e desagregação para simulação de séries hidrológicas. Usando esta metodologia, modelar na teoria pode preservar a incorporação e muitos momentos históricos. A vantagem mais significativa desta metodologia em comparação com o modelo de (MEJIA e ROUSSELLE, 1976) é a preservação de correlações sazonal durante o ano.

(MAHEEPALA e PERERA, 1996) apresenta um método aperfeiçoado de desagregação para a geração de seqüências alternativas de dados hidrológicos mensais. O método é projetado explicitamente para preservar a série mensal durante o ano e a correlação cruzada, além de outros parâmetros mensais e anuais da série histórica. A comparação dos resultados mostra que o método desenvolvido preserva satisfatoriamente os parâmetros estatísticos mensais e anuais das séries históricas, incluindo as correlações mensais durante o ano.

A necessidade de dados de precipitação de alta resolução na escala temporal que variam em base diária para horário ou mesmo de horas para minutos é um problema muito importante na hidrologia. Aplicou-se em (GUENNI e B'ARDOSSY, 1998) um método para a desagregação da

precipitação mensal em diária usando a cadeia de Markov baseado no algoritmo de Monte Carlo. O método foi aplicado a uma série de dados de precipitações das planícies centrais da Venezuela.

Dois modelos de desagregação foram propostos em (MULLER, 1998): MSD (Modelo Simplificado de Desagregação) e MMD (Modelo Modificado de Desagregação) e são baseados no Método dos Fragmentos (SVANIDZE, 1980). Para comparação com os modelos propostos, geraram-se vazões por diversos modelos existentes. Os testes realizados mostraram que os modelos não-paramétricos - DIANA, de Yakowitz, dos fragmentos e os propostos - saíram-se, na maioria dos casos, melhor que os modelos paramétricos (os restantes), por preservarem com maior eficiência as características da hidrografia. E as estatísticas mensais foram bem preservadas pelos modelos propostos, tendo sido, portanto alcançado o objetivo do estudo.

Apresentou-se em (CARVALHO, 2001) uma modelagem estocástica para previsão de vazões diárias a serem utilizadas na Programação da Operação Diária do Sistema Hidroenergético Brasileiro. A modelagem baseia-se na desagregação, em intervalos diários, das previsões de afluências semanais utilizadas na elaboração do Planejamento de Curto Prazo da Operação Hidroenergética do Sistema Interligado Brasileiro. A metodologia de desagregação tem uma abordagem não paramétrica, e faz uso das duas últimas afluências diárias observadas, assim como de seqüências sintéticas de vazões diárias condicionadas às observadas. A modelagem, além da vantagem da menor complexidade em relação aos modelos chuva-vazão, garante a preservação da estrutura de dependência temporal das previsões, para as semanas usadas no Planejamento de Curto Prazo e incorpora as características do processo natural a nível diário, conforme tratado no modelo de geração de seqüências de vazões diárias. Utilizou-se como estudo de caso as séries diárias de vazões afluentes aos aproveitamentos de Jupuí, Sobradinho, Tucuruí e Foz do Areia.

Em (STUDART e CAMPOS, 2001), utilizou-se uma metodologia a qual produz vazões mensais por desagregação de vazões anuais pré-geradas por um modelo apropriado, no caso em questão, uma distribuição Gamma I. Este método, chamado de Método dos Fragmentos, encontra-se detalhado em SVANIDZE (1980) e, segundo ARAÚJO (1991), produz bons resultados para os rios intermitentes do Semi-Árido Nordeste. O uso dessa técnica supõe a existência de uma série histórica de vazões mensais, porém de curta duração, e visa aumentar as informações fluviométricas do posto. Neste trabalho, os duzentos valores de vazões anuais de cada série foram fragmentados pela série histórica do Rio Caxitoré.

Em (MARINHO et al., 2005), apresenta-se uma metodologia baseada em redes neurais MLP para realizar a previsão de vazões afluentes médias mensais vários passos à frente, utilizando a abordagem de agregação de vazões. As previsões de vazões foram desagregadas para os passos à frente realizando-se valores proporcionais a Média de Longo Termo. Os resultados mostram que as previsões realizadas com valores agregados obtiveram resultados significativos quando comparado com os erros de previsão individual.

Uma abordagem para diminuir o erro das previsões de afluências é a proposta de estudo da agregação de vazões neste trabalho, que é de grande importância para o setor elétrico, pois a questão da agregação temporal de vazões visa assegurar erros menores nas previsões de vazões afluentes mensais agregadas, mesmo que a custo de erros maiores nas previsões de vazões afluentes mensais individuais desagregadas, uma vez que o planejamento da operação energética depende principalmente do total previsto vários passos à frente.

Em função desta constatação, a saber, que a decisão ótima de turbinagem do modelo de otimização é sensível ao total das vazões afluentes no próximo ano hidrológico e não ao perfil dessas vazões, foi sugerida a previsão vários passos à frente através da abordagem buscada na agregação das vazões para o planejamento energético a longo prazo. Primeiro é feito a previsão do total de água afluente no ano e depois é desagregada em valores mensais.

Dois métodos foram implementados e testados para a previsão de vazões médias mensais vários passos à frente. O primeiro, denominado Método Direto, utiliza uma rede neural específica para prever cada passo à frente. O segundo, denominado Método Agregado, utiliza uma rede neural para prever a soma das vazões vários passos à frente, desagregando posteriormente em valores mensais proporcionalmente aos valores médios do histórico de vazões.

1.2 Objetivo e Organização do Trabalho

Os objetivos do trabalho foram desenvolvidos em três partes: estudo e análise da previsão de vazões vários passos à frente, previsão de vazões agregadas e direta e o desempenho da previsão de vazões na simulação da operação energética. Os modelos de redes neurais MLP com algoritmos de retropropagação do erro foram aplicados para os estudos de previsão.

Quanto à organização e apresentação do trabalho, este se divide em seis capítulos, com o seguinte conteúdo:

Capítulo 1 – Trata-se da introdução, tendo como finalidade apresentar uma contextualização da previsão de vazões afluentes, os objetivos e a organização do trabalho;

Capítulo 2 – Apresenta-se o problema de planejamento da operação energética de sistemas hidrotérmicos de potência;

Capítulo 3 – Expõe-se os principais tópicos relacionados às arquiteturas multicamadas. Em especial, descreve-se com grande detalhe o algoritmo de retropropagação de erro utilizado no treinamento de redes neurais MLP;

Capítulo 4 – Defini-se os modelos de forma Direta e Agregada para previsão de vazões vários passos à frente aplicado a um estudo de caso. Neste capítulo, realizou-se também, o estudo do método de desagregação baseado na média de longo termo para obter as previsões mensais;

Capítulo 5 – Analisa-se o desempenho da previsão de vazões na simulação da operação energética na política de controle malha aberta, em relação a geração hidrelétrica, custo operacional, trajetórias de volume e defluência da operação do reservatório ao longo do período de simulação;

Capítulo 6 – Apresenta-se as conclusões do trabalho, suas limitações e possibilidades de evolução futura; e,

Referências Bibliográficas – Lista-se as referências bibliográficas utilizadas na elaboração do trabalho.

Capítulo 2

Planejamento da Operação Energética

O planejamento da operação energética visa determinar estratégias de operação que minimizem o custo de operação de cada unidade do sistema durante um determinado horizonte, em geral de até cinco anos. O principal objetivo desta etapa é promover o aproveitamento racional dos recursos disponíveis, garantindo qualidade e segurança no atendimento a demanda, satisfazendo às restrições operativas do sistema, determinando estratégias de geração de forma econômica e confiável considerando os aspectos hidráulicos e estocásticos do problema com maior relevância. Através de estudos de planejamento da operação, as empresas fornecedoras de energia procuram garantir a manutenção dos sistemas existentes e maximizar sua produtividade.

Neste capítulo, apresenta-se o problema de planejamento de sistemas hidrotérmicos, com ênfase no planejamento da operação energética. A formulação determinística do problema de planejamento da operação energética é apresentada, assim como a política de controle de malha fechada da programação dinâmica estocástica e a política de controle de malha aberta, além do estudo da previsão de vazões na política de malha aberta.

2.1 Introdução

O planejamento da operação de sistemas de energia elétrica é um problema complexo, compreendendo desde o gerenciamento dos estoques de água nos reservatórios das usinas hidrelétricas, até aspectos do sistema de transmissão. Planejar e operar adequadamente um sistema de energia elétrica exige uma solução de compromisso entre a minimização dos custos de operação e investimentos e o atendimento com padrões de qualidade do produto energia elétrica, associados à continuidade de suprimento e a padrões de regularização de frequência e tensão. A garantia de um suprimento contínuo e confiável requer, portanto, investimentos na conservação e expansão dos sistemas de geração, transmissão e distribuição de energia elétrica.

As decisões de operação tomadas ao longo do horizonte de planejamento são dependentes no tempo. Os recursos de geração, representados pela água armazenada nos reservatórios, são limitados, e a decisão em cada estágio de planejamento deve assegurar menor complementação térmica no presente sem que a geração futura seja comprometida. O problema é, portanto, um problema de otimização de grande porte, dinâmico, estocástico e interconectado. A aleatoriedade das vazões afluentes às usinas hidrelétricas do sistema e do mercado de energia a ser atendido tornam o problema estocástico, e as funções de produção hidráulica das usinas e a função custo de produção do sistema são não lineares. As metodologias aplicadas na obtenção de uma solução para esse problema sugerem a decomposição do planejamento da operação em etapas de longo, médio e curto prazo.

No planejamento de longo e médio prazo, também chamado de planejamento da operação energética, considera-se uma discretização mensal ou semanal nos horizontes de estudo. Nesta etapa, a representação individualizada das usinas hidrelétricas e a consideração estocástica das afluições, em um único modelo matemático, constituem o maior obstáculo para a solução do problema.

Na literatura, existem diversas publicações apresentando metodologias e algoritmos de otimização aplicados à solução do problema de planejamento da operação energética de sistemas hidrotérmicos. Países como Brasil, Noruega, Suécia e Canadá são grandes produtores de hidreletricidade, porém cada um adota uma metodologia de planejamento específica, de acordo com as características do seu sistema (CICOGNA, 1999).

Em (PEREIRA, 1985) é apresentada uma revisão do estado da arte até 1985 das metodologias empregadas para o problema de coordenação hidrotérmica da operação. Já em (PEREIRA e PINTO, 1985) é descrito o modelo no qual se baseia a metodologia em vigor no setor elétrico brasileiro.

Por várias décadas, a Programação Dinâmica (PD) (BELLMAN, 1962) vêm sendo extensivamente usada na otimização de problemas de planejamento da operação energética em particular e em problemas envolvendo sistemas de recursos hídricos em geral. Em 1946, anos antes de o termo programação dinâmica ser utilizado, (MASSE, 1946) já discutia as idéias básicas desta técnica.

Com a finalidade de tratar a natureza estocástica das variáveis hidrológicas do problema, a Programação Dinâmica Estocástica (PDE) foi introduzida subsequente na solução do problema do planejamento energético (GABLINGER e LOUCKS, 1970).

As primeiras estratégias de operação energética para o sistema elétrico brasileiro, a partir de 1974, eram calculadas através de um método determinístico denominado, Método da Curva Limite Inferior de Armazenamento. Este método é baseado em uma representação agregada e em dados históricos de vazão afluente, em que o sistema operava de acordo com uma curva limite, que representava o mínimo armazenamento necessário para o atendimento da demanda do sistema mesmo na ocorrência da pior série de afluições já registradas no histórico. Em 1978, esta abordagem foi substituída por um modelo de PDE, desenvolvido pela Eletrobrás conjuntamente com o CEPEL (CEPEL/ELETROBRÁS, 1977), baseado em um sistema equivalente (TERRY et al., 1980).

Alguns anos mais tarde, (PEREIRA e PINTO, 1985) propuseram um método, também, implementado por (KLIGERMAN, 1992), baseado na Programação Dinâmica Estocástica Dual (PDED) e na decomposição de Benders, para a otimização do problema de planejamento da operação energética. O método proposto resolve o problema de Programação Dinâmica Estocástica (PDE) de maneira analítica, buscando determinar estratégias ótimas para os subsistemas interligados. Este método resultou no modelo denominado “Newave”, utilizado atualmente pelo setor elétrico brasileiro na determinação de estratégias de operação.

(CARVALHO e SOARES, 1987) propuseram um algoritmo de otimização de primeira ordem que considera vazões afluentes conhecidas, resolvendo o problema de planejamento energético da operação através de um modelo de fluxo em rede não linear. O algoritmo passou a ser aplicado em estudo da operação de sistemas hidrotérmicos de potência (SOARES e CARNEIRO, 1991) e (CARNEIRO, 1991), tendo sido posteriormente aprimorado com a implementação de um método de segunda ordem implantado em um sistema de apoio à decisão, em (OLIVEIRA, 1993) e (VINHAL, 1994 e 1998).

Na otimização determinística, a representação do sistema pode ser feita detalhadamente, considerando cada usina hidrelétrica individualmente, incluindo suas características não lineares de produção e restrições operacionais. A principal característica deste tipo de metodologia é que a mesma pode ser aplicada sem simplificações a sistemas constituídos por múltiplas usinas hidrelétricas. A representação da estocasticidade do problema é feita de forma implícita, com previsões permanentemente atualizadas, caracterizando a solução resultante como uma política de controle em malha aberta.

Baseados na otimização determinística, estudos recentes têm sido propostos onde a estocasticidade do problema de planejamento energético é representada por um conjunto de possíveis valores futuros (MARTINEZ e SOARES, 2001b).

Com o desenvolvimento e a aplicação de modelos de otimização determinísticos no problema de planejamento energético, surgiu também a preocupação de se analisar o desempenho deste tipo de abordagem em relação a otimização estocástica.

Em estudos realizados com dados do sistema elétrico brasileiro em sistemas constituídos de reservatórios únicos, (SILVA, 1999) mostrou que a política de malha aberta apresentou solução muito próxima da abordagem da PDE, com a vantagem de manter maiores níveis de armazenamento no sistema. No entanto, o estudo realizado foi restrito ao período de operação de apenas 12 meses.

(MARTINEZ e SOARES, 2002) e (MARTINEZ e SOARES, 2001a) apresentaram uma comparação entre políticas de controle de malha fechada e de malha aberta, baseadas no modelo periódico auto-regressivo de ordem 1, para o planejamento da operação de usinas hidrelétricas do sistema brasileiro. Os resultados mostraram desempenho similar das duas políticas de controle, para o caso de sistemas com uma única usina hidrelétrica, apontando para as vantagens da malha aberta no caso de várias usinas, uma vez que neste caso, esta política não requer agregação em modelo equivalente.

A determinação de políticas operacionais de longo prazo do Sistema Interligado Nacional tem como base a abordagem por (PDED) (Modelo Newave). Esta abordagem resolve a equação recursiva da PDE convencional de uma maneira alternativa, sem a necessidade da discretização das variáveis de estado do problema, representando a função de custo futuro esperado de operação por linearizações sucessivas (MACEIRA et al., 2002).

Apresentou-se em (MARTINEZ et al., 2002a, 2002b) uma análise da influência da condição terminal do problema de planejamento energético, no desempenho da política baseada na otimização determinística com previsão de vazões. A análise foi feita através de simulações da operação isolada das usinas hidrelétricas de Furnas e Emborcação, sob dados históricos de vazões afluentes. Os resultados mostraram que a influência da condição terminal do problema é relevante para a política de otimização baseada em previsão de vazões.

Em (MARTINEZ et al., 2002c) duas diferentes condições terminais foram consideradas: a primeira refere-se a penalização do volume final de armazenamento de forma a manter o nível do reservatório tão cheio quanto possível sempre no início do próximo período seco do sistema. Neste caso, o horizonte de otimização foi variável. A segunda trata-se de uma função de custo esperado futuro de operação associada ao estado futuro final de armazenamento do reservatório. Embora as duas condições terminais terem levado o sistema a custos operacionais muito próximos, a condição terminal com horizonte variável e enchimento do reservatório no início do período seco ofereceu uma política operacional mais eficiente. Em situações onde a disponibilidade de água foi limitada, esta condição terminal manteve níveis elevados de armazenamento no sistema, elevando a produtividade da usina e, conseqüentemente, reduzindo o custo operacional do sistema, assim como o risco de não atendimento da demanda de energia.

O projeto temático da equipe, intitulado “Planejamento e Programação da Operação de Sistemas de Energia Elétrica”, que foi desenvolvido na Unicamp com financiamento da FAPESP, objetivou a análise e comparação de desempenho de políticas operativas para o planejamento da operação energética a longo prazo, baseadas nas abordagens de (PDE), (PDED) e otimização determinística com vazões previstas. Analisou-se o desempenho dessas diferentes políticas operativas que envolveram a determinação dos valores de geração hidrelétrica, vertimento, e produtividade das usinas do sistema, obtidas através da simulação energética (SOARES, 1999).

A política de controle preditivo é baseada em um modelo de otimização determinístico, o qual permite representar o sistema hidrelétrico em detalhe, considerando cada usina individualmente, com suas próprias restrições operacionais e características não lineares de produção. O modelo estocástico considerado na previsão das afluições pode ser geral, baseado em qualquer metodologia, e específico para cada usina do sistema.

Na próxima seção é apresentado o problema de otimização determinística com vazões previstas.

2.2 Formulação do Problema de Planejamento da Operação Energética

O problema de otimização do planejamento da operação energética, em sua versão determinística, pode ser formulado como o seguinte problema de programação não linear:

$$\min \sum_{t=0}^{T-1} \psi_t (D_t - H_t) + V(x_T) \quad (2.1)$$

sujeito a:

$$H_t = \sum_{i=1}^N k_i [\phi_i(x_{it}) - \theta_i(u_{it}) - hp_i(q_{it})] q_{it} \quad (2.2)$$

$$x_{i(t+1)} - x_{it} - \sum_{j \in \Omega_i} u_{jt} + u_{it} = y_{it} \quad \forall i \in N \quad (2.3)$$

$$u_{it} = q_{it} + s_{it} \quad , \quad \forall i = 1, 2, \dots, N \quad (2.4)$$

$$\underline{x}_{it} \leq x_{it} \leq \bar{x}_{it} \quad , \quad \forall i = 1, 2, \dots, N \quad (2.5)$$

$$\underline{u}_{it} \leq u_{it} \leq \bar{u}_{it} \quad , \quad \forall i = 1, 2, \dots, N \quad (2.6)$$

$$\underline{q}_{it} \leq q_{it} \leq \bar{q}_{it} \quad , \quad \forall i = 1, 2, \dots, N \quad (2.7)$$

$$s_{it} \geq 0 \quad , \quad \forall i = 1, 2, \dots, N \quad (2.8)$$

$$x_{i0} \text{ dado} \quad , \quad \forall i = 1, 2, \dots, N \quad (2.9)$$

$$\forall t, t = 0, 1, \dots, T-1 \quad (2.10)$$

A função objetivo (2.1) é composta pelo custo operacional $\psi_t(\cdot)$ durante o horizonte de planejamento e o custo futuro $V(\cdot)$ associado ao estado final do reservatório. O custo operacional $\psi_t(\cdot)$ representa o custo mínimo de geração complementar de recursos não hidráulicos e, como consequência do processo de minimização, é uma função convexa decrescente da geração hidráulica H_t , e depende da demanda D_t no estágio t . A função $V(\cdot)$ representa o custo futuro como uma função do armazenamento dos reservatórios no final do período de planejamento, cujo objetivo é equilibrar os custos do uso da água no período de planejamento com os custos futuros após o final desse período.

A geração hidráulica no estágio t é uma função não linear representada pela equação (2.2), em que x_{it} representa o volume de água armazenado no reservatório no início do estágio t , q_{it} é o volume de água turbinado pela usina i no estágio t e u_{it} é o volume total de água defluente da usina i no estágio t , representado pela equação (2.4), sendo s_{it} o volume de água vertido do reservatório no estágio t . A constante N representa o número total de usinas hidrelétricas do sistema; k_i , denominada produtividade

específica da usina, é o produto da densidade da água, aceleração da gravidade e eficiência média do conjunto turbina/gerador; $\phi_i(\cdot)$ representa a cota de montante do reservatório como função do volume armazenado; $\theta_i(\cdot)$ representa a cota de jusante como uma função do volume de água liberado do reservatório e hp_i é a perda de carga hidráulica, em metros, que a água sofre pela passagem pelo conduto forçado da usina, função do volume de água turbinado.

A equação (2.3) representa o balanço de água no reservatório, em que Ω_i representa o conjunto de usinas imediatamente a montante da usina i e y_{it} é o volume de água afluente à usina i no estágio t . Termos referentes a evaporação e infiltração não foram considerados por questão de simplicidade.

Limites superiores e inferiores nas variáveis, representados pelas equações (2.5)-(2.8), são impostos por restrições físicas operacionais das usinas hidrelétricas e outras restrições associadas ao uso múltiplo da água, como controle de cheias, irrigação e navegação.

A solução do modelo determinístico (2.1)-(2.9) pode ser obtida por uma técnica de otimização não linear por fluxo em redes especialmente desenvolvida para essa aplicação (OLIVEIRA e SOARES, 1990). É importante destacar que as vazões naturais às usinas hidrelétricas são dados de entrada nesse modelo, devendo ser fornecidas pelo usuário.

Na próxima seção é apresentado a PDE, caracterizada como uma política de malha fechada, cujo objetivo não é encontrar uma trajetória ótima de decisões, mas determinar uma regra de decisões ótimas que ofereça, em cada estágio do período de planejamento, a decisão ótima para cada possível estado do sistema (BERTSEKAS, 1995).

2.3 Política de Malha Fechada

A aplicação desse modelo no planejamento energético da operação, utilizado conforme implementado no sistema elétrico brasileiro, resulta em se considerar o armazenamento do mês e a afluência do mês anterior como as variáveis de estado do sistema. O processo estocástico associado às vazões é então representado por um modelo auto-regressivo periódico de ordem 1 (PAR(1)), descrevendo uma cadeia de Markov (BERTSEKAS, 1995). Assume-se, assim, que a variável

estocástica representando a vazão afluente no estágio t depende somente da vazão afluente ocorrida no estágio anterior $t-1$. A consideração de modelos de ordem superior requer o indesejável aumento da dimensão do espaço de estado do problema, no caso da implementação primal convencional desta técnica, dificuldade conhecida como a “maldição da dimensionalidade” (MARTINEZ, 2001).

As variáveis de estado no modelo são representadas pelo volume de água armazenado no reservatório no começo de cada estágio, x_t , e o volume afluente no período anterior, y_{t-1} . As variáveis de controle são representadas pela quantidade de água total liberada do reservatório durante o estágio t , u_t , turbinada q_t e vertida, s_t .

O problema de planejamento hidrotérmico, em sua versão estocástica, pode ser formulado como:

$$\min E_{y_t|y_{t-1}} \left\{ \sum_{t=0}^{T-1} \psi_t (D_t - H_t) + V(x_T) \right\} \quad (2.11)$$

sujeito as restrições (2.2)-(2.8), sendo $E_{y_t|y_{t-1}} \{ \cdot \}$ o valor esperado com relação ao volume afluente no estágio t condicionado pelo volume afluente durante o estágio $t-1$.

Em cada estágio, decisões são baseadas na minimização da soma do custo presente mais o custo futuro esperado, assumindo decisões ótimas para todos os estágios subseqüentes, através da solução da seguinte equação recursiva:

$$F_t(x_t, y_{t-1}) = \min_{\Lambda_t} [\psi_t (D_t - H_t) + \int_{-\infty}^{+\infty} F_{t+1}(x_{t+1}, y_t) f(y_t|y_{t-1}) dy_t] \quad (2.12)$$

$$\forall t, t = T, T-1, \dots, 0 \text{ com, } F_T(x_T, y_{T-1}) = V(x_T),$$

em que, $\Lambda_t = \{u_t / \text{sujeito a (2.2)-(2.8)}\}$; $F_t(x_t, y_{t-1})$ representa o mínimo custo operacional esperado do estágio t até o final do período de planejamento T , assumindo que o sistema se encontra no estado (x_t, y_{t-1}) e $f_t(y_t|y_{t-1})$ é a função densidade de probabilidade condicionada do volume d'água afluente no estágio t condicionada pelo volume d'água afluente no estágio anterior $t-1$.

No caso de sistemas com múltiplos reservatórios a utilização dessa técnica requer que seja o sistema hidrelétrico seja representado por um reservatório equivalente (ARVANITIDS e ROSING, 1970). O modelo equivalente de um sistema hidrelétrico consiste de um reservatório equivalente que

recebe, armazena e descarrega energia em vez de água. Variáveis hidráulicas são transformadas em variáveis energéticas multiplicando-as pela produtividade média de todas as usinas na cascata pelas quais a água passa para produzir energia.

No caso do modelo equivalente, a política de decisão obtida pela PDE é desagregada a usinas individualizadas através de modelos de simulação baseados na operação dos reservatórios em paralelo, similar à regra de operação adotada pelos modelos de simulação do setor elétrico brasileiro, a qual estabelece que os reservatórios devem manter o mesmo armazenamento relativo, operando nas mesmas faixas de armazenamento.

A consideração de modelo equivalente tem sido amplamente proposta para o planejamento da operação energética à longo prazo, como forma de viabilizar o uso da PDE na operação de sistema com múltiplos reservatórios. No entanto, a principal limitação da metodologia de agregação é que este tipo de representação não considera adequadamente alguns aspectos importantes da operação das usinas hidrelétricas, como a diversidade hidrológica entre bacias hidrográficas, o efeito da queda na produtividade das usinas e a ocorrência de vertimentos localizados no sistema.

Na próxima seção, apresenta-se a política de malha aberta.

2.4 Política de Malha Aberta

Numa política de malha aberta para o planejamento da operação energética, proposto em (MARTINEZ, 2001), a aleatoriedade das afluições é considerada de forma implícita, substituindo valores estocásticos das variáveis por seus valores esperados, os quais podem ser fornecidos por modelos de previsão de vazões. O objetivo dessa política é determinar a trajetória ótima de operação dos reservatórios que constituem o sistema com base na previsão disponível dos dados incertos do problema.

Em cada estágio do período de planejamento um esquema de controle em realimentação determina uma decisão ótima baseada no corrente valor previsto das incertezas futuras. A fim de se evitar propagação de erros através do horizonte de planejamento, novas previsões são realizadas à medida que informações tornam-se disponíveis ao sistema em cada estágio de planejamento.

Uma importante questão no desempenho dessa política é a condição de contorno associada ao modelo determinístico de otimização, a qual estabelece o balanço entre custos do uso da água no período de planejamento com os custos futuros após esse período.

Uma maneira de superar o problema de se obter uma apropriada condição de contorno para o modelo é estender o horizonte de planejamento de maneira a tornar desprezível a influência da mesma na decisão ótima do primeiro estágio. No entanto, este tipo de consideração pode não ser conveniente, uma vez que, com a extensão do horizonte de planejamento, o erro na previsão de aflúências tende a aumentar, comprometendo o desempenho da política de malha aberta. Por outro lado, estabelecer horizontes de planejamento mais curtos, onde os modelos de previsão possam ter melhor desempenho, requer uma precisa estimativa da função de custo esperado futuro de operação, desde que, neste caso, a influência da mesma sobre a decisão do primeiro estágio passa a ser crucial.

Para superar o conflito entre condição terminal e horizonte de otimização, assume-se que os reservatórios devem estar tão cheios quanto possível sempre no início do período seco do sistema, que nos sistemas Sudeste, Nordeste e Norte corresponde ao último mês da estação chuvosa, no caso o mês de Abril. Este critério heurístico tem como base a análise de comportamento da solução ótima determinística sob dados históricos de vazão afluente (MARTINEZ, 2001).

De acordo com a condição de contorno adotada, o horizonte de otimização é considerado variável ao longo do período de planejamento, sendo o estágio final sempre o mês de Abril. Assumindo que T representa o próximo mês de abril, a solução do problema (2.2)-(2.9) é obtida considerando a condição terminal $V(x_{iT}) = M(\bar{x}_i - x_{iT})$, em que M é uma constante suficientemente grande para garantir que a condição terminal prevaleça sobre o restante da função objetivo.

A seguir, apresenta-se a importância da previsão de vazões na trajetória de volume da usina hidrelétrica de Furnas obtida pelas abordagens de malha aberta e malha fechada, durante dois períodos: o período de 1950 a 1960, correspondente as vazões mais baixas do histórico e durante o período de 1980 a 1990, um período que inclui as vazões mais altas do histórico.

2.5 Previsão de Vazões na Política de Malha Aberta

As duas políticas operativas foram comparadas através de simulação em (MARTINEZ, 2001). A solução por malha aberta utilizou o modelo determinístico desenvolvido na Universidade Estadual de Campinas - Unicamp (OLIVEIRA e SOARES, 1990) alimentado por um modelo de previsão de vazões baseado no modelo PAR (1) utilizado pela PDE.

A Figura 2.1 mostra a trajetória do volume da usina hidrelétrica de Furnas obtida pelas duas abordagens, durante o período de 1950 a 1960, sendo o mês inicial do período de planejamento o mês de maio/1950 e o mês final o mês de abril/1960. Pode-se verificar que nos anos com vazões médias, tal como 1950/1951, 1951/1952 e 1959/1960, a diferença entre as políticas de malha aberta e malha fechada são reduzidas, em contraste com a grande diferença verificada para o período crítico de 1952 a 1956, quando a disponibilidade de água foi escassa e a política de controle de malha aberta mostrou-se significativamente superior. A solução ótima absoluta (Solução Ótima), obtida com o modelo de otimização determinístico alimentado pelas vazões verificadas na década de 50, portanto com perfeito conhecimento das vazões, foi também apresentada para efeito comparativo.

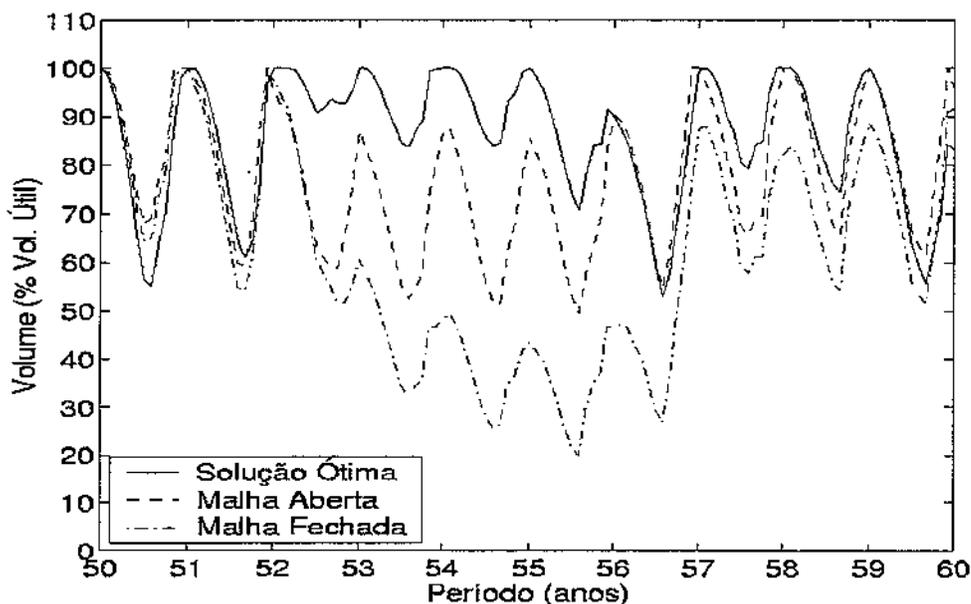


Figura 2.1: Trajetória Ótima de Volume de Furnas (1950-1960).

O desempenho superior da política de malha aberta pode ser explicado pelo fato que embora a afluência seja crítica e em ambas as políticas o modelo PAR(1) não pôde corretamente estimá-la, a condição de contorno considerada na malha aberta (penalidade sobre o esvaziamento do reservatório ao final de abril) é responsável por manter altos níveis de armazenamento no reservatório, desta forma conduzindo a usina a maiores valores de altura de queda, o que aumenta a sua produtividade. Esta é uma importante característica da política de malha aberta, desde que períodos secos são aqueles de maiores custos operacionais e maiores riscos de déficit e, portanto, são os mais importantes no planejamento energético.

A Figura 2.2 mostra a trajetória de volume da usina hidrelétrica de Furnas no período de 1980 a 1990, um período que inclui as vazões mais altas do histórico. Neste caso, onde a condição hidrológica é favorável, as duas políticas operativas apresentaram comportamento muito similar, embora ainda com um pequeno ganho para a política em malha aberta.

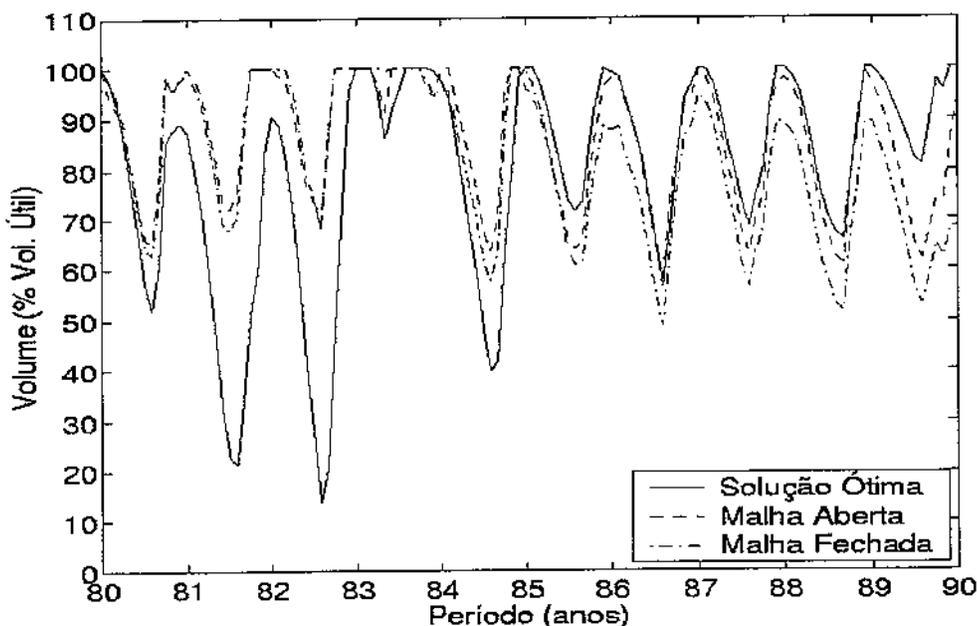


Figura 2.2: Trajetória Ótima de Volume de Furnas (1980-1990)

Para a política de malha aberta, a previsão de vazões vários passos à frente é um insumo fundamental. No próximo capítulo, descreve-se o modelo de Redes Neurais Artificiais Multicamadas, o qual será utilizado na previsão de vazões vários passos à frente.

2.6. Síntese do Capítulo

Neste capítulo, descreveu-se o problema de planejamento de sistemas hidrotérmicos, com ênfase ao planejamento da operação energética. Detalhou-se a formulação determinística do problema de planejamento da operação energética, assim como a política de controle de malha fechada da programação dinâmica estocástica e a política de controle de malha aberta, além do estudo da previsão de vazões na política de malha aberta. Apresentou-se, também, a importância da previsão de vazões na trajetória de volume da usina hidrelétrica de Furnas obtida pelas abordagens de malha aberta e malha fechada, durante dois períodos: o período de 1950 a 1960, correspondente as vazões mais baixas do histórico e durante o período de 1980 a 1990, um período que inclui as vazões mais altas do histórico, e mostrou-se que a política de malha aberta obteve melhor desempenho para os dois períodos.

Capítulo 3

Redes Neurais Multicamadas

Redes neurais artificiais têm sido aplicadas com sucesso nos mais diversos problemas. Dentre as principais áreas de aplicação de redes neurais artificiais pode-se citar: sistemas de controle (WHITE e SOFGE, 1992), (IYODA, 2000), reconhecimento de padrões (BISHOP, 1995), aproximação de funções (VON ZUBEN, 1996) e previsão de séries temporais (MARINHO et al., 2004), (FIGUEIREDO et al., 2004), (CHIEW et al., 2003). Embora existam inúmeras arquiteturas de redes neurais, a arquitetura multicamadas é, sem dúvida, a mais freqüentemente encontrada na literatura. Entre as razões para a sua popularidade, cita-se sua capacidade de aproximação universal e sua flexibilidade para obter soluções de qualidade para uma ampla classe de problemas, a partir de um mesmo algoritmo de aprendizado.

Neste capítulo, apresenta-se os principais tópicos relacionados às arquiteturas multicamadas, e que serão importantes no desenvolvimento deste trabalho. Em especial, descreve-se o algoritmo de retropropagação de erro utilizado no treinamento de redes neurais artificiais multicamadas. Este algoritmo foi um dos principais responsáveis pelo ressurgimento do interesse da comunidade científica em redes neurais, após um período de grande ceticismo em relação às suas potencialidades.

3.1 Modelo do Neurônio Artificial

Um *neurônio* é a unidade fundamental de processamento de informação de uma rede neural (HAYKIN, 1999). A Figura 3.1 mostra o modelo de um neurônio artificial. Pode-se identificar três elementos básicos no modelo:

1. Um conjunto de sinapses ou conexões de entrada, sendo cada entrada ponderada por um *peso sináptico*. Sendo assim, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . Observe a ordem adotada para os índices (subscritos) na notação aqui empregada: o primeiro índice se refere ao neurônio em questão e o segundo índice ao terminal de

entrada da sinapse ao qual o peso se refere. Quando uma entrada fixa está presente (entrada x_0 na Figura 3.1), então o peso sináptico correspondente é denominado peso de polarização.

2. Uma junção de soma, responsável pela combinação aditiva dos sinais de entrada, ponderados pelos respectivos pesos das sinapses do neurônio.
3. Uma função de ativação geralmente não-linear e de formato sigmoidal, representando um efeito de saturação na ativação de saída y_k do neurônio. Tipicamente o intervalo da ativação do neurônio é confinada em $(0, 1)$ ou $(-1, 1)$.

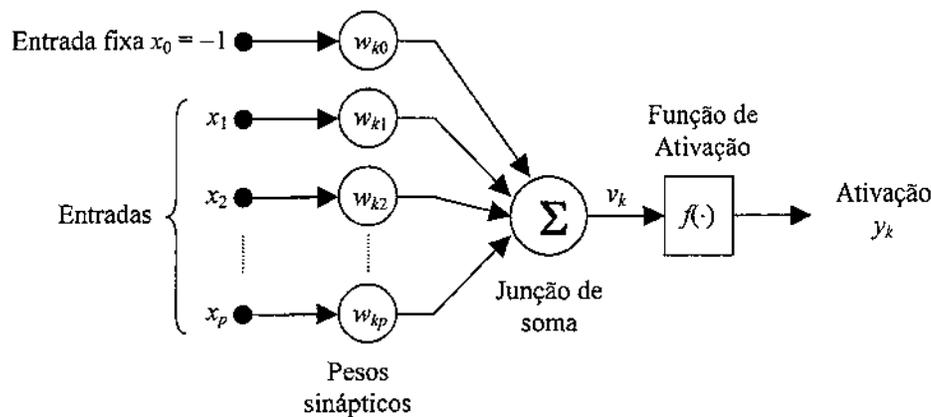


Figura 3.1: Modelo do Neurônio Artificial.

Pode-se descrever o modelo de neurônio ilustrado na Figura 3.1 pelo seguinte par de equações:

$$v_k = \sum_{j=0}^p w_{kj} x_j \quad (3.1)$$

e

$$y_k = f(v_k) \quad (3.2)$$

em que x_0, x_1, \dots, x_p são os sinais de entrada, $w_{k0}, w_{k1}, \dots, w_{kp}$ são os pesos sinápticos do neurônio k , v_k é o nível de ativação interna ou potencial de ativação do neurônio k , $f(\cdot)$ é a função de ativação e y_k é a ativação de saída do neurônio k .

Observe na Figura 3.1 a presença de uma entrada de polarização fixa $x_0 = -1$. Esta entrada, juntamente com o peso w_{k0} , tem o efeito de transladar a função de ativação em torno da origem (transformação afim), fazendo com que a ativação interna v_k do neurônio não seja nula quando todas as demais entradas $\{x_1, x_2, \dots, x_p\}$ forem nulas. Pode-se observar mais claramente este efeito de polarização reescrevendo a Equação (3.2) como:

$$y_k = f\left(\sum_{j=1}^p w_{kj}x_j - w_{k0}\right) \quad (3.3)$$

A entrada de polarização x_0 poderia assumir qualquer outro valor fixo diferente de zero. Alguns autores fazem uma distinção entre os termos polarização (quando a entrada fixa assume o valor $x_0 = +1$) e limiar (quando $x_0 = -1$). Neste trabalho usou-se sempre o termo polarização.

3.1.1 Tipos de Função de Ativação

A função de ativação $f(\cdot)$ é responsável por definir a ativação de saída do neurônio em termos do seu nível de ativação interna. Pode-se identificar três classes principais de função de ativação:

1. Função Sinal. Para este tipo de função, ilustrada na Figura 3.2(a), tem-se:

$$f(v) = \begin{cases} 1 & \text{se } v > 0 \\ 0 & \text{se } v \leq 0 \end{cases} \quad (3.4)$$

Assim, a ativação de um neurônio k que usa este tipo de função de ativação é dada por:

$$y_k = \begin{cases} 1 & \text{se } v_k > 0 \\ 0 & \text{se } v_k \leq 0 \end{cases} \quad (3.5)$$

em que v_k é o nível de ativação interno do neurônio, definido na Equação (3.1). Um neurônio com esta função de ativação é conhecido como *modelo de McCulloch-Pitts*, em homenagem ao trabalho pioneiro de (MCCULLOCH e PITTS, 1943).

2. Função Linear por Partes. Para a função linear por partes, ilustrada na Figura 3.2(b), tem-se:

$$f(v) = \begin{cases} 0, & \text{se } v \leq -a \\ v + a, & \text{se } -a < v < a \\ 2a, & \text{se } v \geq a \end{cases} \quad (3.6)$$

No limite, quando a tende a zero, esta função se aproxima assintoticamente da função sinal.

3. Função Sigmoidal. A função sigmoidal é a função de ativação mais empregada em redes neurais artificiais. Esta função é definida como uma função monotônica crescente que apresenta propriedades assintóticas e de suavidade. Um exemplo de função sigmoidal é a chamada função logística, definida por:

$$f(v) = \frac{1}{1 + e^{-av}}, \quad (3.7)$$

em que a é o parâmetro de inclinação da função sigmoideal. Variando o parâmetro a , pode-se obter funções sigmoideais com diferentes inclinações, como mostrado na Figura 3.2 (c). Aqui também, no limite, quando a tende a infinito, esta função se aproxima da função sinal.

Em muitas situações é desejável ter-se uma função sigmoideal que varie entre -1 e $+1$. Nestas situações, uma função comumente empregada é a tangente hiperbólica, definida por:

$$f(v) = \operatorname{tgh}\left(\frac{v}{2}\right) = \frac{1 - e^{-v}}{1 + e^{-v}}. \quad (3.8)$$

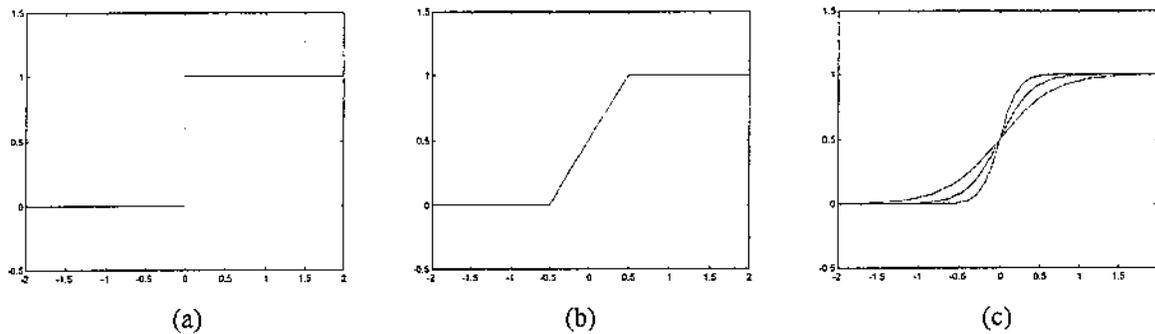


Figura 3.2: Funções de ativação: (a) função sinal, (b) função linear por partes ($a = 0.5$), (c) função sigmoideal.

3.2 Redes Neurais Multicamadas

As redes neurais multicamadas são arquiteturas onde os neurônios são organizados em duas ou mais camadas de processamento, já que sempre vai existir pelo menos uma camada de entrada e uma camada de saída. Estas arquiteturas são as mais frequentemente encontradas na literatura referente a redes neurais artificiais.

As redes neurais com apenas duas camadas são constituídas de uma camada de entrada que se conecta a uma camada de neurônios de saída. Os neurônios da camada de entrada são neurônios especiais, cujo papel é exclusivamente distribuir cada uma das entradas da rede (sem modificá-las) a todos os neurônios da camada seguinte. A forma mais simples deste tipo de rede neural, consiste de um

único neurônio na camada de saída, sendo conhecido como *perceptron*. A Figura 3.1 é um exemplo de um perceptron, com p neurônios na camada de entrada e um único neurônio na camada de saída, de acordo com a notação adotada nesta seção. O perceptron foi objeto de intensa pesquisa durante os anos 50 e 60, mas em 1969, M. Minsky e S. Papert provaram matematicamente que este tipo de estrutura de processamento apresenta limitações importantes e podem ser aplicadas com sucesso a uma classe muito restrita de problemas (MINSKY e PAPERT, 1988). Mais especificamente foi provado que o perceptron é capaz de resolver apenas problemas linearmente separáveis.

Um exemplo de rede neural com apenas duas camadas é apresentado na Figura 3.3(a), com 3 neurônios na camada de entrada e 4 neurônios na camada de saída.

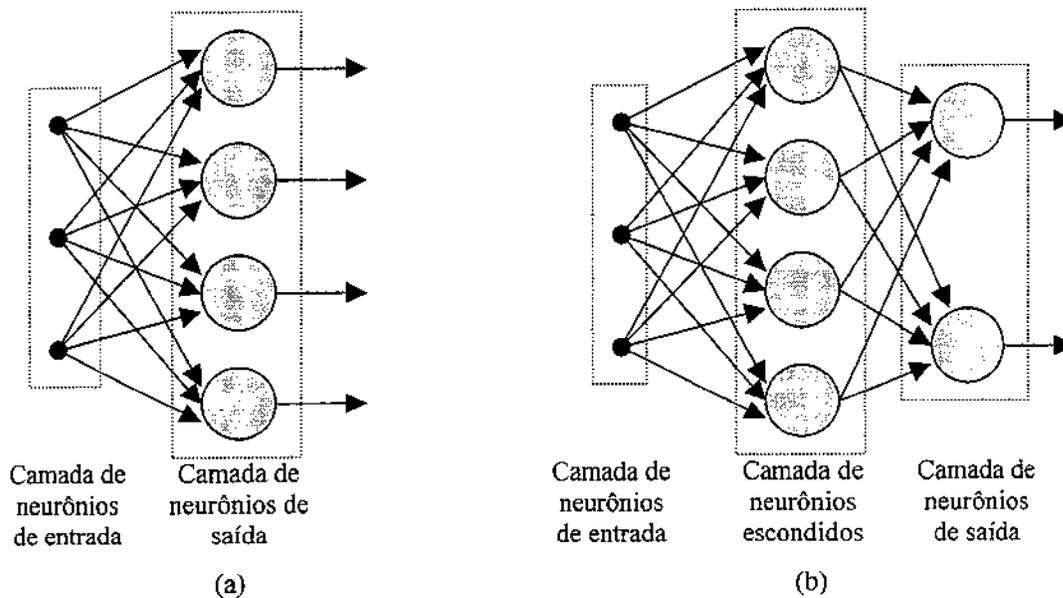


Figura 3.3: Redes neurais em camadas: (a) rede com apenas duas camadas de neurônios, (b) rede com uma camada de entradas, uma camada escondida e uma camada de saída.

No entanto, com a utilização de redes de múltiplas camadas com pelo menos uma camada escondida (camada que não é nem entrada, nem saída), ou *perceptron* multicamadas (MLP – *multilayer perceptron*), muitas das limitações apresentadas pelo perceptron deixam de existir. Na Figura 3.3(b) apresenta-se uma rede neural com uma camada escondida. Por simplicidade, esta arquitetura é referida como uma rede 3-4-2, isto é, 3 neurônios de entrada, 4 neurônios escondidos e 2 neurônios de saída. Como outro exemplo, uma rede neural com p entradas, h_1 neurônios na primeira camada escondida, h_2 na segunda camada escondida e q neurônios na camada de saída é dita ser uma rede $p-h_1-h_2-q$.

3.3 Aprendizado Supervisionado

A mais importante propriedade de uma rede neural artificial é sua capacidade de aprendizado. Uma rede neural aprende através de um processo iterativo de ajustes aplicados aos seus pesos sinápticos e limiares, o qual pode ser expresso na forma de um algoritmo computacional.

Não existe uma definição precisa universalmente aceita de “aprendizado”. No contexto de redes neurais artificiais, (HAYKIN, 1999) define aprendizado da seguinte forma: “Aprendizado é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estímulo pelo ambiente no qual a rede está inserida”. Assim, um processo de aprendizagem de uma rede neural implica na seguinte seqüência de eventos:

1. a rede neural é estimulada pelo ambiente de informação;
2. a estrutura interna da rede é alterada como resultado do estímulo;
3. devido às alterações que ocorreram em sua estrutura interna, a rede tem modificada sua resposta aos estímulos do ambiente.

Um tipo particular de aprendizado será de especial interesse para este trabalho: o aprendizado supervisionado. Este tipo de aprendizado é caracterizado pela presença de um “professor” externo. A função do “professor” durante o processo de aprendizado é suprir a rede neural com uma resposta desejada a um determinado estímulo apresentado pelo ambiente. Defini-se um sinal de erro como a diferença entre resposta desejada e a resposta observada na saída da rede neural. Os parâmetros da rede são então ajustados de acordo com o sinal de erro.

Uma forma de implementar uma estratégia de aprendizado supervisionado em redes neurais é através de procedimentos iterativos de correção de erro. Seja $s_j(n)$ a resposta desejada para um neurônio j no instante n e seja $y_j(n)$ a resposta observada para este neurônio. A resposta $y_j(n)$ é produzida por um estímulo (vetor) $\mathbf{x}(n) = (x_1(n), \dots, x_h)$ aplicado à entrada da rede da qual o neurônio j faz parte. O sinal de erro para o neurônio j é definido como a diferença entre a resposta desejada e a resposta observada:

$$e_j(n) = s_j(n) - y_j(n) \quad (3.9)$$

O objetivo do procedimento de aprendizado por correção de erro é minimizar uma função de custo baseada no sinal de erro $e_j(n)$, de modo que a resposta observada de cada neurônio da rede se

aproxime da resposta desejada para aquele neurônio, em algum sentido estatístico. De fato, uma vez definida uma função de custo, o problema de aprendizado torna-se um problema de otimização.

Uma função de custo comumente empregada é a soma dos erros quadráticos:

$$J = \frac{1}{2} \sum_j e_j^2(n) \quad (3.10)$$

em que o somatório é realizado sobre todos os neurônios da camada de saída da rede neural. A rede neural aprende através da minimização de J em relação aos pesos sinápticos da rede.

Note que J define uma superfície de erro sobre o espaço dos pesos. Se P é o número de pesos ajustáveis da rede neural, então $J: \mathcal{R}^P \rightarrow \mathcal{R}$. A superfície de erro é caracterizada pela presença de mínimos locais e um ou mais mínimos globais. Os métodos de otimização utilizados na minimização de J usualmente recorrem à informação de gradiente do erro para ajustar os parâmetros da rede. Teoricamente, estes métodos sempre atingem um ponto de mínimo da superfície de erro, mas observe que nada se pode afirmar sobre a natureza (local ou global) do ponto de mínimo obtido a partir de uma condição inicial arbitrária.

3.4 O Algoritmo de Retropropagação (*Backpropagation*)

O algoritmo de retropropagação de erro, ou simplesmente retropropagação, é um algoritmo utilizado no treinamento de redes neurais multicamadas com uma ou mais camadas escondidas. Basicamente, o algoritmo de retropropagação consiste em dois passos: o processamento direto e o processamento reverso. No processamento direto, uma entrada é aplicada à rede neural e seu efeito é propagado pela rede, camada a camada. Durante o processamento direto, os pesos da rede permanecem fixos. No processamento reverso, um sinal de erro calculado na saída da rede é propagado no sentido reverso, camada a camada, e ao final deste processo os pesos são ajustados de acordo com uma regra de correção de erro. O treinamento de uma rede através de retropropagação é realizado de forma supervisionada, ou seja, é apresentada à rede uma determinada entrada (exemplo) e também é disponibilizada a resposta desejada para aquela entrada. A seguir, apresenta-se em detalhes o algoritmo de retropropagação.

O sinal de erro na saída do neurônio j na iteração n (isto é, apresentação do n -ésimo padrão de treinamento) é definido por:

$$e_j(n) = s_j(n) - y_j(n) \quad (3.11)$$

em que $s_j(n)$ é a resposta desejada para o neurônio j da camada de saída. O valor instantâneo do erro quadrático para o neurônio j é definido por $\frac{1}{2}e_j^2(n)$. A soma dos erros quadráticos instantânea da rede é definida por:

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.12)$$

em que C é o conjunto que contém todos os neurônios da camada de saída da rede. Seja N o número total de padrões de treinamento contido no conjunto de treinamento. O erro quadrático médio é definido por:

$$\varepsilon_{av} = \frac{1}{N} \sum_{n=1}^N \varepsilon(n) \quad (3.13)$$

Observe que a soma dos erros quadráticos instantâneos, e, portanto o erro quadrático médio, é uma função de todos os pesos sinápticos da rede, pois estes definem a função de transferência ou mapeamento de entrada-saída da rede neural. Para um dado conjunto de treinamento, ε_{av} representa uma *função de custo*, isto é, uma medida de desempenho da rede neural. O objetivo do processo de treinamento é justamente minimizar ε_{av} .

Inicialmente, considera-se um método de treinamento em que os pesos são ajustados padrão-a-padrão. Os pesos da rede são ajustados de acordo com o erro computado para cada padrão apresentado à rede.

A Figura 3.4 mostra o neurônio de saída j , alimentado pelas ativações de todos os neurônios da camada imediatamente anterior. O nível de ativação interno do neurônio j é dado por:

$$v_j(n) = \sum_{i=0}^p w_{ji}(n) y_i(n) \quad (3.14)$$

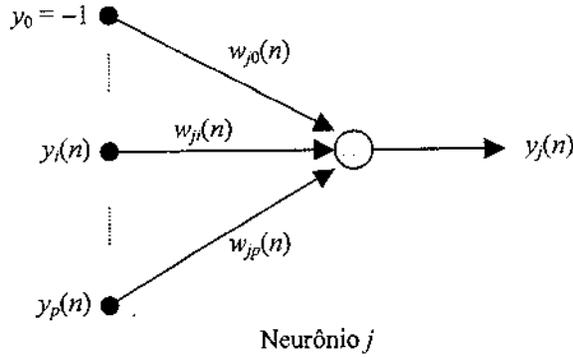


Figura 3.4: Neurônio de saída j , cujas entradas são as ativações de todos os neurônios da camada imediatamente anterior.

em que p é o número total de entradas (excluindo a polarização) aplicadas ao neurônio j , ou seja, o número de neurônios da camada imediatamente anterior. Portanto, a ativação $y_j(n)$ do neurônio j é dada por:

$$y_j(n) = f_j(v_j(n)) \quad (3.15)$$

Para minimizar o erro quadrático médio, necessita-se primeiramente determinar o gradiente instantâneo $\partial \varepsilon(n) / \partial w_{ji}(n)$. Aplicando a regra da cadeia, pode-se expressar este gradiente como:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (3.16)$$

Derivando a Equação (3.12) em relação a $e_j(n)$:

$$\frac{\partial \varepsilon(n)}{\partial e_j(n)} = e_j(n) \quad (3.17)$$

Derivando a Equação (3.11) em relação a $y_j(n)$:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (3.18)$$

Derivando a Equação (3.15) em relação a $v_j(n)$:

$$\frac{\partial y_j(n)}{\partial v_j(n)} = f'_j(v_j(n)) \quad (3.19)$$

em que o símbolo ' significa derivação em relação ao argumento. Finalmente, derivando a Equação (3.14) em relação a $w_{ji}(n)$ obtém-se:

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (3.20)$$

Substituindo as Equações (3.17) a (3.20) na Equação (3.16):

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -e_j(n) f'_j(v_j(n)) y_i(n) \quad (3.21)$$

que é a equação da derivada do erro instantâneo $\varepsilon(n)$ em relação ao peso sináptico $w_{ji}(n)$ do neurônio j da camada de saída. Observe que a Equação (3.21) corresponde a um componente do vetor gradiente do erro, cujos elementos representam a derivada parcial de $\varepsilon(n)$ em relação a todos os pesos da rede neural, arranjados em uma ordem fixa, mas arbitrária. Definindo o gradiente local $\delta_j(n)$ como:

$$\delta_j(n) = -\frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) f'_j(v_j(n)) \quad (3.22)$$

pode-se reescrever (3.21) na forma:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -\delta_j(n) y_i(n) \quad (3.23)$$

Para minimizar o erro, aplica-se aos pesos uma correção proporcional ao oposto do gradiente do erro, pois se caminha no espaço de pesos na direção oposta ao do gradiente. Matematicamente, pode-se expressar esta regra de ajuste na forma:

$$w_{ji}(n+1) = w_{ji}(n) - \eta(n) \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (3.24)$$

em que $\eta(n)$ é o tamanho do passo no algoritmo na iteração n . Note que, no algoritmo de retropropagação original, proposto por (RUMELHART et al., 1986), é utilizado um passo constante durante todas as iterações do algoritmo, passo este conhecido como taxa de aprendizagem.

A taxa de aprendizagem η é uma constante de proporcionalidade, que assume valores no intervalo (0,1), e que determina a natureza de adaptação dos pesos.

Um alto valor de η produzirá uma rápida aprendizagem, resultando em grandes alterações nos pesos. Entretanto, aumentará o risco da rede tornar-se instável, podendo oscilar ao redor da solução e provocar a saturação dos neurônios.

Por outro lado, se a taxa de aprendizagem assumir valores pequenos, as mudanças nos pesos sinápticos serão menores de uma iteração para outra e as trajetórias no espaço definido pelos pesos serão mais suaves. Este benefício é alcançado com um alto custo no processo de treinamento, pois este torna-se lento por requerer muito mais iterações até a convergência (NG, 1997).

Um método simples pra aumentar a velocidade de aprendizagem é modificar a Regra Delta, adicionando um termo *momentum*, como proposto por (RUMELHART et al., 1986):

$$w_{ji}(n+1) = \alpha w_{ji}(n-1) - \eta(n) \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (3.25)$$

O termo *momentum* relaciona as alterações dos pesos sinápticos na iteração n com as alterações realizadas na iteração $(n-1)$. A utilização desta constante dificulta a mudança de tendência na atualização dos pesos, podendo ainda ser usada pra reduzir a possibilidade de ocorrer mínimos locais.

3.5 Síntese do Capítulo

Neste capítulo, apresentou-se uma introdução às redes neurais multicamadas. Os principais pontos abordados foram o modelo do neurônio artificial, os tipos de funções de ativação, o aprendizado supervisionado e a formulação matemática do algoritmo de retropropagação. Os tópicos apresentados serão importantes no próximo capítulo, que trata da previsão de vazões vários passos à frente utilizando as redes neurais multicamadas.

Capítulo 4

Previsão de Vazões Vários Passos à Frente

A geração de energia elétrica no Brasil depende basicamente das vazões que naturalmente transitam nos sistemas de canais fluviais das bacias onde se encontram instalados aproveitamentos hidrelétricos. O processo natural de vazões fluviais tem como característica principal a sua inconstância, dependente da ocorrência de precipitações, fenômeno sabidamente intermitente e de comportamento sazonal ditado pelo clima e de irregularidade dos totais precipitados através dos anos, podendo ocorrer desvios significativos dos totais anuais precipitados normais, configurando-se anos “secos” ou “úmidos”. A região sudeste brasileira está particularmente sujeita a esta inconstância.

Com o processo de privatização do setor de geração de energia elétrica, através do Plano Nacional de Desestatização de 1990, a previsão de afluências a reservatórios tornou-se um diferencial competitivo. Desta forma, as previsões vários passos à frente são de suma importância para o planejamento da operação energética.

(ATIYA et al., 1999) aplicaram redes neurais para previsão de vazões e compararam quatro técnicas para pré-processamento das entradas e saídas incluindo o problema de previsão vários passos à frente. Dois métodos de previsão foram propostos: um chamado de direto e outro de recursivo. No Método Direto a rede neural foi treinada para prever o p -ésimo passo à frente, ou seja, a saída da rede será $y(t+p)$. No Método Recursivo a rede é treinada para prever um passo à frente, e este modelo, é aplicado para prever até p passos à frente. Neste caso, em algum passo intermediário a rede usará alguma das previsões calculadas nos passos anteriores como entrada. Os resultados mostraram que o Método Direto apresentou um desempenho semelhante ao Método Recursivo.

Neste capítulo, será analisado o desempenho do modelo de rede neural multicamadas, para previsão de vazões vários passos à frente, usando o Método Direto proposto em (ATIYA et al., 1999).

Uma outra forma de previsão vários passos à frente proposta neste trabalho é o Método Agregado. Neste método, o valor a ser previsto corresponde a soma das vazões em um determinado

horizonte de previsão. Neste caso, para se obter a previsão das vazões mensais é necessário usar um método de desagregação.

4.1 Estrutura da Rede Neural Multicamadas

A rede neural não-recorrente, usada para previsão nos Métodos Direto e Agregado, foi composta por uma camada intermediária com número de neurônios variando de 1 a 20, taxa de aprendizagem variando de 0,1 a 0,9 e o termo *momentum* variando de 0,1 a 0,9. O número de iterações é igual a 1000 e o número de entradas variando de 1 a 6. Para os dois métodos de previsão, foram ajustados modelos mensais.

O desempenho dos Métodos Direto e Agregado foi analisado segundo os critérios: raiz do erro quadrático médio (REQM), erro absoluto médio (EAM), erros relativo percentual médio (EPM) e relativo percentual máximo (EP_{\max}), definidos como:

$$REQM = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (\%) \quad (4.1)$$

$$EAM = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (m^3/s) \quad (4.2)$$

$$EPM = \frac{100}{n} \sum_{j=1}^n \frac{|y_j - \hat{y}_j|}{y_j} \quad (m^3/s) \quad (4.3)$$

$$EP_{\max} = \max \left\{ 100 \left| \frac{y_j - \hat{y}_j}{y_j} \right| \right\} \quad (\%) \quad (4.4)$$

em que n é o número de padrões no conjunto de teste, y_j é o valor real e \hat{y}_j é o valor previsto.

Uma outra importante medida de desempenho de previsão é o coeficiente de correlação (ρ):

$$\rho = \frac{\sum_{j=1}^n (y_j - \bar{y})(\hat{y}_j - \bar{\hat{y}})}{\sqrt{\sum_{j=1}^n (y_j - \bar{y})^2 (\hat{y}_j - \bar{\hat{y}})^2}} \quad (4.5)$$

O coeficiente de correlação mede como as vazões previstas se correlacionam com as vazões observadas. Certamente, o valor do coeficiente de correlação mais próximo da unidade significa melhor previsão. Em (4.5), \bar{y} e $\bar{\hat{y}}$ são as medidas das vazões médias observadas e previstas, respectivamente.

A seguir, são apresentadas as duas metodologias empregadas para realizar a previsão de vazões afluentes: Método Direto e Método Agregado.

4.2 Método Direto

Como proposto por (ATIYA et al., 1999), analisou-se o desempenho do Método Direto para previsão de vazão para o p -ésimo passo à frente. Neste método, o vetor de entradas inclui apenas valores reais para prever o p -ésimo passo à frente (Figura 4.1). Deve-se observar que, neste método de previsão, pode existir um intervalo entre o dado de entrada e o mês a ser previsto, dependendo do passo a ser previsto.

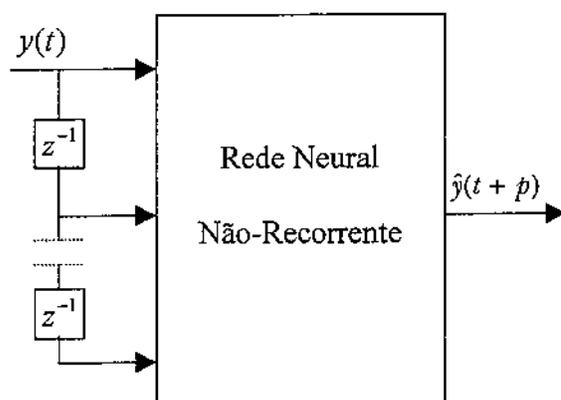


Figura 4.1: Representação do Método Direto de previsão para o p -ésimo passo à frente (z^{-1} representa os atrasos no tempo).

Assim, neste método o valor previsto é diretamente dado na saída da rede. Por exemplo, para prever as vazões afluentes do mês de Janeiro um passo à frente utiliza-se como dado de entrada as vazões afluentes observadas do mês de Dezembro. Já para a previsão dois passos à frente das vazões afluentes do mês de Janeiro, utiliza-se as vazões afluentes observadas do mês de Novembro como entrada no modelo. Este mesmo raciocínio é seguido para a previsão dos demais passos. Analisou-se o desempenho de previsão um passo à frente até o desempenho de se prever doze passos à frente.

4.3 Método Agregado

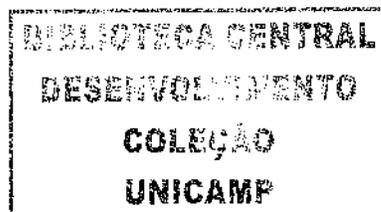
Assim como no Método Direto, no Método Agregado de previsão vários passos à frente foi considerado um horizonte de até 12 passos à frente. O ano hidrológico foi considerado iniciando-se no mês de Maio, seguindo até o último mês úmido, Abril. O mês de Abril foi escolhido como referência,

pois o reservatório tem seu volume máximo atingido quase todos os anos ao final do mês de Abril, o que significa que a previsão global se decompõe em previsões individuais para cada ano do horizonte. Em (MARTINEZ, 2001), verifica-se que este critério heurístico tem como base a análise de comportamento da solução ótima determinística sob dados históricos de vazão afluente.

As vazões afluentes agregadas foram previstas de acordo com os passos à frente. Por exemplo, para prever a vazão do mês de Abril um passo à frente foram desenvolvidos 12 modelos, variando o dado de entrada na rede. Este valor de entrada foi desde o dado de vazão do mês imediatamente anterior, no caso a vazão do mês de Março, como também a soma das vazões de até 12 meses imediatamente anteriores. Assim, para realizar as previsões do mês de Abril, foram ajustadas as 12 redes, com as seguintes entradas:

- 1) a vazão do mês de Março;
- 2) o somatório das vazões dos meses de Fevereiro até Março;
- 3) o somatório das vazões dos meses de Janeiro até Março;
- 4) o somatório das vazões dos meses de Dezembro até Março;
- 5) o somatório das vazões dos meses de Novembro até Março;
- 6) o somatório das vazões dos meses de Outubro até Março;
- 7) o somatório das vazões dos meses de Setembro até Março;
- 8) o somatório das vazões dos meses de Agosto até Março;
- 9) o somatório das vazões dos meses de Julho até Março;
- 10) o somatório das vazões dos meses de Junho até Março;
- 11) o somatório das vazões dos meses de Maio até Março; e,
- 12) o somatório das vazões dos meses de Abril até Março;

Para a previsão de vazões com dois passos à frente, a saída da rede foi o somatório das vazões a serem previstas dos meses de Março e Abril. Considerou-se como entrada da rede um total de 12 entradas correspondente aos 12 meses imediatamente anteriores ao mês de horizonte ou ao montante total a ser previsto. O mesmo raciocínio feito para a previsão de vazões até 12 passos à frente, utilizando-se como saída da rede o somatório das vazões dos meses de Maio até Abril, que corresponde ao ano hidrológico, e como entrada da rede um total de 12 entradas correspondente aos 12 meses imediatamente anteriores ao mês de horizonte a ser previsto.



Os modelos para previsão de vazões afluentes agregadas foram desenvolvidos para 12 passos à frente, tendo um conjunto de 12 tipos de entradas para cada passo à frente, e utilizando até 6 entradas imediatamente anteriores para cada entrada. Essa combinação de entradas teve como objetivo encontrar a melhor combinação de vazões agregadas, ou seja, a melhor entrada para cada passo à frente.

Considerando a série histórica de vazões afluentes médias mensais como sendo representada por um vetor de valores mensais $y_t, t = 1, \dots, N$, sendo N o número de dados do histórico de vazão. Matematicamente, as vazões agregadas podem ser representadas da seguinte forma:

$$v_{i,p} = \sum_{j=1}^h y_{i-j} \quad (4.6)$$

em que:

i : o mês a ser previsto, sendo $i = 24, \dots, N$;

p : os passos à frente, sendo $p = 1, \dots, 12$;

h : o horizonte a ser atingido, sendo $h = 1, \dots, 12$;

y_{i-j} : o valor real observado; e,

$v_{i,p}$: volume no p -ésimo passo à frente.

Selecionou-se 12 (doze) entradas para cada passo à frente, tendo início sempre um mês anterior ao valor previsto, e o valor inicial para $i = 24$ se justifica devido a análise quando utilizou-se 12 passos à frente com a décima segunda entrada, logo precisou-se de 24 meses anteriores: sendo 12 valores da agregação de vazões de Maio até Abril e os outros 12 valores correspondentes a entrada do somatório das vazões dos meses de Maio até Abril do momento anterior.

A partir da previsão agregada é necessário obter a desagregação dos valores, de vazões mensais. Neste trabalho, usou-se uma proposta de desagregação de vazões, que consiste na abordagem da Média de Longo Termo (MLT). A previsão de vazões foi desagregada para os 12 passos à frente utilizando-se os valores proporcionais à MLT para determinar o fator de participação mensal no valor previsto global.

A seguir, apresenta-se um esquema representativo das comparações dos métodos utilizados.

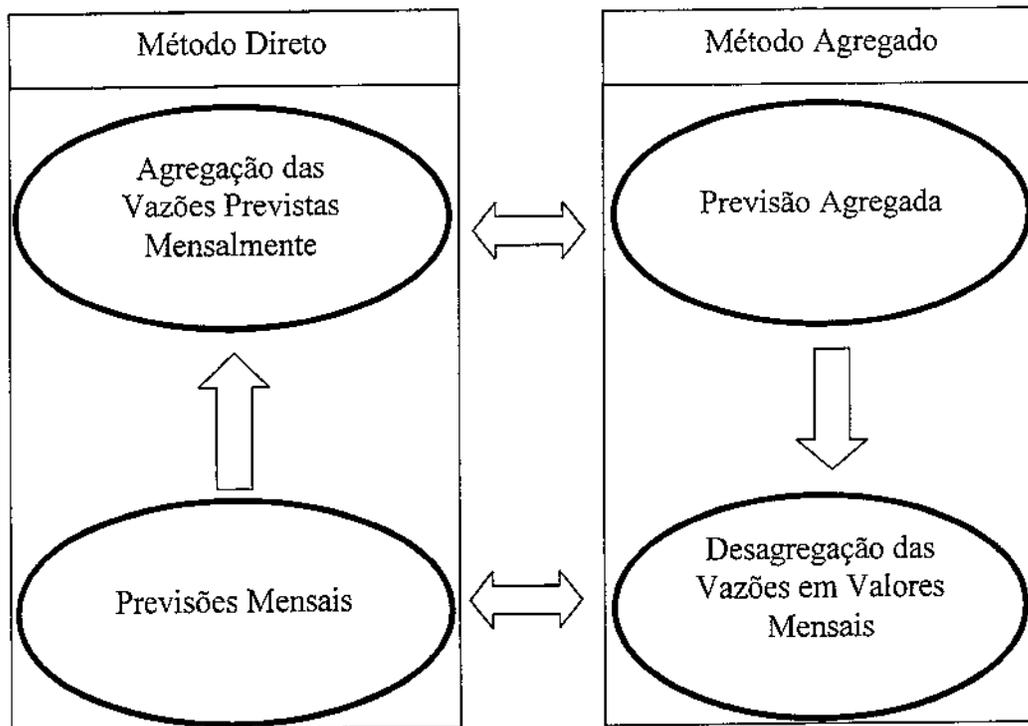


Figura 4.2: Comparação dos Métodos Utilizados.

Observa-se na Figura 4.2 que se realiza a previsão agregada pelo Método Agregado e depois é desagregada em valores mensais, e as vazões previstas mensalmente pelo Método Direto são agregadas para comparação com o Método Agregado. Logo, existe a comparação entre as previsões de valores individuais, assim como a comparação entre as previsões de valores agregados.

4.4 Estudo de Caso

Os modelos de previsão foram ajustados para os dados de vazões afluentes médias mensais referente ao posto hidrológico da usina hidrelétrica de Furnas, que está localizada no curso médio do Rio Grande, no trecho denominado "Corredeiras das Furnas", entre os municípios de São José da Barra (MG) e São João Batista do Glória (MG), pertencente à empresa FURNAS – Centrais Elétricas S.A.

Utilizou-se para todas as abordagens uma série histórica de 71 anos (1931 a 2001), como é mostrado na Figura 4.3. Os modelos foram ajustados para o período de 1931 a 1971, ou seja, para o ajuste dos parâmetros da rede neural utilizou-se 41 anos. Para avaliar o desempenho dos modelos foi escolhido o período de maio de 1971 a abril de 2001, ou seja, foram considerados 360 meses (30 anos) para a fase de validação dos modelos. Ajustou-se um modelo para cada mês para o Método Direto.

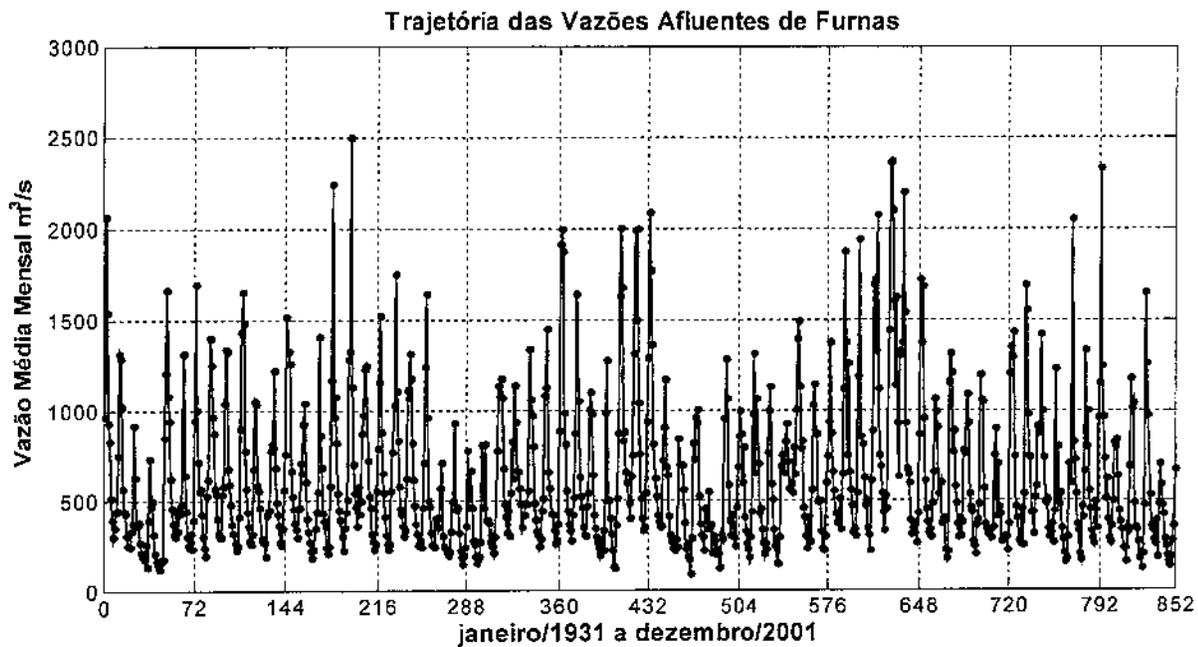


Figura 4.3: Série Histórica de Vazões Afluentes de Furnas.

Na Figura 4.4, apresenta-se a média e o desvio padrão mensais da série histórica das vazões afluentes do posto hidrológico de Furnas. Verifica-se uma das grandes dificuldades na previsão das séries de vazões, que é a presença da sazonalidade devido aos períodos de cheia e seca do ano.

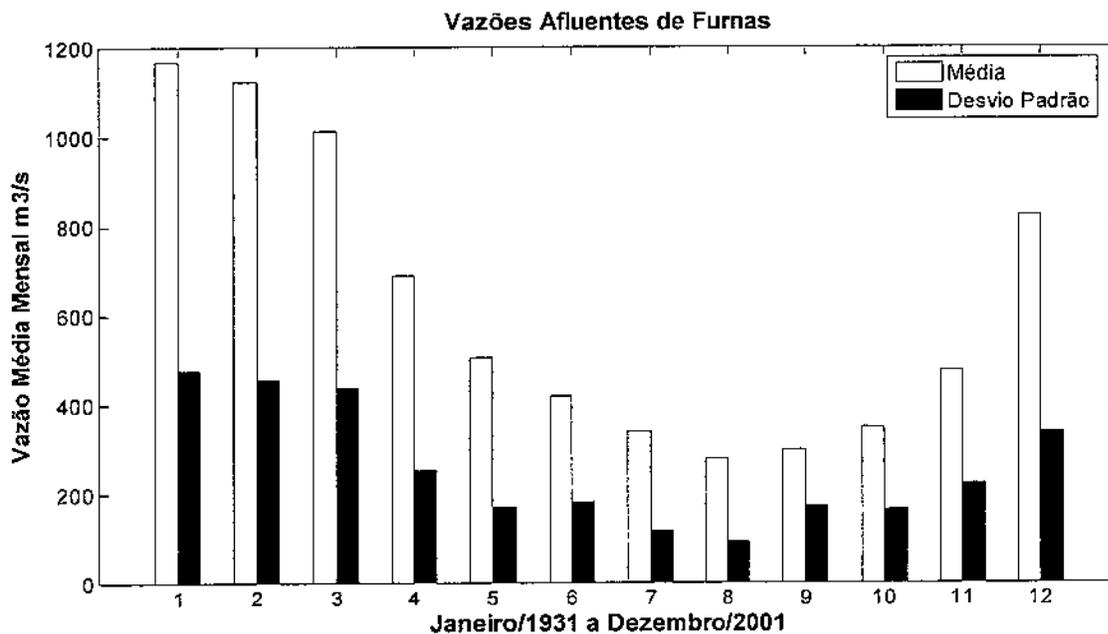


Figura 4.4: Estatísticas da Série Histórica de Vazões Afluentes de Furnas.

A seguir, apresentam-se os resultados da previsão de vazões pelo Método Direto.

4.4.1 Resultados do Método Direto

A seguir, na Tabela 4.1 é apresentado os resultados da busca exaustiva dos menores erros, que foram realizados envolvendo quatro parâmetros: taxa de aprendizado (η), termo *momentum* (α), neurônios na camada intermediária (Ne) e número de entradas (E).

Na Tabela 4.1 são apresentados apenas os parâmetros referentes aos modelos utilizados para a previsão. Ou seja, para a previsão um passo à frente só existiu a necessidade de colocar os resultados do mês de Abril, para dois passos à frente para os meses de Março e Abril, e assim sucessivamente, até doze passos à frente quando se completa o ano hidrológico, que é de Maio até Abril. Todo este procedimento foi requerido devido a comparação posterior com os resultados das previsões desagregadas pelo Método Agregado.

Tabela 4.1: Parâmetros do Método Direto.

Passos à Frente/Parâmetros																									
		01				02				03				04				05				06			
		η	α	Ne	E																				
nov																						0,90	0,90	5	5
dez																		0,10	0,70	20	3	0,10	0,90	13	6
jan										0,10	0,90	18	3	0,10	0,90	19	5	0,50	0,10	19	4				
fev										0,10	0,10	1	2	0,70	0,90	1	6	0,50	0,90	15	5	0,70	0,90	1	4
mar						0,90	0,90	16	2	0,90	0,90	1	1	0,90	0,90	7	1	0,70	0,90	1	1	0,90	0,90	1	1
abr		0,30	0,90	18	5	0,30	0,90	19	5	0,70	0,90	20	6	0,10	0,90	16	2	0,90	0,90	16	5	0,90	0,30	15	6

Nota-se na Tabela 4.1 que, cada passo à frente e cada mês do ano hidrológico apresenta os parâmetros da rede neural MLP. Por exemplo, para o primeiro passo à frente, previsão do mês de Abril, o melhor resultado foi obtido para 5 entradas utilizando o mês de Março como entrada na rede, com 18 neurônios na camada intermediária, taxa de aprendizado igual a 0,30 e termo *momentum* igual a 0,90. a seguir, apresentam-se os resultados dos demais passos à frente.

Tabela 4.1: Parâmetros do Método Direto (continuação).

Passos à Frente/Parâmetros																								
07				08				09				10				11				12				
η	α	Ne	E	η	α	Ne	E	η	α	Ne	E	η	α	Ne	E	η	α	Ne	E	η	α	Ne	E	
mai																				0,90	0,50	20	2	
jun																0,10	0,90	11	3	0,90	0,90	19	2	
jul												0,90	0,30	19	3	0,30	0,10	17	3	0,50	0,90	7	3	
ago								0,90	0,70	20	2	0,70	0,70	16	6	0,10	0,30	17	6	0,70	0,50	15	4	
set				0,30	0,90	1	5	0,90	0,10	20	6	0,90	0,90	19	4	0,50	0,30	18	4	0,70	0,10	5	2	
out	0,90	0,70	14	3	0,50	0,90	8	1	0,90	0,70	7	6	0,90	0,90	6	3	0,30	0,90	4	6	0,10	0,90	16	6
nov	0,70	0,70	15	4	0,70	0,70	12	5	0,70	0,50	15	6	0,90	0,90	17	6	0,90	0,90	11	1	0,70	0,90	2	1
dez	0,10	0,30	18	6	0,70	0,70	19	6	0,10	0,50	17	5	0,30	0,50	12	3	0,10	0,70	18	4	0,30	0,90	10	1
jan	0,10	0,70	17	4	0,10	0,90	1	6	0,10	0,90	11	5	0,10	0,90	16	4	0,30	0,90	3	3	0,30	0,90	1	2
fev	0,70	0,90	4	3	0,70	0,90	20	4	0,70	0,90	18	2	0,90	0,90	3	1	0,90	0,90	1	1	0,10	0,90	15	5
mar	0,90	0,90	1	3	0,90	0,90	14	6	0,90	0,90	4	1	0,90	0,10	20	5	0,90	0,90	1	1	0,70	0,10	19	5
abr	0,90	0,90	19	4	0,90	0,90	19	3	0,50	0,90	5	4	0,90	0,50	17	3	0,90	0,50	19	2	0,10	0,90	19	5

Na Tabela 4.2, apresenta-se os resultados dos erros de previsão de vazões até 12 passos à frente. Esses erros foram obtidos da seguinte forma: para um passo à frente os erros equivalem às previsões de vazões para o mês de Abril, para dois passos à frente os erros são apresentados pela média dos erros das previsões de vazões de Março e Abril. Seguindo o mesmo raciocínio os erros para 12 passos à frente são dados pela média dos erros das previsões de vazões dos meses de Maio até Abril.

Tabela 4.2: Erros de Previsão do Método Direto.

Erros	Passos à Frente											
	1	2	3	4	5	6	7	8	9	10	11	12
EPM	19,41	29,45	29,31	26,51	27,50	30,25	30,06	30,55	27,85	25,94	24,52	21,62
EAM	153,74	252,41	265,71	277,44	286,49	282,10	247,66	241,96	211,46	193,78	176,21	153,39
REQM	229,07	342,32	379,44	397,78	412,98	405,84	367,36	369,38	330,93	312,96	280,39	253,32
EPmax	68,30	104,00	150,69	117,41	169,89	215,01	156,34	137,70	141,08	168,88	162,24	119,74
ρ	0,7328	0,6708	0,5429	0,5175	0,5599	0,5642	0,6869	0,6485	0,7511	0,7738	0,7755	0,7517

Observa-se que os erros apresentados na Tabela 4.2 seguem uma trajetória crescente e ligeiramente constante até o oitavo passo, depois decresce até o passo 12. Por exemplo, o erro

percentual relativo médio (EPM) que apresenta para o primeiro passo à frente o valor de 19,41% e conseqüentemente 29,45% para o segundo passo à frente, para o terceiro passo à frente o valor de 29,31%, seguindo-se até o resultado para oito passos à frente, o que mostra a trajetória crescente dos erros à medida que aumenta a quantidade de passos à frente. Em seguida, a trajetória se torna decrescente com o valor de 27,85 % no nono passo e segue até doze passos à frente com o valor de 21,62 %.

A seguir, apresentam-se os resultados da previsão de vazões pelo Método Agregado.

4.4.2 Resultados do Método Agregado

Assim como no Método Direto, os estudos para o Método Agregado foram desenvolvidos em busca dos menores erros e da melhor entrada, realizando com isso uma busca exaustiva envolvendo quatro parâmetros: taxa de aprendizado (η), termo *momentum* (α), neurônios na camada intermediária (N_e) e número de entradas (E).

Na Tabela 4.3, apresenta-se a melhor configuração dos parâmetros para o Método Agregado.

Tabela 4.3: Parâmetros do Método Agregado.

Parâmetros	Passos à Frente											
	1	2	3	4	5	6	7	8	9	10	11	12
η	0,25	0,80	0,10	0,85	0,40	0,55	0,10	0,55	0,55	0,40	0,55	0,25
α	0,85	0,90	0,55	0,10	0,90	0,85	0,85	0,85	0,85	0,85	0,85	0,85
N_e	16	15	1	9	1	1	2	1	1	1	1	1
E	5	1	6	6	1	3	3	4	3	4	3	6
Melhor Entrada	y_{mar}	y_{fev}	y_{jan}	$\sum_{abr}^{dez} y_j$	$\sum_{abr}^{nov} y_j$	$\sum_{abr}^{out} y_j$	$\sum_{mai}^{set} y_j$	$\sum_{mai}^{ago} y_j$	$\sum_{mai}^{jul} y_j$	$\sum_{fev}^{jun} y_j$	$\sum_{fev}^{mai} y_j$	$\sum_{jan}^{abr} y_j$

Verifica-se que, as previsões para 1 passo à frente o melhor desempenho foi obtido considerando 5 entradas imediatamente anteriores, utilizando-se como melhor entrada o mês de Março, ou seja, utilizou-se 5 valores do mês de Março referente aos anos anteriores. Para 2 passos à frente, usou-se 1 entrada imediatamente anterior e a melhor entrada foi a vazão do mês de Fevereiro. Para 3 passos à frente o melhor desempenho foi obtido considerando 6 entradas imediatamente anteriores,

utilizando-se como melhor entrada a vazão do mês de Janeiro. Seguindo-se até 12 passos à frente, quando a melhor entrada foi o somatório das vazões dos meses de Janeiro até Abril utilizando 6 entradas imediatamente anteriores. Nota-se também que para cada passo à frente se encontrou a melhor configuração de parâmetros visando os menores erros.

Os resultados dos erros para cada passo à frente através do Método Agregado para Furnas são apresentados na Tabela 4.4.

Tabela 4.4: Erros de Previsão do Método Agregado.

Erros	Passos à Frente											
	1	2	3	4	5	6	7	8	9	10	11	12
EPM	20,87	16,33	22,03	20,38	17,99	15,11	13,94	12,52	12,70	13,04	12,40	7,03
EAM	154,87	301,98	660,23	876,98	925,14	884,13	862,52	823,99	899,25	1010,40	1076,50	668,33
REQM	211,06	486,94	1004,00	1312,40	1388,10	1309,10	1316,70	1313,30	1385,50	1528,50	1697,60	1228,20
EPmax	67,83	65,68	100,37	99,20	79,23	56,67	57,22	48,33	45,55	41,99	38,13	36,40
ρ	0,7777	0,6576	0,2764	0,2856	0,4052	0,5755	0,6422	0,7189	0,7453	0,7889	0,8941	0,8742

Verifica-se que os erros apresentados na Tabela 4.4 possuem uma trajetória decrescente conforme ao decorrer dos passos à frente, fato observado devido a questão da agregação de vazões mensais pois, neste método as vazões mensais são agregadas para cada passo à frente, tendo início com as previsões de Abril até as previsões de vazões mensais agregadas de Maio até Abril. Comprova-se que quanto maior for o volume agregado de vazões menores serão os erros de previsão.

A seguir, apresentam-se os resultados da proposta de desagregação das vazões agregadas pelo Método Agregado e os resultados da agregação das vazões previstas mensalmente pelo Método Direto.

4.4.3 Resultados da Desagregação e Agregação

Para a desagregação de vazões afluentes previstas, utilizou-se a Média de Longo Termo (MLT) para os 12 passos à frente.

A Tabela 4.5 apresenta os erros caso fosse considerado como previsão a MLT.

Tabela 4.5: Erros de Previsão da MLT para Furnas.

Estudo de Caso	EPM (%)	EAM (m ³ /s)	REQM (m ³ /s)	EPmax (%)	ρ
Furnas	34,78	196,49	306,72	437,23	0,7142

Na Tabelas 4.6, apresenta-se os resultados da desagregação de vazões agregadas que foram previstas pelo Método Agregado.

Tabela 4.6: Erros de Previsão da Desagregação das Vazões Agregadas pelo Método Agregado.

Erros	Passos à Frente											
	1	2	3	4	5	6	7	8	9	10	11	12
EPM	20,87	21,89	26,42	27,42	29,28	32,54	33,14	33,05	31,32	29,61	28,86	24,53
EAM	154,87	195,14	256,86	284,09	280,81	276,60	257,39	238,09	219,17	200,28	190,59	152,77
REQM	211,06	283,08	383,91	409,01	395,99	383,63	366,56	346,55	327,08	310,47	302,33	231,15
EPmax	67,83	67,56	132,32	139,43	154,76	166,61	168,89	166,83	154,91	154,76	154,89	156,55
ρ	0,7777	0,6401	0,4356	0,4859	0,4498	0,5457	0,6314	0,6916	0,7304	0,7538	0,7642	0,8554

Nota-se que a desagregação das previsões desenvolvidas pelo Método Agregado apresentam os erros de previsão com tendência aos erros obtidos pela MLT, caso fossem consideradas as médias mensais do histórico de vazões como vazões previstas.

Na Tabela 4.7, apresenta-se os resultados dos erros da agregação das vazões afluentes previstas mensalmente pelo Método Direto.

Tabela 4.7: Erros de Previsão da Agregação das Vazões Previstas pelo Método Direto.

Erros	Passos à Frente											
	1	2	3	4	5	6	7	8	9	10	11	12
EPM	19,41	15,42	23,50	20,54	18,35	19,49	19,39	20,08	17,57	17,47	16,89	14,14
EAM	153,74	280,54	651,68	846,48	963,65	1141,20	1278,30	1393,10	1268,10	1344,30	1425,00	1252,30
REQM	229,07	421,50	844,13	1205,90	1377,20	1642,60	1867,00	1993,20	1832,00	2010,40	2267,70	2109,80
EPmax	68,30	43,69	57,08	100,88	69,28	61,25	52,23	50,54	46,06	48,78	54,07	50,33
ρ	0,7328	0,7447	0,4828	0,3730	0,6329	0,4683	0,6710	0,5157	0,8011	0,8452	0,7523	0,7929

Observa-se que os erros apresentados pela Tabela 4.7 demonstram uma trajetória decrescente conforme o horizonte de previsão aumenta, o que indica o fato da previsão de vazões mensais agregadas ser mais sensível aos maiores volumes do que a valores individuais e apresentarem menores erros em suas previsões.

A seguir, apresentam-se os comentários envolvendo a comparação entre as previsões de valores individuais, assim como a comparação entre as previsões de valores agregados.

4.5 Análise dos Resultados

Analisando as Tabelas 4.2 e 4.6 e realizando uma comparação entre os resultados dos erros de previsão de vazões vários passos à frente dos valores individuais, pode-se observar que o Método Direto apresenta desempenho mais estável, com erros menores na maioria dos casos que os erros gerados através da desagregação das previsões desenvolvidas pelo Método Agregado. Também se pode observar que dos erros de previsão com o Método Direto são menores que os erros obtidas com a MLT.

A Figura 4.5 ilustra aos erros relativos percentuais até 12 passos à frente para os métodos.

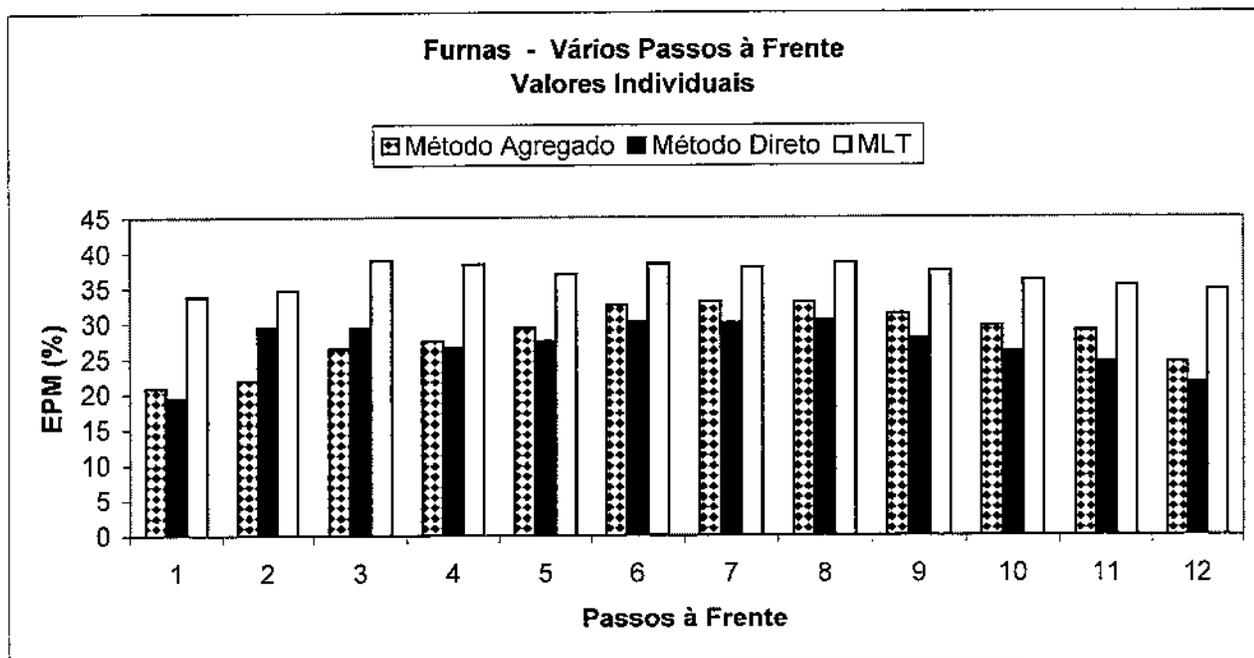


Figura 4.5: EPM para o Posto Hidrológico de Furnas pela Desagregação.

Observa-se na Figura 4.5, que os erros relativos percentuais apresentados pelo Método Direto são inferiores aos erros relativos percentuais resultantes da desagregação das vazões previstas pelo Método Agregado, o que comprova a eficiência do Método Direto quando comparado as previsões de valores individuais.

Analisando os resultados apresentados para o posto hidrológico de Furnas nas Tabelas 4.4 e 4.7, os erros para as previsões de vazões com 12 passos à frente, que representam as previsões realizadas com a agregação de vazões do ano hidrológico, de Maio até Abril, ou seja, os valores agregados, verifica-se que em todas as medidas de desempenho o Método Agregado obteve melhores resultados que o Método Direto. Este resultado vem de encontro ao interesse do setor elétrico, já que para este setor é melhor acertar o valor agregado de vazões do que os valores individuais, pois a previsão de vazões vários passos à frente é de grande importância no desempenho da política energética em malha aberta, devido a decisão obtida, turbinagem e vertimento do primeiro mês do horizonte de otimização depender do montante total de água prevista para chegar até o próximo mês de Abril.

A Figura 4.6 ilustra aos erros relativos percentuais das previsões de vazões mensais do posto hidrológico de Furnas até 12 passos à frente para os métodos em estudo.

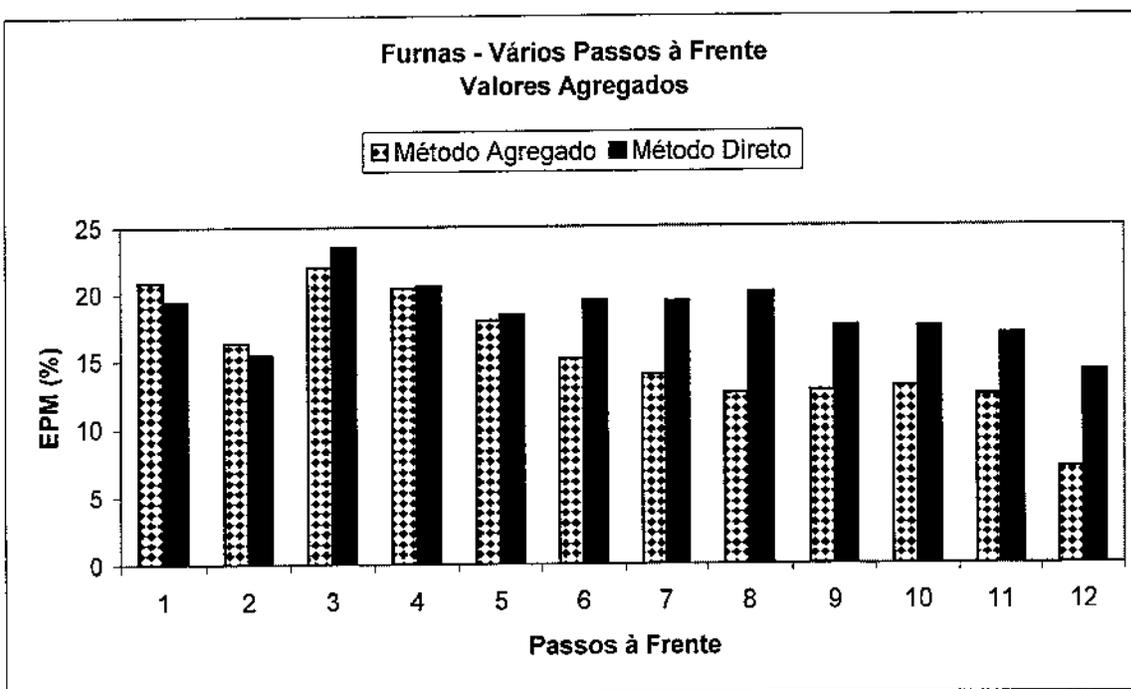
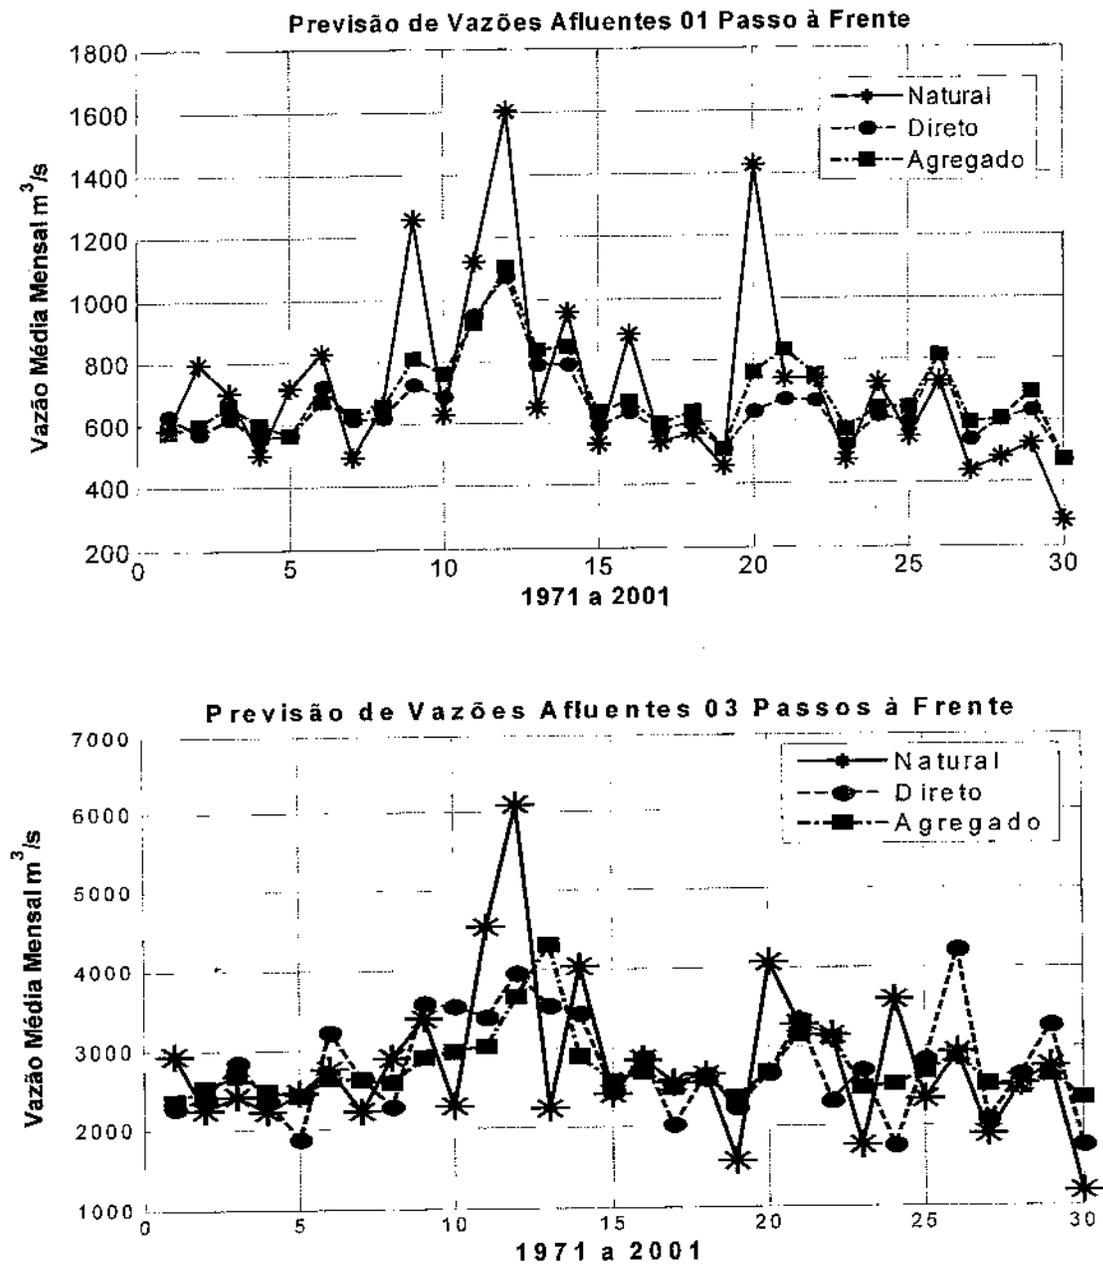


Figura 4.6: EPM para o Posto Hidrológico de Furnas pela Agregação.

Observa-se na Figura 4.6 que os erros relativos percentuais apresentados pelo Método Agregado são inferiores aos erros relativos percentuais resultantes da agregação das vazões previstas pelo Método Direto, o que comprova a eficiência do Método Agregado quando se analisa a previsão da soma das vazões vários passos à frente.

A seguir, na Figura 4.7 se apresenta a comparação dos valores agregados das previsões do Método Agregado e Método Direto com os valores naturais agregados em relação aos erros relativos percentuais, para um, três, seis, nove e doze passos à frente.



Pode-se notar que apenas para um passo à frente o Método Direto consegue ter desempenho equivalente ao Método Agregado, e nos demais passos à frente o Método Agregado chega mais próximo da curva natural, evidenciado pelos resultados da Tabela 4.4 e Tabela 4.7. Pode notar que à medida que aumenta os passos à frente, o erro de previsão diminui e os picos são previstos com melhor desempenho, comprovando a teoria da agregação de vazões. E os

4.6 Síntese do Capítulo

Nota-se pelos resultados apresentados nas Tabelas 4.2, 4.4, 4.6 e 4.7 utilizando as vazões afluentes médias mensais referente ao posto hidrológico da usina hidrelétrica de Furnas, que embora o Método Agregado tenha obtido pior desempenho que o Método Direto na comparação dos erros de previsão a cada passo, essa abordagem apresentou melhor desempenho quando comparados os erros de previsão da soma das vazões vários passos à frente. Também, pode-se observar que os erros de previsão com o Método Direto são menores que os erros de previsão obtidos com a MLT.

A Tabela 4.8 apresenta o resumo dos erros de previsão dos métodos empregados, realizando a média dos passos à frente para cada medida de desempenho para o posto hidrológico de Furnas.

Tabela 4.8: Resumo dos Erros de Previsão dos Métodos.

Erros	Valores Individuais		Valores Agregados	
	Método Direto	Método Agregado	Método Direto	Método Agregado
EPM	27,04	28,25	18,52	15,36
EAM	228,59	225,55	999,87	762,03
REQM	339,60	329,24	1483,38	1181,80
EPmax	143,00	140,44	58,54	61,39
ρ	0,6603	0,6468	0,6511	0,6368

Pode-se concluir que os resultados do Método Agregado foram significativos quando dos valores agregados, e quando dos valores individuais o Método Direto apresentou o melhor ajuste.

Este estudo é de grande importância para o setor elétrico, pois a questão da agregação temporal de vazões visa assegurar erros menores nas vazões afluentes mensais agregadas, mesmo que isso implique em erros maiores nas vazões afluentes mensais individuais desagregadas, uma vez que o planejamento da operação energética depende sobretudo do total previsto vários passos à frente.

No próximo capítulo, os resultados de previsão serão utilizados na política operativa em malha aberta para o planejamento energético.

Capítulo 5

Desempenho da Previsão de Vazões na Simulação da Operação Energética

O planejamento energético da operação de um sistema hidrotérmico engloba estudos de diferentes naturezas e horizontes. Nesses estudos, dá-se destaque aqueles relativos à avaliação energética do sistema nos quais procura-se verificar as condições de operação do sistema gerador frente a um grande conjunto de restrições, tais como: atendimento da demanda, limites operativos de reservatórios e usinas, usos múltiplos da água, configuração dinâmica do sistema gerador, manutenção e na operação das usinas e restrições hidrológicas como, por exemplo, o fenômeno de evaporação na superfície dos reservatórios.

Um dos instrumentos de visualização desse tipo de análise é a simulação individualizada da operação do parque gerador. Com esse tipo de ferramenta, pode-se identificar os impactos que a superposição de restrições operativas tem no comportamento do sistema gerador.

Análise de desempenho de políticas operativas é realizada através de simulação da operação de sistemas hidrotérmicos sob dados históricos de vazões naturais afluentes as usinas hidráulicas do sistema, os quais encontra-se disponível a partir do ano de 1931.

O modelo de simulação tenta reproduzir o comportamento do sistema hidrotérmico em estudo. Este modelo fornece a resposta do sistema para uma seqüência de vazões afluentes especificada, de acordo com a política de controle adotada, permitindo a comparação de diferentes metodologias em um mesmo ambiente computacional.

Em uma visão geral, o processo de simulação consiste no levantamento do comportamento do sistema ao longo do horizonte de simulação, mês a mês, onde a cada mês uma decisão, fornecida por uma determinada política de controle, é implementada. O simulador leva em conta as características individuais de cada usina do sistema (simulação a usinas individualizadas), com os limites operacionais de armazenamento, defluência e turbinagem.

A cada mês do período de simulação, o estado do sistema no início do mês e a vazão afluyente nos meses anteriores são conhecidos e, de acordo com a decisão fornecida pela política de controle, um novo estado do sistema é determinado, de maneira a satisfazer a equação de balanço hidráulico nos reservatórios das usinas do sistema.

Na simulação da política de controle em malha aberta, a decisão a cada mês do período de simulação é obtida a partir de uma otimização partindo do estado de armazenamento dos reservatórios no início do mês, e de uma previsão das vazões futuras em função das informações sobre a série hidrológica verificada até o mês anterior ao corrente mês de simulação.

Assumiu-se que os reservatórios devem estar tão cheios quanto possível sempre no início do período seco do sistema, que corresponde ao último mês da estação chuvosa, no caso o mês de Abril. Este critério heurístico tem como base a análise de comportamento da solução ótima determinística sob dados históricos de vazão afluyente. De acordo com essa condição de contorno adotada, o horizonte de otimização considerado a cada estágio é variável ao longo do período de planejamento, sendo o estágio final sempre o mês de abril e o estado final de armazenamento cheio (MARTINEZ, 2001).

Este trabalho utiliza o modelo proposto em (OLIVEIRA e SOARES, 1990), conhecido como modelo de Planejamento da Operação de Sistemas Hidrotérmicos (POSH), na otimização determinística da política de controle malha aberta. O modelo POSH baseia-se na representação do sistema hidráulico como um problema de fluxo em rede não linear com arcos capacitados.

A seguir, apresenta-se a simulação para as previsões de vazões desenvolvidas pelos dois métodos, Agregado e Direto, no problema de planejamento energético da operação de sistemas hidrelétricos de geração de energia elétrica.

5.1 Estudo de Caso

Selecionou-se a usina hidrelétrica de Furnas para o estudo, localizada no sistema Sudeste brasileiro. As características gerais são apresentadas na Tabela 5.1.

Tabela 5.1: Característica da Usina Hidrelétrica.

Dados	Furnas
Capacidade Instalada (MW)	1.312
Volume útil (hm^3)	17.217
Turbinagem max/min (m^3/s)	196/1.692

Como adotado em estudos de planejamento no sistema elétrico brasileiro, a cota de montante $\phi_i(\cdot)$ e a cota de jusante $\theta_i(\cdot)$ de cada reservatório são ajustadas por polinômios de quarta ordem em função do volume armazenado e da defluência no reservatório, respectivamente.

A Tabela 5.2 apresenta os valores dos coeficientes destes polinômios, onde a_i e b_i são coeficientes dos termos com expoente i para a função polinomial representando a cota de montante e a cota de jusante, respectivamente.

Tabela 5.2: Coeficientes dos Polinômios Cota de Montante/Jusante.

Cota	a_0	a_1	a_2	a_3	a_4
Montante	735,25	$3,4966 \times 10^{-3}$	$-1,9744 \times 10^{-7}$	$6,9170 \times 10^{-12}$	$-9,7736 \times 10^{-17}$
Jusante	671,63	$3,8713 \times 10^6$	$-2,6059 \times 10^{-12}$	$1,3847 \times 10^{-18}$	0,0

Os valores de produtividade específica k e da perda de carga média pc são apresentados na Tabela 5.3, em que h_b é a altura bruta.

Tabela 5.3: Produtibilidade Específica e Perda de Carga Média.

	$k \left(\frac{MW}{m^3 / s m} \right)$	pc	c (%)
Parâmetros	0,008633	$c \cdot h_b$	1,09

O parque térmico real é representado por uma térmica equivalente com capacidade igual a da hidráulica e função custo de geração quadrática da forma:

$$\psi_t = 0,02 \cdot 10^{-3} (D_t - H_t)^2 \quad (5.1)$$

A demanda de carga D_t foi considerada constante e igual a capacidade instalada do sistema hidráulico. Tais suposições não alteram a natureza das conclusões dos estudos realizados, já que o despacho ótimo tenta distribuir a geração hidráulica ao longo do horizonte de planejamento a fim de igualar custos marginais de operação, quaisquer que sejam estes custos.

As abordagens Direta e Agregada são comparadas através de simulações usando 30 anos de dados históricos de vazão afluente (maio/1971 a abril/2001), o mesmo período das previsões realizadas no capítulo anterior. A solução do problema determinístico assumindo que as vazões afluentes são exatamente conhecidas ao longo do período de planejamento é também considerada (Solução Ótima). Essa solução corresponde à política de malha aberta alimentada por perfeitas previsões e sua comparação com políticas que utilizem previsões (imperfeitas) permite estimar o custo da incerteza das vazões na operação energética.

A Tabela 5.4 mostra os valores médios do Custo Operacional e Geração Hidráulica do sistema com seus respectivos Desvio Padrão, obtidos nas simulações com as metodologias consideradas.

Tabela 5.4: Geração Hidráulica e Custo Operacional.

Estatísticas	Solução Ótima	Método Agregado	Método Direto
Custo Operacional Total (\$) (10^8)	1,1381	1,1947	1,2062
Custo Operacional Médio (\$) (10^5)	3,1647	3,3220	3,3538
Desvio Padrão Custo Op. (\$) (10^5)	0,9783	1,4680	1,5101
Ger. Hidráulica Média (MW)	546,07	536,65	529,95
Desvio Padrão Ger. Hidráulica (MW)	145,41	234,43	242,24

Observa-se na Tabela 5.4 que o Método Agregado obteve desempenho significativamente melhor tanto no custo operacional total como na geração hidráulica média em relação ao Método Direto. Evidencia-se, dessa forma, que a metodologia desenvolvida para realizar as previsões agregadas foi satisfatória, e comprovando que a idéia de reduzir os erros de previsão agregando temporalmente vazões, mesmo que a custa de erros maiores nas previsões de vazões afluentes mensais individuais desagregadas, é uma política que apresenta resultados significativos na simulação energética.

A Figura 5.1 mostra a relação percentual do custo operacional total entre os métodos. Verifica-se que os métodos Agregado e Direto tiveram desempenho inferior a 5 % e 6% em relação a Solução Ótima, respectivamente. E que o custo operacional total do Método Direto foi superior ao Método Agregado cerca de 1%.

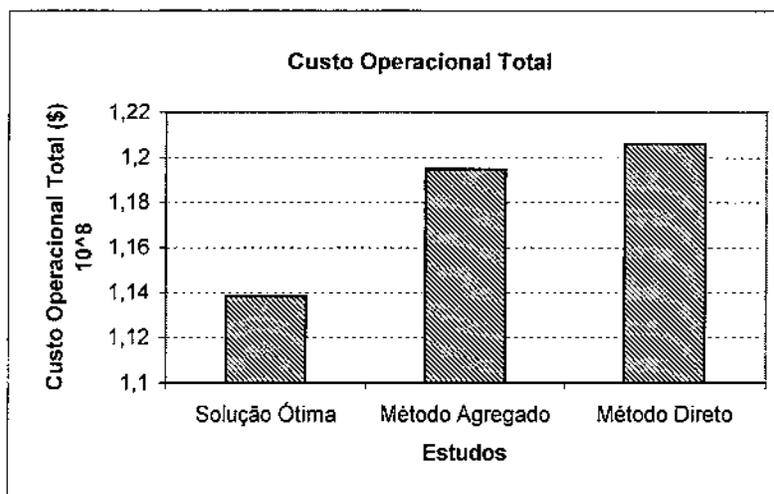


Figura 5.1: Custo Operacional Total dos Estudos.

O desvio padrão da solução indica flutuações na geração hidráulica ao longo do horizonte de planejamento. Desde que o custo operacional é convexo e crescente, tais flutuações provocam aumento de custo. Neste estudo, o maior desvio padrão obtido pelo Método Direto (Figura 5.2) não sendo compensado pela maior geração hidráulica média obtida, conduzem o sistema a um maior custo operacional do que o obtido na simulação com o Método Agregado, diferença cerca de 1% (Figura 5.1).

As Figuras 5.2 e 5.3 mostram as trajetórias de geração hidráulica e volume da usina hidrelétrica de Furnas, obtidas pelas simulações da política de malha aberta com diferentes vazões previstas nas décadas de 70, 80 e 90, respectivamente, do período histórico simulado, sendo o mês inicial de operação o mês de Maio.

De acordo com as trajetórias de volume apresentadas, pode-se notar na Figura 5.3 que nos anos com vazões afluentes médias, tal como 1972/1975, 1977/1979, 1985/1990, 1995/1996 e 1998/1999, a diferença entre os métodos de previsão na simulação energética são reduzidas, em contraste com a diferença verificada nos períodos de 1975/1976, 1979/1980, 1981/1983, 1990/1992 e 1996/1997, em que a disponibilidade de água foi elevada, devido apresentar as maiores cheias do histórico de vazões.

Nota-se, também, que em alguns períodos o Método Direto obteve melhor desempenho que o Método Agregado, como por exemplo 1983/1984, 1987/1988, 1992/1993 e 1998/1999.

Isto pode ser explicado pelo fato que embora a afluência seja crítica e em ambas metodologias a rede neural MLP não pode corretamente estimá-la, a condição de contorno considerada na malha aberta é responsável por manter altos níveis de armazenamento no reservatório, desta forma conduzindo o sistema a maiores valores de altura de queda, o que aumenta a produtividade da usina e portanto melhora a sua eficiência. Esta é uma importante característica da política de malha aberta, desde que períodos secos são aqueles de maiores custos operacionais e maiores riscos de déficit e, portanto, são os mais importantes no planejamento energético.

A condição de contorno da política de malha aberta associada ao bom desempenho da rede neural MLP utilizado na previsão de vazões, faz com que o Método Agregado se aproxime da solução ótima determinística do problema para períodos hidrológicos com características distintas, como pode ser verificado na Figura 5.2.

Quando o volume percentual útil reduz significativamente, por exemplo entre maio/1971 e maio/1972, significa que as vazões neste período foram baixas e apresentam os maiores desvios padrão, mas logo em seguida ocorrem altas vazões até o fim do mês de Abril pra superar as menores vazões, e o otimizador gasta toda a água do reservatório sem verter. Ver Figura 5.3.

Vale ressaltar aqui a importância que o Sistema de Apoio ao Planejamento Energético – SAPE, responsável pelo gerenciamento dos modelos e banco de dados utilizados, teve no desenvolvimento deste trabalho. Sem esta ferramenta de apoio, a realização dos estudos e a análise dos resultados obtidos teria exigido um período muito maior de processamento. De grande importância foi o modelo POSH utilizado na política de controle malha aberta.

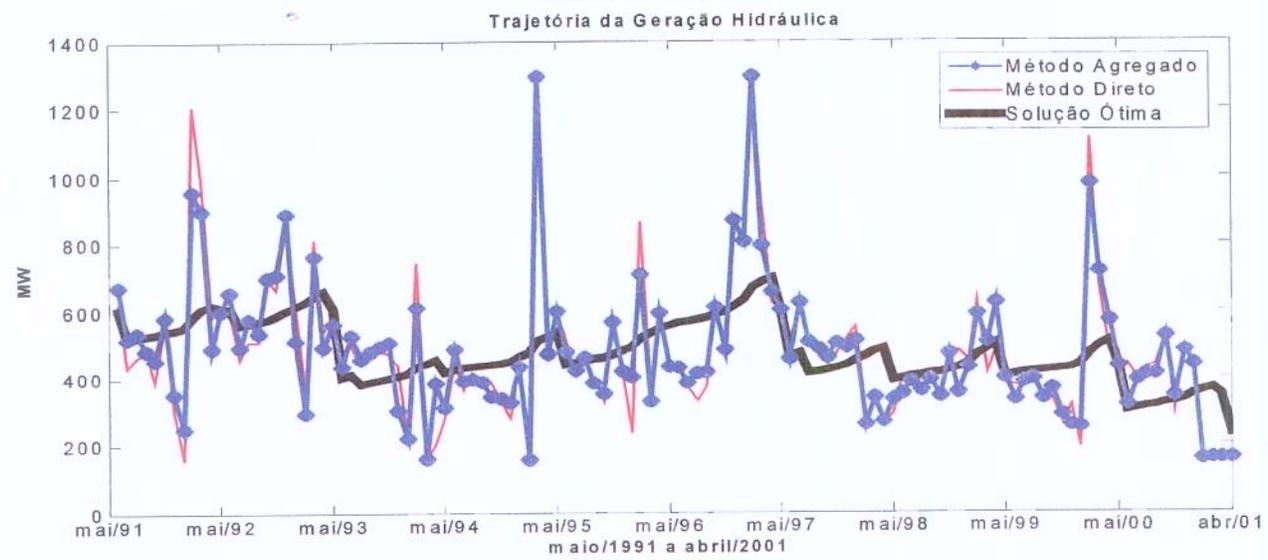
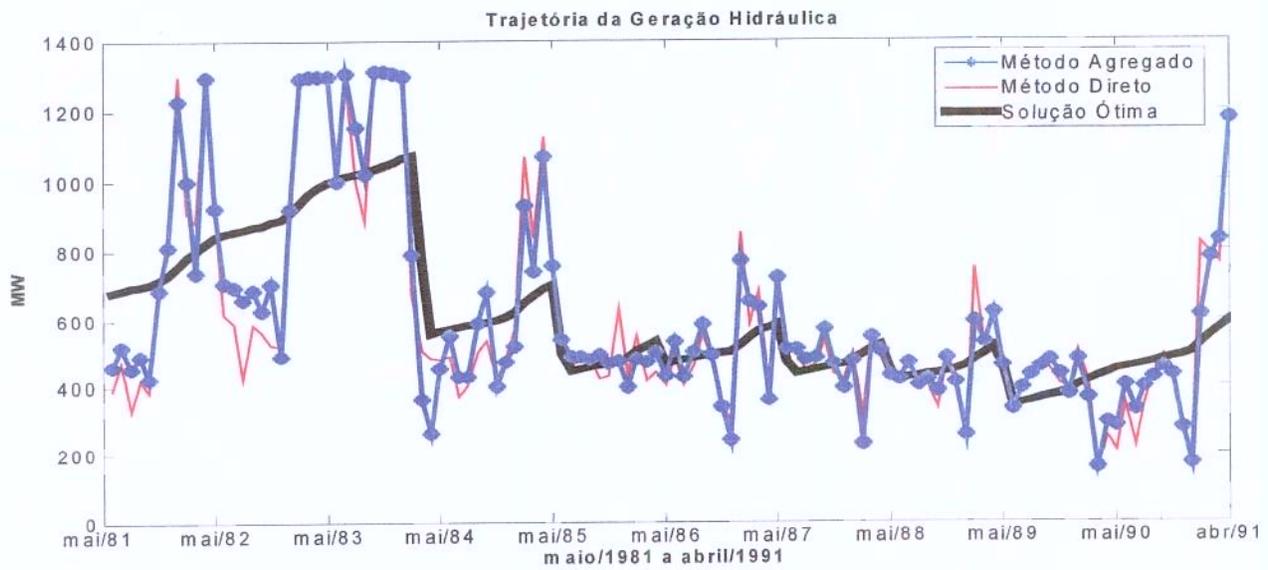
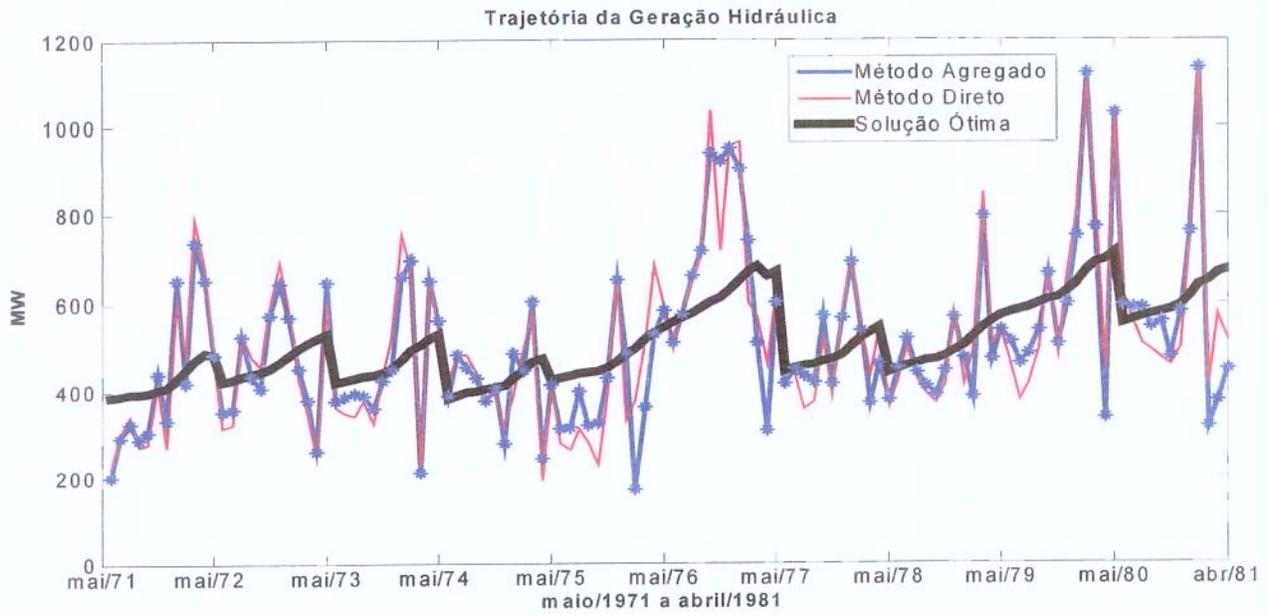


Figura 5.2: Trajetória da Geração Hidráulica (1971/1981, 1981/1991, 1991/2001).

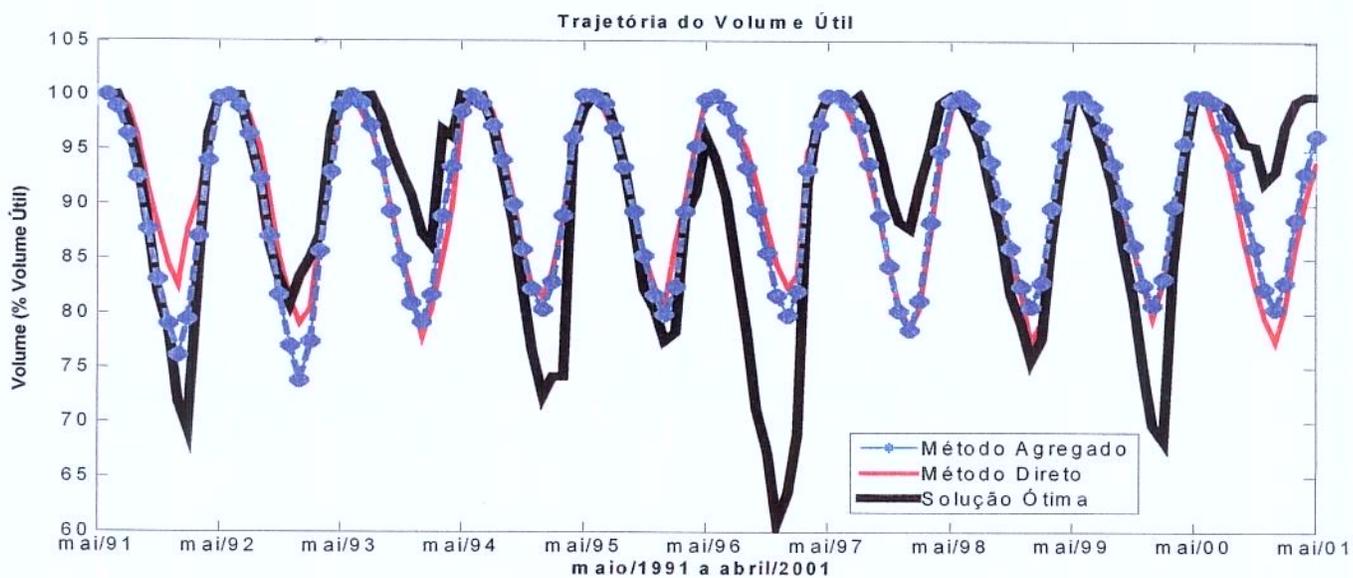
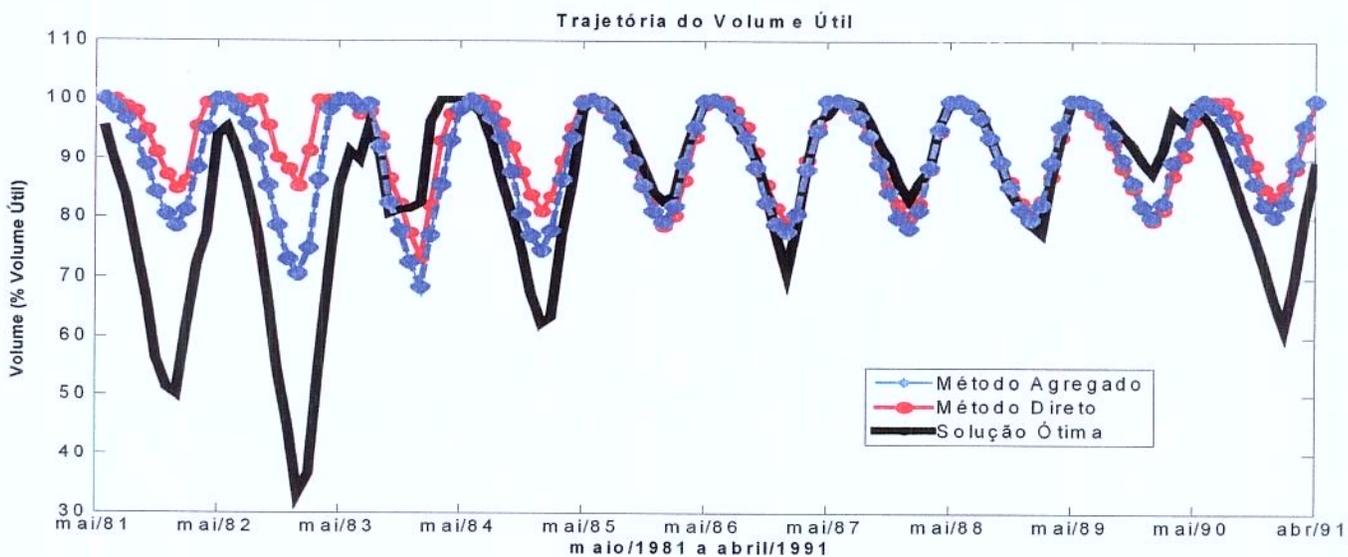
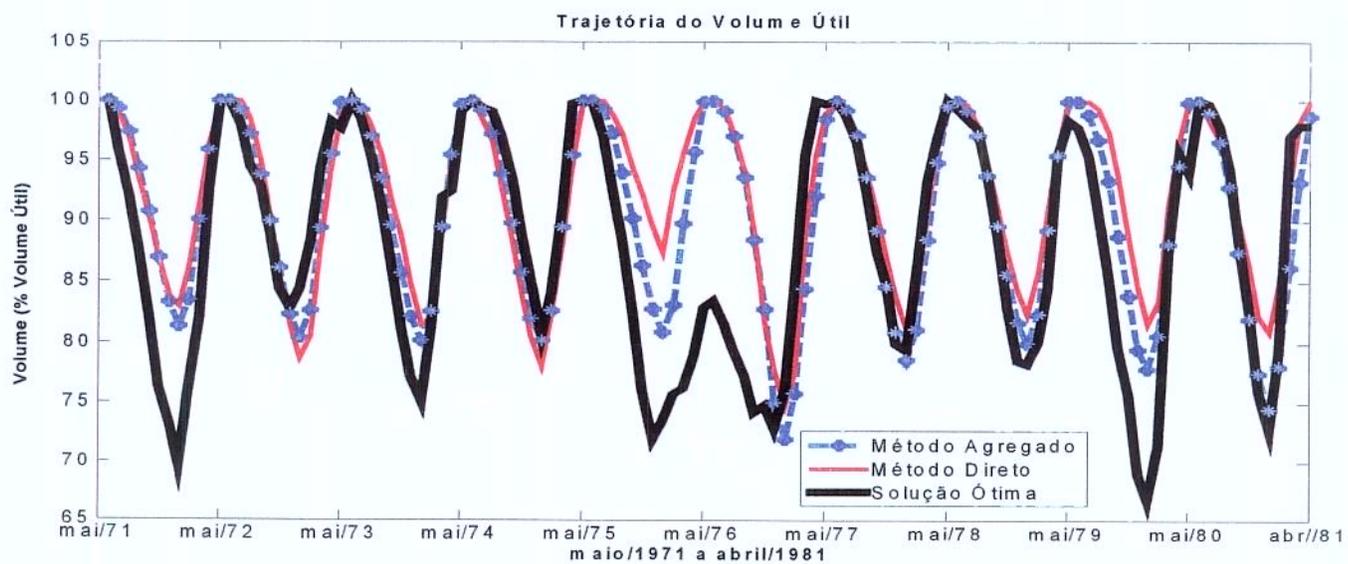


Figura 5.3: Trajetória do Volume de Furnas (1971/1981, 1981/1991, 1991/2001).

5.2 Síntese do Capítulo

A principal ênfase deste capítulo foi a comparação das vazões previstas pelos Métodos Direto e Agregado no problema de planejamento energético da operação de sistemas hidrelétricos de geração de energia elétrica.

Observou-se que o Método Agregado obteve desempenho significativamente melhor tanto no custo operacional total como na geração hidráulica média em relação ao Método Direto. Verificou-se que o custo operacional total do Método Agregado foi melhor que o Método Direto cerca de 1%.

Notou-se que o Método Agregado obteve melhor desempenho que o Método Direto, aproximando-se da solução ótima determinística.

Capítulo 6

Conclusões

Previsões de aflúências servem como subsídio a diversos setores usuários da água como: a irrigação na agricultura, a indústria, o uso doméstico, a pesca, o turismo, como gerenciadora de empregos na infra-estrutura de sua distribuição, a navegação e a geração de energia elétrica. Estes setores se utilizam destas previsões de aflúências para programar suas atividades à luz dos recursos hídricos disponíveis nas diferentes bacias hidrográficas.

Uma condição de fundamental importância para que o atendimento à demanda de energia seja realizado de forma otimizada, é que se disponha de um sistema de previsão de vazões eficientes, uma vez que a capacidade de geração futura do sistema é influenciada pelas futuras vazões afluentes cuja natureza é intrinsecamente estocástica. Esta pesquisa foi desenvolvida visando a previsão das vazões médias mensais para aproveitamentos hidrelétricos.

Uma abordagem para diminuir o erro das previsões de aflúências é a proposta de estudo da agregação de vazões neste trabalho, que é de grande importância para o setor elétrico, pois a questão da agregação temporal de vazões visa assegurar erros menores nas previsões de vazões afluentes mensais agregadas, mesmo que a custa de erros maiores nas previsões de vazões afluentes mensais individuais desagregadas, uma vez que o planejamento da operação energética depende principalmente do total previsto vários passos à frente.

Descreveu-se o problema de planejamento de sistemas hidrotérmicos, com ênfase ao planejamento da operação energética. Detalhou-se a formulação determinística do problema de planejamento da operação energética, assim como a política de controle malha fechada da programação dinâmica estocástica e a política de controle malha aberta, além do estudo da previsão de vazões na política de malha aberta. Neste trabalho, as previsões de vazões foram simuladas na política de controle em malha aberta.

Apresentou-se os principais tópicos relacionados às arquiteturas multicamadas, e se descreveu o algoritmo de retropropagação de erro utilizado no treinamento de redes neurais artificiais multicamadas para realizar a previsão de vazões vários passos à frente. Os estudos desenvolveram-se em busca dos menores erros e da melhor entrada, realizando com isso uma busca exaustiva envolvendo quatro parâmetros: taxa de aprendizado (η), termo *momentum* (α), neurônios na camada intermediária (N_e) e número de entradas (E). Notou-se que para cada passo à frente se encontrou a melhor configuração de parâmetros visando os menores erros. Verificou-se que, as previsões para 1 passo à frente a melhor entrada foi o mês de Março, para 2 passos à frente a melhor entrada foi a vazão do mês de Fevereiro e para 3 passos à frente a melhor entrada foi a vazão do mês de Janeiro. Seguindo-se até 12 passos à frente, quando a melhor entrada foi o somatório das vazões dos meses de Janeiro até Abril.

Duas abordagens foram implementadas, testadas e comparadas: Método Direto e Método Agregado. No Método Direto, as vazões foram previstas mensalmente, logo depois foram agregadas, e no Método Agregado realizou-se a previsão agregada, e em seguida foi desagregada baseada em valores proporcionais à Média de Longo Termo (MLT). Logo, compararam-se as previsões de valores individuais, assim como as previsões de valores agregados.

Notou-se que utilizando as vazões afluentes médias mensais referente do posto hidrológico da usina hidrelétrica de Furnas, o Método Agregado obteve pior desempenho que o Método Direto na comparação dos erros de previsão a cada passo, essa abordagem apresentou melhor desempenho quando comparados os erros de previsão da soma das vazões vários passos à frente. Verificou-se que a desagregação das previsões desenvolvida pelo Método Agregado apresentou os erros de previsão com tendência aos erros obtidos pela MLT, caso fossem consideradas as médias mensais do histórico de vazões como vazões previstas. Comprovou-se que quanto maior for o volume agregado de vazões menores serão os erros de previsão.

As vazões afluentes médias mensais previstas vários passos à frente, pelos métodos Direto e Agregado foram utilizadas na simulação do problema de planejamento energético da operação de sistemas hidrelétricos de geração de energia elétrica. Observou-se que o Método Agregado obteve desempenho significativamente melhor tanto no custo operacional total como na geração hidráulica média em relação ao Método Direto. Verificou-se que o custo operacional total do Método Direto foi maior que o Método Agregado cerca de 1%. Notou-se que o Método Agregado teve melhor desempenho que o Método Direto, aproximando-se da solução ótima determinística.

6.1 Trabalhos Futuros

Os resultados apresentados mostraram que os modelos de redes neurais multicamadas foi uma ferramenta que forneceu bom desempenho na previsão de vazões, sugeriria a análise de outras técnicas de previsão (redes neuro-fuzzy, modelos baseados em agrupamentos e previsão fuzzy) na abordagem de agregação de vazões.

Visando reduzir os erros de previsão das vazões agregadas, outras topologias para a rede neural multicamadas poderiam ser investigadas, como aumentar a quantidade de camadas intermediárias, explorar as melhores entradas nos modelos vários passos à frente, e estudar outras formas de desagregação.

Ao se fazer previsões de vazões para um determinado posto hidrológico deve-se levar em consideração a influência de postos na mesma bacia hidrográfica, que podem afetar as previsões. Outra sugestão seria explorar a correlação espacial, no caso de considerar a previsão nos modelos de agregação para múltiplos reservatórios.

Estender o estudo que foi feito apenas para uma usina, para outras usinas do sistema brasileiro.

A geração de séries sintéticas deve ser estudada, pois estas séries podem ser utilizadas tanto para otimização como para simulação no planejamento energético, diminuindo os eventuais ruídos da série natural.

Referências Bibliográficas

- ARVANITIDS, N. V. e ROSING, J. (1970). Composite representation of multireservoir hydroelectric power system, IEEE Transaction on Power Apparatus and Systems vol. PAS-89, no. 2: 319-326.
- ARAÚJO, J. K. (1991). Método dos Fragmentos Aplicado a Rios Intermitentes: Avaliação dos Erros Introduzidos no Cálculo da Disponibilidade de Reservatórios. Fortaleza, Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará. (Dissertação de Mestrado).
- ATIYA, A. F., EL-SHOURA, S. M., SHAHEEN, S. I. e EL-SHERIF, M. S. (1999). A comparison between neural-network forecasting techniques – case study: River flow forecasting, IEEE Transactions on Neural Networks 10(2): 402-409.
- BALLINI, R., SOARES, S. e ANDRADE, M. G. (1998). An adaptive neural fuzzy network model for seasonal streamflow forecasting, Proceedings of the IV Brazilian Symposium on Neural Networks-IEEE Computer Society, pp. 215-219.
- BALLINI, R., SOARES, S. e ANDRADE, M. G. (1999). Seasonal Streamflow Forecasting Via a Neural Fuzzy System, Proceedings of International Federation of Automatic Control - IFAC'99, Vol. K. pp. 81-86.
- BALLINI, R. (2000). Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais e Redes Neurais Nebulosas, Tese de Doutorado, Universidade Estadual de Campinas, Campinas, SP.
- BALLINI, R., FIGUEIREDO, M., SOARES, S., ANDRADE, M. e GOMIDE, F. (2000). A Seasonal Streamflow Forecasting Model Using Neurofuzzy Network, Information, Uncertainty and Fusion, B. Bouchon-Meunier and R. R. Yager AND I. Zadeh, Eds., Kluwer Academic Publishers, pp. 257-276.
- BELLMAN, R. (1962). Dynamic Programming, Princeton University Press, Princeton –N. J.
- BERTSEKAS D. P. (1995). Dynamic Programming and Optimal Control, Athena Scientific, Belmont, Massachusetts.
- BISHOP, C. M. (1995). Neural Networks for Pattern Recognition, Clarendon Press.
- BOX, G. E. P., JENKINS, G. M. e REINSEL, G. C. (1994). Time Series Analysis, Forecasting and Control, Prentice-Hall, Inc, 3a ed.
- CARNEIRO, A. A. F. M. (1991). Contribuições ao Planejamento da Operação Energética de Sistemas Hidrotérmicos de Potência, Tese de Doutorado, FEEC-Unicamp, Campinas.
- CARVALHO, A.L. (2001). Previsão de afluências diárias para um horizonte de 1 a 7 dias através de uma abordagem estocástica - modelo PREVIVAZH - Tese de Mestrado, COPPE - UFRJ.

CARVALHO, M. F. e SOARES, S. (1987). Na Efficient Hydrothermal Scheduling Algorithm, IEEE Transactions on Power Systems PWRS – 2: 537-542.

CEPEL/ELETRONBRAS. (1977). Modelo de Programação Dinâmica Estocástico para a Operação de Sistemas Hidrotérmicos, Relatório Técnico CEPEL, no. 144/77.

CESP/SYSTAN. (1976). Gerador e Analisador de Vazões Sintéticas de um Posto, 1976.

CHIEW, F. H. S., ZHOU, L. e MCMAHON, T. A. (2003). Use of seasonal streamflow forecasts in water resources management. Journal of Hydrology, Volume 270, Issues 1-2, 10 January 2003, Pages 135-144.

CHOW, V. T. (1964). Handbook of applied hydrology, MacGraw-Hill Book Co., New York.

CICOGNA, M. A. (1999). Modelo de Planejamento da Operação Energética de Sistemas Hidrotérmicos a Usinas Individualizadas Orientado por Objeto, Dissertação de Mestrado, FEEC-Unicamp, Campinas.

CRAWFORD, N.H., LINDSLEY JR., R.K. (1966). Digital Simulation in Hydrology, Stanford Watershed Model IV, Department of Civil Engineering, Stanford University, tech. Report, no. 39.

ELETRONBRÁS - SCEN – GTMC. (1980). Sistema de Previsão de Vazões Médias Mensais para o Programa de Operação, 190 páginas.

FIGUEIREDO, M. e GOMIDE, F. (1997). Adaptive Neuro Fuzzy Modelling, Proceedings of the 6th IEEE Conference on Fuzzy Systems, Barcelona – Espanha, pp. 1567-1572.

FIGUEIREDO, M. e GOMIDE, F. (1998). Fuzzy System Design Using Neurofuzzy Networks, Proceedings of the 7th Information Processing and Management of Uncertainty on Knowledge - Based Systems - IPMU'98, Vol. 2, pp. 1416-1422.

FIGUEIREDO, M., BALLINI, R., SOARES, S., GOMIDE, F. e ANDRADE, M. (2004). Learning Algorithms for a Class of Neurofuzzy Network and Application. IEEE Transactions On Systems Man And Cybernetics Part C Applications And Re, IEEE, v. 34, n. 3, p. 293-301, 2004.

FRANCELIN, R., BALLINI, R. e ANDRADE, M. G. (1996). Back-propagation and Box-Jenkins approaches to streamflow forecasting, Latin-Iberian-American Congress on Operations Research and System Engineering – CLAIO, Simpósio Brasileiro de Pesquisa Operacional – SBPO, Rio de Janeiro – RJ, pp. 1307-1312.

GABLINGER, M. e LOUCKS, D. P. (1970). Markov Model for Flow Regulation, Journal of the Hydraulics Division, ASCE 96 (HYI).

GCOI (1983). Grupo Coordenador da Operação Interligada, Manual do Sistema PREVAZ, Eletrobrás.

GEORGAKAKOS, A. e YAO, H. (2001). Assessment of Folsom Lake Response to Historical and Potential Future Climate Scenarios, Journal of Hydrology, August 2001, vol 249, p.p. 176-196.

GUENNI, L. e B'ARDOSSY, A. (1998). Disaggregation of Highly Seasonal Monthly Rainfall. "citeseer.ist.psu.edu/409615.html". Centro de Estadística y Software Matemático, Universidad Simón Bolívar. Reporte Técnico 98-10. 24 pp.

GUILHON, L. G. F. (2002). Modelo de Previsão de Vazões Naturais Médias Semanais. (COPPE/UFRJ, Dissertação de Mestrado, Planejamento Energético, 2002). Universidade Federal do Rio de Janeiro, COPPE.

HAAS, J. (2003). Utilização da Previsão Meteorológica Quantitativa de Chuva na Previsão de Afluências. Uma publicação trimestral do Instituto CIÊNCIAONLINE - ISSN nº 1676-5893. Dezembro de 2002 a Fevereiro de 2003.

HAYKIN, S. (1999). Neural Networks – A Comprehensive Foundation, 2a edição, Macmillan, 1999.

IYODA, E. M. (2000). Inteligência computacional no projeto automático de redes neurais híbridas e redes neurofuzzy heterogêneas. Faculdade de Engenharia Elétrica e de Computação. Universidade Estadual de Campinas, Dissertação de Mestrado - Campinas, SP: [s.n.], 2000.

JANG, J.-S. R. (1993). "ANFIS: Adaptive-Network-based Fuzzy Inference Systems", IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23, No. 3, pp. 665-685, May 1993.

KELMAN, J., DE OLIVEIRA, G. C. e PEREIRA, M. V. F. (1979). Geração de Séries Hidrológicas - Método de Desagregação. In: V Seminário Nacional de Produção e Transmissão de Energia Elétrica, Recife, 1979. 37 p.

KELMAN, J., DAMÁZIO, J. M. e COSTA, J. P. (1983). Geração de séries sintéticas de vazões diárias – Modelo DIANA. Revista Brasileira de Engenharia, v.1, n.2, pp.5-22, 1983.

KLIGERMAN, A. (1992). Operação Ótima de Subsistemas Hidrotérmicos Interligados Utilizando Programação Estocástica Dual, Dissertação de Mestrado, FEEC-Unicamp, Campinas.

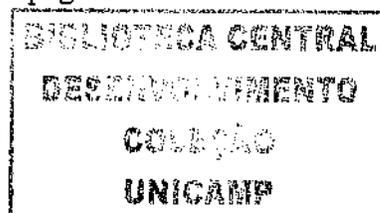
LACHTERMACHER, G. e FULLER, J. D. (1995). Backpropagation in time-series forecasting, Journal of Forecasting 14(4): 381-393.

LIN, GWO-FONG e LEE, FONG-CHUNG. (1992). An aggregation-disaggregation approach for hydrologic time series modeling. Journal of Hydrology, Volume 138, Issues 3-4, October 1992, Pages 543-557.

LUDERMIR, T. e VALENÇA, M. (2000), Neural Networks vs. PARMA Modelling: Case studies of river flow prediction, VIth Brazilian Symposium on Neural Networks, pp. 113-116.

LUDERMIR, T. e VALENÇA, M. (2001a). Multivariate Modelling of Water Resources Time Series Using Constructive Neural Networks, V Brazilian Conference on Neural Networks - Rio de Janeiro - RJ, pp. 163-168.

LUDERMIR T. e VALENÇA, M. e GUILHON, L.G.F. (2001b). Previsão de Vazões Mensais Utilizando Redes Neurais, XVI SNPTEE - Campinas - SP, 6 páginas.



- MACEIRA, M.E.P., DUARTE, V.S. e MARCATO, A.L.M. (2002). Manual do Usuário do Modelo NEWAVE, Versão 8.3, CEPEL, Rio de Janeiro, Jul. 2002.
- MAHEEPALA, S. e PERERA, B. J. C. (1996). Monthly hydrologic data generation by disaggregation. *Journal of Hydrology*, Volume 178, Issues 1-4, 15 April 1996, Pages 277-291.
- MAIER, H. R. e DANDY, G.C. (2000). Neural Networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. *Environmental Modelling & Software*, vol. 5, pp. 101-124, 2000.
- MARINHO, M. H. N., SOARES, S. e BALLINI, R. (2003a). Previsão de Vazões Afluentes Naturais Usando o Modelo ANFIS, Proceedings of the VI Brazilian Conference on Neural Networks - VI, Congresso Brasileiro de Redes Neurais pp. 163-168, June 2-5, 2003.
- MARINHO, M. H. N., CARVALHO, T. M., BALLINI, R. e SOARES, S. (2003b). Comparative Study Of The Models Of Seasonal Streamflow Forecasting, Fifth Latin-American Congress on Electricity Generation and Transmission, November 16th-2, São Pedro - SP - Brazil, 2003.
- MARINHO, M. H. N., ANDRADE FILHO, M. G., BALLINI, R., SOARES, E. F. e SOARES, S. (2004). Previsão de Vazões Afluentes Utilizando Modelos Periódicos Auto-Regressivos, Redes Neurais e Redes Neurais Nebulosas, VII Simpósio de Recursos Hídricos do Nordeste, 30 de novembro a 03 de dezembro, São Luís - MA - Brazil, 2004.
- MARINHO, M. H. N., BALLINI, R. e SOARES, S. (2005). Previsão de Vazões Afluentes Vários Passos à Frente Utilizando Redes Neurais Via Agregação de Vazões. In: XVI Simpósio Brasileiro de Recursos Hídricos, 2005, João Pessoa. Anais do XVI Simpósio Brasileiro de Recursos Hídricos, 2005. v. Único. p. 1-20.
- MARTINEZ, L. (2001). Políticas de Controle Malha Fechada e Malha Aberta no Planejamento da Operação Energética de Sistemas Hidrotérmicos, Tese de Doutorado, Faculdade de Engenharia Elétrica e de Computação -Unicamp, Campinas.
- MARTINEZ, L. e SOARES, S. (2001a). Comparação entre Soluções Malha Aberta e Malha Fechada no Planejamento Energético de Sistemas de Energia Elétrica. XVI Seminário Nacional de Produção e Transmissão de Energia Elétrica, Grupo IX, Campinas -SP.
- MARTINEZ, L. e SOARES, S. (2001b). Scenarios Techniques for Long Term Hydrothermal Scheduling, Hydropower in the New Millenium – Proceeding of the 4th Internacional Conference Hydropower' 01, A. A. Balkema Publishers, Bergen-Norway, pp. 85-91.
- MARTINEZ, L. e SOARES, S. (2002). Comparison Between Closed-Loop and Partial Open-Loop Feedback Control Policies in Long Term Hydrothermal Scheduling. *IEEE Transactions on Power Systems*, vol. 17, no. 2, pp. 1635-1641.
- MARTINEZ, L., BALLINI, R. e SOARES, S. (2002a). A New Approach For Long Term Hydrothermal Scheduling, Symposium of Specialists in Electric Operational and Expansion Planning – VIII SEPOPE. Brasília.

- MARTINEZ, L., BALLINI, R. e SOARES, S. (2002b). The Influence of Hydrologic Information in Long-Term Hydrothermal Scheduling. The International Federation of Automatic Control - 15th IFAC World Congress, Barcelona - Spain.
- MARTINEZ, L., BALLINI, R. e SOARES, S. (2002c). Influência da Condição Terminal no Planejamento Energético de Sistemas Hidrotérmicos. Congresso Brasileiro de Automática - XIV CBA, pp. 1810-1815, Natal - RN-Brasil.
- MASSE, P. (1946). Les Reserves et la Régulation de l'Avenir dans la Vie Économique, Vol I: Avenir Déterminé, Vol. II Avenir Aléatoire, Hermann, Paris.
- MCCULLOCH, W. S. e PITTS, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity, Bulletin of Mathematical Biophysics, 5, 1943.
- MEJIA, J.M. e ROUSSELE, J. (1976). Disaggregation Models in Hydrology Revisited, Water Resources Researches, 12(2), 1976.
- MINSKY, M. e PAPERT, S. (1998). Perceptrons: an Introduction to Computational Geometry, edição expandida, MIT Press, 1988.
- MNPOWER - <http://www.mnpower.com/wintonlicensing/pdf/r.pdf>, 2002
- MULLER, F. (1998). Dois Modelos de Desagregação de Vazões Mensais em Diárias. Revista Brasileira de Recursos Hídricos. Volume 3 - n. 2 Abr/Jun 1998.
- NG, G. W. (1997). Application of Neural Networks to Adaptive Control of Nonlinear Systems, John Wiley & Sons Inc, Control System Centre, UMIST, UK.
- OLIVEIRA, G. G. e SOARES S. (1990). A second-order network flow algorithm for hydrothermal scheduling, IEEE Transaction on Power Systems vol. 10, no. 3: 1635-1641.
- OLIVEIRA, G. G. (1993). Otimização da Operação Energética de Sistemas Hidrotérmicos com Representação Individualizadas das Usinas e Afluências Determinísticas, Dissertação de Mestrado, FEEC-UNICAMP, Campinas.
- OUARDA, T. B. M. J., GIRARD, C., CAVADIAS, G. S. e BOBÉE, B. (2001). Regional flood frequency estimation with canonical correlation analysis, Journal of Hydrology, December-2001, vol. 254, p.p. 157-173.
- PEREIRA, M. V. (1985). Optimal Scheduling of Hydrothermal Systems – An Overview, IFAC symposium on Planning and Operation of Electric Energy Systems pp. 1-9.
- PEREIRA, M. V. e PINTO, L. M. V. G. (1985). Stochastic optimization of a multireservoir hydroelectric system: a decomposition approach, Water Resources Research vol. 21, no. 6: 779-792.
- ROYAL SOCIETY – <http://www.royalsoc.au.uk/policy/IDNDR/rodda.pdf>, 2001
- RUMELHART, D., HINTON, G. e WILLIAMS, R. (1986). Learning representations by back-propagation errors. Nature (London), vol. 323, pp. 533-536, 1986.

SILVA, S. C. P. (1999). Comparação Entre as Soluções de Malha Fechada e Semi-Aberta para a Otimização da Operação de Sistemas de Produção de Energia Elétrica, Dissertação de Mestrado, Instituto de Ciências Matemáticas e de Computação, USP - São Carlos.

SOARES, S. (1999). Planejamento e Programação da Operação de Sistemas de Energia Elétrica. Projeto Temático de Equipe FAPESP, processo 99/12737-9.

SOARES, S. e CARNEIRO, A. A. F. M.(1991). Optimal Operation of Reservoir for Electric Generation, IEEE Transactions on Power Delivery 6(3): 1101-1107.

STUDART, T. M. C. e CAMPOS, J. N. B. (2001). Incertezas nas Estimativas das Vazões Regularizadas por um Reservatório. Revista Brasileira de Recursos Hídricos-RBRH Vol.7 nº3, Associação Brasileira de Recursos Hídricos, setembro de 2001.

SVANIDZE, G.G. (1980). Mathematical Modeling of Hydrologic Series. Water resources Publications, Fort Collins, Colorado, USA, 1980.

TERRY, L. A., CEPEL, DENE/DPE/Eletróbrás e DEOP/DOS/Eletróbrás (1980). Modelo a Sistema Equivalente – Descrição Geral, Relatório Técnico, CEPEL - Eletróbrás.

TUCCI, C. E. M. (1998). Modelos Hidrológicos. 1 ed. Porto Alegre, Universidade/ UFRGS/Associação Brasileira de Recursos Hídricos.

US ARMY ENGINEER DIVISION. (1972). Program description and user manual for SSARR, North Pacific, Portland Oregon.

VALENCIA, D. R e SCHAAKE, J. C. (1972). A Disaggregation Model for Time Series Analysis and Synthesis, Report 149, Ralph M. Parsons Laboratory, Massachusetts Institute of Technology, 1972.

VINHAL, C. D. N. (1994). Um Sistema de Apoio à Decisão no Planejamento da Operação Energética de Sistemas de Energia Elétrica, Dissertação de Mestrado, FEEC-UNICAMP, Campinas.

VINHAL, C. D. N. (1998). Um Sistema de Apoio à Decisão para o Planejamento da Operação Energética de Sistemas de Energia Elétrica, Tese de Doutorado, FEEC-UNICAMP, Campinas.

VOGEL, R. M. (1999). Stochastic and deterministic world views, Journal of Water Resources Planning and Management, v. 125, n. 6, pp. 311-313.

VON ZUBEN, F. J. (1996). Modelos Paramétricos e Não-Paramétricos de Redes Neurais Artificiais e Aplicações, Tese de Doutorado, Faculdade de Engenharia Elétrica e de Computação, Unicamp, 1996.

WANG, Z.M. e VANDEWIELE, G.L. (1994). Forecast ad Monte Carlo simulation of Zaire River Flow, Hydrology continental, vol. 9, no. 1, p.p. 69-83.

WRC – <http://www.wrc.org.za/wrcpublications/wrcsanciohs/vdspry.html>, 2002

WHITE, D. A. e SOFGE, D. A. (1992). Handbook of Intelligent Control – Neural, Fuzzy and Adaptive Approaches, Van Nostrand Reinhold, 1992.

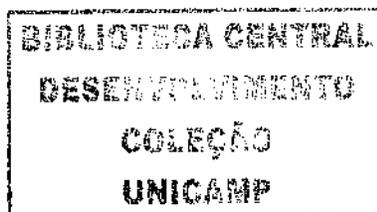
YEVJEVICH, V.M. (1972). Structural Analysis of Hydrologic Time Series, Hidrology Papers, Colorado State University, Fort Collins.

Índice de Autores

ARVANITIDS, N. V. e ROSING, J. (1970).	19
ARAÚJO, J. K. (1991).	9
ATIYA, A. F., EL-SHOURA, S. M., SHAHEEN, S. I. e EL-SHERIF, M. S. (1999).	36,38
BALLINI, R., SOARES, S. e ANDRADE, M. G. (1998).	5
BALLINI, R., SOARES, S. e ANDRADE, M. G. (1999).	5
BALLINI, R. (2000).	4,5
BALLINI, R., FIGUEIREDO, M., SOARES, S., ANDRADE, M. e GOMIDE, F. (2000).	5
BELLMAN, R. (1962).	13
BERTSEKAS D. P. (1995).	18
BISHOP, C. M. (1995).	25
BOX, G. E. P., JENKINS, G. M. e REINSEL, G. C. (1994).	4,6
CARNEIRO, A. A. F. M. (1991).	14
CARVALHO, A.L. (2001).	6,9
CARVALHO, M. F. e SOARES, S. (1987).	14
CEPEL/ELETRORBRAS. (1977).	14
CESP/SYSTAN. (1976).	9
CHIEW, F. H. S., ZHOU, L. e MCMAHON, T. A. (2003).	25
CHOW, V. T. (1964).	3
CICOGNA, M. A. (1999).	13
CRAWFORD, N.H. e LINDSLEY JR., R.K. (1966).	7
ELETRORBRÁS - SCEN – GTMC. (1980).	4
FIGUEIREDO, M. e GOMIDE, F. (1997).	5
FIGUEIREDO, M. e GOMIDE, F. (1998).	5
FIGUEIREDO, M., BALLINI, R., SOARES, S., GOMIDE, F. e ANDRADE, M. (2004).	25
FRANCELIN, R., BALLINI, R., e ANDRADE, M. G. (1996).	4

GABLINGER, M. e LOUCKS, D. P. (1970).	13
GCOI (1983).	4
GEORGAKAKOS, A. e YAO, H. (2001).	7
GUENNI, L. e B'ARDOSSY, A. (1998).	8
GUILHON, L. G. F. (2002).	3
HAAS, J. (2003).	4
HAYKIN, S. (1999).	25,30
IYODA, E. M. (2000).	25
JANG, J.-S. R. (1993).	5
KELMAN, J.; DE OLIVEIRA, G. C. e PEREIRA, M. V. F. (1979).	8
KELMAN, J., DAMÁZIO, J. M. e COSTA, J. P. (1983).	6
KLIGERMAN, A. (1992).	14
LACHTERMACHER, G. e FULLER, J. D. (1995).	5
LIN, GWO-FONG e LEE, FONG-CHUNG. (1992).	8
LUDERMIR, T. e VALENÇA, M. (2000),	5
LUDERMIR, T. e VALENÇA, M. (2001a).	5
LUDERMIR T. e VALENÇA, M. e GUILHON, L.G.F. (2001b).	5
MACEIRA, M.E.P., DUARTE, V.S. e MARCATO, A.L.M., M	15
MAHEEPALA, S. e PERERA, B. J. C. (1996).	8
MAIER, H. R. e DANDY, G.C. (2000).	4
MARINHO, M. H. N., SOARES, S. e BALLINI, R. (2003a).	5
MARINHO, M. H. N., CARVALHO, T. M., BALLINI, R. e SOARES, S. (2003b).	5
MARINHO, M. H. N., ANDRADE FILHO, M. G., BALLINI, R., SOARES, E. F. e SOARES, S. (2004).	25
MARINHO, M. H. N., BALLINI, R. e SOARES, S. (2005).	10
MARTINEZ, L. (2001).	19,20,21,22,39,55
MARTINEZ, L. e SOARES, S. (2001a).	15

MARTINEZ, L. e SOARES, S. (2001b).	15
MARTINEZ, L. e SOARES, S. (2002).	15
MARTINEZ, L., BALLINI, R. e SOARES, S. (2002a).	15
MARTINEZ, L., BALLINI, R. e SOARES, S. (2002b).	15
MARTINEZ, L., BALLINI, R. e SOARES, S. (2002c).	16
MASSE, P. (1946).	13
MCCULLOCH, W. S. e PITTS, W. (1943).	27
MEJIA, J. M.e ROUSSELE, J. (1976).	8
MINSKY, M. e PAPERT, S. (1998).	29
MNPOWER. (2002).	7
MULLER, F. (1998).	9
NG, G. W. (1997).	35
OLIVEIRA, G. G. e SOARES S. (1990).	18,22,55
OLIVEIRA, G. G. (1993).	14
OUARDA, T. B. M. J., GIRARD, C., CAVADIAS, G. S. e BOBÉE, B. (2001).	7
PEREIRA, M. V. (1985).	13
PEREIRA, M. V. e PINTO, L. M. V. G. (1985).	13,14
ROYAL SOCIETY. (2001).	7
RUMELHART, D., HINTON, G. e WILLIAMS, R. (1986).	4,34,35
SILVA, S. C. P. (1999).	15
SOARES, S. (1999).	16
SOARES, S. e CARNEIRO, A. A. F. M.(1991).	15
STUDART , T. M. C. e CAMPOS, J. N. B. (2001).	9
SVANIDZE, G.G. (1980).	9
TERRY, L. A. (1980).	14
TUCCI, C. E. M. (1998).	3
US ARMY ENGINEER DIVISION. (1972).	6,8



VALENCIA, D. R e SCHAAKE, J. C. (1972).	8
VINHAL, C. D. N. (1994).	14
VINHAL, C. D. N. (1998).	14
VOGEL, R. M. (1999).	2
VON ZUBEN, F. J. (1996).	25
WANG, Z.M. e VANDEWIELE, G.L. (1994).	6
WRC. (2002).	7
WHITE, D. A. e SOFGE, D. A. (1992).	25
YEVJEVICH, V.M. (1972).	4