



Marcelo Alfredo de Assis Fayal

**Previsão de Vazão por Redes Neurais Artificiais e
Transformada Wavelet**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica da PUC-Rio.

Orientadora: Profa. Marley Maria Bernardes Rebuszi Vellasco

Co-Orientador: Prof. Carlos Roberto Hall Barbosa

Rio de Janeiro
Fevereiro de 2008



Marcelo Alfredo de Assis Fayal

**Previsão de Vazão por Redes Neurais Artificiais e
Transformada Wavelet**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Dra. Marley Maria Bernardes Rebuszi Vellasco
Orientadora
Departamento de Engenharia Elétrica - PUC-Rio

Dra. Carlos Roberto Hall Barbosa
Co-Orientador
Departamento de Metrologia - PUC-Rio

Dr. Marco Aurélio Cavalcanti Pacheco
Departamento de Engenharia Elétrica - PUC-Rio

Dra. Karla Tereza Figueiredo Leite
UERJ

Prof. Gerson Zaverucha
COPPE/UFRJ

Prof. José Eugênio Leal
Coordenador Setorial do Centro
Técnico Científico - PUC-Rio

Rio de Janeiro, 28 de fevereiro de 2008

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Marcelo Alfredo de Assis Fayal

Graduou-se em Engenharia Elétrica no IME (Instituto Militar de Engenharia) em 1995, e especializou-se em Sistemas Computacionais na CCE/PUC-Rio, em 2004. Com foco na modelagem de novos sistemas de apoio a decisão, atua como integrante da Seção de Inteligência Tecnológica e da Coordenadoria de Pesquisa e Desenvolvimento de Projetos do CTEEx (Centro Tecnológico do Exército).

Ficha Catalográfica

Fayal, Marcelo Alfredo de Assis

Previsão de vazão por redes neurais artificiais e transformada Wavelet / Marcelo Alfredo de Assis Fayal ; orientador: Marley Maria Bernardes Rebuzzi Vellasco ; co-orientador: Carlos Roberto Hall Barbosa. – 2008.

158 f. ; 30 cm

Dissertação (Mestrado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Previsão de vazão. 3. Redes neurais artificiais. 4. Transformada wavelet. I. Vellasco, Marley Maria Bernardes Rebuzzi. II. Barbosa, Carlos Roberto Hall. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

Dedico este trabalho a Maria das Graças, Mariana Banana Paçoca Estrelinha e a Maria Eduarda Ligeirinha.

Agradecimentos

De início, por questão de justiça, agradeço aos meus orientadores Marley e Hall, pelas centenas de horas reservadas para a orientação deste trabalho. Pela enorme paciência, confiança e pela extrema cordialidade com que sempre fui tratado por eles. Sinto-me um afortunado.

Agradeço ao pessoal do ICA, em especial a Karla Figueiredo e a Iury Steiner.

Agradeço o apoio imprescindível prestado pela equipe de engenheiros da Intratec Consulting, em especial, à figura de seu diretor Luiz Felipe de Souza Tavares e de seus engenheiros Jansley Pascoal, Ademir Marreiros, Daniel Barros e Thiago Carneiro, sem o qual seria impossível a realização deste trabalho.

Agradeço ao amigo Adrian Pizzinga, jovem doutor e mago da estatística, por suas inúmeras colaborações desde o começo deste trabalho.

Agradeço ao meu pai e ao meu irmão pelo exemplo de bondade, carinho e honestidade. Pelo amparo nas horas difíceis, pelo sentido de que na vida é preciso perseverar sempre e sobretudo por terem sido os exemplos através dos quais sempre me guiei.

Agradeço a minha mãe por todos os momentos puros, felizes e de tranqüilidade da minha infância, juventude e maturidade, passando paz interior e apaziguando o coração e serenando as angústias das pessoas à sua volta.

Agradeço a Senhora Nilca, por sua bondade e sobretudo por amar minhas filhas.

Agradeço, ainda, aos meus amigos, mentores, e oficiais exemplares, os Senhores: Coronel Maurílio, Coronel Josedes e Coronel Ângelo.

Finalmente, agradeço a Deus, todos os santos, arcanjos e anjos do céu pela saúde das minhas duas filhas Mariana e Maria Eduarda.

Resumo

Fayal, Marcelo Alfredo de Assis; Vellasco, Marley Maria Bernardes Rebuzzi (Orientadora). **Previsão de Vazão Por Redes Neurais Artificiais e Transformada Wavelet**. Rio de Janeiro, 2008. 158p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

O sistema hidroelétrico é responsável por 83,7% da energia elétrica gerada no país. Assim sendo, a geração de energia elétrica no Brasil depende basicamente das vazões naturais que fluem aos aproveitamentos hidroelétricos distribuídos por doze bacias hidrográficas no país. Sendo o Operador Nacional do Sistema Elétrico (ONS) o órgão responsável por elaborar a previsão e a geração de cenários de vazões naturais médias diárias, semanais e mensais para todos os locais de aproveitamentos hidroelétricos do Sistema Interligado Nacional (SIN), a qualidade da previsão da vazão natural é de suma importância para este órgão. A qualidade dessa previsão impacta diretamente no planejamento e em programas de operação do SIN, tal como o Programa Mensal de Operação – PMO. Mesmo com a melhoria na qualidade da previsão de vazões por meio da criação e adoção dos mais diversos modelos determinísticos e estocásticos nos últimos anos, os erros de previsão são, ainda, significativos. Deste modo, o objetivo principal desta dissertação foi propor um novo modelo capaz de proporcionar um significativo ganho de qualidade na previsão de vazões nas regiões dos aproveitamentos hidroelétricos das bacias hidrográficas do país. O modelo proposto, baseado em redes neurais, tem como ferramenta primordial a utilização de transformadas wavelets, que filtram os dados históricos de vazões, ou seja, as entradas das redes neurais de previsão, dividindo esses dados de entrada (sinais) em diversas escalas, no intuito de que as redes neurais possam melhor analisá-los. Para verificar a eficácia do modelo proposto, aqui denominado MIP (Modelo Inteligente de Previsão), procedeu-se um estudo de caso que realiza a previsão de vazões naturais incrementais médias diárias e semanais no trecho incremental entre as Usinas Hidroelétricas (UHE) Porto Primavera, Rosana e Itaipu da Bacia do Rio Paraná, chegando-se a um erro de aproximadamente 3,5% para previsão de vazões um dia à frente, 16% para 12 dias à frente, e 9% para previsão média semanal. Esta dissertação objetiva, também, investigar a eficácia do uso de informações das precipitações observadas e previstas na previsão de vazão, em conjunção com o uso do histórico de vazões.

Palavras-chave

Previsão de vazão; informações de precipitação; modelos chuva-vazão, redes neurais artificiais, transformada wavelet

Abstract

Fayal, Marcelo Alfredo de Assis; Vellasco, Marley Maria Bernardes Rebuzzi (Advisor). **Outflow Forecast Based on Artificial Neural Networks and Wavelet Transform**. Rio de Janeiro, 2008. 158p. MSc Dissertation - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

The hydroelectricity system is responsible for 83.7% of the electric energy generated at Brazil. Therefore, the generation of electric power in Brazil depends basically on the natural flow rates distributed by twelve basins in the country. The quality of prediction of natural flow is of crucial importance for the Brazilian governmental agency, ONS (from the portuguese language Electrical National Operator System), responsible for preparing the forecast and the generation of scenarios of daily, weekly and monthly average natural streamflows of all places of hydroelectric exploitations of SIN (from the portuguese language National Linked System). The quality of that forecast impacts directly in the planning and operation programs of SIN, for example, the PMO (from the portuguese language Monthly Operation Program). Even with the improvement in the quality of river flow forecasts through the creation and adoption of the various deterministic and stochastic models in recent years, the errors of forecasting are still significant. Thus, the main goal of this dissertation was proposing a new model capable of providing a significant improvement in Streamflow forecasts in regions of exploitations of hydroelectric basins of the country. The proposed model, based on neural networks, has the primary tool the use of wavelet transforms, to filter streamflows historical data, or the entries of predict neural networks, dividing the input data (signals) in several scales, in order that the neural networks can better analyse them. In order to check the effectiveness of the proposed model, here called MIP (from the portuguese language Forecast Intelligent Model), it was developed a case study to forecast daily and weekly average of natural incremental streamflows between the Hydroelectric Plants: Porto Primavera, Rosana e Itaipu belonging to the the Parana River Basin. The model reaches up an error of about 3,5% to estimates of streamflows one day ahead, 16% to 12 days ahead, and 9% for average weekly forecast. This thesis aims to also investigate the effectiveness of the use of information of observed and predicted rainfall in the forecast flow, in conjunction with the use of the historical streamflows.

Keywords

Outflow forecast, artificial neural networks, wavelet transform.

Sumário

1. Introdução	14
1.1. Motivação	14
1.1.1. Previsão Hidrológica no âmbito do SIN	15
1.1.2 Previsão Hidrológica usando Redes Neurais, chuvas observadas e previstas	16
1.2. Objetivos	18
1.3. Descrição do Trabalho	19
1.4. Organização da Dissertação	21
2. Modelagem Hidrológica	23
2.1. Introdução	23
2.2. Histórico	25
2.3. Modelos atualmente usados no Mundo	28
2.4. Escolha do Modelo	38
3. Métodos e Modelos	40
3.1. Método de Seleção de Variáveis	40
3.1.1. Introdução	40
3.1.2. Método do Estimador por Mínimos Quadrados (LSE)	41
3.1.2.1. Descrição	41
3.1.2.2. Algoritmo do LSE	42
3.1.2.3. Importância das Variáveis de Entrada	44
3.2. Redes Neurais Artificiais	44
3.2.1. Histórico	44
3.2.2. Estrutura do Neurônio	46
3.2.3. Estrutura da Rede	48
3.2.4. Processamento Neural	49
3.2.5. Aprendizagem e Treinamento	50
3.3. Wavelets	55
3.3.1. Introdução	55
3.3.2. Perspectiva Histórica	56
3.3.3. A Transformada de Fourier	58
3.3.3.1. Análise de Fourier Short-Time (Windowed)	61
3.3.4. A Transformada Wavelet	63
3.3.4.1. A Transformada Wavelet Contínua (TWC)	65
3.3.4.2. A Transformada Wavelet Discreta (TWD)	69
3.3.4.3. O Algoritmo Piramidal de Mallat: Aproximações e Detalhes	70
3.3.4.4. Decomposição e Múltiplos Níveis	72
3.3.4.5. Reconstrução Wavelet	73
3.3.4.6. Reconstrução de Aproximações e Detalhes	74
3.3.4.7. Famílias Wavelets	75
4. Modelo Inteligente de Previsão (MIP)	78
4.1. Modelo Proposto	78
4.2. Módulo 1 – Módulo de Tratamento dos Dados	80
4.3. Módulo 2 – Módulo Wavelet	87
4.4. Módulo 3 – Módulo de Redes Neurais	88

5. Estudo de Caso	90
5.1. Introdução	90
5.2. Módulo 1 – Tratamento dos Dados	93
5.2.1. Séries Histórias Disponíveis	93
5.2.2. Cálculo da chuva de Thiessen para a Bacia e Completamento dos Dados	95
5.2.3. Confeção das Matrizes de Dados e Seleção de Variáveis	99
5.3. Previsão sem Transformação Wavelet	104
5.3.1. Características e Modelagem das Redes Neurais	104
5.3.2. Previsão de Vazões	106
5.3.3. Avaliação dos Resultados	111
5.4. Previsão com Transformação Wavelet	112
5.4.1. Características dos Módulos 2 e 3	112
5.4.2. Testes Preliminares	112
5.5. Previsão sem Wavelet x Previsão com Wavelet	118
6. Conclusões e Trabalhos Futuros	120
6.1. Conclusões	120
6.2. Trabalhos Futuros	121
Referências Bibliográficas	123
Apêndice 1	130
Apêndice 2	138
Apêndice 3	140
Apêndice 4	142
Apêndice 5	143
Apêndice 6	145
Apêndice 7	153
Apêndice 8	155
Apêndice 9	158

Lista de figuras

Figura 3.1: Neurônio biológico	47
Figura 3.2: Descrição de um k-ésimo neurônio	47
Figura 3.3: Exemplo de estrutura da rede	48
Figura 3.4: Treinamento Supervisionado	51
Figura 3.5: Treinamento Não-Supervisionado.....	52
Figura 3.6: Conexões de um neurônio de camada escondida	54
Figura 3.7: A função na parte de baixo é composta pelas três funções acima dela	59
Figura 3.8: Dois gráficos ilustrativos da STFT, também conhecida como Windowed Fourier Analysis.....	62
Figura 3.9: Uma senóide à esquerda e uma wavelet à direita	64
Figura 3.10: Produto de 2 seções de uma função a pela wavelet b , gerando áreas d e f – cujas áreas são os coeficientes Wavelets	64
Figura 3.11: O efeito do fator de escala numa senóide.....	66
Figura 3.12: O efeito do fator de escala numa wavelet $\psi(t)$	67
Figura 3.13: Deslocando uma wavelet.....	67
Figura 3.14: Exemplos de translação e escalonamento	68
Figura 3.15: Exemplos de translação e escalonamento	69
Figura 3.16: $S=A+D$	71
Figura 3.17: Filtragem básica e Downsampling	71
Figura 3.18: Downsampling	72
Figura 3.19: Árvore de decomposição wavelet	72
Figura 3.20: Detalhes dos coeficientes na árvore de decomposição wavelet.....	73
Figura 3.21: Reconstrução wavelet	73
Figura 3.22: Upsampling do sinal.....	74
Figura 3.23: Construção dos detalhes e aproximações	74
Figura 3.24: Decomposição em múltiplos níveis.....	75
Figura 3.25: Wavelet Haar	75
Figura 3.26: Família Daubechies	76
Figura 3.27: Família Biortogonal	77
Figura 3.28: Família Coiflets.....	77
Figura 4.1: Modelo MIP composto pelos módulos 1,2 e 3	79
Figura 4.2: Previsão de vazão incremental média diária do 1º ao 12º dia	80

Figura 4.3: Três previsões de vazões médias semanais	80
Figura 4.4: Módulo 3 com seus dois núcleos fictícios.....	88
Figura 4.5: Módulo 3 com suas 15 redes neurais	89
Figura 5.1: Mapa da bacia incremental de Itaipu e sub-bacias	91
Figura 5.2: Aproveitamentos hidrelétricos onde aparecem as UHE Rosana, Porto Primavera e Itaipu	92
Figura 5.3: Localização dos 37 postos pluviométricos [88]	94
Figura 5.4: Os 37 postos pluviométricos e suas relativas áreas de domínio [88]	96
Figura 5.5: Pesos de Thiessen dos 37 postos pluviométricos	97
Figura A.1.1: Componentes de um ciclo hidrológico	131
Figura A2.1: Traçado da mediatriz.....	138
Figura A2.2: Definição do polígono de área.....	139
Figura A.5.1: Parada tardia e ponto ótimo de generalização	143
Figura A.7.1: Gráfico da Função Sigmóide	153
Figura A.7.2: Gráfico da Função Sigmóide com a tendendo ao infinito	154
Figura A.7.3: Gráfico da Função Tangente Hiperbólica.....	154
Figura A.8.1: Vazões observada e simulada de Vmd2 com Wavelet	155
Figura A.8.2: Vazões observada e simulada de Vmd2 sem Wavelet.....	155
Figura A.8.3: Vazões observada e simulada de Vmd4 com Wavelet	156
Figura A.8.4: Vazões observada e simulada de Vmd4 sem wavelet	156
Figura A.8.5: Vazões observada e simulada de Vmd11 com wavelet	157
Figura A.8.6: Vazões observada e simulada de Vmd11 sem wavelet.....	157

Lista de tabelas

Tabela 1.1: Índices MAPE (%) dos modelos de previsão de vazões PREVIVAZ (de 1997 a 2004) e PREVIVAZH (de 2000 a 2001).....	16
Tabela 1.2: Resultados dos modelos de previsão de vazões médias semanais	17
Tabela 1.3: Resultados dos modelos de previsão de vazões médias semanais NSRBN e PARMA	17
Tabela 2.1: Relação entre as diversas áreas apoiadas pela modelagem hidrológica e respectivos modelos.....	24
Tabela 5.1: Postos pluviométricos e respectivos percentuais de falhas	93
Tabela 5.2: Tabela com os dados dos 5 postos fluviométricos da Bacia do Rio Paraná – trecho Itaipu.....	95
Tabela 5.3: Tabela de pesos de Thiessen relativos aos 37 postos pluviométricos	96
Tabela 5.4: Ajuste da matriz de chuvas médias de Thiessen	98
Tabela 5.5: Tabela de formação das matrizes de dados.....	99
Tabela 5.6: Variáveis selecionadas pelo 1º LSE.....	101
Tabela 5.7: Variáveis selecionadas pelo 2º LSE.....	102
Tabela 5.8: Resultados das previsões semanais sem uso de Wavelets	107
Tabela 5.9: Resultados das previsões diárias sem uso de Wavelets	108
Tabela 5.10: Melhores resultados obtidos e respectivos conjuntos de entrada.....	110
Tabela 5.11: Tabela comparativa dos resultados com e sem ETA	111
Tabela 5.12: Previsões usando wavelets daubechies	113
Tabela 5.13: Previsões usando como entradas janela de 3 valores anteriores da última vazão natural	114
Tabela 5.14: Previsões usando wavelet coif_5 e como entradas 5 valores anteriores da última vazão natural.....	114
Tabela 5.15: Previsões usando wavelet coif_5 e bior e como entradas 7 valores anteriores da última vazão natural	115
Tabela 5.16: Previsões usando wavelet daubechies e como entradas 7 valores anteriores da última vazão natural	115
Tabela 5.17: Previsões usando wavelet db_{25}	116
Tabela 5.18: Seis Previsões usando wavelet db_{25}	116
Tabela 5.19: Previsões diárias usando wavelet db_{25} e 7 valores anteriores de vazões diárias	117
Tabela 5.20: Previsão sem wavelet x Previsão com wavelet.....	119
Tabela A.1.1: Características de modelos usados no gerenciamento de recursos hídricos.....	136

Gráfico/Tabela A.6.1: Graus de importância em relação à Vms1	145
Gráfico/Tabela A.6.2: Graus de importância em relação à Vms2	145
Gráfico/Tabela A.6.3: Graus de importância em relação à Vms3	146
Gráfico/Tabela A.6.4: Graus de importância em relação à Vmd1	146
Gráfico/Tabela A.6.5: Graus de importância em relação à Vmd2	147
Gráfico/Tabela A.6.6: Graus de importância em relação à Vmd3	147
Gráfico/Tabela A.6.7: Graus de importância em relação à Vmd4	148
Gráfico/Tabela A.6.8: Graus de importância em relação à Vmd5	148
Gráfico/Tabela A.6.9: Graus de importância em relação à Vmd6	149
Gráfico/Tabela A.6.10: Graus de importância em relação à Vmd7	149
Gráfico/Tabela A.6.11: Graus de importância em relação à Vmd8	150
Gráfico/Tabela A.6.12: Graus de importância em relação à Vmd9	150
Gráfico/Tabela A.6.13: Graus de importância em relação à Vmd10	151
Gráfico/Tabela A.6.14: Graus de importância em relação à Vmd11	151
Gráfico/Tabela A.6.15: Graus de importância em relação à Vmd12	152