

**UNIVERSIDADE FEDERAL DE ALFENAS
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

Danilo Braga de Lima

**MODELO INTELIGENTE DE PREVISÃO DE VAZÕES
AFLUENTES PARA O AUXÍLIO À TOMADA DE DECISÃO NO
SETOR ELÉTRICO**

Alfenas, 01 de Julho de 2010.

UNIVERSIDADE FEDERAL DE ALFENAS
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

MODELO INTELIGENTE DE PREVISÃO DE VAZÕES
AFLUENTES PARA O AUXÍLIO À TOMADA DE DECISÃO NO
SETOR ELÉTRICO

Danilo Braga de Lima

Monografia apresentada ao Curso de Bacharelado em Ciência da Computação da Universidade Federal de Alfenas como requisito parcial para obtenção do Título de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Ricardo Menezes Salgado

Alfenas, 01 de Julho de 2010.

Danilo Braga de Lima

**MODELO INTELIGENTE DE PREVISÃO DE VAZÕES
AFLUENTES PARA O AUXÍLIO À TOMADA DE DECISÃO NO
SETOR ELÉTRICO**

A Banca examinadora abaixo-assinada aprova a monografia apresentada como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação pela Universidade Federal de Alfenas.

Profa. Dra. Thaís Gama de Siqueira

Universidade Federal de Alfenas

Prof. M.e Luiz Eduardo da Silva

Universidade Federal de Alfenas

Prof. Dr. Ricardo Menezes Salgado

Universidade Federal de Alfenas

Alfenas, 01 de Julho de 2010.

À minha Mãe, ao meu Pai e a minha Irmã.

AGRADECIMENTO

Agradeço principalmente à minha família que me apoiou e me deu forças para sempre seguir em frente. Agradeço a minha mãe pelo incentivo, dedicação, educação e pelos ensinamentos que estarão presentes em toda a minha vida. Agradeço o meu pai, pelo exemplo que sempre foi para mim e que nos momentos mais difíceis soube me amparar e mostrar um caminho a seguir. Agradeço a minha irmã, que sempre esteve ao meu lado, por me dar ainda mais motivação em minha vida. Certamente, todas as minhas conquistas são frutos da dedicação e cuidado dos meus pais e, principalmente, pelo amor que existe na minha família.

Agradeço aos meus amigos que me ajudaram a superar os desafios e a conquistar objetivos que, às vezes, pareciam impossíveis. Agradeço aos meus amigos mais antigos e aos que fiz durante a faculdade, ao pessoal da turma e principalmente aos amigos da república: José Alexandre, Luís Theodoro e Neubio, que durante quatro anos formamos uma família. Compartilhamos vitórias, derrotas, conquistas e superamos desafios que surgiram ao longo destes anos. Os anos vão passar, os tempos de faculdade ficarão para trás, porém certamente as nossas amizades se estenderam ao longo de nossas vidas.

Agradeço aos meus orientadores principalmente pelo conhecimento passado, pelas supervisões e pela paciência para passar os seus ensinamentos. Além disso, em muitos momentos, estes não ensinaram apenas as ciências, mas também lições de vida que as carregarei comigo. À professora Melise que me “adotou” com sua amizade, carinho e pela compreensão em momentos delicados. Ao professor Ricardo que me ajudou na conclusão desta monografia, dando direcionamentos e solucionando as dúvidas que frequentemente surgiam.

Agradeço a todos os professores que contribuíram para o meu desenvolvimento intelectual, que colaboraram com parte dos seus conhecimentos fazendo com que eu pudesse construir os meus.

Enfim, agradeço a todos que de alguma forma contribuíram para o resultado deste trabalho.

"Tu te tornas eternamente responsável por aquilo que cativas"
Antoine de Saint Exupéry

"A vida só pode ser compreendida olhando-se para trás,
mas só pode ser vivida olhando-se para frente."
Soren Kierkegaard

RESUMO

O Brasil possui grande potencial energético advindo de fontes hidrominerais, no qual a maior parte da energia elétrica consumida provém desta fonte. Aliado a este fato, vale destacar que a tomada de decisão relacionada ao planejamento da operação dos reservatórios das usinas hidrelétricas é realizada com base, principalmente, no conhecimento antecipado das vazões. Para realizar a previsão de vazões de uma determinada bacia, é possível a utilização de alguma abordagem computacional para beneficiar este processo, tais como: Redes Neurais Artificiais, Modelos Autorregressivos, Programação Genética, Lógica *Neuro-Fuzzy*, entre outras, que são utilizadas com frequência na construção de modelos para solucionar problemas relacionados à previsão de séries temporais em diferentes áreas. No entanto, ao usar apenas um determinado modelo, é possível que este esteja adaptado a prever somente uma faixa específica da série temporal em questão, não apresentando bons resultados para outras partes da série. Para solucionar este problema, neste trabalho é proposto um *ensemble* para realizar a combinação dos resultados obtidos por modelos individuais de previsão, com o objetivo de minimizar os erros apresentados pelos modelos e com isso aprimorar os resultados obtidos. Para a realização dos estudos deste trabalho, serão utilizados como base os dados das usinas que compõem a cabeceira da Bacia do Rio Grande, mais especificadamente, as usinas de: Camargos, Funil Grande, Furnas e Itutinga, além disso, serão expostos os resultados obtidos para todas as usinas que compõem o Sistema Interligado Nacional (SIN).

Palavras-Chave: Sistema de Previsão, Análise de Séries Temporais, Previsão de Vazões, Inteligência Artificial, Modelos de previsão, *Ensembles*.

ABSTRACT

In Brazil there is a large potential energy that comes from hydro mineral sources, which most part of the electricity consumed comes from this source. In addition this, it is important emphasize that the decision-making related with planning of the operation of the reservoirs of hydroelectric plants has been done based mainly on stream flow's earliness knowledge. To perform the forecast of a determinate basin, it is possible to use some computational approach to facilitate this process, such as: Neural Networks, Autoregressive Models, Genetic Programming, Neuro-Fuzzy Logic, and others, which have been often used to building models to solve problems related to time series forecasting. However, when only one model is used, it is possible that is adapted to perform the forecast only a specific range of the time series. To solve this problem, in this work is proposed an *ensemble* to combine the results obtained by individual model forecast, in order to minimize errors showed from these models and attempt to improve the forecasts results. The experiments used the plants' data of the beginning Rio Grande Basin, more specifically, the plants of: Camargos, Funil Grande, Furnas and Itutinga. Moreover, it also will be showed the results to all plants of the Brazilian Interconnected System.

Keywords: Forecast Systems, Time Series Analysis, Stream flow Forecast, Artificial Intelligence, Predictive models, Ensembles.

LISTA DE FIGURAS

FIGURA 1 – OBTENÇÃO DE UM DADO VALOR ATRAVÉS DE UM DETERMINADO TEMPO	32
FIGURA 2 – MODELO REDE NEURAL MLP.....	39
FIGURA 3 – REPRESENTAÇÃO DA FÓRMULA $X^2 + Y$	40
FIGURA 4 – FUNCIONAMENTO DO ALGORITMO DE PROGRAMAÇÃO GENÉTICA.....	41
FIGURA 5 – ESTRUTURA DE UM <i>ENSEMBLE</i> DE PREVISÃO	43
FIGURA 6 – METODOLOGIA DE <i>TREINAMENTO ÚNICO</i>	46
FIGURA 7 – METODOLOGIA DE <i>TREINAMENTO CONTÍNUO</i>	47
FIGURA 8 – METODOLOGIA UTILIZADA PARA ENCONTRAR OS PARÂMETROS MAIS ADAPTADOS.....	50
FIGURA 9 – OBTENÇÃO DOS DADOS DE VAZÕES. FORTUNATO (1990, APUD BALLINI, 2000 P. 2).....	56
FIGURA 10 – SÉRIES DE VAZÕES DAS USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS – JAN/96-DEZ/05.....	57
FIGURA 11 – DADOS BRUTOS – USINA DE FURNAS (1997-2007)	58
FIGURA 12 – DADOS NORMALIZADOS – USINA DE FURNAS (1997-2007).....	59
FIGURA 13 – METODOLOGIA DOS TESTES.	62
FIGURA 14 – PREVISÃO UTILIZANDO <i>TREINAMENTO ÚNICO</i> (1976 - 1985). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	63
FIGURA 15 – PREVISÃO UTILIZANDO <i>TREINAMENTO CONTÍNUO</i> (1976 - 1985). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	63
FIGURA 16 – PREVISÃO UTILIZANDO <i>TREINAMENTO ÚNICO</i> (1996 - 2005). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	64
FIGURA 17 – PREVISÃO UTILIZANDO <i>TREINAMENTO CONTÍNUO</i> (1996 - 2005). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	64
FIGURA 18 – PREVISÃO UTILIZANDO <i>TREINAMENTO ÚNICO</i> (1976 - 1985). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	66
FIGURA 19 – PREVISÃO UTILIZANDO <i>TREINAMENTO CONTÍNUO</i> (1976 - 1985). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	67
FIGURA 20 – PREVISÃO UTILIZANDO <i>TREINAMENTO ÚNICO</i> (1996 - 2005). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	67
FIGURA 21 – PREVISÃO UTILIZANDO <i>TREINAMENTO CONTÍNUO</i> (1996 - 2005). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	68
FIGURA 22 – PREVISÃO UTILIZANDO <i>TREINAMENTO ÚNICO</i> (1976 - 1985). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	69
FIGURA 23 – PREVISÃO UTILIZANDO <i>TREINAMENTO CONTÍNUO</i> (1976 - 1985). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	70
FIGURA 24 – PREVISÃO UTILIZANDO <i>TREINAMENTO ÚNICO</i> (1996 - 2005). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	70
FIGURA 25 – PREVISÃO UTILIZANDO <i>TREINAMENTO CONTÍNUO</i> (1996 - 2005). USINAS: CAMARGOS, ITUTINGA, FUNIL GRANDE E FURNAS.....	71
FIGURA 26 – <i>ENSEMBLE</i> APLICADO À USINA DE FURNAS. METODOLOGIA DE <i>TREINAMENTO CONTÍNUO</i>	72
FIGURA 27 – <i>ENSEMBLE</i> APLICADO À USINA DE FURNAS. METODOLOGIA DE <i>TREINAMENTO ÚNICO</i> . ..	73

LISTA DE TABELAS

TABELA 1 – ERROS OBTIDOS. FONTE: LUNA; BALLINI & SOARES (2007A).....	36
TABELA 2 – ÍNDICES DE DESEMPENHO - SISTEMA RIO GRANDE	38
TABELA 3 – EXEMPLO DE PADRÕES UTILIZADOS PARA TREINAMENTO	48
TABELA 4 – EXEMPLO DO PADRÃO UTILIZADO PELOS MODELOS.....	49
TABELA 5 – FAIXA DE VALORES DOS PARÂMETROS DO MODELO RNA.	49
TABELA 6 – FAIXA DE VALORES DOS PARÂMETROS DO MODELO DE RNA.	51
TABELA 7 – FAIXA DE VALORES DOS PARÂMETROS DO MODELO DE PROGRAMAÇÃO GENÉTICA.	51
TABELA 8 – <i>ENSEMBLES</i> UTILIZADOS PARA PREVISÃO.....	54
TABELA 9 – PREVISÃO PARA JULHO 1996 – 2006. USINA DE FURNAS (m ³ /s).....	54
TABELA 10 – RESULTADO DOS <i>ENSEMBLES</i> JULHO 1996 – 2010. USINA FURNAS (m ³ /s).	55
TABELA 11 – CARACTERÍSTICA DOS DADOS.....	57
TABELA 12 – ERROS MÉDIOS (EMR) – MODELO DE REDES NEURAIS ARTIFICIAIS.....	65
TABELA 13 – ERROS MÉDIOS (EMR) – MODELO DE PROGRAMAÇÃO GENÉTICA.....	68
TABELA 14 – ERROS MÉDIOS (EMR) – MODELO DE REGRESSÃO LINEAR MÚLTIPLA.....	71
TABELA 15 – <i>ENSEMBLES</i> APLICADOS A USINA DE CAMARGOS.....	74
TABELA 16 – <i>ENSEMBLES</i> APLICADOS A USINA DE FURNAS.....	75
TABELA 17 – <i>ENSEMBLES</i> APLICADOS A USINA DE FUNIL GRANDE.	75
TABELA 18 – <i>ENSEMBLES</i> APLICADOS A USINA DE ITUTINGA.....	75
TABELA 19 – EMR PARA AS USINAS DO SIN	94

LISTA DE ABREVIACÕES

ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
A-FSM	<i>Adaptive Fuzzy System Model</i>
ANA	Agência Nacional das Águas
ANEEL	Agência Nacional de Energia Elétrica
C-FSM	<i>Constructive Fuzzy System Model</i>
ETA	<i>Estimated time of arrival</i>
EMR	Erro Médio Relativo
MA	Média Aritmética
MG	Média Geométrica
MLP	<i>Multi Layer Perceptron</i>
MP	Média Ponderada
MQ	Média Quadrática
ONS	Operador Nacional do Sistema
PNN	<i>Probabilistic Neural Networks</i>
PRG	Programação Genética
RBF	<i>Radial Basis Function</i>
RLM	Regressão Linear Múltipla
RNA	Redes Neurais Artificiais
RNR	<i>Recurrent Neural Networks</i>
SIN	Sistema Interligado Nacional

SUMÁRIO

1 INTRODUÇÃO	25
1.1 JUSTIFICATIVA E MOTIVAÇÃO	25
1.2 PROBLEMATIZAÇÃO	27
1.3 OBJETIVOS	27
1.3.1 Gerais	27
1.3.2 Específicos	27
1.4 ORGANIZAÇÃO DA MONOGRAFIA	28
2 DESCRIÇÃO DO PROBLEMA.....	29
2.1 CONSIDERAÇÕES INICIAIS	29
2.2 GERAÇÃO DE ENERGIA	29
2.3 PREVISÃO DE VAZÕES.....	31
2.4 SUMÁRIO DO CAPÍTULO	33
3 REVISÃO BIBLIOGRÁFICA	35
3.1 CONSIDERAÇÕES INICIAIS	35
3.2 TRABALHOS CORRELATOS.....	35
3.3 TÉCNICAS DE PREVISÃO	38
3.3.1 Redes Neurais Artificiais	38
3.3.2 Programação Genética	40
3.3.3 Regressão Linear Múltipla	41
3.3.4 <i>Ensembles</i> de Previsão	42
3.4 SUMÁRIO DO CAPÍTULO	44
4 METODOLOGIA.....	45
4.1 CONSIDERAÇÕES INICIAIS	45
4.2 TREINAMENTO DO MODELO	46
4.2.1 Treinamento Único.....	46
4.2.2 Treinamento Contínuo.....	47
4.3 COMPONENTES DE PREVISÃO.....	48
4.3.1 Componentes: Redes Neurais Artificiais	49
4.3.2 Componente: Programação Genética	51
4.3.3 Componente: Regressão Linear Múltipla.....	53
4.4 <i>ENSEMBLES</i> DE PREVISÃO	53
4.5 ANÁLISE DOS DADOS	56
4.6 ANÁLISE ESTATÍSTICA.....	59
4.7 SUMÁRIO DO CAPÍTULO.....	60
5 RESULTADOS	61
5.1 MODELO DE REDE NEURAL ARTIFICIAL	62
5.2 MODELO DE PROGRAMAÇÃO GENÉTICA.....	66
5.3 MODELO DE REGRESSÃO LINEAR MÚLTIPLA	69
5.4 RESULTADOS COM <i>ENSEMBLES</i>	72
5.5 RESULTADOS DOS TESTES ESTATÍSTICOS.....	76
5.6 SUMÁRIO	77

6 CONCLUSÕES	79
7 REFERÊNCIAS BIBLIOGRÁFICAS	81
8 APÊNDICES E ANEXOS	85
8.1 APÊNDICE I	85
8.2 APÊNDICE II	94
8.3 ANEXO I	103

1

Introdução

Neste capítulo será apresentada uma visão geral sobre o tema que será tratado neste trabalho. Na Seção 1.1 são apresentadas a justificativa e a motivação do trabalho. Na Seção 1.2 é discutido o problema que envolve o tema proposto. Na Seção 1.3 são mostrados quais são os objetivos que este trabalho se propõe a realizar e na Seção 1.4 é mostrada a organização desta monografia.

No contexto atual, a energia pode ser considerada um elemento indispensável ao desenvolvimento econômico, na qual, de um lado fornece os serviços e infraestrutura essenciais para a sociedade e de outro, sua grande quantidade ou carência tem impacto em diversas áreas, tais como: segurança nacional, competitividade industrial, economia e a estrutura social (Salgado, 2009).

Segundo ANEEL (2009), cerca de 80% da energia elétrica que é utilizada no Brasil origina-se de usinas hidrelétricas. Isto ocorre porque o Brasil possui bacias hidrográficas compostas de rios estáveis e caudalosos e que estão localizados em várias regiões do país. Desta forma, como o país possui grande parte da energia elétrica advinda de fontes hidrominerais, uma pequena redução nos desperdícios pode impactar em uma grande economia nos recursos naturais disponíveis e na redução de custos de uma empresa geradora de energia.

1.1 Justificativa e Motivação

A produção energética por uma hidrelétrica depende fundamentalmente das séries de vazões afluentes. Entretanto, a incerteza das vazões futuras e sua aleatoriedade são obstáculos que dificultam todo o planejamento da operação do sistema energético brasileiro.

A partir disso, para auxiliar na busca pela redução dos fatores que prejudicam o planejamento das hidrelétricas, pode-se destacar a realização da previsão de vazões como uma das alternativas para maximizar os resultados obtidos, pois a geração desta forma de energia depende principalmente das séries de vazões afluentes. Com a previsão de vazões, as hidrelétricas podem planejar suas decisões com a possibilidade de se anteciparem sobre algumas desconformidades que poderão vir a acontecer, tornando-as mais competitivas e aproveitando de forma mais adequada os recursos hídricos disponíveis. Além disso, as previsões servem como subsídio a outros setores usuários da água, como a irrigação, a pesca, o turismo, o lazer e a navegação. Vale lembrar que o setor elétrico brasileiro detém a maior parte do controle da quantidade de água disponível nos grandes reservatórios, que até pouco tempo destinavam-se exclusivamente à geração de energia, hoje são alvos de interesses diversos e conflitantes dos demais setores que utilizam a água. Nesse contexto, cresce a importância na área de planejamento e controle de sistemas de recursos hídricos.

Vale salientar que este processo de previsão pode ser considerado custoso, onde a aleatoriedade das vazões são limitações que dificultam o planejamento da operação do sistema energético brasileiro (Silva, 2007). Neste sentido, para se conhecer a disponibilidade energética é possível realizar um estudo sobre a quantidade de água disponível nos reservatórios das usinas, isto é, pode-se realizar a previsão de vazões deste reservatório. Uma das formas para se alcançar tal objetivo é utilizar alguma abordagem computacional para beneficiar este processo, assim é possível citar: Redes Neurais Artificiais (Haykin, 2007), Programação Genética (Koza, 1992), Modelos Autorregressivos (Box & Jenkins, 1976), Lógica Neuro-Fuzzy (Jang, 2008), entre outras, que são utilizadas com frequência na construção de modelos para solucionar problemas relacionados à previsão de séries temporais em diferentes áreas.

Contudo, é muito difícil encontrar um modelo que é capaz de sempre obter bons resultados de previsão, pois geralmente uma série de dados pode assumir novo padrão de comportamento e tornar o modelo ineficaz, ou então, um modelo pode compreender melhor um comportamento peculiar de uma série, enquanto outro pode identificar de forma mais eficaz outro comportamento de uma mesma série. Neste sentido, o objetivo deste trabalho é realizar a combinação de vários

preditores, tais como: Rede Neural Artificial (RNA), Programação Genética (PRG), Regressão Linear Múltipla (RLM), para se conseguir obter melhores resultados na realização da previsão de vazões para algumas Usinas da Bacia do Rio Grande, mais especificadamente: Camargos, Itutinga, Funil Grande e Furnas.

1.2 Problematização

A geração de energia elétrica através de recursos hidrominerais pode ser considerada um processo difícil de ser gerenciado devido aos fatores climáticos que envolvem este processo, além disso, é difícil encontrar um modelo computacional capaz de representar, de forma correta, uma série de vazões devido a sua aleatoriedade, dificultando o processo de previsão da mesma. Com base nisto, esta pesquisa se propõem a resolução da seguinte questão:

É possível combinar os resultados obtidos por vários modelos de previsão e estes se apresentarem de forma satisfatória para a resolução do problema de previsão de vazões?

1.3 Objetivos

1.3.1 Gerais

Combinar vários preditores com objetivo de minimizar os erros obtidos na previsão de vazões afluentes, para que seja possível auxiliar o planejamento da geração de energia por hidrelétricas.

1.3.2 Específicos

- Estudar modelos de previsão a fim de conhecer os que mais se enquadram no problema;

- Aplicar os modelos computacionais para realizar a previsão de vazões;
- Construir uma metodologia capaz de combinar os resultados obtidos;
- Verificar o comportamento dos resultados combinados.
- Realizar um estudo detalhado sobre as previsões de algumas usinas da Bacia do Rio Grande;
- Criar uma base com resultados de previsão de vazões das usinas pertencentes ao SIN.

1.4 Organização da Monografia

O Capítulo 2 é dedicado a realizar a descrição do problema de previsão de vazões, onde é feita uma breve análise de como se dá a geração de energia elétrica no Brasil e são considerados alguns aspectos sobre a previsão de séries temporais assim como as séries de vazões. No Capítulo 3 são mostrados alguns sistemas que objetivam realizar a previsão de vazões afluentes, assim como, os erros obtidos por estes sistemas. Neste capítulo são mostradas as técnicas que serão utilizadas para a resolução deste problema. As técnicas abordadas são os modelos de: Redes Neurais Artificiais, Programação Genética e Regressão Linear Múltipla. O Capítulo 4, por sua vez, mostra a metodologia que foi utilizada para realizar as previsões, neste capítulo são discutidos como foram realizados o treinamento e a configuração dos parâmetros utilizados pelos modelos de previsão. No Capítulo 5 são mostrados os resultados obtidos pelos modelos individuais e pelos *ensembles* propostos. Já no Capítulo 6 são apresentadas as conclusões do trabalho, assim como algumas considerações que apontam para trabalhos futuros.

2

Descrição do Problema

Nesse capítulo, inicialmente são abordados alguns conceitos a forma que ocorre a geração atual de energia no Brasil e é realizada uma descrição do problema de previsão de vazões. Na Seção 2.2 são feitas algumas considerações sobre a geração de energia no setor elétrico brasileiro. Na Seção 2.3 são discutidos aspectos sobre séries temporais e séries de vazões.

2.1 Considerações Iniciais

No Brasil, a geração de energia ocorre principalmente através de hidrelétricas devido à disponibilidade abundante de água e pelos aspectos geográficos presentes. Para maximizar o uso dos recursos hidrominerais existentes pode-se utilizar a previsão de vazões afluentes com o intuito de auxiliar no planejamento da operação de uma hidrelétrica.

A previsão de vazão consiste basicamente na estimativa do escoamento afluente com determinada antecedência, e pode ser considerada uma das formas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos (Tucci & Collischonn, 2003).

2.2 Geração de Energia

No contexto atual, a energia elétrica representa cerca de 40% do consumo total de energia do Brasil. De acordo com os dados levantados por Cicogna (2003), o investimento brasileiro em energia elétrica teve maior relevância a partir da década de 70, quando em 1975 a eletricidade representava menos de 22% do consumo total de energia no país.

Devido a fatores hidrográficos, a geração de energia elétrica no Brasil é predominantemente hidrelétrica, com apenas 16% de capacidade de origem termelétrica. Essa concentração na produção de eletricidade por fontes hidrelétricas distingue o país dentre as demais nações do mundo (Cicogna, 2003). Segundo o Balanço Energético Nacional de 2009, publicado no site da Empresa de Pesquisa Energética - EPE (EPE, 2009), as hidrelétricas são responsáveis por quase 80% de toda a energia elétrica gerada no país, o que torna o Brasil o terceiro maior produtor de energia hidrelétrica do mundo, permanecendo atrás somente do Canadá e da China, respectivamente, seguido dos Estados Unidos e da Rússia.

No Brasil, a maior parte da energia utilizada provém basicamente das usinas hidrelétricas e das termelétricas. Entretanto deve-se minimizar a utilização de energia gerada pelas termelétricas, pois este tipo de geração de energia apresenta elevada taxa de poluição e geração de resíduos, que podem afetar diretamente o meio ambiente comprometendo a sociedade como um todo (Machado & Hoffmann, 2003). Já as usinas hidrelétricas podem trazer danos ao meio ambiente no momento da sua construção, onde é necessário inundar uma determinada região para os reservatórios (Farias & Melo, 2006). No entanto, é importante salientar que a energia provinda de usinas hidrelétricas é a que apresenta menores desgastes ambientais em se comparado com as termelétricas, pois ocorre de maneira limpa não gerando grandes quantidades de poluição ao meio ambiente.

De acordo com Biondi *et al* (2005), o sistema hidrelétrico brasileiro proporciona certos aspectos que o torna desigual de outros sistemas que utilizam a geração de energia através de hidrelétricas. Uma característica marcante nas vazões dos rios brasileiros é que possuem grande sazonalidade e alto nível de incerteza, ao contrário do hemisfério norte, onde o regime hidrológico é proveniente, basicamente, do degelo. Este fato contribui para aumentar ainda mais a dificuldade de planejamento e operação do setor elétrico brasileiro.

2.3 Previsão de Vazões

O comportamento da série de vazões pode ser definido como uma série temporal, onde é obtido um conjunto de observações que são realizadas sequencialmente em determinado espaço de tempo, desta forma, realizar a previsão de vazões significa prever uma série temporal.

Antecipar os resultados em uma série temporal significa conhecer de antemão determinados acontecimentos que se realizarão em um determinado período de tempo. De uma forma conceitual, Samohyl; Rocha & Matos (2001, p. 5) afirmam que:

“Uma série temporal, $f(t)$, pode ser definida como uma função de uma variável independente de tempo t , vinculada a um processo em que uma descrição matemática é desconhecida (ou considerada como tal). A característica principal de tais séries é que o seu comportamento futuro não pode ser previsto exatamente, como pode ser previsto de uma função determinística, conhecida em t . Contudo, o comportamento de uma série temporal pode algumas vezes ser antecipado através de procedimentos estocásticos.”

Neste contexto, de acordo com Barbancho (1970), uma previsão é uma manifestação relativa a sucessos desconhecidos em um futuro determinado, no qual a previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma conseqüente tomada de decisão, visando atingir determinados objetivos.

Segundo Mueller (1996), uma série temporal pode ser representada considerando um conjunto de observações coletadas até o instante t e de um modelo que represente esses fenômenos, a previsão do valor da série no tempo $t+h$ pode ser obtida. A Figura 1 lustra esta abordagem, onde é possível conseguir um dado valor a partir de um determinado tempo.




Figura 1 - Obtenção de um dado valor através de um determinado tempo

Fonte: Mueller, 1996.

O autor Abelém (1994) afirma que, para que seja possível realizar a análise de uma série temporal deve-se observar os seguintes fatores: investigar o mecanismo gerador da série temporal, descrever o comportamento da série, procurar periodicidades relevantes nos dados e fazer previsões de valores futuros da série. Portanto, para este trabalho devem ser considerados estes fatores, onde o objetivo é encontrar intervalos regulares na série e a partir deles conseguir estimar a previsão de valores futuros dado um determinado tempo.

Segundo Guilhon (2002), o ser humano está em uma busca constante para conseguir prever os fatores que influenciam no comportamento da natureza. Neste trabalho, um dos aspectos que deve ser considerado é o de prever o comportamento das vazões nos rios, mais precisamente, encontrar as previsões das vazões afluentes. De acordo com Bravo *et al* (2008), a previsão de vazão consiste em estimar o escoamento em um curso de água com uma determinada antecedência. Além disso, pode ser considerada uma das técnicas utilizadas para minimizar o impacto das incertezas do clima sobre o planejamento dos recursos hídricos disponíveis (Tucci & Collischonn, 2003).

Previsões auxiliam no desenvolvimento de sistemas de prevenção contra cheias ou secas, o que pode facilitar a antecipação do começo das ações a fim de diminuir os possíveis danos materiais, sociais e humanos causados por eventos extremos (Bravo *et al*, 2008).

A previsão de vazões pode ser dividida em: previsão mínima, previsão média e previsão máxima, na qual é possível auxiliar de diferentes formas o planejamento de uma usina hidrelétrica. De acordo com Valença (1999 *apud* Prudêncio, 2002), a

previsão de vazões mínimas pode ser útil para planejar o abastecimento de água e prever condições críticas. A previsão das vazões médias auxilia o atendimento à demanda de energia, uma vez que essas previsões indicam o potencial de geração de energia no futuro. Já a previsão das vazões máximas é útil para o controle de inundações e planejamento de obras a serem realizadas.

Neste trabalho, será abordada a previsão de vazões médias, no qual permite que os diferentes modelos de operação, otimização e simulação energética possam avaliar as condições operacionais das usinas hidrelétricas no futuro, propiciando subsídios para a tomada de decisões. Desta forma, é possível utilizar os resultados destas previsões para programar as atividades à luz dos recursos hídricos disponíveis nas diferentes bacias hidrográficas (Guilhon, 2002).

Além do que foi discutido anteriormente, a previsão de vazões também serve como subsídio a outros setores usuários da água, como: a irrigação, a pesca, o turismo, o lazer e a navegação. Estes setores utilizam destas previsões para programar suas atividades de acordo com a disponibilidade dos recursos hídricos presentes (Guilhon, 2002).

No entanto, para que seja possível realizar a previsão de um determinado valor, é necessário que exista alguma técnica que favoreça tal fato. Neste trabalho serão utilizadas as Redes Neurais Artificiais (Haykin, 2007), Programação Genética (Koza, 1992) e a Regressão Linear Múltipla (Box & Jenkins, 1976).

2.4 Sumário do Capítulo

Neste capítulo foram apresentados alguns conceitos sobre geração de energia com o intuito de demonstrar a relevância das hidrelétricas no cenário atual de geração de energia. Além disso, foram discutidos aspectos sobre como a previsão de vazões pode auxiliar no planejamento da operação de usinas hidrelétricas.

No capítulo seguinte, será feita uma revisão em trabalhos que objetivam realizar a previsão de vazões, assim como alguns sistemas que são efetivamente utilizados no mercado para auxiliar no gerenciamento dos recursos hídricos. Serão mostradas também as abordagens computacionais utilizadas para realizar as previsões neste trabalho.

3

Revisão Bibliográfica

Neste capítulo serão mostrados alguns trabalhos relacionados e sistemas que são efetivamente utilizados no mercado para realizar a previsão de vazões, além disso, são discutidas as técnicas computacionais que serão utilizadas para realizar as previsões neste trabalho. Na Seção 3.2 são mostrados os trabalhos relacionados com a previsão de vazões. Na Seção 3.3 são apresentados os modelos de previsão utilizados e como serão apresentados os resultados utilizando os ensembles.

3.1 Considerações Iniciais

Na literatura sobre previsão de vazões são discutidos diversos aspectos sobre a maneira como são realizadas as previsões, tais como: qual o modelo utilizado para prever, a configuração dos parâmetros do modelo, os horizontes de previsão, entre outros. Na seção seguinte, segue uma revisão de alguns sistemas que realizam a previsão para a bacia do Rio Grande, desta forma será possível verificar a consistência dos dados e dos resultados obtidos neste trabalho.

3.2 Trabalhos Correlatos

No sistema descrito por Luna; Ballini & Soares (2007a) é apresentada uma metodologia que realiza a previsão das vazões para a Usina de Furnas seguindo um horizonte mensal. Para realizar as previsões, é utilizado um método baseado em regras *fuzzy* adaptativas, denominado A-FSM. Neste trabalho, os dados estão apresentados desde 1931 até 2005 seguindo uma discretização mensal, no qual representam o volume da vazão da Usina de Furnas. Para o ajuste do modelo de previsão foram utilizados os dados de 1931 até 1995 e os testes foram realizados

para os anos de 1996 até 2005. Com relação aos resultados, Luna; Ballini & Soares (2007a) apresentam uma análise dos erros obtidos pelo sistema desenvolvido (A-FSM) e por outros sistemas relacionados, tais como: C-FSM (Luna; Ballini & Soares, 2007b) e ANFIS (Jang, 2008). A Tabela 1 mostra os resultados obtidos por estes sistemas.

Tabela 1 - Erros Obtidos. Fonte: Luna; Ballini & Soares (2007a)

<i>Média dos Erros Obtidos</i>		
A-FSM	ANFIS	C-FSM
19,08%	20,12%	20,19%

Outro sistema que se propõem a realizar a previsão de vazões para Furnas é mostrado por Bravo *et al* (2008). Neste trabalho é mostrado um modelo de previsão diário de vazão que utiliza RNA como técnica de previsão. Neste modelo, a previsão segue um horizonte de doze dias à frente, no qual, para cada dia é criada uma nova RNA com intuito específico de realizar a previsão para um determinado dia. Os dados utilizados neste trabalho compõem uma série histórica diária de 1970 até 1980. Para a utilização de uma RNA é necessário a divisão dos dados em conjunto de treino e validação. Portanto, o conjunto de treinamento é composto de dados dos períodos de 12/01/1970 à 17/07/1974 e 13/10/1978 à 31/12/1980. O conjunto de validação se estende de 18/07/1974 à 12/10/1978. Para avaliar o desempenho da rede o conjunto de verificação é composto dos dados de 12/01/1996 à 31/12/2000. Os resultados obtidos por este sistema se apresentam melhores do que os obtidos pelo modelo ETA (Cataldi *et al*, 2007), que é atualmente utilizado pelo ONS. Para o período que foi utilizado como base de testes os resultados do modelo ETA foram de 22% e o resultado obtido pela RNA foi de 13,7%.

No trabalho apresentado por Gonçalves & Buba (2007) é descrito um sistema de previsão de vazões que é utilizado pela Companhia Paranaense de Energia (COPEL). Este pode ser considerado um sistema de previsão hidrológico que gera previsões de vazão em escala horária em pontos de interesse da Bacia do Iguaçu. Esse sistema foi desenvolvido com base no modelo de Sacramento Modificado (Georgakakos *et al*, 1988). A implementação desse modelo ocorreu na forma semi distribuída onde foi efetuada com a subdivisão da Bacia do Iguaçu em

sub-bacias com áreas da ordem de 3.000 Km², obedecendo ao fluxo normal de vazão da bacia.

Segundo Gonçalves & Buba (2007), o Sistema de Previsão e Simulação Hidrológica da bacia do Rio Iguaçu (SISPSHI) já está em funcionamento há pelo menos cinco anos na divisão de hidrologia da COPEL, no qual foi implementado para simular o comportamento hidrológico do Rio Iguaçu. O SISPSHI é composto por um núcleo, representado pelo modelo hidrológico de Sacramento Modificado (Georgakakos *et al*, 1988), que realiza a consulta a um banco de dados, que contém os dados hidrometeorológicos e monta os arquivos de entrada do modelo. Existe ainda um módulo correspondente à interface gráfica, desenhada para visualizar o resultado das previsões. O sistema realiza previsões quatro vezes ao dia, em escala horária com horizonte de 120 horas (cinco dias). Neste sistema, o processo de eliminação de erros, frequentemente denominado por atualizador de estado, é fundamentado na aplicação do Filtro de Kalman Estendido (Elch & Bishop, 2001).

Com relação aos resultados apresentados por este sistema, os seguintes erros foram obtidos: desvios de 3,7% para o horizonte de 24 horas, desvios de 8,5% para o horizonte de 48 horas e aproximadamente de 13,7% para o horizonte de 72 horas. Com bases nestes dados é possível perceber que quanto mais se distancia da data atual, maior é a taxa de erro apresentada pelo sistema, vale ressaltar que a discretização dos dados se dá por escala horária e com isto o sistema não apresenta bons resultados para realizar as previsões para horizontes de médio e longo prazo.

Outro sistema de previsão de vazões que também é aplicado na prática foi desenvolvido pela Companhia Energética de Minas Gerais (CEMIG) em conjunto com o Departamento de Engenharia Hidráulica e de Recursos Hídricos da Escola de Engenharia da Universidade Federal de Minas Gerais (UFMG). Neste projeto, foi concebido um sistema de previsão afluente para o seu parque de usinas hidrelétricas e como fruto desta pesquisa foi concebido o Modelo Rio Grande. Primeiramente o Modelo Rio Grande foi construído para a bacia hidrográfica da Usina Hidrelétrica de Camargos, localizada na cabeceira do Rio Grande, posteriormente o modelo passou por modificações visando torná-lo apropriado a aplicações genéricas e passou a se chamar Sistema Rio Grande. No trabalho apresentado por Chiari; Costa & Botelho (2007), é apresentado este sistema de previsão de vazões aplicado à Bacia do Rio Grande. Este sistema opera sobre a área

incremental entre as Usinas de Itumbiara e São Simão. Os dados utilizados nesse trabalho incluem dados de vazão, precipitação, temperatura do ar, umidade relativa do ar, velocidade do vento, pressão atmosférica e radiação solar. Estes dados foram fornecidos dos bancos de dados da Agência Nacional de Águas (ANA), da CEMIG e do ONS. O período corresponde aos anos de 1980 a 2001, no qual estes 22 anos de registros foram divididos em um período de calibração (1991 a 2001) e um período de verificação (1980 a 1990). Mais detalhes sobre estes dados estão disponíveis em Chiari; Costa & Botelho (2007). Com relação aos resultados obtidos, a Tabela 2 apresenta os erros que foram obtidos por este sistema. Como é possível perceber, as previsões foram realizadas de forma separada entre as estações secas e úmidas, a fim de tentar minimizar os erros obtidos nas previsões.

Tabela 2 - Índices de desempenho - Sistema Rio Grande

<i>Período</i>	<i>Erro Médio Percentual</i>
1981 a 1990	7,1%
Estação seca 1981 a 1990	15,7%
Estação úmida 1981 a 1990	15,7%
Ano mais seco - 1981	8,3%
Ano mais úmido -1981/1982	17,1%

3.3 Técnicas de Previsão

Para realizar a previsão de vazões é necessária alguma abordagem que possibilite tal fato. A seguir serão mostradas as técnicas computacionais de previsão que foram utilizadas neste trabalho.

3.3.1 Redes Neurais Artificiais

Um dos modelos utilizados neste trabalho para realizar as previsões é a técnica baseada em Redes Neurais Artificiais (RNAs). Estas técnicas podem ser consideradas poderosas ferramentas na previsão de séries e reconhecimento de padrões, pois se inspiram em sistemas biológicos relacionados com o cérebro humano para a resolução destes problemas. Devido a este aspecto biológico, as

RNAs são capazes de aprender e generalizar com a experiência de dados passados. Atualmente, RNAs têm sido utilizadas para uma grande variedade de aplicações em diferentes áreas de negócios, indústria e ciência (Zhang *et al*, 1998). No trabalho apresentado por Chakraborty *et al* (1992), é mostrado que as RNAs constituem modelos eficientes e que garantem resultados aceitáveis para a resolução de problemas que envolvem a previsão de séries temporais.

Existem várias formas de estruturar as Redes Neurais Artificiais, tais como, *Radial Basis Function* (RBF), *Probabilistic Neural Networks* (PNN), *Recurrent Neural Networks* (RNR), *Multi Layer Perceptron* (MLP), entre outras (Haykin, 2007). Neste trabalho serão utilizadas as redes neurais do tipo MLP, pois essas têm sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não linearidade (Silva, 1998).

Tipicamente, esta estrutura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias e uma ou mais camadas de saída, dependendo do problema. Os sinais de entrada são propagados camada a camada pela rede. A Figura 2 mostra um modelo neural MLP.

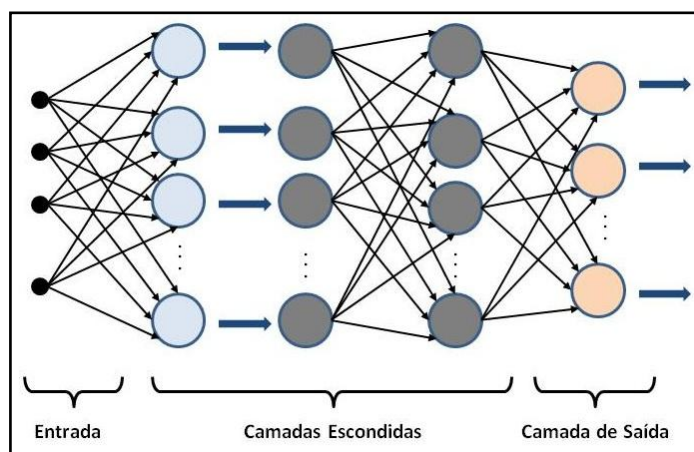


Figura 2 - Modelo Rede Neural MLP.

Um método amplamente utilizado para ajuste dos parâmetros é o algoritmo de retropropagação do erro. Este algoritmo é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (Haykin, 2007).

3.3.2 Programação Genética

A Programação Genética (PRG) é uma das técnicas da Computação Evolucionária, no qual os indivíduos que se fazem presentes no decorrer do algoritmo são representados através de árvores sintáticas, que armazenam uma determinada solução para o problema em questão. Esta técnica foi desenvolvida por John Koza (Koza, 1992) e da mesma forma como os Algoritmos Genéticos, é baseada no princípio da evolução, proposta por Charles Darwin (Darwin, 1859), onde os indivíduos que mais se adaptam ao meio ambiente sobrevivem. Com isso, a carga genética destes indivíduos será repassada aos seus descendentes que sofrerão modificações, com o objetivo de melhor se ajustar ao meio. Ao final de várias gerações, o resultado é a obtenção de uma população de indivíduos com características naturalmente selecionadas, ocorrendo desta forma uma evolução natural da população (Souza, 2006).

Na PRG, cada indivíduo é representado por uma árvore sintática, ou seja, os indivíduos são formados por uma combinação dos conjuntos de funções (operadores) e terminais (variáveis e constantes), que são determinados conforme o domínio do problema. Por exemplo, um indivíduo da população que possui a forma: $x^2 + y$, tem sua representação em forma de árvore conforme ilustra a Figura 3.




Figura 3 - Representação da fórmula $x^2 + y$

A PRG funciona da seguinte forma: primeiro é definido uma população inicial com os indivíduos aleatórios, e a partir desta população o sistema cria novos indivíduos gerando novas populações. Para que isso ocorra, os indivíduos passam por modificações, ou seja, é possível se que sejam feitas alterações em cada

indivíduo com a finalidade de encontrar uma boa solução, isto tende a continuar até que um critério de parada seja estabelecido.

A Figura 4 ilustra de forma mais clara um fluxograma do funcionamento do algoritmo de programação genética. Nessa figura é possível perceber como pode ser obtida uma solução que possua um resultado desejável para o problema.

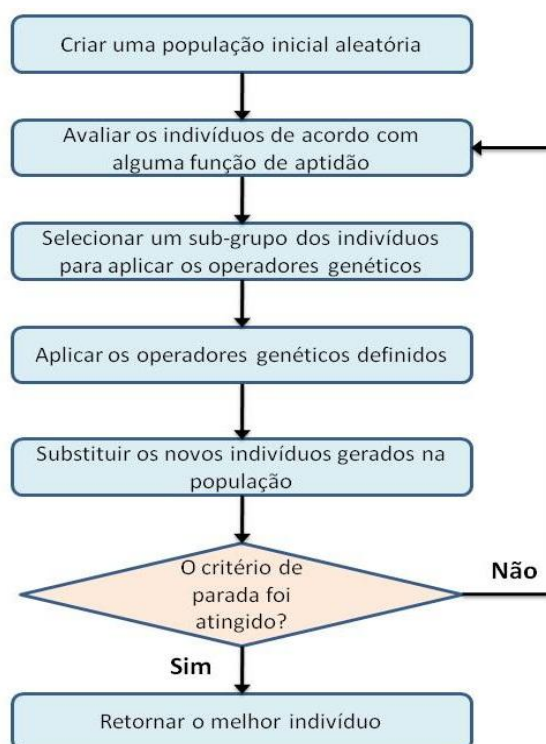


Figura 4 - Funcionamento do Algoritmo de Programação Genética

Este trabalho não tem por finalidade descrever de forma detalhada o funcionamento da Programação Genética, mais detalhes podem ser obtidos em (Koza, 1992, Souza, 2006, Ferreira; Oliveira & Paula, 2009).

3.3.3 Regressão Linear Múltipla

A Regressão Linear Múltipla (RLM) consiste em uma técnica de modelagem para analisar a relação entre uma variável dependente contínua \hat{Y} e uma ou mais variáveis independentes $\{X_1, X_2, X_3, \dots, X_n\}$ (Box & Jenkins, 1976). O principal objetivo da análise de regressão é identificar a função que a descreve, da melhor

forma, a relação existente entre estas variáveis para que seja possível prever qual valor a variável dependente vai assumir quando forem atribuídos valores para a variável independente (Russo; Camargo & Simon, 2010).

No método de RLM, a variável independente é encontrada em termos das variáveis explícitas (independentes). O modelo usado pode ser expressado da seguinte forma:

$$\hat{Y} = \alpha + \alpha_1 X_1 + \alpha_2 X_2 + \alpha_3 X_3 + \dots + \alpha_n X_n + \varepsilon \quad (1)$$

Onde \hat{Y} é a variável dependente, X_i são as variáveis independentes, α_i são os parâmetros da regressão com seus respectivos X_i e ε é o termo de erro.

O modelo de regressão linear é amplamente utilizado em diversas áreas onde se deseja realizar a previsão seguindo alguma série já conhecida. Leone (2006) faz um estudo sobre os modelos de regressão que podem ser utilizados, e em Luna; Ballini & Soares (2007a) e Bravo *et al* (2008) são mostrados alguns sistemas que utilizam a regressão linear como base para se realizar a previsão.

3.3.4 *Ensembles de Previsão*

De acordo com (Villanueva, 2006), os *ensembles* consistem de um conjunto de componentes, onde cada um representa uma possível solução, cujas classificações, no caso de problemas de classificação de padrões, ou previsões, no caso de problemas de regressão, são combinadas de diferentes formas visando ganho nos resultados.

Em Hansen & Salamon (1990) é mostrado que os resultados obtidos a partir de um sistema neural podem ser melhorados através da combinação de várias redes neurais, de forma que, as redes seriam treinadas independentes e os resultados apresentados seriam combinados resultando em um único resultado.

A partir disto, Leone (2006) define os *ensembles* como uma forma de combinar os resultados obtidos através de múltiplos regressores. O principal objetivo desta abordagem está no fato que ao fazer esta combinação há uma tendência de se conseguir um resultado mais preciso do que aquele obtido

individualmente pelo melhor dos previsores no conjunto dos modelos de previsão utilizados.

Normalmente os *ensembles* são utilizados em duas etapas, na primeira são definidos os modelos e componentes de previsão que serão utilizados e com isso todos passam pelo processo de treinamento. Já na segunda etapa, os resultados obtidos pelos previsores são agrupados seguindo alguma função, onde é gerado um único valor resultante das previsões realizadas por todos os previsores que compuseram o sistema. Existem várias formas de realizar a combinação dos resultados, no entanto as mais usadas são votação múltipla ou votação majoritária para problemas de classificação de padrões e média aritmética, média ponderada, ou até mesmo algum modelo inteligente, por exemplo RNAs, para problemas de previsão. A Figura 5 apresenta um exemplo da estrutura definida para um *ensemble* com alguns modelos de previsão e com uma única saída combinada através dos modelos definidos.

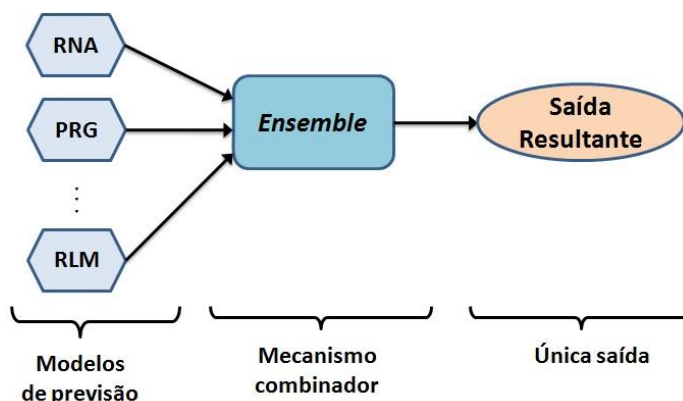


Figura 5 - Estrutura de um *ensemble* de previsão

De acordo com Leone (2006), tanto observações realizadas de forma empírica quanto em aplicações de determinados previsores específicos, é possível perceber que, dado um modelo inteligente, em alguns casos ele possui melhor comportamento do que outro para prever determinado subconjunto de dados de entrada. No entanto, é muito difícil que um determinado previsor seja capaz se comportar sempre de forma mais eficiente do que qualquer outro previsor para todo o domínio de dados de entrada. Neste sentido, a utilização de vários

previsores tem como objetivo explorar o comportamento específico de cada previsor, com o intuito de aumentar a precisão e a confiabilidade da previsão.

Vale destacar que um dos requisitos fundamentais para obter sucesso ao utilizar as técnicas de *ensembles*, é que os componentes de previsão generalizem de forma diferente, pois não faz sentido combinar modelos que adotam os mesmos procedimentos e hipóteses para a solução de um problema. É necessário que os erros cometidos pelos componentes sejam descorrelacionados (Perrone & Cooper, 1993). Devido a este fato, neste trabalho serão utilizados diferentes modelos de previsão para conseguir os resultados desejados.

3.4 Sumário do Capítulo

A partir do que foi descrito neste capítulo, foi possível perceber que existe uma busca para se realizar a previsão de vazões, pois ter conhecimento antecipado sobre as vazões afluentes pode ser considerado uma vantagem, no qual é possível auxiliar no processo de planejamento e operação de uma usina hidrelétrica. No entanto, é necessária a utilização de alguma técnica para realizar a previsão de vazões. Neste trabalho serão utilizadas as Redes Neurais Artificiais (Haykin, 2007), Programação Genética (Koza, 1992) e Regressão Linear Múltipla (Box & Jenkins, 1976) como modelos de previsão. Além disso, serão utilizados os *ensembles* (Hansen & Salamon, 1990) para realizar a combinação dos resultados apresentados pelos previsores.

No próximo capítulo será mostrada a metodologia de como os modelos de previsão foram configurados e como serão aplicados os *ensembles*, ainda é feita uma análise dos dados que servirão como base para realizar as previsões.

4

Metodologia

Neste capítulo é mostrada a metodologia utilizada. Na Seção 4.1 é feita uma breve revisão nos objetivos deste trabalho. Na Seção 4.2 são discutidos os processos de treinamento do modelo de previsão utilizados. Na Seção 4.3 é mostrada a metodologia na qual é possível obter os componentes de previsão a partir de cada modelo. A Seção 4.4 ilustra a maneira de como funcionam os ensembles propostos. Na Seção 4.5 é realizada uma análise nos dados que foram utilizados como base para realizar as previsões. Já na Seção 4.6 são mostrados quais foram os testes estatísticos utilizados neste trabalho.

4.1 Considerações Iniciais

Como já foi dito anteriormente, este trabalho foca em realizar as previsões para a Bacia do Rio Grande, mais especificadamente para as usinas de: Camargos, Itutinga, Funil Grande e Furnas. Portanto, todos os resultados obtidos pelos modelos de previsão serão referentes a estas usinas.

Para realizar as previsões propostas e com o intuito de obter bons resultados, neste trabalho foram empregados três modelos de previsão: RNA, PRG e RLM. Cada um destes modelos apresentam peculiaridades com relação aos parâmetros de configuração, ao método de entrada, à forma de realizar a previsão, entre outros. Vale ressaltar que cada configuração assumida por um modelo é denominado um componente do modelo de previsão, portanto uma RNA, por exemplo, pode possuir inúmeras configurações diferentes e cada uma delas será denominada um componente de uma RNA e cada um destes componentes poderá apresentar resultados diferentes para as mesmas entradas.

Neste trabalho serão realizadas as previsões utilizando-se de diversos componentes dos modelos já citados, e ao final os resultados apresentados pelos componentes serão combinados seguindo a metodologia dos *ensembles*. Com isso,

será possível explorar de forma mais precisa os resultados obtidos, onde é levado em consideração que um determinado modelo pode se comportar de forma mais precisa para um subconjunto de dados.

4.2 Treinamento do Modelo

Nesta pesquisa serão discutidos dois processos de configurar o treinamento do modelo para realizar a previsão, *Treinamento Único* e *Treinamento Contínuo*.

4.2.1 Treinamento Único

No processo de *Treinamento Único*, o modelo é treinado até certo ponto e é realizada a previsão para anos posteriores, sem que haja novo treinamento. A Figura 6 ilustra esta abordagem, onde é possível perceber que o modelo só precisa saber qual é o mês que será previsto, pois o ano já foi predeterminado anteriormente e possui um valor fixo durante todo o processo de treinamento do modelo. Vale lembrar que para realizar a previsão de um determinado mês, são gerados diversos componentes com o intuito de encontrar o mais adaptado para a série proposta.

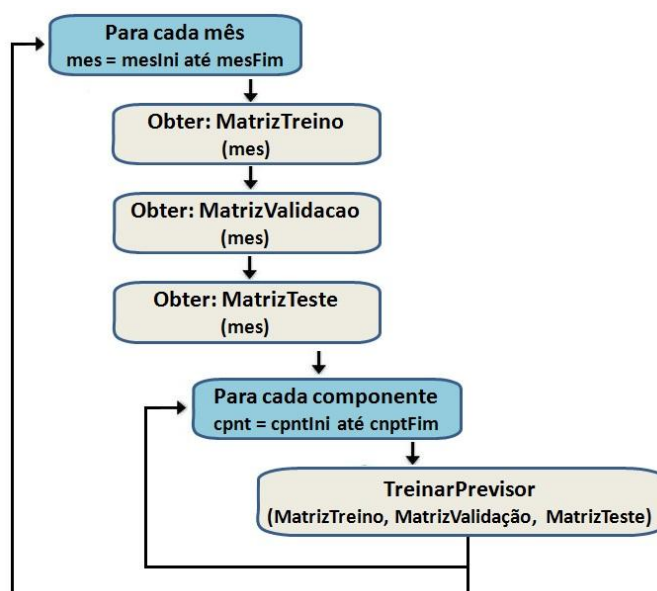


Figura 6 - Metodologia de *Treinamento Único*

4.2.2 Treinamento Contínuo

No processo de *Treinamento Contínuo*, sempre se utiliza um ano anterior ao previsto para auxiliar no treino do previsor, ou seja, a todo novo ano a ser previsto o ano anterior é utilizado como parte dos dados utilizados para realizar o treinamento do modelo. A metodologia de *Treinamento Contínuo* está ilustrada na Figura 7 e a partir desta é possível perceber que para cada mês utilizado e para cada ano previamente definido, para realizar a previsão são obtidos os dados que serão utilizados como base para o treinamento e validação do modelo de previsão. Após isto, é definida certa quantidade de componentes que serão criados para cada mês e ano, no qual, cada componente criado os parâmetros são alterados, assim, é possível encontrar componentes diferentes para realizar a previsão de um determinado período. Deste modo, para cada mês e ano que será previsto são gerados diversos componentes com o objetivo de encontrar o que mais se adapta ao período desejado.

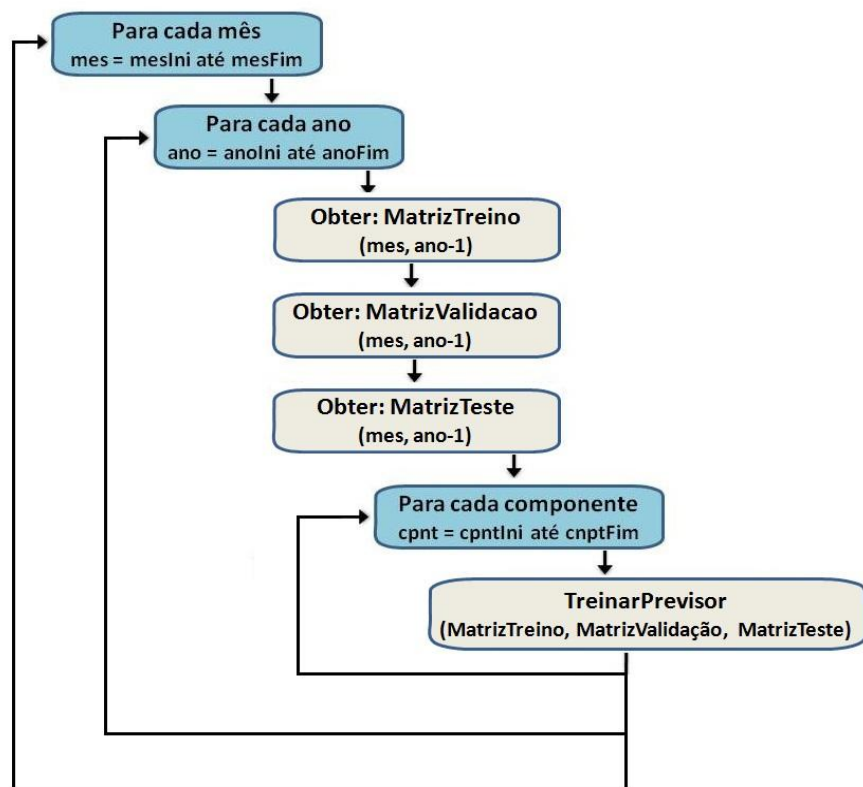


Figura 7 - Metodologia de *Treinamento Contínuo*.

Para deixar claro, por exemplo, caso se queira realizar a previsão para o mês de janeiro de 1998, os dados utilizados para o treino do modelo são os dados dos meses precedentes a janeiro de 1987 até janeiro de 1997, para conseguir os dados de validação são utilizados os dez anos que precedem o ano anterior ao desejado, neste caso, são utilizados os dados de janeiro de 1987 até janeiro 1997 e os dados utilizados para testar a rede é o ano anterior ao ano que será previsto, ou seja, os dados dos meses de julho de 1997 até dezembro de 1997. A Tabela 3 ilustra de forma clara os dados utilizados para realizar o treino, a validação e o teste do modelo de previsão.

Tabela 3 - Exemplo de padrões utilizados para treinamento

Matriz Treino				
jul/86	ago/86	...	dez/86	jan/87
⋮	⋮		⋮	⋮
jul/97	ago/97	...	dez/97	jan/98

Matriz Validação				
jul/96	ago/96	...	dez/96	jan/97
⋮	⋮		⋮	⋮
jul/97	ago/97	...	dez/97	jan/98

Padrão Teste				
jul/97	ago/97	...	dez/97	<i>previsto</i>

4.3 Componentes de Previsão

Conforme já foi mencionado anteriormente, para se conseguir um componente de previsão a partir de um modelo, é preciso que sejam alterados alguns parâmetros ou as entradas do modelo e assim realizar a previsão. Uma das dificuldades encontradas para se realizar esta tarefa é que cada modelo apresenta suas próprias características e parâmetros que devem ser exploradas de forma a encontrar melhores resultados.

Um parâmetro que é comumente utilizado pelos modelos de previsão de vazões é o número de atrasos que compõem os padrões de entrada, neste caso os padrões utilizados pelo modelo foram os meses imediatamente anteriores ao mês desejado a ser previsto. Desta forma, o número de atrasos corresponde à quantidade de meses que serão levados em consideração para a composição do padrão. A Tabela 4 exemplifica um padrão utilizado pelo sistema que utiliza seis atrasos, onde a previsão será realizada para o mês de janeiro de 1998 e os meses de julho até dezembro de 1997 são utilizados como entradas para o modelo. Neste caso t representa apenas uma generalização do padrão utilizado pelo modelo, no qual $t-n$ são as componentes do padrão utilizadas como entrada e $t+1$ é a saída desejada do modelo.

Tabela 4 - Exemplo do padrão utilizado pelos modelos

<i>Entradas</i>							<i>Saída Desejada</i>
Mês	jul	ago	set	out	nov	dez	jan
Série	$t-5$	$t-4$	$t-3$	$t-2$	$t-1$	t	$t+1$

A seguir será mostrada a forma como serão gerados os componentes a partir dos modelos de RNA, PRG e RLM utilizados neste trabalho.

4.3.1 Componentes: Redes Neurais Artificiais

Para o modelo de RNA, foi realizado um estudo exploratório sobre os parâmetros que mais se adaptaram ao problema de previsão de vazões. Para iniciar este estudo foi necessário definir quais seriam os parâmetros e qual a faixa de valores que cada parâmetro poderia assumir durante a fase de treinamento das RNAs. Na Tabela 5 é possível visualizar quais foram estes valores.

Tabela 5 - Faixa de valores dos parâmetros do modelo RNA.

<i>Parâmetros da RNA.</i>	
Número de Camadas	[3 - 8]
Número de Neurônios	[1 - 12]
Taxa Aprendizagem	[0.0 - 1.0]
Termo Momentum	[0.0 - 1.0]
Função de Ativação	[Tan. Hiperbólica, Logística]

Para encontrar os melhores parâmetros, o experimento ocorreu da seguinte forma: foram realizadas 500 previsões para as usinas definidas, onde os parâmetros da RNA foram estimados aleatoriamente através de uma busca exaustiva no domínio apresentado na Tabela 5, desta forma foi possível encontrar os parâmetros que poderiam ser os mais adaptados para este modelo de previsão. A Figura 8 ilustra a metodologia de como foram realizados os experimentos para a determinação dos resultados e para a definição dos parâmetros do modelo.

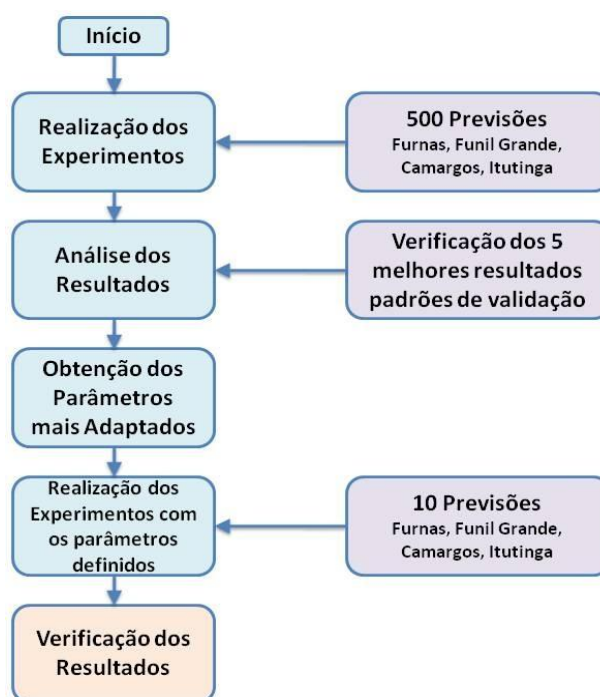


Figura 8 - Metodologia utilizada para encontrar os parâmetros mais adaptados.

Como é possível perceber através dessa figura, em princípio foram realizadas 500 previsões para as usinas definidas e a partir dos resultados obtidos foi realizada uma análise para encontrar os valores dos parâmetros que mais se adaptaram ao modelo, foi considerado o modelo com os parâmetros mais adaptados o que possuiu menor erro percentual em relação ao resultado real, onde o erro foi calculado com base na média de previsão dos cinco melhores resultados obtidos nos padrões de validação. Após isso, foram realizados novos experimentos já com os parâmetros definidos, foram geradas 10 previsões para cada usina, desta forma foi possível verificar se o modelo configurado com os parâmetros obtidos

realmente se comportou de forma estável, ou seja, se os resultados obtidos não possuíam grande variação.

A partir destes experimentos foi possível identificar qual a faixa de valores que mais se adaptam para realizar a previsão de vazões. A Tabela 6 mostra quais valores tiveram maior adaptabilidade tornando o modelo mais estável com menores índices de erros.

Tabela 6 - Faixa de valores dos parâmetros do modelo de RNA.

<i>Parâmetros da RNA</i>	
Quantidade de padrões	[20 - 65]
Número de Atrasos	[5 - 12]
Número de Camadas	[3 - 4]
Número de Neurônios	[9 - 10]
Taxa Aprendizagem	[1.0 - 2.0]
Termo Momentum	[0.4 - 0.6]
Função de Ativação	[Tan. Hiperbólica, Logística]

Uma descrição mais detalhada de como foram realizados os experimentos e sobre os resultados obtidos podem ser encontrados em no Apêndice I.

Portanto, todos os componentes de previsão que utilizam as RNAs como modelo, terão os parâmetros e a faixa de valores que foram definidas na Tabela 6.

4.3.2 Componente: Programação Genética

Para o modelo de programação genética utilizado neste trabalho, para criar os componentes de previsão, além do número de atrasos que já foi dito, existem outros parâmetros que podem ser alterados. Os parâmetros presentes no modelo de programação genética que foram explorados neste trabalho durante a execução dos testes estão descritos na Tabela 7.

Tabela 7 - Faixa de valores dos parâmetros do modelo de Programação Genética.

<i>Parâmetros da Programação Genética</i>	
Quantidade de padrões	[20 - 65]
Número de Atrasos	[5 - 12]
Operadores	[+, -, *, /]
Tipos de Mutações	[M1, M2, M3, M4]

A quantidade de padrões que são utilizados como treinamento é um parâmetro, que, na programação genética, se apresenta de forma bastante sensível. Pois, ao se utilizar poucos ou muitos padrões para o treinamento, o previsor não apresenta bons resultados. Isto ocorre, pois o modelo de programação genética gera árvores que se adaptam a série que será prevista, desta forma, quando se utiliza poucos padrões as árvores não são treinadas o suficiente para se adequar aos padrões determinados, já quando se trabalha com muitos padrões de treinamento, é possível que haja desconformidades na série e isto faz com que o modelo não consiga determinar uma equação que defina de forma correta a série a ser prevista. No caso da previsão de vazões, isto é fácil de perceber devido às mudanças climáticas que estão ocorrendo, pois quando se trabalha com dados mais antigos é certo que há uma diferença dos padrões atuais das vazões (Marengo, 2008).

Vale lembrar que o funcionamento do modelo de programação genética utilizado neste trabalho, consiste em gerar árvores sintáticas, que representam equações matemáticas, onde são utilizados: operadores, variáveis e constantes. Conforme o modelo vai sendo treinado, as árvores vão se adaptando às entradas, e ao final, espera-se encontrar uma equação que possa representar da melhor forma este conjunto de dados. No caso de previsão de vazões, é gerada uma árvore para representar cada mês e ano definidos, onde as entradas são os meses que antecedem ao mês desejado para realizar a previsão.

Considerando a geração de árvores para se conseguir realizar a previsão, outro parâmetro explorado neste trabalho foi quais operadores poderiam compor a equação que define o previsor utilizado. Como mostra a Tabela 7, os operadores utilizados foram: soma, subtração, multiplicação e divisão. Devido à programação genética ser um algoritmo evolutivo, uma das formas de se conseguir novos indivíduos é através das mutações. Neste trabalho foram utilizadas quatro tipos de mutações: Mutação 1, Mutação 2, Mutação 3 e Mutação 4.

A Mutação 1 consiste em escolher um nó aleatório da árvore, removê-lo e na sua posição colocar ou uma nova subárvore, uma constante ou uma variável criada aleatoriamente. Na Mutação 2, é selecionado um operador e este é substituído por

algum outro operador que foi definido no conjunto de operadores. A Mutação 3 permite que seja alterado o valor de uma constante na equação ou então que seja alterado o domínio de uma variável e na Mutação 4, assim como na Mutação 1, é possível que a árvore sofra algumas podas, no qual um nó que pode representar uma subárvore, seja substituído por uma constante ou uma variável. No decorrer dos experimentos estas mutações são combinadas de forma aleatória e a partir desta combinação podem ser gerados diversos componentes de previsão. É importante salientar que os algoritmos evolutivos podem apresentar inúmeros parâmetros de configuração que podem ser ajustados conforme o problema proposto, no entanto o foco deste trabalho não é explorar todos os possíveis parâmetros e sim focar apenas nos parâmetros já citados na Tabela 7.

4.3.3 Componente: Regressão Linear Múltipla

No modelo de regressão linear múltipla não é possível a configuração de muitos parâmetros, entretanto para gerar os componentes de previsão foram utilizados os seguintes parâmetros:

- Número de atrasos que compõem o padrão de treinamento, que já foi discutido anteriormente;
- Quantidade de padrões que são utilizados para realizar o treinamento do modelo.

A partir da variação destes parâmetros será possível obter vários componentes de RLM para realizar a previsão de vazões.

4.4 *Ensembles* de Previsão

O intuito principal deste trabalho foca na combinação dos resultados apresentados pelos modelos de previsão com o objetivo de se conseguir melhores resultados. A partir da definição dos modelos já realizada, agora será possível compreender os mecanismos de combinação que foram aplicados.

Os *ensembles*, como já foram discutidos, consistem em agrupar os valores apresentados pelos diversos componentes que foram gerados através das variações dos parâmetros dos modelos de previsão. Foram utilizados quatro diferentes tipos de combinação dos resultados: Média Aritmética, Média Ponderada, Média Geométrica e Média Quadrática. A Tabela 8 apresenta estas médias que foram utilizadas para combinar os valores obtidos.

Tabela 8 - Ensembles utilizados para previsão

Médias Utilizadas	Descrição
Média Aritmética	$\overline{MA} = \frac{X_1 + X_2 + X_3 + \dots + X_n}{n} \quad (2)$
Média Ponderada	$\overline{MP} = \frac{\rho_1 X_1 + \rho_2 X_2 + \rho_3 X_3 + \dots + \rho_n X_n}{\rho_1 + \rho_2 + \rho_3 + \dots + \rho_n} \quad (3)$
Média Geométrica	$\overline{MG} = \sqrt[n]{X_1 \cdot X_2 \cdot X_3 \cdot \dots \cdot X_n} \quad (4)$
Média Quadrática	$\overline{MQ} = \sqrt{\frac{X_1^2 + X_2^2 + X_3^2 + \dots + X_n^2}{n}} \quad (5)$

Para exemplificar esta metodologia, a Tabela 9 ilustra um exemplo no qual é realizada a previsão para o mês de julho para os anos de 1996 até 2005 utilizando como base os dados das vazões da Usina de Furnas. Essa tabela mostra os resultados obtidos por quatro componentes individuais e ao final é calculado o Erro Médio Relativo (EMR) de cada componente. Vale salientar que é possível utilizar várias componentes para realizar a previsão de um determinado período, pois ao final o erro apresentado será combinado, além disso, não é necessário conhecer qual é o modelo que gerou um componente, mas saber os resultados apresentados pelo componente, ou seja, para os *ensembles* não importa quais são as técnicas de previsão que foram utilizadas, o que é importante conhecer são os resultados apresentados pelos previsores.

Tabela 9 - Previsão para julho 1996 - 2006. Usina de Furnas (m³/s).

Julho	Resultado Real	Componente #1	Componente #2	Componente #3	Componente #4
1996	442	418	425	429	437
1997	578	586	609	615	592

<i>Julho</i>	<i>Resultado Real</i>	<i>Componente #1</i>	<i>Componente #2</i>	<i>Componente #3</i>	<i>Componente #4</i>
1998	362	479	406	409	408
1999	400	351	383	379	416
2000	419	369	369	351	410
2001	250	256	260	247	279
2002	381	351	360	360	375
2003	385	372	342	340	411
2004	564	542	524	530	467
2005	561	515	575	588	580
Média de Erro (EMR)		8,95%	6,80%	7,28%	6,28%

A Tabela 10 mostra a aplicação dos *ensembles* aos resultados obtidos pelas previsões mostradas na Tabela 9. Na Tabela 10 é possível perceber que os resultados dos componentes foram combinados de acordo com o ano no qual foi realizada a previsão. Nesta tabela, é mostrado também o erro médio obtido pelos *ensembles* onde é importante notar que os erros foram inferiores aos apresentados pelos componentes individuais.

Tabela 10 - Resultado dos *ensembles* julho 1996 - 2010. Usina Furnas (m³/s).

<i>Julho de:</i>	<i>Média Aritmética</i>	<i>Média Ponderada*</i>	<i>Média Quadrática</i>	<i>Média Geométrica</i>
1996	427	427	426	430
1997	601	607	601	596
1998	426	415	427	411
1999	382	382	383	385
2000	375	368	376	383
2001	261	258	261	258
2002	361	360	361	365
2003	366	351	367	369
2004	516	522	517	524
2005	564	573	565	563
Média de Erro (EMR)	6,34%	6,67%	6,31%	5,08%

* Para fins de exemplo, a ponderação utilizada foi escolhida de forma empírica, onde foi aplicado 50% para componente 2, 30% para o componente 3 e 10% para os componentes 1 e 4.

4.5 Análise dos dados

Com relação aos dados utilizados neste trabalho, estes são disponibilizados pelo Operador Nacional do Sistema – ONS (ONS, 2010). Estes dados representam o fluxo médio mensal de vazão afluente, estão armazenados em arquivos e representados em um intervalo de 1931 até 2007. Em Fortunato (1990, *apud* Ballini, 2000 p. 2) é mostrado o processo de obtenção dos dados das vazões, a Figura 9 mostra um esquema de como são obtidos tais dados, nessa figura é possível perceber que este é um processo complexo, baseado em medições e análises.

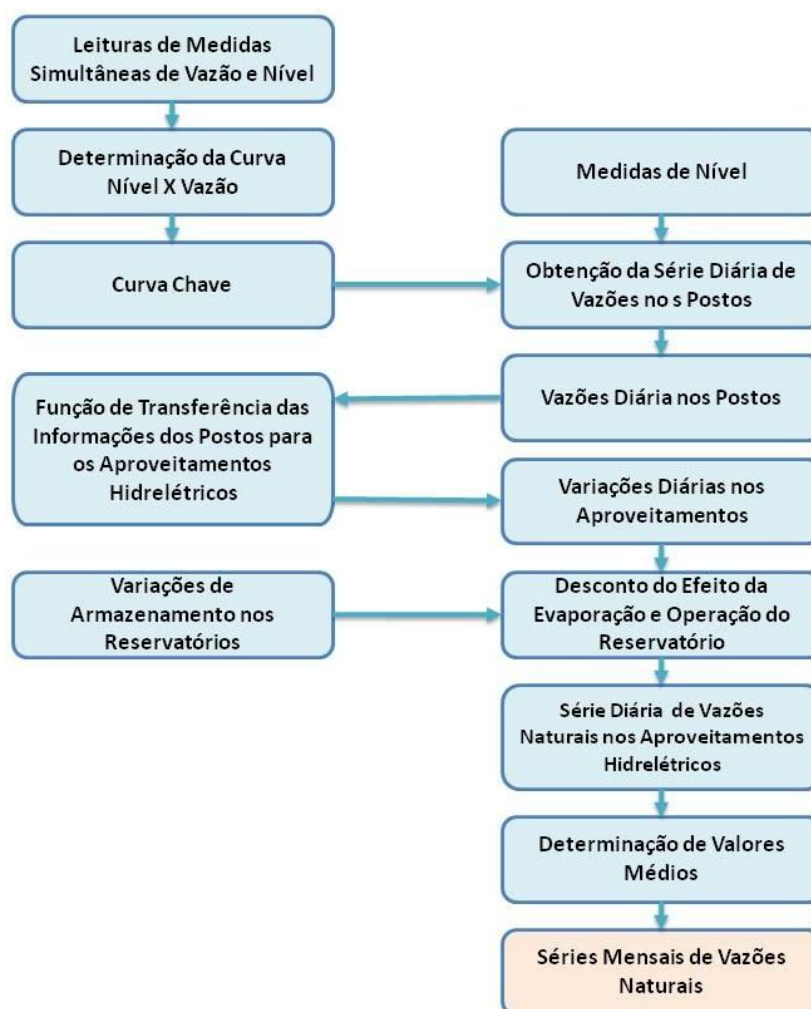


Figura 9 – Obtenção dos dados de vazões. Fortunato (1990, *apud* Ballini, 2000 p. 2).

Neste trabalho foram utilizados dados referentes às usinas de Camargos, Itutinga, Funil Grande e Furnas. A Tabela 11 mostra o máximo, o mínimo, a média, desvio padrão e o coeficiente de variação das séries de vazões das usinas utilizadas. Como é possível perceber nessa tabela, o coeficiente de variação apresenta alta variabilidade nos dados, devido a este comportamento irregular desta série de dados, se torna mais difícil realizar a previsão com grande precisão de acertos.

Tabela 11 - Característica dos Dados.

<i>Usina</i>	<i>Máx.</i>	<i>Min.</i>	<i>Méd.</i>	<i>Desv. Pad.</i>	<i>Coef. Var.</i>
Camargos	576m ³ /s	34m ³ /s	132,8m ³ /s	84,3 m ³ /s	63,47%
Itutinga	576m ³ /s	34m ³ /s	132,9m ³ /s	84,4 m ³ /s	63,49%
Funil Grande	1288m ³ /s	68m ³ /s	305,1m ³ /s	197,4m ³ /s	64,71%
Furnas	3757m ³ /s	204m ³ /s	926,6m ³ /s	612,5m ³ /s	66,11%

Para ilustrar esta variabilidade nos dados, a Figura 10 mostra um gráfico com as séries que foram utilizadas para realizar as previsões, que vão desde janeiro de 1996 até dezembro de 2005. Neste gráfico é possível observar a grande diferença existente no conjunto de dados referentes às vazões de uma hidrelétrica.

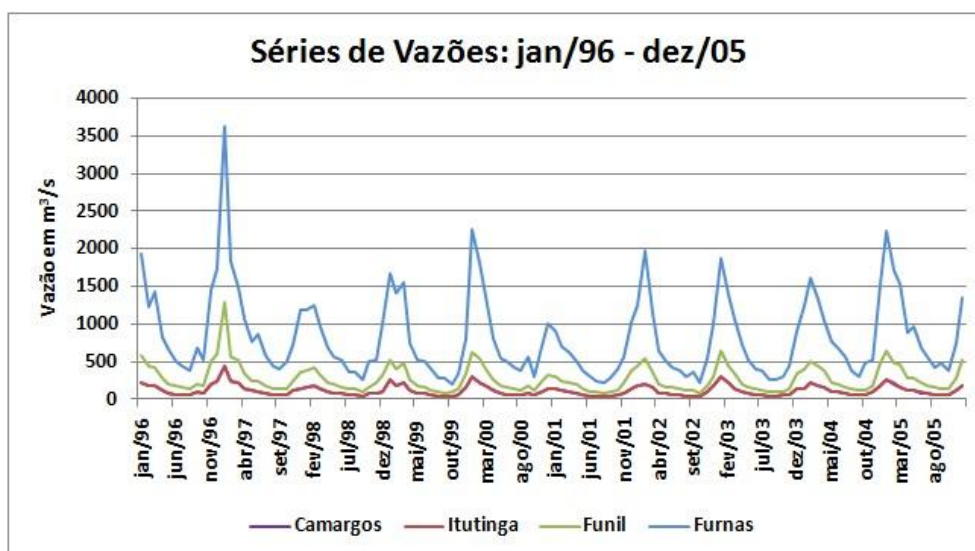


Figura 10 - Séries de Vazões das Usinas: Camargos, Itutinga, Funil Grande e Furnas - Jan/96-Dez/05.

Vale ressaltar que, para o bom funcionamento de um modelo computacional de previsão é importante que a base de dados a ser utilizada passe por um processo

de normalização, pois através desta abordagem é possível padronizar os dados dentro de limites pré-definidos para que os dados não apresentem um desvio muito alto. Nesta pesquisa, o processo de normalização utilizado consiste em dividir todos os dados pelo maior valor apresentado na base de dados, desta forma os dados estarão sempre contidos em um intervalo entre zero e um. Este processo não acarretou na perda da representatividade dos dados normalizados em relação aos dados brutos e para demonstrar visualmente que os dados não perdem suas características, a Figura 11 e a Figura 12 mostram os gráficos dos dados brutos e normalizados. Foram utilizados para gerar estes gráficos os dados referentes Usina de Furnas no período de janeiro de 1997 até dezembro de 2007.




Figura 11 - Dados Brutos - Usina de Furnas (1997-2007)




Figura 12 - Dados Normalizados - Usina de Furnas (1997-2007)

4.6 Análise estatística

Neste trabalho os resultados serão apresentados basicamente através de erros médios relativos, no qual são feitas várias comparações entre médias. Desta forma é necessário algum mecanismo que possibilite fornecer maior confiabilidade na definição dos resultados.

Foram utilizados os seguintes testes:

- **Teste "F" da análise de variância (ANAVA):** que indica se existe alguma diferença significativa entre os resultados apresentados;
- **Teste de Tukey:** que é utilizado para agrupar os resultados que se apresentarem de forma estatisticamente semelhantes.

A ANAVA e o Teste de *Tukey* foram realizados utilizando um software gratuito de estatística chamado **R**, desenvolvido na Universidade de *Auckland* na Nova Zelândia e de grande aceitação em universidades e empresas.

4.7 Sumário do capítulo

Neste capítulo foram discutidos os processos utilizados para realizar o treinamento do modelo. Além disso, foi mostrada a forma de como são construídos as componentes de previsão a partir dos modelos utilizados e também quais serão as formas de combinação dos resultados obtidos através dos *ensembles* propostos.

No capítulo seguinte são mostrados os resultados obtidos pelos componentes individuais e pelos *ensembles* de previsão e é feita uma discussão sobre as vantagens de se utilizar *ensembles* para realizar as previsões de vazões.

5

Resultados

Este capítulo apresenta os resultados obtidos pelos modelos individuais de previsão e pelos ensembles propostos neste trabalho. Na Seção 5.1 são mostrados os resultados obtidos pelos componentes de RNA. A Seção 5.2 mostra os resultados obtidos pelas componentes de PRG. Já na Seção 5.3 são apresentados os resultados obtidos pelas componentes de RLM. Na Seção 5.4 são mostrados os resultados obtidos pelos ensembles, também é feita uma análise sobre a utilização destes em relação aos componentes individuais.

Para se conseguir maior abrangência nos resultados obtidos nesta pesquisa, a realização das previsões foi efetivada de várias formas. A princípio os testes foram executados individualmente com os componentes de previsão, dessa forma foi possível comparar os resultados apresentados por cada um deles de forma isolada com os resultados apresentados pelo *ensemble* proposto. As usinas utilizadas como base de testes foram às usinas de Camargos, Furnas, Funil Grande e Itutinga. Vale lembrar que para que seja possível realizar a comparação dos resultados é necessário adotar alguma medida padrão para avaliar os resultados, assim em todos os resultados será adotado o Erro Médio Relativo (EMR):

$$\text{EMR} = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_i - \tilde{X}_i}{X_i} \right| \quad (6)$$

onde X_i é o valor real e \tilde{X}_i é o valor previsto.

A Figura 13 representa a metodologia utilizada para a realização dos testes, na qual nota-se que são realizadas as previsões utilizando os processos de *Treinamento Único* e *Contínuo* com o intuito de testar a influência de realizar o treinamento a cada ano previsto, além disso, a previsão ocorreu seguindo um discretização mensal para dez anos consecutivos e para diferentes séries anuais com o objetivo de testar a estabilidade dos modelos de previsão, desta forma para cada série testada foram executadas 120 previsões. Vale salientar, que para

conseguir maior confiabilidade nos modelos de previsão, este processo foi realizado 20 vezes para cada usina e para cada processo de treinamento que foi definido.

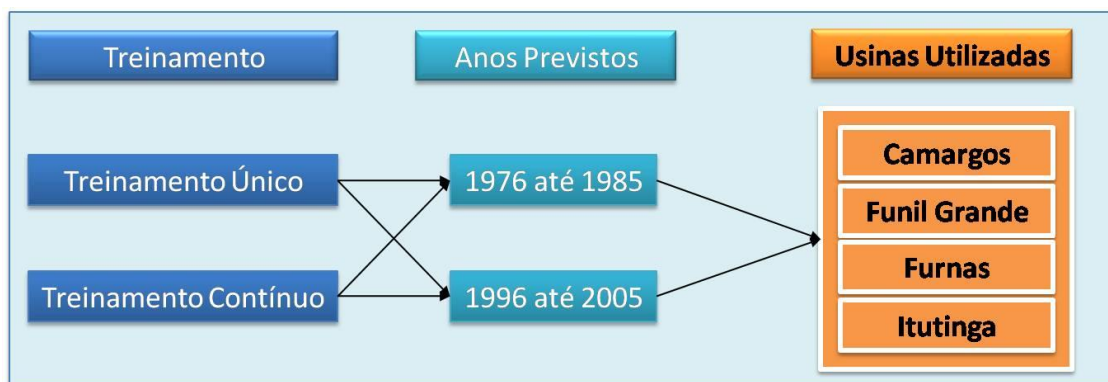


Figura 13 - Metodologia dos testes.

Primeiramente, o objetivo desses experimentos foi realizar a previsão utilizando-se os modelos isolados com o intuito de conseguir encontrar uma boa configuração dos parâmetros, a seguir serão mostrados os resultados obtidos pelos modelos.

É importante salientar que, todos gráficos onde serão expostos os resultados representam a média mensal dos erros obtidos para os anos que serão previstos. Para facilitar a análise, também é mostrada a média de erro de cada usina para toda a série, desta forma será possível identificar qual mês teve maior influência no resultado e a médias gerais dos erros.

5.1 Modelo de Rede Neural Artificial

A Figura 14 mostra os resultados apresentados pelos componentes do modelo de RNA, neste primeiro teste foi utilizado o processo de *Treinamento Único* e a previsão foi realizada para todos os meses dos anos entre 1976 até 1985.




Figura 14 - Previsão utilizando *Treinamento Único* (1976 - 1985). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

Já a Figura 15 ilustra os resultados apresentados da previsão utilizando o processo de *Treinamento Contínuo*, onde os testes foram realizados para todos os meses dos anos entre 1976 até 1985.




Figura 15 - Previsão utilizando *Treinamento Contínuo* (1976 - 1985). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

A Figura 16 ilustra os resultados obtidos através do processo de *Treinamento Único*, mas agora para outra série de dados, no qual a previsão foi realizada para os

anos de 1996 até 2005. Vale lembrar que variar a série que será prevista é interessante, pois dessa forma é possível perceber se houve estabilidade no modelo de previsão.




Figura 16 - Previsão utilizando *Treinamento Único* (1996 - 2005). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

Para finalizar os testes com o modelo de RNA, foi realizada a previsão seguindo o processo de *Treinamento Contínuo* para os anos de 1996 até 2005. A Figura 17 mostra os resultados apresentados por estes testes.

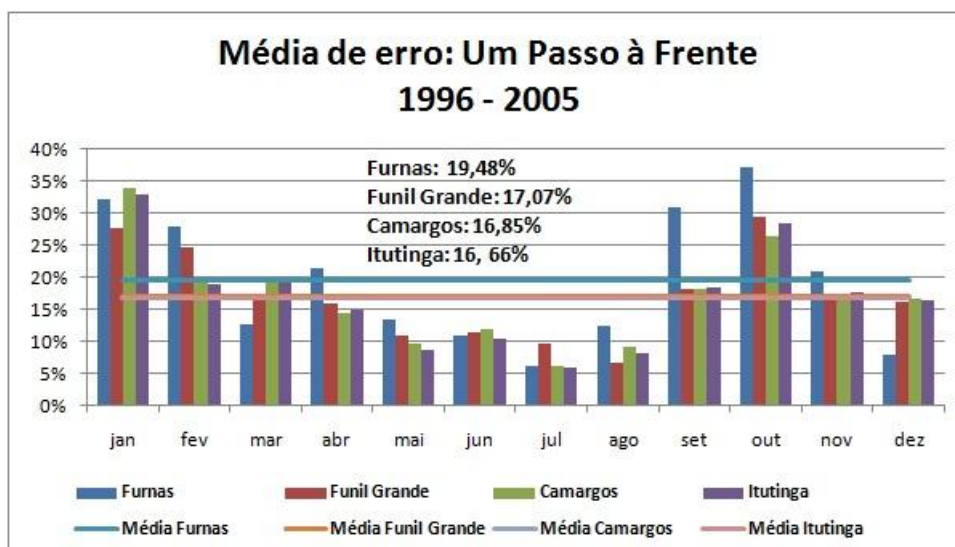


Figura 17 - Previsão utilizando *Treinamento Contínuo* (1996 - 2005). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

Para facilitar a análise dos resultados obtidos através do modelo de previsão, a Tabela 12 apresenta uma visão geral sobre a média de erros que foram apresentados por este modelo.

Tabela 12 – Erros Médios (EMR) – Modelo de Redes Neurais Artificiais.

<i>Furnas</i>			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
21,78%	19,48%	26,56%	20,79%
<i>Camargos</i>			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
18,93%	16,85%	21,91%	19,58%
<i>Funil Grande</i>			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
18,19%	17,07%	22,90%	18,80%
<i>Itutinga</i>			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
18,85%	16,66%	22,90%	19,79%

A partir dos testes realizados e dos resultados apresentados, foi possível perceber que ao utilizar o processo de *Treinamento Contínuo*, o modelo de rede neural pode se tornar mais adaptado para realizar as previsões, uma vez que a cada ano previsto o ano anterior é utilizado como parte do treinamento. Esta abordagem mostra que dessa forma o modelo pode se adequar as desconformidades da série o que pode facilitar no processo de treinamento e com isso apresentar bons resultados.

Outro fato importante que foi possível perceber é que ao utilizar o processo de *Treinamento Único* os erros apresentados pelo modelo se tornam mais constantes, não apresentando grande variação entre os meses. Isto acontece porque como o modelo é treinado uma única vez os resultados apresentados tendem a se estabilizar em determinados valores.

5.2 Modelo de Programação Genética

Seguindo a metodologia que foi descrita para a realização dos testes, o modelo a ser testado individualmente agora será o modelo de programação genética. A Figura 18 mostra os resultados apresentados para as previsões para os meses compreendidos entre os anos de 1976 até 1985 utilizando o processo de Treinamento *Único*.




Figura 18 - Previsão utilizando *Treinamento Único* (1976 - 1985). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

A Figura 19 mostra os erros médios obtidos para os mesmos anos descritos anteriormente, porém utilizando a metodologia de *Treinamento Contínuo*.




Figura 19 - Previsão utilizando *Treinamento Contínuo* (1976 - 1985). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

Para testar a estabilidade deste modelo serão apresentados os resultados para outra série de vazão. As Figuras 20 e 21 mostram os erros médios obtidos pelas previsões realizadas para todos os meses dos anos de 1996 até 2005. Nos resultados apresentados na Figura 20 foi utilizado o processo de *Treinamento Único* e para os resultados apresentados na Figura 21 foi utilizado o processo de *Treinamento Contínuo*.




Figura 20 - Previsão utilizando *Treinamento Único* (1996 - 2005). Usinas: Camargos, Itutinga, Funil Grande e Furnas.




Figura 21 - Previsão utilizando *Treinamento Contínuo* (1996 - 2005). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

Com o intuito de facilitar a análise dos resultados, a Tabela 13 mostra os erros médios obtidos pelo modelo de programação genética.

Tabela 13 - Erros Médios (EMR) - Modelo de Programação Genética

<i>Furnas</i>			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
23,06%	22,12%	25,76%	26,43%
<i>Camargos</i>			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
22,54%	19,97%	27,91%	25,67%
<i>Funil Grande</i>			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
18,43%	20,59%	26,25%	26,01%
<i>Itutinga</i>			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
21,13%	20,58%	26,02%	25,29%

A partir da Tabela 13, foi possível perceber que, assim como o modelo de rede neural artificial, o modelo de programação genética se comporta de forma mais eficiente utilizando o processo de *Treinamento Contínuo*, isto acontece porque as equações que são geradas durante o processo de treinamento se adaptam melhor aos dados imediatamente anteriores ao ano previsto, além disso, é possível que a série sofra alguma alteração e isto não seja levado em consideração ao utilizar o processo de *Treinamento Único*.

5.3 Modelo de Regressão Linear Múltipla

O último modelo testado individualmente neste trabalho foi o modelo de regressão linear múltipla. A Figura 22 ilustra os resultados com os erros médios apresentados pela previsão dos anos de 1976 até 1985 utilizando o processo de *Treinamento Único*.




Figura 22 - Previsão utilizando *Treinamento Único* (1976 - 1985). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

A Figura 23 mostra os resultados obtidos pela previsão dos anos de 1976 até 1985 utilizando o processo de *Treinamento Contínuo*.




Figura 23 - Previsão utilizando *Treinamento Contínuo* (1976 - 1985). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

Assim como foi feito para os outros modelos, agora serão mostrados os resultados obtidos para outros anos com a finalidade de não testar apenas uma série de dados. A Figura 24 apresenta os resultados para a previsão dos anos de 1996 até 2005 utilizando o processo de *Treinamento Único*.




Figura 24 - Previsão utilizando *Treinamento Único* (1996 - 2005). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

A Figura 25 mostra os erros médios obtidos pela previsão dos anos de 1996 até 2005, porém agora utilizando o processo de *Treinamento Contínuo*.




Figura 25 - Previsão utilizando *Treinamento Contínuo* (1996 - 2005). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

Assim como foi realizado para os outros modelos a Tabela 14 mostra uma visão geral dos erros obtidos pelo modelo de regressão linear múltipla para todos os testes realizados.

Tabela 14 - Erros Médios (EMR) - Modelo de Regressão Linear Múltipla

Furnas			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
21,00%	19,61%	20,98%	19,80%
Camargos			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
15,33%	15,38%	19,54%	15,89%
Funil Grande			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
19,69%	15,41%	20,58%	15,43%
Itutinga			
<i>Treinamento Contínuo</i>		<i>Treinamento Único</i>	
1976-1985	1996-2005	1976-1985	1996-2005
18,93%	15,33%	19,60%	15,82%

Vale salientar que este modelo de previsão não apresenta grande variação nos resultados levando em consideração o qual o processo de treinamento escolhido, ou seja, tanto para o processo de *Treinamento Único* como no processo de *Treinamento Contínuo* os resultados permaneceram próximos.

5.4 Resultados com *Ensembles*

O principal objetivo deste trabalho consiste na aplicação de *ensembles* para buscar soluções que mais se adaptam ao problema de previsão de vazões. Desta forma, nesta seção serão mostrados os resultados que foram obtidos seguindo esta abordagem.

A Figura 26 mostra os resultados obtidos pelos *ensembles* quando aplicados a previsão dos anos de 1996 até 2005, utilizando-se do processo de *Treinamento Contínuo* para a Usina de Furnas.




Figura 26 – *Ensemble* aplicado à Usina de Furnas. Metodologia de *Treinamento Contínuo*.

A Figura 27 mostra os resultados para a Usina de Furnas e para os anos de 1996 até 2005, porém foi utilizado o processo de *Treinamento Único*.




Figura 27 - Ensemble aplicado à Usina de Furnas. Metodologia de *Treinamento Único*.

A partir das Figuras 26 e 27 é possível perceber que, para a Usina de Furnas, o resultado obtido com a aplicação dos *ensembles* apresentou menores erros percentuais em relação aos modelos individuais de previsão. Vale notar que, mesmo com a aplicação dos *ensembles* os resultados obtidos com o processo de *Treinamento Contínuo* se mantiveram melhores do que o *Treinamento Único*, entretanto a diferença entre os erros de cada processo foi reduzida. Isso ocorre, pois neste trabalho os *ensembles* são compostos basicamente por médias, o que pode atenuar as diferenças entre os modelos.

Para demonstrar a eficiência dos *ensembles* e facilitar a análise destes neste trabalho, a seguir serão mostrados os resultados obtidos com a aplicação dos *ensembles* para as usinas de Camargos, Furnas, Funil Grande e Itutinga para os anos de 1996 até 2005, foram utilizados estes anos com o intuito de tornar possível a comparação entre os resultados obtidos com *ensembles* e com os modelos individuais.

As Tabelas 15, 16, 17 e 18 mostram os resultados obtidos pelas melhores componentes utilizadas para a previsão e pelos *ensembles* que foram propostos neste trabalho. De acordo com essas tabelas é possível perceber que nem sempre os *ensembles* superam o resultado do melhor componente. Este fato ocorre, provavelmente, porque que estes componentes estão muito bem adaptados para prever esta série temporal, no entanto, vale salientar que há uma grande possibilidade destes componentes terem sido melhores sucedidos do que o *ensemble* somente para este determinado período de previsão, ou então que na etapa de validação o modelo tenha se adaptado de forma mais precisa para o período de teste em questão. Dessa forma, é possível que em algum trecho diferente da série, outro componente apresente melhor resultado.

Com isso, vale o esforço para a aplicação dos *ensembles*, pois através deste, é possível que os resultados sejam combinados de forma a explorar as variações apresentadas pelos componentes, mantendo certa estabilidade na previsão e favorecendo a busca por bons resultados.

Para deixar claro o que foi dito anteriormente, nas Tabelas 15 a 18 são mostradas as variações obtidas pelos componentes individuais e pelos *ensembles*. É possível perceber que para todas as usinas utilizadas, a variação nos componentes apresenta-se de forma muito maior do que nos *ensembles*, isso ajuda a mostrar que com os *ensembles* os resultados podem ser mais confiáveis, pois possuem maior estabilidade.

Tabela 15 - Ensembles aplicados a Usina de Camargos.

<i>Componentes</i>							
#1	#2	#3	#4	#5	#6	#7	#8
15,51%	15,80%	15,83%	19,43%	20,16%	20,31%	23,21%	25,69%
<i>Ensembles</i>							
Média Aritmética		Média Ponderada		Média Quadrática		Média Geométrica	
16,13%		15,84%		16,29%		16,05%	
<i>Coefficiente de Variação</i>							
Componentes				Ensembles			
19,02%				1,16%			

Tabela 16 – Ensembles aplicados a Usina de Furnas.

<i>Componentes</i>							
#1	#2	#3	#4	#5	#6	#7	#8
19,34%	19,38%	19,82%	20,00%	23,10%	27,21%	28,22%	30,18%
<i>Ensembles</i>							
Média Aritmética		Média Ponderada		Média Quadrática		Média Geométrica	
17,58%		18,21%		18,09%		17,47%	
<i>Coefficiente de Variação</i>							
Componentes				Ensembles			
19,16%				2,04%			

Tabela 17 – Ensembles aplicados a Usina de Funil Grande.

<i>Componentes</i>							
#1	#2	#3	#4	#5	#6	#7	#8
15,05%	15,17%	15,57%	15,75%	18,54%	19,50%	21,73%	23,04%
<i>Ensembles</i>							
Média Aritmética		Média Ponderada		Média Quadrática		Média Geométrica	
16,09%		15,77%		16,36%		15,92%	
<i>Coefficiente de Variação</i>							
Componentes				Ensembles			
17,47%				1,58%			

Tabela 18 – Ensembles aplicados a Usina de Itutinga.

<i>Componentes</i>							
#1	#2	#3	#4	#5	#6	#7	#8
15,35%	15,51%	15,80%	15,83%	18,30%	18,66%	20,10%	23,15%
<i>Ensembles</i>							
Média Aritmética		Média Ponderada		Média Quadrática		Média Geométrica	
15,91%		15,50%		16,59%		15,75%	
<i>Coefficiente de Variação</i>							
Componentes				Ensembles			
15,56%				2,91%			

Como já foi mencionado, para a composição dos *ensembles*, foram utilizados a combinação dos oito melhores componentes de previsão que foram gerados para

realizar a previsão, no qual os componentes foram arranjados da seguinte forma: 4 RLM, 2 RNA e 2 PRG. Estes componentes foram definidos desta forma levando em consideração os testes empíricos realizados durante o desenvolvimento do trabalho. Vale salientar que para se conseguir os melhores resultados, os erros apresentados pelos componentes de RNA e PRG deveriam apresentar maiores erros que o da RLM.

Este fato ocorre, pois, sabendo que os componentes RLM apresentam sempre os mesmos resultados para as mesmas entradas e estes foram os que na média geral apresentaram um erro menor, se os componentes de RNA e PRG apresentarem resultados que se aproximam dos resultados da RLM os *ensembles* não teriam uma faixa de variação muito extensa para realizar a composição, ou seja, os *ensembles* funcionam bem quando os componentes individuais apresentam variação relevante, pois dessa forma se um componente apresentar um erro positivo e outro apresentar um erro negativo, na média é possível que o resultado se torne mais próximo do real.

Após a configuração dos modelos de previsão e da verificação dos resultados apresentados pelos *ensembles*, outro estudo produzido neste trabalho foi realizar a previsão de vazões para várias usinas quem compõem o Sistema Interligado Nacional (SIN). Foram feitas as previsões para 189 usinas para os anos de 1996 até 2005 utilizando o processo de *Treinamento Contínuo*. Este estudo objetiva criar uma base com os resultados obtidos para que seja possível permitir comparações com outras metodologias de previsão. Os resultados obtidos podem ser encontrados no Apêndice II.

5.5 Resultados dos testes estatísticos

Conforme foi mencionado anteriormente, para se conseguir maior confiabilidade nos resultados foram aplicados dois testes estatísticos, o Teste “F” e o Teste de *Tukey*. Para a execução destes testes foram utilizados os resultados obtidos para a previsão da Usina de Furnas no período de 1996 até 2005, utilizando como processo de *Treinamento Contínuo*.

A partir do Teste “F” foi possível identificar, com um nível de 5% de significância, que todos os resultados obtidos, tanto pelos previsores individuais quanto para os *ensembles*, se apresentaram estatisticamente equivalentes, ou seja, não é possível afirmar que existe algum previsor que seja melhor do que outro.

Com base nisto, ao aplicar o Teste de *Tukey* para verificar os agrupamentos que poderiam surgir, certamente os resultados estariam agrupados em um único grupo, pois o Teste “F” já havia demonstrado que todos os componentes foram estatisticamente equivalentes.

Mais detalhes sobre os resultados apresentados pelo Sistema **R**, onde foram realizados os testes estatísticos, podem ser encontrados no Anexo I.

5.6 Sumário

Este capítulo apresentou a maneira de como foram realizadas as previsões, os anos que foram previstos e as usinas que foram utilizadas como base para as previsões. Primeiramente foram mostrados os resultados obtidos pelos componentes individuais de previsão, após isso foram apresentados os resultados obtidos pelos *ensembles*, com isso foi feita uma discussão sobre a utilização dos mesmos para a previsão de vazões.

A partir disso, foi possível verificar que, com os *ensembles* não foi possível obter sempre os melhores resultados para todas as séries que foram utilizadas, porém estes foram os que mais se apresentaram estáveis para realizar as previsões.

No próximo capítulo serão apresentadas as conclusões obtidas neste trabalho e as propostas futuras que podem ser realizadas.

6

Conclusões

Neste capítulo são apresentadas as conclusões que foram obtidas a partir dos experimentos realizados nesta monografia e são discutidas as propostas futuras que poderão ser realizadas acerca deste tema.

As previsões de vazão estão sujeitas a uma série de erros oriundos de diversos fatores. Segundo Krauskopf (2005) as fontes de erros mais importantes estão relacionadas à: (1) incapacidade da correta representação do fenômeno hidrológico pelo modelo matemático; (2) dificuldade de obtenção do melhor conjunto de parâmetros do modelo; (3) erros nas medidas das grandezas físicas, precipitação e nível; (4) incerteza das vazões futuras e sua aleatoriedade. O somatório de todos esses erros reflete diretamente nos resultados obtidos através das previsões.

Este trabalho apresenta um estudo sobre as previsões de vazões realizadas sobre algumas usinas que compõem a cabeceira do Rio Grande. A partir dos resultados encontrados na literatura sobre a previsão de vazões, foi possível perceber que os modelos computacionais descritos neste trabalho podem ser alternativas viáveis para realizar a previsão de vazões afluentes.

No entanto, é comum acontecer com modelos de previsão à adaptação somente a um determinado período de previsão, dessa forma para outros períodos este modelo não seria viável. Para contornar este problema, neste trabalho foi feita uma proposta de criar uma metodologia de combinação de resultados, os *ensembles*. A partir dos testes realizados com os *ensembles*, pode-se perceber que houve um ganho nos resultados, pois mesmo os *ensembles* não apresentando sempre os melhores resultados para todas as séries previstas, com esta abordagem é possível conseguir maior estabilidade, diminuindo a variação que ocorria constantemente nos resultados apresentados pelos modelos individuais de previsão.

Como propostas futuras, é possível que sejam abordadas novas metodologias de testes aplicando outros modelos computacionais a fim de obter

resultados mais precisos e poderão ser construídas novas propostas de *ensembles* baseadas em modelos inteligentes. Além disso, é possível que sejam realizados testes para realizar a previsão seguindo um horizonte diário, como também é discutido na literatura e realizar a previsão para outras séries de vazões com o intuito de fornecer maior estabilidade para os modelos de previsão.

7 Referências Bibliográficas

- Abelém, A. J. G. *Redes Neurais Artificiais na Previsão de Séries Temporais*. 1994. 187f. Tese de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro (PUC-RJ), Rio de Janeiro, 1994.
- Agência Nacional de Energia Elétrica, ANEEL. *Matriz de energia elétrica*, 2009. Disponível em <http://www.aneel.gov.br/>. Acessado em 19-set-2009.
- Ballini, R. *Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Rede Neurais e Redes Neurais Nebulosas*. 2000. 187f. Tese de Mestrado – Faculdade de Engenharia Elétrica e de Computação, Universidade de Campinas (UNICAMP), Campinas, 2000.
- Barbancho, A. G. *Fundamentos e possibilidades da econometria*. Rio de Janeiro. Fórum Editora, p. 18 – 32, 1970.
- Biondi Neto, L. et al. *Previsão da Vazão Afluente Mensal do Rio São Francisco Usando-se Redes de Elman*. *Engevista - Revista da Escola de Engenharia da Uff, Niterói - Rj*, v. 7, n. 1, p.63-72, abr. 2005.
- Box, G.E.P. & Jenkins G.M.. *Time Series Analysis, Forecasting and Control*. 1976. California, USA, San Francisco: Holden Day, 575 págs, Revised Edition
- Brasil. Ministério de Minas e Energia. Empresa de Pesquisa Energética, EPE. *Balanço Energético Nacional*. 2009. Disponível em <https://ben.epe.gov.br/default.aspx>. Acessado em 23-nov-2009.
- Bravo, j. M. et al. *Previsões de curto prazo de vazão afluente ao reservatório de Furnas utilizando redes neurais artificiais*. *Revista Brasileira de Recursos Hídricos*, v. 13, p. 77-88, 2008.
- Cataldi M., Machado C. O. & Guilhon, L. G. F., *Análise das previsões de precipitação obtidas com a utilização do modelo Eta como insumo para modelos de previsão semanal de vazão natural*. 556.18, v12, n 3. *Revista Brasileira de Recursos Hídricos - RBRH*. Porto Alegre: ABRH, v.12, n.3, jul/set. 2007. 219 p.
- Chakraborty K. et al. *Forecasting the Behavior of Multivariate time Series Using Neural Networks*. 1992. *Neural Networks*, v. 5, n. 6, p. 961 – 970.
- Chiari, G. R. P., Costa, J. C. E. & E Botelho, L. C. M. *Previsão de Afluências na Cemig: Aplicação do Sistema de Simulação Hidrológica Rio Grande para a Bacia*

- Incremental do Rio Paranaíba entre as UHE's Itumbiara e São Simão*. 2007. I Workshop Previsão de Vazões.
- Cicogna, M. A. *Sistema de Suporte à Decisão para o Planejamento e a Programação da Operação de Sistemas de Energia Elétrica*. 2003. 223f. Tese de Doutorado – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas (UNICAMP), Campinas, 2003.
- Darwin, C., *On the Origin of Species by Means for Natural Selection*. London: Jhon Murray, 1859.
- Farias, W. B. & Melo, I. V. *Avaliação de Impactos Ambientais de Barragens: oportunidades para a atuação dos Tribunais de Contas*. 2006. XI Simpósio Nacional de Auditoria de Obras Públicas (SINAOP).
- Ferreira, J. O., Oliveira, H. C. B. & Paula, M. M. V. *Sigm-Tree: Otimização de Árvores Sintáticas Aplicada à Classificação de Padrões*. XLI Simpósio Brasileiro De Pesquisa Operacional (SBPO). 2009, Porto Seguro – BA. Anais do Simpósio Brasileiro de Pesquisa Operacional, p. 1478 - 1489.
- Fortunato, L. A. M. et al. *Introdução ao Planejamento da Expansão e Operação de Sistemas de Produção de Energia Elétrica*. 1990. Ed. Universitária, Niterói– RJ.
- Georgakakos, K. P. *On improved operational hydrologic forecasting of streamflow*. 1988. IIHR Report n. 525. Universidade de Iowa.
- Gonçalves, J. & Buba H. *Sistema de Simulação e Previsão Hidrológica do Iguaçu*. 2007. I Workshop Previsão de Vazões.
- Guilhon, L. G. F. *Modelo Heurístico de Previsão de Vazões Naturais Médias Semanais Aplicada à Usina de Foz do Areia*. 2002. 88f. Tese de Doutorado – Programa de Engenharia de Sistemas e Computação (COPPE). Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, 2002.
- Hansen, L. K. & Salamon, P. *Neural Network Ensembles*, em IEEE Trans. Pattern Analysis and Machine Intelligence 12, no 10, 1990, p. 993-1001.
- Haykin, S. *Redes Neurais: Princípios e Práticas*. 2007. Editora Bookman, 2 ed.
- Jang J. S. R. *ANFIS: Adaptive Network Based Fuzzy Inference System*. IEEE Transaction System, Man and Cybernetics. 2003.
- Koza, J. R., *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. MIT Press, Cambridge – MA, USA, 1992.

- Krauskopf Neto, R. 2005. *Atualização de Modelos Chuva-Vazão – Propagação Com Estimador de Estado*. 2005. 264f. Tese de Mestrado, Departamento de Engenharia Hidrológica, Universidade Federal do Paraná. Curitiba, 2005.
- Leone Filho, M. A. *Previsão de carga de curto prazo usando ensembles de previsores selecionados e evoluídos por Algoritmos Genéticos*. 2006. 143 f. Tese Mestrado – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2006.
- Luna H. I., Ballini, R. & Soares, S. *A Constructive-Fuzzy System Modelling for Time series Forecasting*. International Joint Conference on Neural Networks - IJCNN'07, 2007, Orlando, Flórida. Proceedings of the International Joint Conference on Neural Networks - IJCNN'07, 2007. p. 1-6.
- Luna H. I., Ballini, R. & Soares, S. *An Adaptive Hybrid Model for Monthly Streamflow Forecasting*. The IEEE International Conference on Fuzzy Systems - FUZZ-IEEE'07, 2007, London. Proceedings of the IEEE International Conference on Fuzzy Systems, 2007. p. 1-6.
- Machado L. A. & Hoffmann R.. *Impactos Ambientais da Geração de Energia Elétrica no Rio Grande do Sul*. XXIII Encontro Nacional de Engenharia de Produção (ENEGERP). Ouro Preto. 2003
- Marengo, J. A.. *Água e Mudanças Climáticas*. Revista Estudos Avançados. Universidade de São Paulo (USP). 2008, n. 63, vol 22. São Paulo – SP.
- Mueller, A. *Uma Aplicação de Redes Neurais Artificiais na Previsão do Mercado Acionário*. 1996. Tese de Mestrado – Departamento de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina (UFSC), Florianópolis, 1996.
- Operador Nacional do Sistema - ONS. *Séries de Vazões Mensais*. 2010. Disponível em http://www.ons.org.br/download/operacao/hidrologia/Series_Mensais.zip. Acessado em 30-abr-2010.
- Perrone, M. P.; Cooper, L. N. *When networks disagree: Ensemble methods for hybrid neural networks*. In R. J. Mammone, editor, *Neural Networks for Speech and Image Processing*, chapter 10. Chapman-Hall, 1993.
- Prudêncio, R. B. C. *Projeto Híbrido de Redes Neurais*. 2002. 101f. Tese de Mestrado – Centro de Informática. Pernambuco, Universidade Federal de Pernambuco (UFPA), Fortaleza, 2002.

- Russo, S. L., Camargo M. E. & Simon V. H. *Avaliação de Perfis Sônicos Sintéticos em Poços de Petróleo Perfurados nas Unidades Geológicas Pertencentes à Bacia Sedimentar Sergipe-Alagoas*. 2010. Revista de Gestão Industrial. Universidade Tecnológica Federal do Paraná - UTFPR. ISSN 1808-0448, v. 06, n 01, p 216-237.
- Salgado, R. M. *Sistema de Suporte à Decisão para Previsão de Carga por Barramento*. 2009. 207f. Tese de Doutorado – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas (UNICAMP), Campinas, 2009.
- Samohyl, R. W. Rocha, R. & Matos, V. L. D. 2001. *Utilização do Método de Holt-Winters para Previsão do Leite às Indústrias Catarinenses*. XXI Encontro Nacional de Engenharia de Produção, v. 1, pág. 1-1, Salvador, 2001.
- Silva, L. N. C. *Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais*. 1998. 225f. Tese de Mestrado – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas (UNICAMP), Campinas, 1998.
- Souza, L. V. *Programação Genética e Combinação de Preditores para Previsão de Séries Temporais*. 2006. 154 f. Tese (Doutorado) - Departamento de Tecnologia e de Ciências Exatas, Universidade Federal do Paraná. Curitiba, 2006.
- Tucci, C.E.M. & Collischonn, W. *Previsão de Vazão, Clima e Recursos Hídricos no Brasil*. 2003. Porto Alegre. Associação Brasileira de Recursos Hídricos (ABRH), p.281-348.
- Valença, M. J. S. *Analysis and Design of the Constructive Neural Networks for Complex Systems Modeling*. 1999. Tese de Doutorado, Departamento de Informática, Universidade Federal de Pernambuco, Recife, Brasil, 1999 apud Prudêncio, R. B. C. *Projeto Híbrido de Redes Neurais*. 2002.101f. Tese de Mestrado – Centro de Informática. Pernambuco, Universidade Federal de Pernambuco (UFPA), Fortaleza, 2002.
- Villanueva, J. P. W. *Comitê de Máquinas em Predição de Séries Temporais*. 2006. 178f. Tese Mestrado – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas (UNICAMP), Campinas, 2006.
- Welch, G.; Bishop, G. *An Introduction to the Kalman Filter*. 2001. Proceedings of the ACM computer graphics conference (SIGGRAPH-2001).
- Zhang, Q., Patuwo, B. & Hu, M. *Forecasting with Artificial Neural Networks: the State of the Art*. 1998. International Journal of Forecasting. p. 35–62.

8 Apêndices e Anexos

8.1 Apêndice I

Uma análise empírica de redes neurais MLP aplicado à previsão de vazões

DANILO B. LIMA¹, RICARDO M. SALGADO¹, HUMBERTO C. B. DE OLIVEIRA¹, TAKAAKI OHISHI²

¹*Laboratório de Inteligência Computacional(LInC), Universidade Federal de Alfenas – UNIFAL-MG
Rua Gabriel Monteiro da Silva, 700 Alfenas, MG*

²*Departamento de Engenharia de Sistema (Densis), Universidade Estadual de Campinas - UNICAMP
Av. Albert Einstein, 400, Campinas-SP*

*E-mails: {danilobraga, ricardo, humberto}@bcc.unifal-mg.edu.br,
taka@denisis.fee.unicamp.br*

Abstract— Currently, in Brazil there is a large potential energy that comes from hydro mineral sources, which most part of the electricity consumed comes from this source. According to this, it is important emphasize that the decision-making related with planning of the operation of the reservoirs of hydroelectric plants has been done based mainly on preview knowledge of the flow. Thereby, this work aims to conduct an exploratory study about the Artificial Neural Networks type MLP to estimate which is the best setting to perform the stream flow forecast. This study was applied to the Rio Grande basin, in addition, with the achieved results, it was possible to observe that the search of appropriate parameters shows significant gains in the execution of the forecasts and can to reduce the error level obtained.

Keywords— Time Series Forecasting, Stream Flow Forecast, Exhaustive Search of Parameters, Neural Networks.

Resumo— Atualmente, no Brasil, existe um grande potencial energético advindo de fontes hidrominerais, no qual a maior parte da energia elétrica consumida provém desta fonte. Aliado a este fato, vale destacar que a tomada de decisão relacionada ao planejamento da operação dos reservatórios das usinas hidrelétricas é realizada com base, principalmente, no conhecimento antecipado das vazões. Neste sentido este trabalho objetiva realizar um estudo exploratório sobre os parâmetros de configuração das Redes Neurais Artificiais do tipo MLP visando estimar quais são as melhores configurações para realizar a previsão de vazões. Este estudo foi aplicado em usinas do Rio Grande, mais especificamente sobre as usinas de: Camargos, Itutinga, Funil Grande e Furnas e, com os resultados obtidos, foi possível perceber que a escolha de parâmetros adequados apresenta ganhos significativos no desempenho das previsões melhorando o nível de erro obtido.

Palavras-chave— Previsão de Séries Temporais, Previsão de Vazões, Busca Exaustiva de Parâmetros, Redes Neurais Artificiais.

1 Introdução

No contexto atual, a energia pode ser considerada um elemento indispensável ao desenvolvimento econômico, na qual, de um lado fornece os serviços e infra-estrutura essenciais para a sociedade e de outro sua grande quantidade ou carência tem impacto em diversas áreas, tais como: segurança nacional, competitividade industrial, economia e a estrutura social (Salgado, 2009).

Segundo ANEEL (2009), cerca de 80% da energia elétrica que é utilizada no Brasil origina-se de usinas hidrelétricas. Isto ocorre porque o Brasil possui bacias hidrográficas compostas de centenas de rios permanentes e caudalosos e que se distribuem por todas as regiões do país. Desta forma, como o país possui grande parte da energia elétrica advinda de fontes hidrominerais, uma pequena redução nos desperdícios pode impactar em uma grande economia nos recursos naturais disponíveis e na redução de custos de uma empresa geradora de energia.

Para auxiliar na busca pela redução nos desperdícios de recursos hidrominerais pelas hidrelétricas, pode-se destacar a realização da previsão de vazões como uma das alternativas para maximizar os resultados obtidos, pois a geração desta forma de energia depende principalmente das séries de vazões afluentes. Com a previsão de vazões, as hidrelétricas podem planejar suas decisões com a possibilidade de se anteciparem sobre algumas desconformidades que poderão vir a acontecer, tornando-as mais competitivas e aproveitando de forma mais adequada os recursos hídricos disponíveis. Além disso, as previsões servem como subsídio a outros setores usuários da água, como a irrigação, a pesca, o turismo, o lazer e a navegação. Vale lembrar que o setor elétrico brasileiro detém a maior parte do controle da quantidade de água disponível nos grandes reservatórios, que até pouco tempo destinavam-se exclusivamente à geração de energia, hoje são alvos de interesse diversos e conflitantes dos demais setores que utilizam a água. Nesse contexto, cresce a importância na área de planejamento e controle de sistemas de recursos hídricos.

No entanto, vale salientar que este processo de previsão pode ser considerado custoso, onde a aleatoriedade das vazões são limitações que

dificultam o planejamento da operação do sistema energético brasileiro (Silva, 2007). Neste sentido, para se conhecer a disponibilidade energética é possível realizar um estudo sobre a quantidade de água disponível nos reservatórios das usinas, isto é, pode-se realizar a previsão de vazões deste reservatório. Uma das formas para se alcançar tal objetivo é utilizar alguma abordagem computacional para beneficiar este processo, assim é possível citar: Redes Neurais Artificiais (RNAs) (Ballini, 2000), Modelos Auto-regressivos (Box e Jenkins, 1976), Lógica Neuro-Fuzzy (Jang, 2008), entre outras, que são utilizadas com frequência na construção de modelos para solucionar problemas relacionados à previsão de séries temporais em diferentes áreas.

Na literatura sobre previsão de vazões são discutidos diversos aspectos sobre a maneira como são realizadas as previsões, tais como: qual o modelo utilizado para prever, a configuração dos parâmetros do modelo, os horizontes de previsão, entre outros.

No sistema descrito por Luna, Ballini e Soares (2007a) é apresentada uma metodologia que realiza a previsão das vazões para a Usina de Furnas seguindo um horizonte mensal. Para realizar as previsões, é utilizado um método baseado em regras fuzzy adaptativas, denominado A-FSM. Mais detalhes podem ser obtidos em (Luna, Ballini e Soares, 2007a). Neste trabalho, os dados estão apresentados desde 1931 até 2005 seguindo uma discretização mensal, no qual representam o volume da vazão da Usina de Furnas. Para o ajuste do modelo de previsão foram utilizados os dados de 1931 até 1995 e os testes foram realizados para os anos de 1996 até 2005. Com relação aos resultados Luna, Ballini e Soares (2007a) apresentam uma análise dos erros obtidos pelo sistema desenvolvido, o A-FSM, que possui 19,08% de erro e mostra os erros obtidos por outros sistemas relacionados, tais como: C-FSM (Luna, Ballini e Soares, 2007b) que possui 20,19% e ANFIS (Jang, 2008) que apresenta 20,12%

Outro sistema que se propõem a realizar a previsão de vazões para Furnas é mostrado por Bravo et al (2008). Neste trabalho é mostrado um modelo de previsão diário de vazão que utiliza RNAs como técnica de previsão. Neste modelo, a previsão segue um horizonte de doze dias à frente, no qual, para cada dia é criada uma nova RNA com intuito específico de

realizar a previsão para um determinado dia. Os dados utilizados neste trabalho compõem uma série histórica diária de 1970 até 1980. Para a utilização de uma RNA é necessário a divisão dos dados em conjunto de treino e validação. Portanto, o conjunto de treinamento é composto de dados dos períodos de 12/01/1970 à 17/07/1974 e 13/10/1978 à 31/12/1980. O conjunto de validação se estende de 18/07/1974 à 12 /10/1978. Para avaliar o desempenho da rede o conjunto de verificação é composto dos dados de 12/01/1996 à 31/12/2000. Os resultados obtidos por este sistema se apresentam melhores do que os obtidos pelo modelo ETA (Cataldi et al, 2007), que é atualmente utilizado pelo ONS. Para o período que foi utilizado como base de testes os resultados do modelo ETA foram de 22% e o resultado obtido pela RNA foi de 13,7%.

A partir do exposto acima, é possível perceber que ter conhecimento antecipado sobre as vazões afluentes pode ser considerado uma vantagem, pois pode auxiliar no processo de planejamento de uma usina hidrelétrica. Entretanto, a grande maioria dos trabalhos não exploram exaustivamente os parâmetros do modelo de previsão, o que pode facilitar na busca por melhores resultados.

Neste sentido, o objetivo deste trabalho é a realização de um estudo exploratório nos parâmetros do modelo de Rede Neural Artificial do tipo *Multi Layer Perceptron* (MLP) para previsão de vazões para algumas Usinas da cabeceira do Rio Grande, mais especificadamente: Camargos, Itutinga, Funil Grande e Furnas. Esta busca exaustiva tem o intuito de investigar quais os valores que mais se adequam para cada parâmetro do modelo de previsão para as séries anteriormente descritas.

Este trabalho está dividido da seguinte forma: na Seção 2 são apresentados alguns conceitos sobre a Previsão de vazões, na Seção 3 é abordada a metodologia utilizada para realizar os experimentos, já na Seção 4 é feita uma discussão sobre os dados que serviram de entrada para o modelo, na Seção 5 são mostrados os resultados obtidos pelo modelo de previsão e finalmente na Seção 6 são feitas as considerações finais do trabalho.

2 O Problema de Previsão de Vazões

Segundo Guilhon (2002), o ser humano está em busca constante para conseguir prever os fatores que influenciam no comportamento da natureza. Neste trabalho, o foco é prever o comportamento das vazões nos rios, mais precisamente, encontrar a previsão das vazões afluentes.

A previsão de vazões pode ser dividida em: previsão mínima, previsão média e previsão máxima, na qual é possível auxiliar de diferentes formas o planejamento de uma usina hidrelétrica. De acordo com Valença (1999 apud Prudêncio, 2002), a previsão de vazões mínimas pode ser útil para planejar o abastecimento de água e prever condições críticas. A previsão das vazões médias auxilia o atendimento à demanda de energia, uma vez que essas previsões indicam o potencial de geração de energia no futuro. Já a previsão das vazões máximas é útil para o controle de inundações e planejamento de obras a serem realizadas.

Neste trabalho, será abordada a previsão de vazões médias, no qual permite que os diferentes modelos de operação, otimização e simulação energética possam avaliar as condições operacionais das usinas hidrelétricas no futuro, propiciando subsídios para a tomada de decisões. Além disso, é possível utilizar destas previsões de afluições para programar as atividades à luz dos recursos hídricos disponíveis nas diferentes bacias hidrográficas (Guilhon, 2002).

Devido ao fato de que uma previsão de vazões pode maximizar os resultados obtidos no planejamento de uma empresa geradora de energia, este trabalho tem como objetivo realizar um estudo exploratório das RNAs do tipo MLP para definir quais são os parâmetros deste modelo que mais se adaptam para realizar a previsão de vazões médias.

As arquiteturas do tipo MLP representam os modelos de redes neurais mais conhecidos e utilizados atualmente. Uma MLP consiste de n nós de entrada, h camadas de nós escondidos (intermediários) e m nós de saída conectados de uma maneira realimentada a partir de pesos multiplicativos W .

A MLP deve ser treinada com dados históricos para se encontrar os valores apropriados de W e o número de neurônios requeridos na camada escondida (intermediária). Neste trabalho, o algoritmo de treinamento utilizado foi o

conhecido algoritmo de retropropagação do erro (*backpropagation*).

O processo de encontrar os parâmetros de configuração de uma RNA não é trivial devido à influência de diversos fatores neste processo, tais como: definição do número de camadas, escolha do número de neurônios, o tipo de função de ativação e também os termos *momentum* e a taxa de aprendizagem.

Neste contexto, este trabalho apresenta estudos exploratórios para se realizar a previsão de vazões médias, assim como os resultados obtidos pelo modelo quando aplicado a previsão de algumas usinas que compõem a cabeceira do Rio Grande. Além disso, o modelo foi submetido a uma série de testes para verificar a estabilidade levando em consideração a configuração encontrada dos parâmetros.

Neste trabalho os códigos-fontes utilizados no modelo de previsão estão disponíveis no endereço: bcc.unifal-mg.edu.br/~ricardo/modelos/neural20.zip.

Sendo que na versão original o modelo de rede neural foi desenvolvido para realizar classificação de padrões. Esta rede foi adaptada para a previsão de vazões seguindo a metodologia descrita neste trabalho.

3 Metodologia

Como já foi dito anteriormente, este trabalho foca em realizar as previsões para a Bacia do Rio Grande, mais especificadamente para as usinas de: Camargos, Itutinga, Funil Grande e Furnas. Portanto todos os resultados obtidos pelo modelo de previsão serão referentes a estas usinas.

Para se conseguir maior abrangência nos resultados obtidos nesta pesquisa, a realização das previsões, com o intuito de testar o modelo de previsão, foi efetivada seguindo uma discretização mensal durante 10 anos, ou seja, foram feitas as previsões desde janeiro de 1996 até dezembro de 2005, totalizando 120 previsões para cada usina utilizada.

Neste trabalho serão discutidos dois processos de configurar o treinamento de uma RNA, *Previsão Dez Passos à Frente* e *Previsão Um Passo à Frente*. Na *Previsão Dez Passos à Frente*, a rede é treinada até certo ponto e é realizada a previsão para dez anos subsequentes, sem que haja novo treinamento da rede, nos experimentos realizados, os anos utilizados

como treinamento foram de 1931 até 1995 e a partir da rede treinada com estes anos, os dez anos posteriores foram previstos, ou seja, de 1996 até 2005.

No processo de *Previsão Um Passo à Frente*, sempre se utiliza um ano anterior ao previsto para auxiliar no treino do previsor, ou seja, a todo novo ano a ser previsto o ano anterior é utilizado como parte dos dados utilizados para realizar o treinamento da rede.

A metodologia *Um Passo à Frente* está ilustrada na Figura 1. Nesta figura é possível perceber que para cada mês utilizado e para cada ano previamente definido, para realizar a previsão são obtidos os dados que serão utilizados como base para o treinamento e validação da RNA. Após isso, é definida certa quantidade de redes que serão criadas para cada mês e ano, no qual, cada nova rede criada os parâmetros são alterados, assim, é possível encontrar de forma exaustiva os parâmetros que mais se adequam a um determinado período. Deste modo, para cada mês e ano que será previsto são geradas diversas redes com o objetivo de encontrar a que mais se adapta ao período desejado.

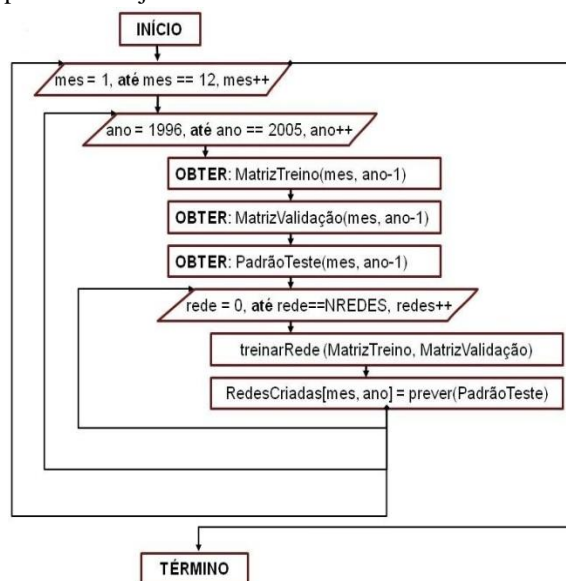


Figura 1: Metodologia de Previsão.

Para deixar claro, por exemplo, caso se queira realizar a previsão para o mês de janeiro de 1998, os dados utilizados para o treino da rede são os dados dos meses precedentes a janeiro de 1987 até janeiro de 1992, para conseguir os dados de validação são utilizados os 10 anos

que precedem um ano antes do desejado, neste caso, são utilizados os dados de janeiro de 1996 até janeiro 1988 e os dados utilizados para testar a rede é o ano anterior ao ano que será previsto, ou seja, os dados dos meses de julho de 1996 até janeiro 1997. A Tabela 1 ilustra de forma clara os dados utilizados para realizar o treino, a validação e o teste da RNA.

Tabela 1: Padrões Utilizados.

Matriz Treino				
jul/86	ago/86	...	dez/86	jan/87
⋮	⋮		⋮	⋮
jul/31	ago/31	...	dez/31	jan/32

Matriz Validação				
jul/95	ago/95	...	dez/95	jan/96
⋮	⋮		⋮	⋮
jul/87	ago/87	...	dez/87	jan/88

Padrão Teste				
jul/96	ago/96	...	dez/96	jan/97

Na são mostrados quais foram os parâmetros utilizados pelo modelo e a faixa de valores que estes parâmetros puderam assumir durante o treinamento da RNA. Para o início dos experimentos foram realizadas 500 previsões para cada um dos meses propostos, onde os parâmetros da RNA foram estimados aleatoriamente através de uma busca exaustiva no domínio apresentado na Tabela 2, desta forma foi possível encontrar os parâmetros que poderiam ser os mais adaptados para este modelo de previsão.

Tabela 2: Parâmetros da RNA.

Número de Camadas	[3 - 8]
Número de Neurônios	[1 - 12]
Taxa Aprendizagem	[0.0 - 1.0]
Termo Momentum	[0.0 - 1.0]
Função de Ativação	[Tan Hiperbólica, Logística]

Outro parâmetro que é comumente utilizado para se realizar previsões é o número de atrasos que compõem os padrões para a previsão, neste caso os padrões utilizados pelo modelo foram os meses imediatamente anteriores ao mês

desejado a ser previsto. Desta forma, o número de atrasos corresponde à quantidade de meses que serão levados em consideração para a composição do padrão. A Tabela 3 exemplifica um padrão utilizado pelo sistema que utiliza seis atrasos, onde a previsão será realizada para o mês de janeiro de 1998 e os meses de julho até dezembro de 1997 são utilizados como entradas para o modelo. Neste caso t representa apenas uma generalização do padrão utilizado pelo modelo, no qual $t-n$ são as componentes do padrão utilizadas como entrada e $t+1$ é a saída desejada do modelo.

Tabela 3: Exemplo do padrão utilizado no modelo.

	Entradas						Saída Desejada
Mês	jul	ago	set	out	nov	dez	jan
Série	t-5	t-4	t-3	t-2	t-1	t	t+1

A Figura 2 ilustra a metodologia de como foram realizados os experimentos para a determinação dos resultados e para a definição dos parâmetros do modelo.

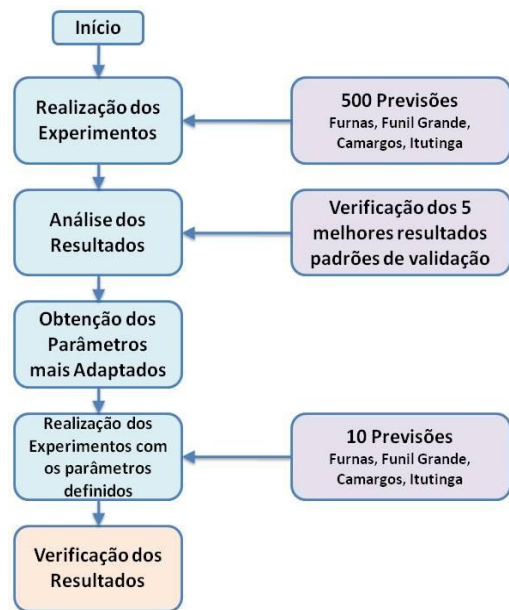


Figura 2: Metodologia utilizada para encontrar os parâmetros mais adaptados.

Como é possível perceber através desta figura, em principio foram realizadas 500 previsões para as usinas definidas e a partir dos resultados obtidos foi realizada uma análise para encontrar os valores dos parâmetros que mais se adaptaram ao modelo, foi considerado o modelo com os parâmetros mais adaptados os que

possuíram menor erro percentual em relação ao resultado real, onde o erro foi calculado com base na média de previsão dos 5 melhores resultados obtidos nos padrões de validação. Após isso, foram realizados novos experimentos já com os parâmetros definidos, foram geradas 10 previsões para cada usina, desta forma foi possível verificar se o modelo configurado com os parâmetros obtidos realmente se comportou de forma estável, ou seja, se os resultados obtidos não possuíam grande variação.

4 Análise dos Dados

Com relação aos dados utilizados neste trabalho, estes são disponibilizados pelo Operador Nacional do Sistema – ONS. Estes dados estão armazenados em arquivos, no qual foram discretizados seguindo um horizonte mensal, e estão representados em um intervalo de 1931 até 2007, no qual representam o fluxo médio de vazão referente aos meses. Em Fortunato (1990, apud Ballini, 2000 p. 2) é mostrado o processo de obtenção dos dados das vazões, a Figura 3 mostra um esquema de como são obtidos tais dados, nessa figura é possível perceber que este processo é complexo baseado em medições e análises.

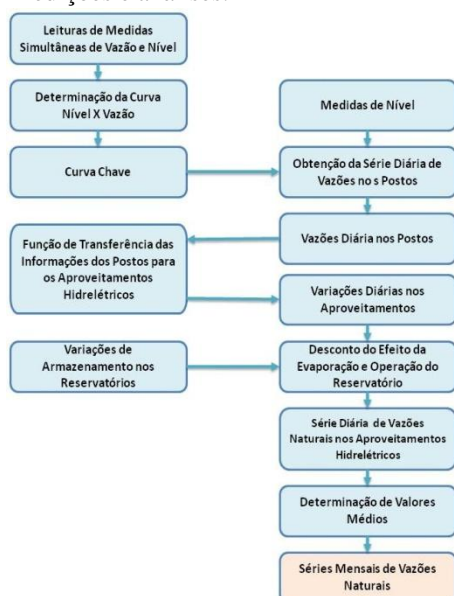


Figura 3: Obtenção dos dados de vazões. Fortunato (1990, apud Ballini, 2000 p. 2).

Nesta pesquisa foram utilizados dados referentes às usinas de Camargos, Itutinga,

Funil Grande e Furnas. A Tabela 4 mostra o máximo, o mínimo, a média, desvio padrão e o coeficiente de variação das séries de vazões das usinas utilizadas neste trabalho. Como é possível perceber nesta tabela, o coeficiente de variação apresenta alta variabilidade nos dados, devido a este comportamento irregular desta série de dados, se torna mais difícil realizar a previsão com grande precisão de acertos.

Tabela 4: Característica dos Dados.

Usina	Máx.	Min.	Méd.	Desv. Pad.	Coef. Var.
Camargos	576m ³ /s	34m ³ /s	132,8m ³ /s	84,3 m ³ /s	63,47%
Itutinga	576m ³ /s	34m ³ /s	132,9m ³ /s	84,4 m ³ /s	63,49%
Funil Gde	1288m ³ /s	68m ³ /s	305,1m ³ /s	197,4m ³ /s	64,71%
Furnas	3757m ³ /s	204m ³ /s	926,6m ³ /s	612,5m ³ /s	66,11%

Para ilustrar esta variabilidade nos dados, a Figura 4 mostra um gráfico com as séries que foram utilizadas para realizar as previsões, que vão desde janeiro de 1996 até dezembro de 2005. Neste gráfico é possível observar a grande diferença existente no conjunto de dados referentes às vazões de uma hidrelétrica.




Figura 4: Séries de Vazões das Usinas: Camargos, Itutinga, Funil Grande e Furnas – Jan/96-Dez/05.

Vale ressaltar que, para o bom funcionamento de um modelo computacional de previsão é importante que a base de dados a ser utilizada passe por um processo de normalização, pois através desta abordagem é possível padronizar os dados dentro de limites pré-definidos para que os dados não apresentem um desvio muito alto. Nesta pesquisa, foi empregado, sobre os dados de vazões, um processo de normalização, para padronizar os dados. Este processo não acarretou na perda da representatividade dos dados normalizados em relação aos dados brutos.

5 Análise dos Resultados

O modelo de previsão utilizado neste trabalho é composto por uma fase de treinamento, no qual os parâmetros são ajustados, e fase de testes, onde é verificado o desempenho do modelo com os parâmetros já definidos. Com o objetivo de avaliar e comparar o desempenho dos resultados obtidos foi adotado o erro absoluto percentual médio (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_i - \tilde{X}_i}{X_i} \right| \quad (1)$$

onde X_i é o valor real e \tilde{X}_i é o valor previsto. A Figura 5 representa a metodologia utilizada para a realização dos testes, na qual nota-se que são realizadas as previsões para as usinas em questão, utilizando-se de *um e dez passos à frente*. Dessa forma será possível perceber qual a influência de se realizar o treinamento a cada ano previsto.




Figura 5: Metodologia utilizada para realizar a previsão.

Para encontrar os resultados, após a rede ter sido treinada e os parâmetros adequados já definidos, foram realizadas dez previsões para cada mês e ano desejado e ao final foi tirado uma média destes resultados obtidos para verificar a porcentagem de erro presente no modelo.

Considerando o processo de previsão com *Dez Passos à Frente*, a Figura 6 ilustra a média de erro encontrada. Nessa figura é possível perceber que os meses que possuem maior valor de precipitação tendem a apresentar uma variação maior, logo o modelo apresenta erros mais elevados. Neste caso a média de erro apresentada pelo sistema foi de 20,79% para a Usina de Furnas, 18,80% para a Usina de Funil Grande, 19,58% para a Usina de Camargos e 19,79% para a Usina de Itutinga.




Figura 6: Previsão *Dez Passos à Frente* (1996 - 2005). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

A Figura 7 apresenta os erros obtidos pelo modelo considerando a previsão *Um Passo à Frente*. Os erros obtidos pelo sistema para as usinas em questão foram: 19,48% para Furnas, 17,07% para Funil Grande, 16,85% para Camargos e 16,66% para Itutinga. Nesta figura é possível visualizar de forma mais clara a variação apresentada nos meses de maior precipitação, no qual, por exemplo, para a Usina de Furnas o erro médio em julho chegou a somente 5%.




Figura 7: Previsão *Um Passo à Frente* (1996 - 2005). Usinas: Camargos, Itutinga, Funil Grande e Furnas.

A partir das Figuras 6 e Figura 7, é possível perceber que a previsão *Um Passo à Frente* apresentou melhores resultados. Isto ocorre porque a rede passa por um treinamento a cada novo ano utilizado como previsão, isto torna a rede mais adaptada aos fatores que ocorrem em anos próximos aos anos que serão previstos, outro fato que é possível notar é que a previsão *Dez Passos à Frente*, apesar de apresentar um erro maior, possui uma taxa de erro mais constante ao longo dos meses, não apresentando grande variação entre a previsão para um mês de seca e um mês de cheia. Este fato ocorre porque

como a rede é treinada apenas uma vez, e esta acaba se estabilizando tendendo a uma faixa de erros constante para todos os meses previstos.

Considerando a previsão *Um Passo à Frente* que aparentou melhores resultados, a Figura 8 ilustra a previsão para os dez anos para a Usina de Furnas seguindo uma discretização mensal, nesta figura é possível visualizar a sequência completa de previsões realizadas sobre os anos desejados, assim como os valores reais das vazões.




Figura 8: Previsão real e desejada – Furnas (1996 - 2005).

Para facilitar a análise dos resultados obtidos através do modelo de previsão, a Tabela 5 apresenta uma visão mais geral sobre a média de erros que foram apresentadas neste trabalho.

Tabela 5: Erros Médios (MAPE) apresentados pelo Modelo de previsão.

Furnas		Funil Grande	
<i>Um Passo à Frente</i>	19,48 %	<i>Um Passo à Frente</i>	17,07 %
<i>Dez Passos à Frente</i>	20,79 %	<i>Dez Passos à Frente</i>	18,80 %
Camargos		Itutinga	
<i>Um Passo à Frente</i>	16,85 %	<i>Um Passo à Frente</i>	16,66 %
<i>Dez Passos à Frente</i>	19,58 %	<i>Dez Passos à Frente</i>	19,79 %

A partir dos experimentos realizados e considerando a busca exaustiva dos parâmetros quem compõem o modelo de RNA presentes neste trabalho, foi possível identificar qual a faixa de valores que mais se adaptam para realizar a previsão de vazões. A Tabela 6 mostra quais valores tiveram maior adaptabilidade tornando o modelo mais estável com menores índices de erros.

Tabela 6: Faixa de valores dos parâmetros do modelo.

Parâmetros da RNA	
Número de Camadas	[3 - 4]
Número de Neurônios	[9 - 10]
Taxa Aprendizagem	[0.1 - 0.2]
Termo Momentum	[0.4 - 0.6]
Função de Ativação	[Tan Hiperbólica, Logística]

Para testar a estabilidade do modelo seguindo a configuração dos parâmetros definidas, foi realizado a previsão para 10 novos anos diferentes dos anos já previstos. O objetivo principal destes testes era verificar se o modelo se comportava de forma consistente com outros padrões de entrada.

As previsões foram feitas para os anos de 1976 até 1985 para as usinas já definidas utilizando-se do processo de previsão com *Um Passo à Frente*, que já foi descrito anteriormente. A Figura 9 apresenta um gráfico contendo a média de erro obtida pelo modelo. A partir desta figura, é possível perceber que os erros médios apresentados pelo modelo foram: 21,78% para a usina de Furnas, 18,19%, para a Usina de Funil Grande, 18,93% para a Usina de Camargos e 18,85% para a Usina de Itutinga. Isto mostra que a variação em relação ao período descrito nos experimentos não foi alta, dessa forma é possível afirmar que o modelo se comportou de forma estável para realizar a previsão para outro período.




Figura 9: Previsão *Um Passo à Frente* (1976 - 1985). Usina: Camargos, Itutinga, Funil Grande e Furnas.

Após a realização dos experimentos foi possível identificar nos parâmetros das redes uma configuração, que na média das previsões, teve maior adaptação para realizar a previsão de vazões, estes parâmetros são: **4** camadas intermediárias, **10** neurônios, taxa de aprendizagem de **0.2**, termo momentum igual a

0.5 e *Tangente Hiperbólica* como função de ativação. Seguindo estas configurações, e realizando a previsão para a usina de Furnas nos 10 anos utilizados, este modelo apresentou erro médio de 19,94%. Em contrapartida, foi escolhida uma configuração aleatória dos parâmetros, que não necessariamente, estavam dentro a faixa de parâmetros pré-definida. Os parâmetros encontrados foram: *1* camada intermediária, *15* neurônios, taxa de aprendizagem de *0.6*, termo *momentum* igual a *0.9* e Logística como função de ativação. Com estas configurações, os resultados apresentaram um erro médio de 26,86%, com isso é possível perceber a influência da escolha de bons parâmetros no processo de configuração das RNAs com o intuito de realizar a previsão de vazões.

4 Conclusão

As previsões de vazão estão sujeitas a uma série de erros oriundos de diversos fatores. Segundo Krauskopf (2005) as fontes de erros mais importantes estão relacionadas à: (1) incapacidade da correta representação do fenômeno hidrológico pelo modelo matemático; (2) dificuldade de obtenção do melhor conjunto de parâmetros do modelo; (3) erros nas medidas das grandezas físicas, precipitação e nível; (4) incerteza das vazões futuras e sua aleatoriedade. O somatório de todos esses erros reflete diretamente nos resultados obtidos através das previsões.

Portanto, este trabalho apresenta um estudo sobre as previsões de vazões realizadas sobre algumas usinas do Rio Grande, no qual foram consideradas as usinas quem compõem a cabeceira do Rio Grande. Desta forma, foi possível perceber que o modelo computacional descrito, especialmente as Redes Neurais, podem ser alternativas interessantes para realizar a previsão de vazões afluentes, no qual através dos resultados obtidos com este trabalho é possível que estes sejam utilizados como comparativos aos demais estudos que venham a ser elaborados para esta mesma bacia. Além disso, a principal contribuição deste trabalho foi explorar os parâmetros das redes neurais que mais se adaptam a previsão de vazões, onde foi mostrada a faixa de valores que os parâmetros podem assumir maximizando os resultados obtidos.

Com propostas futuras, é possível que sejam realizados novas metodologias de testes aplicando outros modelos computacionais a fim de obter resultados mais precisos, além disso, poderão ser realizados testes para realizar a previsão seguindo um horizonte diário, como é mostrado na literatura.

Agradecimentos

Agradecemos à Universidade Federal de Alfenas (UNIFAL-MG), ao Laboratório de Inteligência Computacional (LIInC) e a FAPEMIG pelo apoio e incentivo a pesquisa.

Referências Bibliográficas

- Agência Nacional de Energia Elétrica, ANEEL. “Matriz de energia elétrica”, 2009. Disponível em <http://www.aneel.gov.br/>. Acessado em 19-set-2009.
- Ballini, R. “Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Rede Neurais e Redes Neurais Nebulosas”. 2000. 187f. Tese de Mestrado – Faculdade de Engenharia Elétrica e de Computação, Universidade de Campinas (UNICAMP), Campinas, 2000.
- Box, G.E.P. , Jenkins G.M., 1976, Time Series Analysis, Forecasting and Control, California, USA, San Francisco: Holden Day, 575 págs, Revised Edition
- Bravo, j. M. ; Pedrollo, O. C. ; Collischonn, Walter ; Paz, A. R. ; Uvo, C. B. “Previsões de curto prazo de vazão afluente ao reservatório de Furnas utilizando redes neurais artificiais”. Revista Brasileira de Recursos Hídricos, v. 13, p. 77-88, 2008.
- Cataldi M, Machado C. O., Guilhon, L. G. F., “Análise das previsões de precipitação obtidas com a utilização do modelo Eta como insumo para modelos de previsão semanal de vazão natural”. 556.18, v12, n 3. Revista Brasileira de Recursos Hídricos - RBRH. Porto Alegre: ABRH, v.12, n.3, jul/set. 2007. 219 p.
- Fortunato, L. A. M., Neto, T. A. A., Albuquerque, J. C. R. e Ferreira, C. “Introdução ao Planejamento da Expansão e Operação de Sistemas de Produção de Energia Elétrica”. 1990. Editora Universitária, Niterói, Rio de Janeiro.

- Guilhon, L. G. F. “Modelo heurístico de previsão de vazões naturais médias semanais aplicada à usina de foz do areia”. 2002. 88f. Tese de Doutorado – Programa de Engenharia de Sistemas e Computação (COPPE). Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, 2002.
- Henderson Amparado de Oliveira Silva, 2007 – “Power Map Explorer: Uma Ferramenta para visualização e previsões de vazões”. 2007. 112f. Tese de Mestrado – Instituto de Ciências Matemáticas e de Computação – ICMC/USP, Universidade de São Paulo (USP), São Carlos, 2007.
- Jang J. S. R. “ANFIS: Adaptive Network Based Fuzzy Inference System”. IEEE Transaction System, Man and Cybernetics. 2003
- Krauskopf Neto, R., 2005. “Atualização de Modelos Chuva-Vazão – Propagação Com Estimador de Estado”. 2005. 264f. Tese de Mestrado, Departamento de Engenharia Hidrológica, Universidade Federal do Paraná. Curitiba, 2005.
- Luna H. I., Ballini, R. e Soares, S. “An Adaptive Hybrid Model for Monthly Streamflow Forecasting”. In: The IEEE International Conference on Fuzzy Systems - FUZZ-IEEE'07, 2007, London. Proceedings of the IEEE International Conference on Fuzzy Systems, 2007. p. 1-6.
- Luna H. I., Ballini, R. e Soares, S. “A Constructive-Fuzzy System Modelling for Time series Forecasting”. In: International Joint Conference on Neural Networks - IJCNN'07, 2007, Orlando, Flórida. Proceedings of the International Joint Conference on Neural Networks - IJCNN'07, 2007. p. 1-6.
- Operador Nacional do Sistema - ONS. “Séries de Vazões Mensais”, 2009. Disponível em http://www.ons.org.br/download/operacao/hidrologia/Series_Mensais.zip Acessado em 21-nov-2009.
- Prudêncio, R. B. C. “Projeto Híbrido de Redes Neurais”. 2002.101f. Tese de Mestrado – Centro de Informática. Pernambuco, Universidade Federal de Pernambuco (UFPE), Fortaleza, 2002.
- Salgado, R. M. “Sistema de Suporte à Decisão para Previsão de Carga por Barramento. 2009”. 238f. Tese de Doutorado – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas (UNICAMP), Campinas, 2009.
- Takagi T. e Sugeno M. “Fuzzy Identification of Systems and Its Applications to modeling and Control”. IEEE Transactions on Systems, Man and Cybernetics, 2005.

8.2 Apêndice II

A Tabela 19 mostra os erros obtidos, por oito componentes individuais e quatro modelos de *ensembles*, para a realização das previsões dos anos de 1996 até 2005 utilizando-se o processo de *Treinamento Contínuo*.

Tabela 19 - EMR para as Usinas do SIN

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
14 De Julho	56,0%	61,8%	67,9%	68,2%	70,1%	70,2%	72,7%	75,2%	61,0%	65,7%	66,8%	56,1%
A.A.Laydner	23,1%	25,3%	25,7%	26,8%	27,1%	28,2%	28,9%	35,7%	22,8%	24,6%	22,9%	23,4%
A.S.Lima	22,3%	22,9%	23,0%	23,3%	24,5%	24,7%	26,5%	32,6%	21,8%	22,2%	22,3%	21,8%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
A.S.Lima Artificial	22,2%	22,6%	22,8%	23,2%	24,6%	26,3%	26,9%	33,4%	21,2%	21,9%	21,1%	21,9%
A.S.Oliveira	19,4%	19,6%	19,6%	19,9%	20,3%	28,6%	30,2%	31,1%	49,1%	36,4%	114,3%	19,3%
Agua Vermelha	17,4%	17,5%	17,6%	18,2%	18,2%	21,5%	24,9%	25,7%	16,3%	16,4%	18,0%	15,7%
Aimores	24,9%	24,9%	25,1%	25,1%	27,4%	28,4%	34,3%	36,6%	31,1%	29,2%	46,0%	24,4%
Alto Tiete	27,4%	27,9%	27,9%	28,1%	30,9%	33,2%	35,6%	37,2%	35,8%	33,6%	55,1%	27,2%
Antonio Dias Sa Carvalho	21,6%	22,0%	22,2%	22,3%	23,6%	26,3%	31,4%	32,0%	20,4%	21,1%	21,3%	19,8%
Baguari	20,9%	21,0%	21,5%	21,7%	23,1%	26,9%	28,0%	28,3%	20,2%	21,0%	22,4%	19,3%
Baixo Iguacu	50,3%	56,3%	56,8%	57,1%	57,3%	58,5%	58,8%	58,8%	47,4%	50,6%	50,1%	46,2%
Balbina	28,8%	29,1%	29,2%	29,4%	29,5%	35,1%	38,6%	38,7%	24,5%	25,5%	24,5%	24,6%
Barra Bonita	23,7%	24,2%	24,5%	24,5%	24,8%	25,9%	30,6%	32,0%	22,2%	23,0%	22,3%	22,3%
Barra Bonita Artificial	23,5%	24,1%	24,4%	24,7%	26,0%	26,4%	26,7%	33,0%	22,0%	22,8%	22,4%	22,3%
Barra Dos Coqueiros	17,3%	17,6%	18,0%	18,2%	18,2%	19,8%	20,3%	21,8%	15,4%	15,8%	16,5%	15,5%
Barra Do Brauna	19,6%	20,0%	20,3%	20,8%	21,2%	28,0%	32,4%	33,3%	19,4%	19,3%	19,2%	20,8%
Barra Grande	59,7%	61,8%	64,9%	67,7%	69,8%	69,9%	72,3%	73,8%	60,1%	64,8%	65,5%	55,2%
Batalha	21,1%	22,1%	22,1%	22,3%	23,4%	30,5%	31,3%	32,3%	21,3%	21,7%	22,1%	21,9%
Bau I	17,1%	17,4%	17,6%	17,6%	17,8%	23,2%	25,3%	26,5%	16,4%	16,5%	16,8%	16,3%
Billings	45,6%	45,8%	46,2%	46,4%	46,5%	46,9%	47,4%	49,1%	37,8%	41,3%	39,6%	35,8%
Billings Artificial	32,9%	33,7%	33,8%	34,0%	34,9%	35,3%	35,9%	37,9%	28,8%	31,0%	30,2%	27,6%
Billings Pedras	45,3%	45,5%	45,8%	46,0%	46,0%	46,6%	46,8%	47,7%	38,3%	41,5%	40,2%	36,7%
Boa Esperanca	18,9%	19,4%	19,5%	19,9%	20,2%	20,7%	21,3%	23,6%	17,1%	18,2%	17,6%	17,3%
Bocaina	22,5%	22,5%	22,6%	22,7%	22,8%	27,4%	29,4%	29,5%	20,8%	21,2%	21,6%	20,3%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
Cachoeira Dourada	20,2%	20,4%	20,7%	20,8%	21,3%	25,4%	27,0%	31,3%	18,8%	19,6%	18,8%	19,2%
Cachoeirinha	70,7%	72,5%	82,7%	89,6%	94,8%	96,2%	96,3%	96,9%	78,2%	87,5%	85,0%	71,6%
Caconde	18,6%	19,1%	19,6%	20,3%	20,6%	25,1%	28,0%	28,5%	106,2%	70,5%	298,5%	17,9%
Cacu	15,3%	15,6%	15,7%	15,7%	15,7%	16,6%	17,2%	19,5%	13,8%	14,2%	13,7%	14,0%
Camargos	15,6%	15,8%	15,9%	16,1%	16,2%	24,2%	24,6%	26,3%	14,7%	15,0%	14,9%	14,8%
Campos Novos	55,1%	56,1%	57,6%	58,7%	59,3%	62,9%	63,9%	64,6%	49,5%	54,1%	53,6%	47,2%
Cana Brava	23,9%	24,7%	24,9%	25,3%	25,4%	30,7%	32,4%	32,4%	24,3%	24,3%	26,6%	23,1%
Candongá	17,1%	17,4%	17,6%	17,6%	17,8%	24,1%	24,3%	28,6%	16,3%	16,5%	16,5%	16,4%
Canoas Ii	24,6%	25,2%	26,2%	27,0%	27,4%	27,7%	29,6%	35,7%	23,7%	25,5%	23,7%	23,7%
Canoas I	24,5%	26,1%	26,9%	27,7%	28,4%	29,4%	29,4%	33,3%	24,2%	25,9%	24,4%	24,6%
Capim Branco Ii	19,9%	20,3%	20,4%	20,5%	21,3%	22,1%	24,5%	24,9%	18,9%	19,7%	20,1%	18,5%
Capim Branco I	19,9%	20,2%	20,3%	20,4%	20,9%	24,8%	24,9%	25,3%	17,9%	18,9%	18,0%	17,9%
Capivara	29,0%	29,8%	30,3%	30,8%	33,4%	33,6%	33,7%	36,5%	27,2%	29,1%	28,1%	26,8%
Castro Alves	64,6%	73,2%	74,0%	74,3%	77,8%	78,8%	81,0%	87,7%	68,9%	72,4%	81,0%	59,7%
Chavantes	26,7%	28,8%	29,6%	30,3%	30,7%	32,5%	32,9%	34,6%	28,5%	29,7%	31,9%	27,1%
Coaracy Nunes	25,1%	25,3%	26,1%	26,4%	26,8%	34,2%	38,1%	39,6%	25,4%	25,0%	29,2%	23,6%
Complexo Paulo Afonso-Moxoto	19,0%	19,9%	20,0%	20,7%	21,1%	26,9%	32,9%	34,3%	23,0%	21,4%	32,8%	18,9%
Corumba Iii	19,9%	20,0%	20,7%	20,8%	21,4%	25,5%	27,5%	33,6%	20,5%	20,8%	22,0%	19,6%
Corumba Iv	20,4%	20,4%	21,0%	21,2%	21,9%	25,4%	25,4%	29,3%	19,0%	20,0%	19,5%	18,6%
Corumba I	20,1%	20,6%	21,1%	21,3%	22,4%	25,9%	29,0%	29,2%	21,7%	21,7%	22,4%	21,1%
Couto Magalhaes	14,3%	14,8%	14,9%	15,4%	15,7%	16,0%	16,5%	16,7%	13,7%	14,3%	13,8%	13,6%
Cubatao-Sul	17,5%	17,5%	18,0%	19,4%	19,5%	20,7%	21,1%	42,4%	20,5%	19,6%	19,9%	22,7%
Curua-Una	15,4%	15,7%	15,7%	15,9%	16,0%	26,8%	28,0%	29,8%	16,2%	15,3%	18,0%	15,5%
Dardanelos	32,3%	34,7%	35,4%	35,7%	36,0%	38,2%	38,3%	38,7%	28,5%	29,3%	31,1%	26,8%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
Desvio Jordao	48,4%	54,0%	54,5%	54,8%	56,2%	56,6%	59,2%	60,3%	45,1%	47,9%	53,0%	40,8%
Desvio Jordao Artificial	164,3 %	164,8 %	165,6 %	172,1 %	182,6 %	183,7 %	199,9 %	223,9 %	208,2%	198,2%	359,0 %	95,4%
Dona Francisca	48,0%	48,3%	49,1%	49,8%	50,1%	51,5%	51,9%	54,8%	42,4%	46,6%	46,0%	39,3%
Edgard De Souza Com Tributarios	27,8%	29,4%	29,5%	29,8%	30,6%	33,3%	33,4%	35,9%	27,0%	28,0%	27,2%	27,2%
Edgard De Souza Sem Tributarios	27,9%	29,4%	29,9%	29,9%	30,3%	34,1%	36,0%	37,3%	28,7%	29,0%	31,1%	28,0%
Emborcacao	22,7%	22,8%	23,5%	23,9%	25,4%	26,4%	28,7%	29,2%	22,7%	23,4%	23,3%	22,5%
Ernestina	76,7%	78,7%	80,1%	87,8%	90,1%	90,6%	99,9%	103,9 %	187,6%	145,9%	432,5 %	72,7%
Espora	13,3%	13,3%	13,6%	13,8%	14,4%	17,5%	20,6%	20,9%	14,3%	14,0%	14,4%	14,3%
Estreito	18,9%	19,0%	19,4%	19,7%	19,8%	26,1%	26,2%	26,5%	17,4%	17,9%	17,6%	17,4%
Estreito Tocantins	20,6%	20,6%	20,9%	20,9%	21,0%	26,8%	33,9%	45,8%	26,0%	23,2%	34,4%	22,0%
Euclides Da Cunha	19,4%	19,5%	19,6%	19,7%	20,3%	27,5%	29,8%	30,5%	17,8%	18,0%	18,0%	18,2%
Fontes Artificial	35,4%	39,6%	40,7%	41,3%	42,4%	43,0%	43,8%	44,8%	36,4%	39,3%	41,5%	33,7%
Foz Do Areia	51,5%	52,8%	53,6%	53,8%	56,4%	58,2%	58,5%	58,7%	46,0%	49,9%	50,5%	45,3%
Foz Do Chapeco	53,9%	56,5%	57,6%	58,2%	59,5%	61,8%	65,9%	66,0%	51,1%	56,2%	55,8%	46,9%
Foz Do Chopim	36,5%	42,7%	42,7%	42,8%	43,6%	44,0%	49,3%	65,5%	42,6%	43,8%	46,0%	41,3%
Foz Do Rio Claro	13,6%	13,7%	13,7%	13,8%	13,8%	15,1%	16,9%	21,0%	15,3%	14,2%	23,7%	11,9%
Fundao	51,0%	55,1%	56,5%	56,5%	58,2%	58,5%	58,8%	59,0%	45,9%	49,2%	50,3%	43,2%
Funil-Grande	15,2%	15,4%	15,7%	15,8%	16,0%	24,7%	25,1%	27,3%	15,4%	15,4%	15,6%	15,4%
Funil	22,3%	22,5%	22,9%	23,0%	24,2%	29,1%	31,9%	32,4%	21,3%	22,3%	21,7%	21,1%
Furnas	19,3%	19,4%	19,8%	19,8%	20,0%	24,1%	26,9%	27,0%	17,9%	18,4%	18,7%	17,7%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
Governador Parigot De Souza	23,4%	23,4%	23,4%	23,4%	23,5%	25,4%	25,8%	31,2%	20,6%	22,2%	20,9%	20,5%
Guapore	10,9%	11,0%	11,2%	11,2%	11,4%	16,4%	19,2%	19,9%	10,8%	10,6%	10,8%	10,9%
Guarapiranga	31,3%	31,5%	31,9%	32,3%	34,0%	34,7%	35,7%	37,3%	26,8%	29,4%	27,6%	26,6%
Guilman-Amorim	21,3%	21,8%	21,9%	22,0%	23,5%	29,2%	29,7%	30,2%	20,3%	20,8%	20,5%	20,5%
Henry Borden Artificial	33,9%	34,6%	34,6%	34,8%	35,6%	35,7%	36,7%	37,4%	29,0%	31,5%	30,1%	28,0%
Ibitinga	20,8%	21,2%	21,4%	21,8%	23,2%	24,0%	25,5%	29,3%	20,5%	21,2%	20,5%	20,6%
Ibitinga Artificial	20,5%	20,9%	21,3%	21,7%	23,3%	24,9%	26,4%	28,3%	20,4%	21,3%	20,5%	20,5%
Igarapava	18,8%	19,0%	19,4%	19,7%	19,8%	23,7%	28,3%	28,4%	17,7%	18,1%	18,3%	17,4%
Ilha Dos Pombos	16,4%	16,7%	16,7%	16,9%	17,2%	20,1%	21,7%	25,1%	15,8%	15,9%	16,1%	16,2%
Ilha Dos Pombos Artificial	17,8%	18,0%	18,3%	18,6%	19,6%	25,2%	28,2%	28,5%	17,4%	17,9%	17,1%	18,1%
Ilha Solteira	15,3%	15,7%	15,9%	16,0%	16,0%	18,7%	19,3%	24,1%	14,5%	14,5%	14,3%	14,7%
Ilha Solteira Equivalente	14,6%	14,8%	15,1%	15,3%	15,4%	17,2%	20,2%	23,1%	14,7%	14,4%	16,3%	14,1%
Ilha Solteira Equivalente Artificial	14,6%	14,9%	15,2%	15,3%	15,5%	17,8%	22,9%	23,1%	14,4%	14,2%	14,3%	14,6%
Irape	35,7%	38,4%	39,8%	41,4%	41,6%	41,7%	45,1%	56,8%	42,4%	42,9%	50,1%	37,6%
Itaguacu	15,4%	15,7%	15,7%	15,8%	15,9%	17,1%	18,9%	22,2%	23,1%	19,6%	41,6%	15,0%
Itaipu	15,7%	16,2%	16,4%	16,5%	17,2%	17,2%	17,5%	24,0%	16,3%	16,4%	16,1%	16,6%
Itaipu Artificial	15,7%	16,3%	16,4%	16,5%	17,2%	18,1%	18,3%	26,6%	16,9%	16,8%	17,1%	17,0%
Itaocara	16,4%	16,7%	16,7%	16,9%	17,2%	21,3%	24,3%	26,0%	16,1%	16,2%	15,9%	16,4%
Itaparica	19,6%	20,5%	20,6%	20,8%	21,6%	23,4%	24,4%	31,5%	18,6%	19,1%	20,2%	17,8%
Itapebi	36,5%	36,5%	37,1%	37,5%	38,9%	41,2%	43,6%	104,1%	44,3%	40,9%	65,0%	35,9%
Itauba	45,3%	45,8%	45,8%	46,2%	48,2%	53,1%	53,2%	53,3%	40,3%	44,6%	45,5%	37,5%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
Ita	58,7%	60,1%	62,4%	62,7%	66,2%	66,3%	66,7%	74,0%	57,0%	59,9%	68,6%	49,4%
Itiquira I E li	13,1%	13,2%	13,2%	13,5%	13,9%	15,3%	15,5%	17,7%	12,2%	12,3%	12,1%	12,2%
Itumbiara	20,3%	20,4%	20,7%	21,0%	21,5%	23,4%	29,8%	30,0%	19,6%	20,2%	20,8%	19,0%
Itumirim	13,6%	13,7%	14,1%	14,4%	14,9%	17,8%	17,9%	20,6%	15,2%	14,9%	15,3%	15,1%
Itutinga	15,6%	15,8%	15,9%	16,1%	16,2%	21,9%	24,9%	27,5%	16,0%	15,7%	18,8%	15,0%
Jacui	44,3%	44,4%	44,8%	46,6%	50,9%	51,5%	53,9%	57,2%	43,2%	45,3%	51,8%	38,7%
Jaguara	18,8%	19,0%	19,4%	19,6%	19,8%	26,0%	27,2%	27,7%	18,3%	18,4%	18,6%	18,2%
Jaguari	22,7%	22,8%	22,8%	23,1%	25,0%	27,8%	31,0%	32,9%	20,6%	21,7%	21,3%	20,5%
Jauru	7,1%	7,2%	7,2%	7,2%	7,9%	9,4%	9,5%	12,6%	7,1%	7,3%	7,2%	6,9%
Jirau	12,3%	12,4%	12,7%	12,8%	14,0%	16,8%	18,3%	18,7%	12,0%	12,4%	11,9%	12,0%
Jupia	13,8%	14,0%	14,2%	14,3%	14,4%	15,6%	19,0%	23,1%	13,4%	13,2%	13,2%	13,9%
Jupia Artificial	13,8%	14,0%	14,3%	14,3%	14,4%	15,0%	18,2%	22,8%	13,2%	13,1%	13,0%	13,5%
Lajeado	22,9%	24,0%	24,2%	24,5%	24,5%	29,7%	30,0%	30,8%	22,6%	21,8%	25,0%	21,3%
Lajes Artificial	25,6%	26,4%	28,0%	28,3%	29,4%	30,4%	30,9%	32,2%	24,7%	26,5%	25,1%	24,6%
Lucas Nogueira Garcez	24,7%	26,3%	27,1%	27,8%	28,2%	29,4%	29,7%	31,6%	24,7%	26,5%	25,0%	24,5%
Machadinho	54,4%	55,0%	56,5%	58,4%	58,7%	62,6%	62,9%	62,9%	48,8%	53,2%	54,3%	45,9%
Manso	23,6%	23,6%	23,7%	23,8%	23,8%	23,8%	25,5%	28,8%	20,3%	21,4%	20,9%	20,3%
Marimbond o	17,3%	17,4%	17,7%	18,3%	18,3%	20,6%	23,5%	25,4%	16,0%	16,0%	16,5%	15,8%
Mascarenhas	25,6%	26,0%	26,1%	26,1%	27,9%	29,2%	29,5%	33,2%	24,3%	25,2%	25,1%	24,3%
Mascarenhas De Moraes	18,8%	19,0%	19,4%	19,6%	19,7%	25,5%	26,2%	27,5%	17,4%	18,0%	17,9%	17,4%
Maua	44,1%	44,7%	46,5%	47,4%	48,1%	48,7%	48,8%	50,2%	39,5%	42,2%	42,0%	39,1%
Miranda	20,1%	20,3%	20,5%	20,5%	21,0%	23,0%	24,1%	25,1%	18,2%	19,1%	18,2%	18,1%
Monjolinho	62,6%	64,5%	68,0%	68,4%	68,9%	76,3%	77,3%	93,6%	134,6%	109,0%	295,3%	57,7%
Monte Claro	58,6%	59,3%	62,4%	67,9%	68,2%	70,0%	72,6%	75,5%	58,4%	64,5%	63,8%	55,1%
Moxoto	19,0%	19,9%	20,0%	20,7%	21,1%	29,2%	29,8%	30,4%	18,8%	19,1%	20,4%	18,1%
Murta	34,7%	35,6%	36,4%	36,5%	37,2%	37,5%	40,7%	61,3%	39,6%	39,6%	45,7%	35,0%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
Nilo Pecanha Artificial	9,2%	9,4%	9,5%	9,7%	9,9%	11,6%	12,3%	16,6%	10,3%	9,3%	10,1%	10,5%
Nova Avanhandava	19,6%	19,7%	20,3%	20,8%	22,3%	22,9%	26,4%	29,0%	18,9%	20,1%	19,0%	19,2%
Nova Avanhandava Artificial	19,6%	19,6%	20,4%	20,9%	23,1%	24,3%	26,2%	26,8%	19,6%	20,8%	19,7%	19,7%
Nova Ponte	23,0%	23,1%	23,5%	23,6%	23,7%	26,7%	28,8%	31,9%	21,3%	22,0%	21,5%	21,5%
Olho Dagua	13,1%	13,2%	13,4%	13,5%	14,1%	20,3%	20,7%	21,4%	14,2%	13,8%	15,0%	13,7%
Ourinhos	26,7%	28,9%	29,6%	30,3%	30,4%	32,4%	33,0%	39,7%	26,4%	28,5%	27,2%	26,3%
Pai Quere	61,5%	67,2%	69,5%	71,9%	72,8%	73,9%	75,9%	76,1%	64,2%	69,5%	67,2%	59,1%
Paraibuna	19,7%	19,8%	19,9%	20,9%	22,5%	27,2%	27,4%	27,7%	19,8%	20,6%	20,1%	19,9%
Passo Fundo	51,1%	54,2%	54,6%	54,7%	58,1%	59,2%	62,3%	65,7%	47,3%	51,3%	52,7%	43,7%
Passo Real	44,5%	44,6%	45,0%	46,8%	47,5%	48,7%	51,7%	51,9%	40,5%	44,1%	44,4%	37,6%
Passo Sao Joao	48,3%	54,6%	55,1%	56,6%	58,2%	58,6%	61,9%	62,0%	46,8%	52,5%	54,9%	41,4%
Paulo Afonso	19,0%	19,9%	20,0%	20,7%	21,1%	24,3%	27,6%	28,4%	18,9%	19,3%	20,2%	18,3%
Pedra Do Cavalo	100,3%	101,3%	104,0%	107,0%	115,2%	119,2%	122,3%	214,5%	180,6%	152,1%	345,0%	91,7%
Pedreira	45,8%	46,2%	46,4%	46,5%	46,9%	47,1%	47,2%	47,4%	38,7%	41,9%	40,4%	36,9%
Peixe Angical	24,3%	25,1%	25,2%	25,5%	25,6%	25,7%	30,0%	43,3%	24,3%	22,9%	29,4%	22,2%
Pereira Passos Artificial	11,9%	11,9%	12,0%	12,1%	12,3%	12,6%	14,1%	17,9%	11,5%	11,3%	11,5%	11,9%
Picada	15,8%	15,9%	16,1%	16,1%	16,9%	22,1%	22,1%	23,4%	14,5%	15,1%	14,9%	14,4%
Piraju	23,1%	25,4%	25,8%	26,5%	26,9%	29,1%	32,0%	37,1%	23,5%	25,2%	23,8%	23,6%
Ponte De Pedra	8,3%	8,5%	8,5%	9,0%	9,0%	14,2%	14,3%	14,7%	9,7%	9,0%	9,6%	9,9%
Porto Colombia	19,5%	19,7%	19,9%	20,2%	20,3%	26,3%	26,7%	26,8%	18,3%	18,6%	18,5%	18,2%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
Porto Estrela	27,9%	28,1%	28,4%	29,2%	30,4%	31,1%	31,3%	35,0%	26,7%	28,0%	28,3%	26,4%
Porto Primavera	13,6%	13,6%	13,8%	13,8%	14,0%	15,1%	17,6%	22,1%	13,4%	13,3%	13,2%	13,8%
Porto Primavera Artificial	13,6%	13,7%	13,8%	13,8%	14,0%	16,1%	16,8%	21,7%	13,8%	13,6%	14,6%	13,7%
Promissao	19,7%	19,8%	20,4%	20,8%	21,6%	21,8%	23,2%	28,9%	19,8%	20,8%	19,7%	20,0%
Promissao Artificial	19,7%	19,8%	20,5%	20,9%	21,6%	22,3%	23,4%	26,9%	19,4%	20,7%	19,4%	19,6%
Quebra Queixo	51,0%	62,1%	65,2%	65,3%	66,1%	67,3%	68,3%	69,1%	56,2%	60,9%	60,4%	52,3%
Queimado	18,6%	20,4%	20,8%	20,8%	21,2%	26,1%	27,9%	38,4%	19,9%	20,1%	23,2%	18,2%
Retiro Baixo	27,2%	27,3%	27,7%	27,8%	28,2%	33,8%	36,0%	47,1%	26,4%	26,3%	33,5%	23,0%
Rondon 2	11,0%	11,1%	11,4%	11,4%	11,5%	13,8%	14,0%	14,8%	10,1%	10,5%	10,3%	10,0%
Rosal	26,1%	26,3%	26,3%	26,7%	26,8%	29,4%	31,8%	32,6%	26,3%	26,0%	30,5%	24,3%
Rosana	26,1%	27,0%	27,5%	27,7%	30,2%	31,9%	32,8%	35,2%	25,3%	26,7%	27,3%	24,2%
Salto	13,9%	14,1%	14,3%	14,5%	14,7%	18,1%	18,3%	18,9%	3964,9%	2337,7%	12508,0%	15,2%
Salto Caxias	51,5%	54,9%	55,5%	56,3%	56,8%	57,3%	58,5%	58,6%	44,7%	48,9%	48,1%	43,2%
Salto Grande	27,9%	28,1%	28,4%	29,1%	31,0%	31,3%	32,9%	33,7%	27,0%	28,1%	28,4%	26,2%
Salto Grande Chopim	70,0%	70,6%	84,3%	90,2%	90,4%	91,7%	91,9%	93,2%	99,8%	96,1%	166,2%	67,6%
Salto Osorio	51,5%	52,8%	53,3%	53,6%	54,6%	54,7%	56,2%	56,6%	44,9%	48,6%	48,0%	43,5%
Salto Pilao	46,4%	47,5%	48,5%	48,5%	50,1%	54,1%	56,0%	58,7%	44,4%	48,2%	45,5%	43,4%
Salto Santiago	52,4%	52,8%	52,9%	54,1%	56,2%	56,3%	56,8%	57,7%	47,9%	50,3%	58,1%	44,5%
Salto Verdinho	14,0%	14,1%	14,4%	14,5%	14,8%	17,6%	18,0%	18,3%	13,3%	13,5%	13,4%	13,2%
Samuel	30,5%	32,4%	33,1%	33,4%	33,4%	34,3%	35,0%	35,0%	31,4%	32,6%	34,8%	31,3%
Santana	25,4%	26,3%	27,1%	27,3%	28,9%	30,1%	31,7%	34,8%	23,9%	25,5%	25,3%	23,5%
Santana Artificial	12,2%	12,3%	12,4%	12,7%	12,7%	13,9%	13,9%	19,7%	12,6%	12,1%	13,6%	12,4%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
Santa Branca	19,2%	19,5%	19,5%	20,1%	21,8%	24,6%	25,1%	26,1%	30,8%	26,6%	56,8%	19,0%
Santa Cecilia Bombeamento	11,2%	11,3%	11,5%	11,6%	11,6%	13,9%	14,4%	18,3%	11,8%	11,2%	12,0%	11,8%
Santa Clara Mg	39,8%	39,9%	40,0%	40,1%	40,1%	40,9%	44,4%	60,0%	39,6%	40,0%	45,8%	37,2%
Santa Clara Pr	45,6%	51,4%	55,2%	56,6%	56,7%	58,3%	59,2%	61,5%	45,0%	48,9%	48,9%	41,8%
Santa Isabel	15,6%	15,8%	16,3%	16,3%	17,5%	21,0%	21,7%	22,8%	16,8%	16,7%	17,4%	16,9%
Santo Antonio	12,3%	12,4%	12,7%	12,8%	14,0%	16,6%	17,3%	19,1%	11,8%	12,2%	11,7%	12,6%
Sao Domingos	8,0%	8,1%	8,1%	8,3%	8,5%	11,3%	12,6%	15,1%	9,3%	8,3%	9,4%	9,4%
Sao Jeronimo	41,1%	42,1%	44,3%	45,4%	47,0%	47,3%	47,4%	47,4%	36,8%	40,5%	38,8%	35,8%
Sao Joao	74,1%	75,1%	85,7%	88,2%	94,0%	95,2%	95,5%	95,8%	76,3%	85,5%	86,0%	68,2%
Sao Jose	52,3%	54,6%	54,9%	58,6%	58,7%	61,4%	62,3%	62,6%	51,7%	54,8%	66,5%	43,6%
Sao Salvador	23,8%	23,9%	24,2%	24,3%	24,9%	26,1%	38,4%	50,4%	68,1%	49,6%	163,5%	24,3%
Sao Simao	17,9%	17,9%	17,9%	18,0%	18,2%	23,3%	23,4%	24,4%	16,8%	17,0%	16,5%	17,0%
Segredo	49,3%	49,7%	50,6%	51,4%	52,3%	52,9%	54,1%	54,8%	42,7%	46,6%	45,0%	41,9%
Serra Da Mesa	24,9%	25,4%	26,1%	26,1%	26,4%	28,0%	29,2%	32,7%	26,3%	26,0%	28,7%	24,1%
Serra Do Facao	20,4%	20,5%	21,5%	21,9%	22,8%	24,9%	28,9%	31,5%	20,6%	21,1%	20,9%	20,8%
Simplicio	18,0%	18,1%	18,4%	18,8%	19,8%	25,5%	27,0%	27,6%	18,0%	18,3%	18,0%	18,4%
Simplicio	16,1%	16,3%	16,4%	16,6%	17,0%	22,6%	23,0%	25,0%	15,8%	15,9%	15,6%	16,2%
Sobradinho	20,4%	20,8%	22,0%	22,2%	22,9%	27,4%	32,4%	33,2%	19,5%	20,2%	20,7%	19,7%
Sobradinho Incremental	24,5%	25,1%	26,0%	27,3%	28,0%	32,9%	34,9%	35,9%	23,2%	24,5%	24,4%	22,4%
Sobragi	13,8%	13,8%	13,9%	14,0%	14,4%	20,1%	24,8%	26,7%	14,7%	14,2%	16,9%	13,7%
Sta Cecilia	21,2%	21,3%	21,6%	21,8%	23,1%	26,1%	26,4%	27,9%	19,6%	20,6%	20,4%	19,4%
Taquarucu	27,6%	28,3%	28,8%	29,0%	29,2%	32,0%	32,9%	38,1%	26,1%	28,0%	27,4%	25,7%
Tocos	25,5%	26,7%	27,9%	28,1%	30,1%	33,0%	33,8%	34,3%	25,6%	27,0%	28,7%	24,3%

Usinas	Componentes								Ensemble			
	#Cp1	#Cp2	#Cp3	#Cp4	#Cp5	#Cp6	#Cp7	#Cp8	MA	MP	MQ	MG
Traicao	35,7%	36,4%	36,8%	37,2%	37,5%	37,9%	38,2%	40,5%	29,8%	32,6%	31,0%	28,7%
Tres Irmaos	17,9%	17,9%	18,4%	18,8%	19,5%	20,8%	22,6%	26,5%	18,3%	18,9%	18,3%	18,5%
Tres Irmaos Artificial	17,8%	18,0%	18,5%	18,9%	20,0%	20,8%	24,9%	27,4%	18,2%	19,0%	18,3%	18,3%
Tres Marias	30,8%	32,4%	33,4%	33,9%	34,1%	34,7%	37,0%	37,7%	29,4%	31,2%	30,3%	29,1%
Tucuruí	14,7%	15,0%	15,1%	16,1%	16,2%	20,4%	21,3%	21,5%	15,4%	15,4%	15,8%	15,3%
Vigario Artificial	12,0%	12,1%	12,2%	12,5%	12,5%	13,3%	14,8%	20,2%	12,4%	11,8%	12,2%	12,6%
Volta Grande	18,9%	19,1%	19,4%	19,8%	19,8%	26,0%	26,2%	28,6%	17,9%	18,3%	18,7%	17,7%
Xingo	19,0%	19,9%	20,0%	20,7%	21,1%	25,1%	25,7%	34,6%	17,8%	18,6%	19,5%	16,7%
Segredo Desvio Artificial	47,5%	48,1%	48,7%	50,0%	50,7%	51,1%	51,8%	54,7%	41,3%	44,2%	43,2%	40,5%

#Cp1, #Cp2, #Cp3 e #Cp4 são componentes de RLM, #Cp5 e #Cp6 são componentes de PRG e #Cp7, #Cp8 são componentes de RNA.

8.3 Anexo I

A seguir serão apresentados os resultados que foram obtidos a partir da aplicação dos Testes “F” e de *Tukey* utilizando o Software **R**. Os dados mostram os testes aplicados seguindo uma discretização mensal para a Usina de Furnas. Nesses testes é possível visualizar maiores detalhes sobre a o Teste “F” da ANAVA e o Teste de *Tukey*.

Janeiro

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.017	0.003	0.053	0.999
Resíduo	63.000	3.264	0.052		
Total	69.000	3.280			

Teste de Tukey

Grupos	Tratamentos	Médias
a	RNA	0.3210674
a	MG	0.3129711
a	MA	0.2990338
a	RLM	0.2931728
a	MQ	0.2882825
a	PRG	0.2801957
a	MP	0.2755312

Fevereiro

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.161	0.027	0.616	0.717
Resíduo	63.000	2.738	0.043		
Total	69.000	2.899			

Teste de Tukey

Grupos	Tratamentos	Médias
a	RNA	0.2795604
a	PRG	0.263749
a	RLM	0.2191970
a	MP	0.1732384
a	MQ	0.1685833
a	MA	0.1577737
a	MG	0.1569323

Março

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.065	0.011	1.468	0.204
Resíduo	63.000	0.463	0.007		
Total	69.000	0.528			

Teste de Tukey

Grupos	Tratamentos	Médias
a	PRG	0.1633296
a	RLM	0.1423696
a	RNA	0.1270958
a	MG	0.09832064
a	MQ	0.0895295
a	MA	0.0835187
a	MP	0.07753348

Abril

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.138	0.023	1.279	0.280
Resíduo	63.000	1.130	0.018		
Total	69.000	1.267			

Teste de Tukey

Grupos	Tratamentos	Médias
a	PRG	0.2854375
a	RNA	0.2147760
a	RLM	0.1804154
a	MQ	0.1713181
a	MP	0.1675950
a	MA	0.1576218
a	MG	0.1445716

Maio

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.003	0.001	0.058	0.999
Resíduo	63.000	0.586	0.009		
Total	69.000	0.589			

Teste de Tukey

Grupos	Tratamentos	Médias
a	PRG	0.1461894
a	MQ	0.1418567
a	RLM	0.1404120
a	RNA	0.1348398
a	MA	0.1328576
a	MP	0.1285427
a	MG	0.1260263

Junho

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.010	0.002	0.249	0.958
Resíduo	63.000	0.439	0.007		
Total	69.000	0.450			

Teste de Tukey

Grupos	Tratamentos	Médias
a	MQ	0.1222530
a	PRG	0.1194654

a	RNA	0.1082384
a	MA	0.09683361
a	RLM	0.09645666
a	MP	0.09406503
a	MG	0.08836324

Julho

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.023	0.004	1.910	0.093
Resíduo	63.000	0.124	0.002		
Total	69.000	0.147			

Teste de Tukey

Grupos	Tratamentos	Médias
a	PRG	0.1044636
a	RNA	0.06100953
a	MG	0.05974984
a	MP	0.05776951
a	RLM	0.05555341
a	MA	0.05242844
a	MQ	0.04469623

Agosto

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.008	0.001	0.217	0.970
Resíduo	63.000	0.391	0.006		
Total	69.000	0.399			

Teste de Tukey

Grupos	Tratamentos	Médias
a	PRG	0.1330151
a	RNA	0.1246705
a	RLM	0.11236
a	MQ	0.1114219
a	MP	0.109138
a	MA	0.1050562
a	MG	0.09910247

Setembro

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.020	0.003	0.085	0.998
Resíduo	63.000	2.491	0.040		

Total 69.000 2.511

Teste de Tukey

Grupos Tratamentos Médias
a PRG 0.3319933
a RLM 0.3178590
a RNA 0.3079572
a MP 0.3026914
a MQ 0.2891502
a MA 0.2857639
a MG 0.2821959

----- ----- Outubro -----

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.038	0.006	0.074	0.998
Resíduo	63.000	5.434	0.086		
Total	69.000	5.473			

Teste de Tukey

Grupos Tratamentos Médias
a MP 0.4387655
a RLM 0.423864
a MQ 0.414931
a PRG 0.4097091
a MA 0.3954451
a MG 0.3739917
a RNA 0.3706448

----- ----- Novembro -----

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.082	0.014	0.667	0.677
Resíduo	63.000	1.291	0.020		
Total	69.000	1.373			

Teste de Tukey

Grupos Tratamentos Médias
a PRG 0.2825842
a RNA 0.2090981
a RLM 0.2062312
a MQ 0.1870252
a MA 0.1835657
a MP 0.1826880
a MG 0.1752043

Dezembro

Quadro da análise de variância

	GL	SQ	QM	Fc	Pr>Fc
Tratamento	6.000	0.017	0.003	0.053	0.999
Resíduo	63.000	3.264	0.052		
Total	69.000	3.280			

Teste de Tukey

Grupos	Tratamentos	Médias
a	RNA	0.3210674
a	MG	0.3129711
a	MA	0.2990338
a	RLM	0.2931728
a	MQ	0.2882825
a	PRG	0.2801957
a	MP	0.2755312
