

**ISABELA ALBUQUERQUE TAVARES**

**PREVISÃO DE VAZÃO UTILIZANDO MODELOS DE  
INTELIGÊNCIA ARTIFICIAL**

**Recife – Pernambuco – Brasil**

**Outubro de 2009**

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**  
**CENTRO DE TECNOLOGIA E GEOCIÊNCIAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**PREVISÃO DE VAZÃO UTILIZANDO MODELOS DE  
INTELIGÊNCIA ARTIFICIAL**

por

**ISABELA ALBUQUERQUE TAVARES**

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

**ORIENTADOR: PROF. RONALDO RIBEIRO BARBOSA DE AQUINO**  
**CO-ORIENTADORA: PROF<sup>a</sup>. MILDE MARIA DA SILVA LIRA**

Recife, outubro de 2009.

©Isabela Albuquerque Tavares, 2009

**T231p**

**Tavares, Isabela Albuquerque.**

Previsão de vazão utilizando modelos de inteligência artificial /  
Isabela Albuquerque Tavares. - Recife: O Autor, 2009.  
xiii, 89 folhas, il : figs., tabs.

Dissertação (Mestrado) – Universidade Federal de Pernambuco.  
CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2009.

Inclui Referências Bibliográficas.

1. Engenharia Elétrica. 2. Lógica Fuzzy. 3. Redes Neurais  
Artificiais. 4. Inteligência Artificial. 5. Previsão de vazão. 6. Sistema  
Hidroelétrico. I. Título.

UFPE

621.3

CDD (22. ed.)

BCTG/2009-254



**Universidade Federal de Pernambuco**

**Pós-Graduação em Engenharia Elétrica**

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE  
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

**ISABELA ALBUQUERQUE TAVARES**

TÍTULO

**“PREVISÃO DE VAZÃO UTILIZANDO  
MODELOS DE INTELIGÊNCIA ARTIFICIAL”**

A comissão examinadora composta pelos professores: RONALDO RIBEIRO BARBOSA DE AQUINO, DEESP/UFPE, MARCELO CABRAL CAVALCANTI, DEESP/UFPE, MILDE MARIA DA SILVA LIRA, DEESP/UFPE e BENEMAR ALENCAR DE SOUZA, DEE/UFCG sob a presidência do primeiro, consideram a candidata **ISABELA ALBUQUERQUE TAVARES APROVADA.**

Recife, 16 de outubro de 2009.

**RAFAEL DUEIRE LINS**  
Coordenador do PPGE

**RONALDO RIBEIRO BARBOSA DE AQUINO**  
Orientador e Membro Titular Interno

**MILDE MARIA DA SILVA LIRA**  
Co-Orientadora e Membro Titular Externo

**MARCELO CABRAL CAVALCANTI**  
Membro Titular Interno

**BENEMAR ALENCAR DE SOUZA**  
Membro Titular Externo

## DEDICATÓRIA

A DEUS pelo dom da vida.

A Jorge José e Maria Luiza, meus pais, fontes de inspiração para realização de todos os projetos de minha vida.

A Pedro, meu irmão, anjo de Deus em minha vida.

A meu amado esposo Filipe presente em toda essa jornada.

A minha tia-avó, Nina in memoriam.

A todos os meus familiares que sempre foram “porto seguro” durante toda a jornada, em especial as minhas avós, Maria e Nidinha.

Eu dedico este trabalho.

## AGRADECIMENTOS

A Deus, pela sua presença constante em minha vida, por colocar tantas pessoas maravilhosas ao meu redor e principalmente pelo dom da sabedoria para o desenvolvimento deste trabalho.

Ao meu pai, Jorge José pelo amor, dedicação, apoio e ao incentivo para seguir sempre em frente.

A minha mãe, Maria Luiza pelo amor que só as mães são capazes de oferecer, pelas força e presença constante em todos os momentos de minha vida. E, por me ensinar tantas coisas na vida.

A meu irmão, Pedro pela união que ajudou a tornar o caminho mais suave.

Ao meu amado esposo, Filipe por todo amor, carinho, dedicação, alegria e por compartilhar todos estes momentos ao meu lado.

Especialmente ao Prof. Dr. Ronaldo Aquino pela paciência, dedicação, apoio e motivação; verdadeiro professor, PAI e amigo de todas as horas.

A todos os professores do mestrado, ao Prof. Dr. Manoel Afonso que sempre apoiou este projeto.

Aos meus amigos do LEEQE, Priscila e Jorge, pelo apoio, incentivo e compartilhar todas as dificuldades da vida de mestrando.

A todos do LDSP, a Josinaldo pelo apoio e atenção dispensada, nos momentos que mais precisamos e pela sincera amizade.

A todos do grupo católico “Água Viva” pela linda missão de levar Cristo a todos, em especial pelo trabalho realizado na UFPE.

A todos meus amigos, pela compreensão, pois são muitas as dificuldades na vida acadêmica.

Outrossim, agradeço a todos que auxiliaram a tornar este projeto possível.

## **PENSAMENTO**

"Lutar Sempre, Desistir Nunca!"

É nessa promessa que venho buscando viver, e seguir a vontade de Deus. Por mais difícil que seja os obstáculos, os problemas, as nossas fraquezas, Deus está sempre conosco, e a cada dia dá as maiores provas do seu amor.

Resumo da Dissertação como parte dos requisitos necessários para obtenção do grau de Mestre em Engenharia Elétrica.

## **PREVISÃO DE VAZÃO UTILIZANDO MODELOS DE INTELIGÊNCIA ARTIFICIAL**

**Isabela Albuquerque Tavares**

Outubro de 2009

**Orientador:** Prof. Ronaldo Ribeiro Barbosa de Aquino, D. Sc.

**Co-orientadora:** Prof<sup>a</sup>. Milde Maria da Silva Lira, D. Sc.

**Área de Concentração:** Processamento de Energia

**Palavras-chave:** Lógica Fuzzy, Redes Neurais Artificiais, Inteligência Artificial, Previsão de vazão, Sistema Hidroelétrico.

**Número de Páginas:** 89

Este trabalho apresenta a previsão de vazão na bacia do rio São Francisco, utilizando-se de quatro modelos baseado nas principais ferramentas de inteligência artificiais: RNA (Redes Neurais Artificiais) e lógica fuzzy. No primeiro modelo foram escolhidas as RNAs para prever a vazão mensal com horizonte de um ano. No segundo modelo, utilizou-se a RNA e o sistema ANFIS (Adaptive Neuro-Fuzzy Inference System) para realizar a previsão mensal em horizonte de um e dois meses à frente. No terceiro modelo, foi estudado um sistema híbrido, no qual a RNA realiza uma previsão de vazão com horizonte anual e o sistema ANFIS desagrega em meses. Por fim, foi estudado outro sistema híbrido semelhante ao anterior, no qual se utilizou o método dos fragmentos para a desagregação mensal da vazão. O processo de escolha dos modelos das redes neurais e sistema ANFIS, passaram por uma análise de estrutura da entrada a partir da base de dados. Os dados de vazão utilizados foram do Operador Nacional do Sistema Elétrico (ONS) no período de 1931 a 2004, para realizar o ajuste dos modelos. Para avaliar o desempenho dos modelos foram utilizados os resultados das previsões obtidas no período 2005 a 2008. Através destes modelos, este trabalho visa contribuir de forma direta com o setor elétrico brasileiro que tem cerca de 90% de sua energia proveniente de usinas hidroelétricas.



Abstract of Dissertation as a partial fulfillment of the requirement for the Master's degree in Electrical Engineering.

## **FLOW FORECAST USING ARTIFICIAL INTELLIGENCE MODELS**

**Isabela Albuquerque Tavares**

October of 2009

**Supervisor:** Prof. Ronaldo Ribeiro Barbosa de Aquino, D. Sc.

**Co-supervisor:** Prof<sup>a</sup>. Milde Maria da Silva Lira, D. Sc.

**Area of Concentration:** Energy processing

**Keywords:** Fuzzy Logic, Artificial Neural Network, Artificial Intelligence, Flow Forecasting, hydroelectric system.

**Number of Pages:** 89

This work uses four models based on the most important techniques of Artificial Intelligence: Artificial Neural Network (ANN) and fuzzy logic for flow forecasting in San Francisco River. In the first model, ANN was used to forecast the flow one year ahead. In the second model, ANN and ANFIS system (Adaptive Network-based Fuzzy Inference System) were used to forecast the flow one and two months ahead. In the third model, a hybrid system was studied, in which the ANN forecast an annual flow and the ANFIS system disaggregates it into monthly flow. Finally, another hybrid system based on the disaggregated method was used to disaggregate annual flow into monthly flow. An analysis of the database structure was necessary in order to choose the best neural network architecture and ANFIS system. The database used in this work had been taken from the National Power System Operator (ONS), whose data in the period from 1931 to 2004 was used to develop the models and that in the period from 2005 to 2008 was used to evaluate their performance. After analyzing the simulation results, we have concluded that this work can contribute to the Brazilian electric sector where more than 90% of its electricity comes from hydroelectric sources.

# SUMÁRIO

<b>LISTA DE FIGURAS</b> .....	XII
<b>LISTA DE TABELAS</b> .....	XIII
<b>LISTA DE ABREVIATURAS E SIGLAS</b> .....	XIV
<b>LISTA DE SÍMBOLOS</b> .....	XV
<b>CAPÍTULO 1</b> .....	16
1 INTRODUÇÃO.....	16
1.1 Sistema Hidroelétrico do São Francisco.....	18
1.2 Organização do Trabalho.....	21
<b>CAPÍTULO 2</b> .....	23
2 REDES NEURAIS ARTIFICIAIS.....	23
2.1 Introdução.....	23
2.2 Introdução às Redes Neurais Artificiais.....	23
2.2.1 Histórico das Redes Neurais.....	24
2.2.2 Neurônio Artificial.....	25
2.2.3 Função de Ativação.....	26
2.2.4 Processo de Aprendizagem.....	27
2.2.5 Redes Perceptron Múltiplas Camadas.....	29
2.3 Algoritmos de Treinamento.....	30
2.3.1 Gradiente Descendente com Momento (GDM).....	30
2.3.2 Algoritmo Resilient Propagation (RPROP).....	31
2.4 Conclusões do Capítulo.....	33
<b>CAPÍTULO 3</b> .....	34
3 LÓGICA FUZZY.....	34
3.1 Introdução.....	34
3.2 Histórico da Lógica Fuzzy.....	34
3.3 Metodologia da Lógica Fuzzy.....	36
3.4 Sistema de Inferência Fuzzy.....	37
3.5 Sistema Híbrido: Lógica Fuzzy + Redes Neurais Artificiais.....	38
3.6 Sistema Neuro-Fuzzy: ANFIS.....	39
3.7 Conclusões do Capítulo.....	42
<b>CAPÍTULO 4</b> .....	44
4 METODOLOGIA APLICADA.....	44
4.1 Metodologia.....	44
4.2 Tratamento dos Dados.....	45
4.2.1 Embaralhamento dos Dados.....	46
4.2.2 Normalização dos Dados.....	46
4.2.3 Separação dos Dados para Treinamento e Validação.....	47
4.3 Experimentos para Escolha da Arquitetura.....	47
4.3.1 Avaliação de Desempenho.....	48
4.3.2 Critérios de Parada dos Treinamentos.....	48
4.4 Seleção de Arquitetura.....	49
4.5 Algoritmo de Treinamento.....	50
4.6 Validação Cruzada: Usando o Método 10-fold.....	50
4.7 Conclusões do Capítulo.....	51
<b>CAPÍTULO 5</b> .....	52
5 MODELOS DE PREVISÃO.....	52
5.1 Horizontes para Previsão de Vazão.....	52

5.2	Função Autocorrelação (ACF) .....	53
5.3	Modelos para Previsão Utilizando RNA .....	55
5.3.1	Primeira Configuração.....	56
5.3.2	Segunda Configuração.....	56
5.3.3	Terceira Configuração .....	57
5.4	Modelos para Previsão Utilizando RNA e ANFIS.....	58
5.4.1	Configuração Um Mês à Frente para o Treinamento com RNA e ANFIS.	58
5.4.2	Configuração Dois Meses à Frente para o Treinamento com RNA e ANFIS	59
5.5	Modelos para Previsão Utilizando o Sistema Híbrido RNA-ANFIS .....	60
5.6	Modelos para Previsão Utilizando o Sistema Híbrido RNA-Fragmentos.....	61
5.7	Conclusões do Capítulo .....	62
CAPÍTULO 6 .....		63
6	RESULTADOS .....	63
6.1	Resultados da Previsão Utilizando RNA: Horizonte Anual.....	63
6.1.1	Resultados do Treinamento .....	63
6.1.2	Avaliação das Previsões .....	64
a.	Simulação da Melhor Rede para Primeira Configuração .....	64
b.	Simulação da Melhor Rede para Segunda Configuração .....	65
c.	Simulação da Melhor Rede para Terceira Configuração.....	66
d.	Erro Calculado com Relação à Média .....	67
e.	Avaliação da Melhor Configuração Simulada.....	68
6.2	Resultados da Previsão Utilizando RNA e ANFIS: Horizonte Mensal .....	69
6.2.1	Resultados do Treinamento com RNA na Configuração Um Mês à Frente	69
6.2.2	Resultados da Previsão com RNA na Configuração Um Mês à Frente .....	70
6.2.3	Resultados do Treinamento com RNA na Configuração Dois Meses à Frente	70
6.2.4	Resultados da Previsão com RNA na Configuração Dois Meses à Frente	71
6.2.5	Conclusão dos Resultados com RNA para o Horizonte Mensal .....	72
6.2.6	Resultados do Treinamento com o ANFIS na Configuração Um Mês à Frente	72
6.2.7	Resultados da Previsão com o ANFIS na Configuração Um Mês à Frente	73
6.2.8	Resultados do Treinamento com o ANFIS na Configuração Dois Meses à Frente	74
6.2.9	Resultados da Previsão com o ANFIS na Configuração Dois Meses à Frente	75
6.2.10	Conclusão dos Resultados com o ANFIS.....	75
6.3	Resultados da Previsão Utilizando o Sistema HÍBRIDO RNA-ANFIS .....	76
6.4	Sistema Híbrido RNA-Fragmentos .....	77
6.5	Análise Final dos Resultados.....	78
6.6	Comentários dos Resultados Finais.....	82
6.7	Conclusões do Capítulo .....	83
CAPÍTULO 7 .....		84
7	CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS.....	84
7.1	Conclusões.....	84
7.2	Trabalhos Futuros .....	85
REFERÊNCIAS BIBLIOGRÁFICAS .....		88

## LISTA DE FIGURAS

<i>Figura 1.1</i> <i>Bacia do Rio São Francisco</i> .....	19
<i>Figura 1.2</i> <i>Localização das Usinas Hidroelétricas no Rio São Francisco</i> .....	20
<i>Figura 2.1</i> <i>Modelo de um Neurônio Artificial</i> .....	26
<i>Figura 2.2</i> <i>Funções de Ativações</i> .....	27
<i>Figura 2.3</i> <i>Diagramas de Blocos da Aprendizagem com Professor</i> .....	28
<i>Figura 2.4</i> <i>Aprendizado não supervisionado</i> .....	29
<i>Figura 2.5</i> <i>Arquitetura perceptron de múltiplas camadas com uma camada oculta</i> .....	30
<i>Figura 3.1</i> <i>Sistema de Inferência Fuzzy</i> .....	38
<i>Figura 3.2</i> <i>Arquitetura Neuro-Fuzzy: ANFIS</i> .....	40
<i>Figura 3.3</i> <i>Exemplo do Sistema Takagi-Sugeno de Primeira Ordem</i> .....	42
<i>Figura 4.1</i> <i>Vazão Média do rio São Francisco em função dos meses do ano</i> .....	45
<i>Figura 5. 1</i> <i>Função Autocorrelação Mensal</i> .....	54
<i>Figura 5. 2</i> <i>Função Autocorrelação Anual</i> .....	55
<i>Figura 5. 3</i> <i>Elementos básicos da primeira configuração</i> .....	56
<i>Figura 5. 4</i> <i>Elementos básicos da segunda configuração: (a) 5 meses de cheia (dezembro a abril); (b) 7 meses considerados secos (maio a novembro)</i> .....	57
<i>Figura 5. 5</i> <i>Elementos básicos da terceira configuração: usando senos e cossenos</i> .....	58
<i>Figura 5. 6</i> <i>Modelo de previsão Híbrido RNA-ANFIS</i> .....	61
<i>Figura 5. 7</i> <i>Previsão de vazão anual utilizando redes neurais</i> .....	62
<i>Figura 6.1</i> <i>MAPE das três configurações</i> .....	64
<i>Figura 6.2</i> <i>Erro da previsão dos anos de 2005, 2006, 2007 e 2008 com a Configuração 1</i> .....	65
<i>Figura 6.3</i> <i>Erro da previsão dos anos de 2005, 2006, 2007 e 2008 com a Configuração 2</i> .....	66
<i>Figura 6.4</i> <i>Erro da previsão do ano de 2005, 2006, 2007 e 2008 com a Configuração 3</i> .....	66
<i>Figura 6. 5</i> <i>Erro Calculado com Relação à Média</i> .....	67
<i>Figura 6.6</i> <i>Vazão calculada na Configuração 2</i> .....	68
<i>Figura 6.7</i> <i>MAPE da Previsão na Configuração Um mês à Frente com RNA</i> .....	70
<i>Figura 6.8</i> <i>MAPE da Previsão na Configuração Dois Meses à Frente com RNA</i> .....	72
<i>Figura 6.9</i> <i>MAPE da Previsão na Configuração Um Mês à Frente com o ANFIS</i> .....	74
<i>Figura 6.10</i> <i>MAPE da Previsão na Configuração Dois Meses à Frente com o ANFIS</i> .....	75

## LISTA DE TABELAS

<i>Tabela 4.1 Formação dos conjuntos .....</i>	<i>51</i>
<i>Tabela 5.1 Configuração Um Mês à Frente Utilizada para o Treinamento da RNA e ANFIS .....</i>	<i>59</i>
<i>Tabela 5.2 Configuração Dois Meses à Frente Utilizada para o Treinamento da RNA e ANFIS .....</i>	<i>59</i>
<i>Tabela 6.1 Comparação entre os resultados das três configurações.....</i>	<i>64</i>
<i>Tabela 6.2 Resumo das Previsões com as Configurações 1, 2 e 3 e o Erro com Relação à Média. ....</i>	<i>68</i>
<i>Tabela 6.3 MAPE para a Configuração Um Mês à Frente.....</i>	<i>69</i>
<i>Tabela 6.4 MAPE para a Configuração Dois Meses à Frente.....</i>	<i>71</i>
<i>Tabela 6.5 MAPE para a Configuração Um Mês à Frente.....</i>	<i>73</i>
<i>Tabela 6.6 MAPE para a Configuração Dois Meses à Frente.....</i>	<i>74</i>
<i>Tabela 6.7 Previsão da média anual utilizando RNA.....</i>	<i>76</i>
<i>Tabela 6.8 Erro pelo Sistema Híbrido RNA-ANFIS.....</i>	<i>77</i>
<i>Tabela 6.9 Erro pelo Sistema Híbrido RNA-Fragmentos.....</i>	<i>78</i>
<i>Tabela 6.10 Resultados de Teste dos Modelos de Previsões Desenvolvidos para 2005 .....</i>	<i>79</i>
<i>Tabela 6. 11 Resultados de Teste dos Modelos de Previsões Desenvolvidos para 2006 .....</i>	<i>80</i>
<i>Tabela 6. 12 Resultados de Teste dos Modelos de Previsões Desenvolvidos para 2007 .....</i>	<i>81</i>
<i>Tabela 6. 13 Resultados de Teste dos Modelos de Previsões Desenvolvidos para 2008 .....</i>	<i>82</i>
<i>Tabela 6. 14 Resultados de Teste dos Modelos de Previsões de Vazão .....</i>	<i>82</i>

## LISTA DE ABREVIATURAS E SIGLAS

ANFIS	Adaptive Network-based Fuzzy Inference System.
CEPEL	Centro de Pesquisas em Energia Elétrica.
FIS	Fuzzy Inference System
GD	Algoritmo Gradiente Descendente.
GDM	Algoritmo Gradiente Descendente com Momento.
LDSP	Laboratório Digital de Sistemas de Potência.
LM	Algoritmo de Levenberg Marquat.
MAE	Erro Médio Absoluto.
MAPE	Erro Médio Absoluto Percentual.
MLP	<i>Multi Layer Perceptron.</i>
MSE	Erro Médio Quadrático.
ONS	Operador Nacional do Sistema Elétrico.
RBF	Radial-Basis Function.
RNA	Redes Neurais Artificiais.
RPROP	Algoritmo Resilient Propagation.
SOM	Self-Organizing Maps.
TSK	Takagi-Sugeno-Kang

## LISTA DE SÍMBOLOS

$Q$	Vazão (l/h).
$x$	Sinal de entrada genérico da RNA.
$y$	Sinal de saída genérico da RNA.
$b$	bias genérico da RNA.
$v$	campo local induzido.
$e$	Erro genérico.
$u$	Função de ativação.
$W$	Peso sináptico.
$\eta$	Taxa de aprendizado.
$\alpha$	Constante de momento.
$L_{\max}$	Valor máximo dos coeficientes de saída da rede neural.
$L_{\min}$	Valor mínimo dos coeficientes de saída da rede neural.
$N$	Número de unidades de saída da rede neural.
$P$	Número de padrões da base de dados considerada.
$L_{pi}$	Saída calculada por cada unidade de saída da rede neural.
$T_{pi}$	Saída desejada da rede neural para cada unidade.
$T$	Período de tempo.

# CAPÍTULO 1

## 1 INTRODUÇÃO

---

No Brasil, a geração de energia depende basicamente da quantidade de água disponível nos grandes reservatórios de acumulação existentes no país. Todo o planejamento da operação, de curto, médio e longo prazo é feito com base nas previsões de vazões. A segurança dos aproveitamentos e o controle de cheias dependem igualmente de uma boa previsão de vazões e a adequação do sistema às novas restrições de controle ambiental e uso múltiplo da água também depende de boas previsões de vazões [1]. Enfim, o conhecimento antecipado da quantidade de água que estará disponível no sistema permite ao planejador tomar decisões adequadas para maximização da geração.

Atualmente, a área de planejamento e controle de sistemas de recursos hídricos é de grande importância, uma vez que influencia diretamente na produção de energia hidroelétrica do país. Esta, por sua vez, depende da série histórica de vazões das diversas usinas do sistema, no sentido de sua utilização como dado de entrada para um modelo de simulação. Estes modelos são importantes para realizar as previsões de vazões necessárias para um planejamento energético efetivo. Entretanto, trata-se de um problema estocástico e não-linear.

O sistema hidroelétrico brasileiro encontra-se distribuído em diversas regiões geográficas com dados coletados através de diversas redes de aquisição de dados que resulta em uma considerável incerteza na informação hidrológica coletada. Além disso, a inerente relação não-linear entre as variáveis envolvidas dificulta e afeta o desempenho dos modelos de previsão. Uma outra dificuldade na previsão de vazões é a natureza não estacionária devido aos períodos úmidos e secos ao longo do ano [2].

A maior parte dos modelos de previsão atualmente utilizada baseia-se em relações lineares entre as variáveis [3]. Este modelo tem sido amplamente aplicado a problemas associados a recursos hídricos, principalmente na previsão de vazões mensais. Nos últimos anos, modelos baseados em redes neurais artificiais tem surgido como



alternativas de modelos de previsão [4], uma vez que estes são capazes de capturar as relações não-lineares entre as entradas e a saída do modelo.

O Programa Mensal de Operação Energética do Setor Elétrico, coordenado pelo Operador Nacional do Sistema Elétrico (ONS) com o objetivo de otimizar o despacho centralizado das usinas, é realizado de forma mensal, ocorrendo também revisões semanais necessárias aos ajustes devido às variabilidades das afluições, das demandas e das indisponibilidades não previstas nos equipamentos. Para efetuar a programação mensal da operação e suas revisões é necessário realizar previsão de afluições para os reservatórios despachados centralizadamente, o qual vem sendo realizado pelo ONS, utilizando o sistema PREVIVAZ, desenvolvido pelo Centro de Pesquisas em Energia Elétrica - CEPEL (1997) [5]. Este sistema seleciona o melhor modelo dentre 94 combinações de modelos de séries temporais com diferentes métodos de estimação de parâmetros, e começou a ser utilizado no início de 1999. Mesmo sendo um modelo de pouco tempo de utilização já se mostrou mais eficiente que seu antecessor no Setor Elétrico, o sistema PREVAZ, substituindo-o no Programa Mensal de Operação e apresentando erro percentual médio na ordem de 18% [6].

Em anos recentes, Redes Neurais Artificiais, principalmente redes neurais multicamadas com algoritmo de retro-propagação do erro [7], tornaram-se extremamente conhecidas para previsão em diversas áreas, incluindo finanças [8], carga elétrica [9] e recursos hídricos [10, 11, 12]. Estes modelos apresentam habilidade de aprendizado e capacidade de generalização, destacando a sua capacidade para tratar relações não-lineares de entradas-saídas. Na maioria dos estudos realizados, o modelo empregado é a rede multicamadas com algoritmo backpropagation. Este modelo vem sendo aplicado para previsão de vazões mostrando resultados satisfatórios [13,14, 15].

A comparação de redes neurais com abordagens tradicionais na previsão de séries temporais ainda não é conclusiva. As explicações podem estar relacionadas a diferentes fatores, tais como a estrutura da rede neural, o tipo de série (estacionária, não-estacionária) analisada e a relação do tamanho da rede e o número de entradas das séries temporais. Além disso, a capacidade de mapeamentos complexos das redes neurais cresce com o número de camadas e neurônios, acarretando maior tempo de processamento, bem como considerável soma de dados para treinamento [16].

Este trabalho propõe a aplicação em previsão de vazões afluentes médias mensais de modelos de redes neurais e lógica fuzzy utilizando quatro modelos diferentes para o posto hidrológico de Sobradinho, localizado no Rio São Francisco.

No primeiro modelo, com horizonte de previsão anual, onde as Redes Neurais Artificiais (RNA) utilizadas foram preparadas com o objetivo de receber como entrada amostras da série temporal da vazão afluente do Rio São Francisco deslocadas mês a mês. Para isso, foram utilizadas três configurações diferentes, onde a primeira configuração representa a previsão dos doze meses de um ano utilizando como entrada o ano anterior. Na segunda configuração, o ano foi dividido em dois períodos: o período dos meses de cheia (dezembro a abril) e o período dos meses considerados secos (maio a novembro) prevendo assim todos os meses do ano com horizonte de um ano. A terceira configuração é bastante similar a primeira, onde são previstos os doze meses de um ano tendo como entrada os doze meses do ano anterior, neste caso, sendo levado em consideração o efeito da sazonalidade.

Os resultados obtidos são baseados no tipo de normalização e sazonalidade, os quais serão explicados no desenvolvimento deste trabalho.

No segundo modelo são feitas previsões de vazão com horizonte mensal utilizando RNA e o ANFIS. São realizadas previsões com um e dois meses à frente dando como entrada três meses anteriores.

No terceiro modelo foram realizadas previsões de vazão com horizonte anual utilizando o sistema híbrido RNA-ANFIS composto de uma primeira etapa, onde é feita um previsão da média anual da vazão do ano que se deseja utilizando RNA, dando como entrada a vazão média anual de quatro anos anteriores; e de uma segunda etapa realizada com o ANFIS, onde é dado como entrada o mês, a vazão média anual dos dois anos anteriores e a saída da rede neural. Do exposto acima, observa-se que o ANFIS desagrega a vazão anual prevista pela rede neural em meses.

Por fim, no quarto modelo, utilizando o sistema híbrido RNA-Fragmentos, semelhante ao modelo anterior, inicialmente, é realizada uma previsão da média anual da vazão do ano que se deseja utilizando RNA, em seguida, é aplicado o método dos Fragmentos para desagregar em vazões mensais.

### **1.1 Sistema Hidroelétrico do São Francisco**

O sistema hidroelétrico do São Francisco apresenta aspectos peculiares que o torna diferente dos outros sistemas de base hidroelétrica pelas características das afluências nos rios brasileiros, que apresentam acentuada sazonalidade e elevado nível

de incerteza. Assim, o planejamento da operação dessas usinas depende do conhecimento prévio do volume da água disponível nesses reservatórios, para que se possa estimar a quantidade máxima de energia a ser gerada pela usina. Logo, em função dos bons resultados da previsão das vazões é possível realizar o planejamento energético de modo a atingir níveis ótimos de geração de energia.


A previsão de vazão pode ser de curto, médio e longo prazo. A previsão de curto prazo é usada para estimar a vazão num trecho da bacia com antecedência de horas ou poucos dias. A previsão de médio prazo envolve a previsão de vazão com antecedência de um a alguns meses e depende, fortemente, das condições conhecidas de clima e dos oceanos que podem influenciar as vazões futuras na bacia hidrográfica. A previsão de longo prazo é a estimativa, normalmente estatística, dos riscos de ocorrência de vazões num determinado local.

O reservatório de Sobradinho está localizado na bacia do São Francisco, sendo o mais importante reservatório da região Nordeste para fins de irrigação, consumo de água e geração hidroelétrica. A Figura 1.1 mostra a localização da Bacia do São Francisco, do reservatório Sobradinho (triângulo), que está localizado no baixo São Francisco e possui uma área de drenagem de cerca de 498.425 km<sup>2</sup> e dos reservatórios à jusante (círculos).



**Figura 1.1 Bacia do Rio São Francisco.**

Na Figura 1.2, observa-se que à montante está localizado o reservatório Três Marias, importante regulador das afluições de Sobradinho. A área incremental de drenagem entre Três Marias e Sobradinho é de aproximadamente 447.865 km<sup>2</sup>. O máximo volume de armazenamento de Sobradinho é de 28.669 hm<sup>3</sup>, o que leva a uma capacidade máxima de geração elétrica de 1.050 MW. A água liberada por Sobradinho é reaproveitada em mais sete usinas hidroelétricas, que tem uma pequena capacidade de armazenamento de água, mas aumentam a máxima capacidade de geração de energia para cerca de 9.800 MW [17].



**Figura 1.2 Localização das Usinas Hidroelétricas no Rio São Francisco.**

Devido a sua localização equatorial, o reservatório de Sobradinho apresenta uma alta taxa de evaporação, que pode atingir 480 m<sup>3</sup>/s durante o dia. Seu uso também inclui controle de cheias, o que reforça a necessidade de uma ótima política operacional. A

série mensal de afluições ao reservatório Sobradinho, correspondente ao período 1931-2004 (Apêndice), é disponibilizada pelo ONS, responsável pela política operacional do sistema hidroelétrico interconectado. A estação chuvosa inicia-se aproximadamente em dezembro e termina em abril. Os meses remanescentes representam a estação seca. As maiores afluições são observadas em janeiro e março.

### 1.1.1. **Influências Climáticas e Fonte de Dados**

O reservatório de Sobradinho está localizado na parte sul da região Nordeste, caracterizada por alta variabilidade climática e bastante vulnerável a secas. Entretanto, uma parte significativa das afluições é originada no alto São Francisco, localizado na região Sudeste do país e com características climáticas diferentes da região Nordeste.

O alto São Francisco está localizado numa região de transição, onde eventos de El Niño levam a condições secas ao norte e condições úmidas ao sul. Essas condições sugerem que a influência remota de fatores climáticos na afluição a Sobradinho não é completamente determinada por meio de uma análise da precipitação sobre a bacia. Como vazões agem como um integrador espaço-tempo da chuva, uma análise direta entre a série temporal de vazões pode ser a melhor forma de se obter sucessos nos resultados de previsão de vazão no reservatório de Sobradinho [17].

## 1.2 **Organização do Trabalho**

No capítulo 2 são apresentados os principais conceitos sobre Redes Neurais Artificiais (RNA) e sua importância em previsão. Os principais algoritmos de treinamento e suas peculiaridades são descritos. Explica-se como é feita a análise da melhor arquitetura para escolha da RNA a ser aplicada na previsão de vazão na bacia do Rio São Francisco.

O capítulo 3 tem como objetivo apresentar uma introdução à lógica fuzzy e, principalmente ao sistema ANFIS (Adaptive Network-based Fuzzy Inference System). Descrevem-se as técnicas mais usadas de representação e o processo de conhecimento de sistemas fuzzy. São apresentados e ilustrados os modelos de Mamdani e de Takagi-Sugeno-Kang para definição e processo de regras de produção fuzzy. Por fim, apresenta-se o sistema ANFIS e a sua fundamental importância para o desenvolvimento

deste trabalho, permitindo a comparação com o modelo neural descrito no capítulo anterior.

No capítulo 4, descreve-se a metodologia aplicada para a implementação dos diferentes modelos utilizados para a previsão de vazão da bacia do São Francisco detalhados no capítulo seguinte. Para isso, apresenta-se a metodologia para tratamento dos dados, algoritmos de treinamento, escolha da melhor arquitetura, método de validação cruzada e a avaliação de desempenho através do MAPE (Mean Absolute Percentage Error) que será o parâmetro de comparação para definir o melhor modelo.

No capítulo 5, descrevem-se os quatro modelos de previsão utilizados. No primeiro modelo, descreve-se a previsão utilizando as redes neurais artificiais em uma previsão com horizonte anual; no segundo modelo são feitas comparações entre a previsão utilizando-se ANFIS e RNA em uma previsão com horizonte mensal; o terceiro modelo trata da previsão utilizando o sistema híbrido para a previsão, ou seja, utilizando as redes neurais como entrada para o ANFIS, obtendo-se assim a previsão anual dada mês a mês. Por fim, utilizou-se o método dos fragmentos, utilizando a previsão com RNA e em seguida calculando o fator de cada mês.

No capítulo 6, são apresentados os resultados para os diferentes modelos e configurações, e os resultados de suas comparações. Por fim, são realizadas simulações para os anos de 2005, 2006, 2007 e 2008 cujos resultados apresentaram um pequeno erro percentual.

No capítulo 7, são apresentadas as considerações finais do trabalho, analisando a importância da previsão de vazão para o sistema elétrico brasileiro, bem como os méritos obtidos com o auxílio da inteligência artificial seja com as redes neurais, seja com a lógica fuzzy em previsão de vazão e as sugestões de trabalhos futuros.

# CAPÍTULO 2

## 2 REDES NEURAIS ARTIFICIAIS

---

### 2.1 Introdução

Este capítulo tem como objetivo apresentar uma introdução às Redes Neurais Artificiais. Além disso, explica-se como é feita a análise da melhor arquitetura para escolha da melhor rede neural a ser aplicada e, com isso, são descritos os principais algoritmos de treinamento e suas peculiaridades.

### 2.2 Introdução às Redes Neurais Artificiais

As Redes Neurais Artificiais – RNA são uma das áreas de pesquisa da grande área Inteligência Artificial e têm sido baseadas nos estudos de como o cérebro processa informações. Na sua forma mais geral, rede neural é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. A RNA é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação em um computador digital. Para alcançarem bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples, denominadas neurônios ou unidades de processamento.

Uma rede neural é um processador, paralelo distribuído, constituído de unidades de processamento simples que têm a propensão natural para armazenar conhecimentos experimentais e torná-los disponível para o uso, que se assemelha ao cérebro em dois aspectos:

- O conhecimento é adquirido pela rede neural por meio de dados do ambiente, num processo de aprendizagem. O processo de treinamento é chamado de “Algoritmo de Aprendizagem”, que tem como finalidade ajustar os pesos sinápticos da RNA de uma forma ordenada para alcançar um objetivo desejado.

- As conexões entre os neurônios, conhecidos como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido [18].

As Redes Neurais Artificiais são sistemas paralelos distribuídos compostos por unidades de processamento, chamadas de nodos (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não-lineares). Esta forma de computação não-algorítmica é caracterizada por um sistema que, lembra a estrutura do cérebro humano. O grande apelo destes modelos está em sua capacidade de “aprender”, generalizar ou extrair regras automaticamente de conjuntos de dados complexos [18].

As RNAs se constituem em uma técnica de inteligência artificial cuja utilização prática está se tornando cada vez mais presente no nosso dia-a-dia. Aplicações realizadas com RNAs têm apresentado desempenho satisfatório em diversas áreas de pesquisas, tais como: classificação, reconhecimento de padrão, aproximação de funções, processamento de séries temporais, otimização, controle, previsão (foco deste trabalho) etc.

### 2.2.1 Histórico das Redes Neurais

Historicamente, o início das RNAs se deu em 1943 com o Psiquiatra e Neuroanatomista McCulloch e o matemático Pitts [19], que modelou o funcionamento do neurônio. O neurônio de McCulloch e Pitts foi proposto com pesos fixos, isto é, não-ajustáveis, e só conseguem implementar funções linearmente separáveis, limitando sua utilização. Em 1949, houve um avanço e, pela primeira vez, foi apresentada uma regra de aprendizado fisiológico para as modificações sinápticas, que afirma que a eficiência de uma sinapse variável entre dois neurônios é aumentada pela ativação repetida de um neurônio, causado pelo outro neurônio, através daquela sinapse.

Em 1958, Rosenblatt demonstrou o seu novo modelo, o perceptron, e em 1962 apresentou o “Teorema de Convergência do Perceptron”[20]. Nesse período muitos pesquisadores deram ótimas contribuições ao campo de redes neurais. Em 1960, Widrow e Hoff, baseados no método do gradiente para minimização do erro na saída de um neurônio com resposta linear, apresentaram uma regra de aprendizado conhecida como Regra de Widrow e Hoff ou Regra Delta [21].

Durante os anos 70 muitos pesquisadores, exceto os Psicólogos e Neurocientistas, desistiram desse campo. Nos anos 80 ressurgiu o interesse por RNA, com a publicação de vários trabalhos como Kohonen (self-organizing maps)[22]. Em



1986, Rumelhart, Hinton e Williams apresentaram a descrição do algoritmo retropropagação de erro [23].

Hoje, RNA representa uma vigorosa área de pesquisa multidisciplinar e é freqüentemente identificada como uma sub especialidade de Inteligência Artificial; outras vezes como uma classe de modelos matemáticos para problemas de classificação e reconhecimento de padrões; finalmente, uma categoria de modelos em ciência da cognição e conexãoismo.

### 2.2.2 Neurônio Artificial

Após várias pesquisas chega-se a uma rede neural artificial constituída de vários neurônios artificiais que estão altamente conectados [18,24].

Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. A Figura 2.1 mostra o modelo de um neurônio, de onde se identificam três partes básicas do modelo neuronal:

- Um conjunto de sinapse ou elos de conexões é caracterizado por um peso ou força própria. Especificamente, um sinal  $x_j$  na entrada da sinapse  $j$  conectada ao neurônio  $k$  é multiplicado pelo peso sináptico  $W_{kj}$ .
- Um somador para somar os sinais de entradas, ponderado pelas respectivas sinapses.
- Uma função de ativação para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que pode restringir (limitar) o intervalo admissível de amplitude do sinal de saída de um valor finito. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo fechado  $[0 \ 1]$  ou alternativamente  $[-1 \ 1]$ .

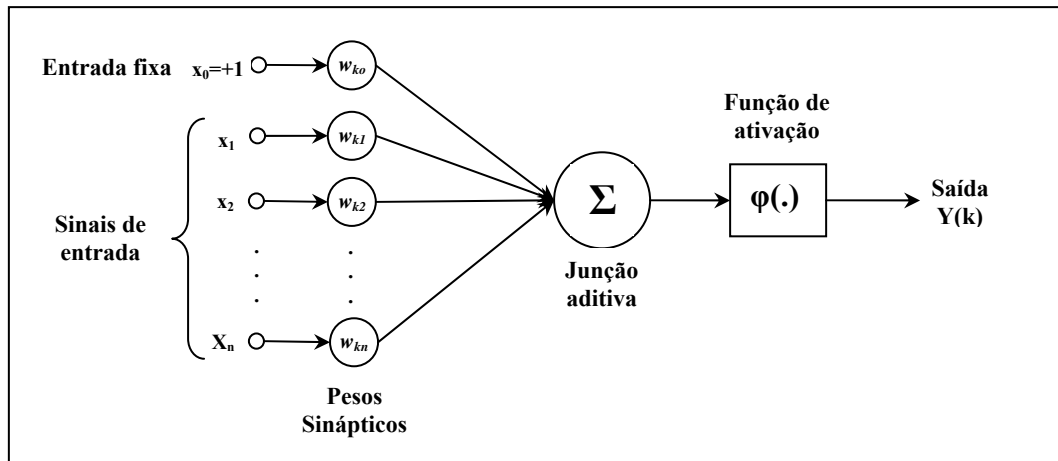


Figura 2.1 Modelo de um Neurônio Artificial.

O modelo neural da Figura 2.1 inclui também um bias aplicado externamente, representado por  $w_{k0}$ . O bias tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo.

Em termos matemáticos podemos descrever um neurônio  $k$  conforme as seguintes equações.

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (2.1)$$

$$y_k = \varphi(v_k) \quad (2.2)$$

onde sinais  $x_1, x_2, x_3 \dots x_n$  são os sinais de entrada;  $w_{k1}, w_{k2}, \dots, w_{kn}$  são os pesos sinápticos associados ao neurônio  $k$  definido um campo local induzido  $v_k$ , como sendo a saída do combinador linear que será aplicado à função de ativação  $\varphi(\cdot)$ , obtém-se a saída do neurônio  $k$  ( $y_k$ ).

### 2.2.3 Função de Ativação

A partir do modelo proposto por McCulloch e Pitts [19], em que a saída do neurônio assume apenas valores binários 0 ou 1, foram derivados vários outros modelos que permitem a produção de uma saída qualquer, não necessariamente sendo 0 ou 1, e com diferentes funções de ativação, onde estas podem ser lineares ou não, conforme apresentado na Figura 2.2.

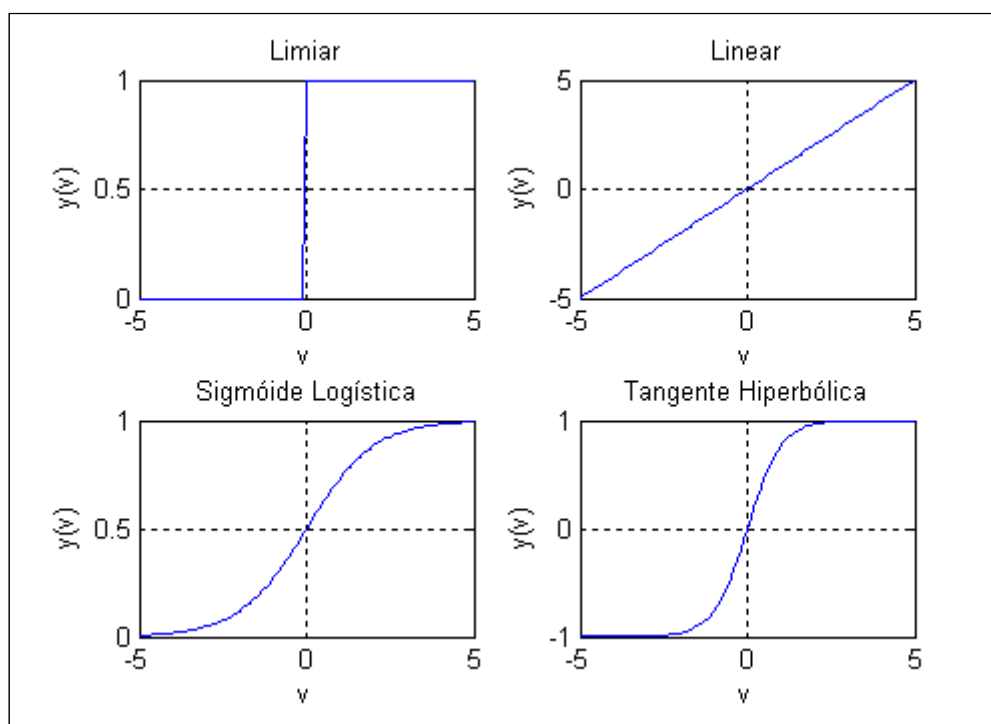


Figura 2.2 Funções de Ativações.

#### 2.2.4 Processo de Aprendizagem

A utilização de uma RNA na solução de uma tarefa passa inicialmente por uma fase de aprendizagem. Segundo Mendel e McLaren [25]: “Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando”.

O objetivo principal do processo de aprendizado é conceder a RNA a capacidade de generalizar os resultados do treinamento. Esta capacidade da RNA é conhecida como processo de generalização.

O processo de aprendizagem das RNA é realizado basicamente a partir de dois grandes paradigmas: aprendizado supervisionado, também conhecido como aprendizado com um professor, e aprendizado não supervisionado. O paradigma a ser utilizado na solução do problema depende do tipo de problema e do tipo de RNA.

##### Aprendizado Supervisionado

Este paradigma de aprendizagem também conhecido como aprendizagem com um professor é o mais comum nos treinamentos das RNAs. Neste paradigma as entradas e saídas desejadas são fornecidas por um supervisor externo (professor).

Suponha que o professor e a rede neural sejam expostos ao conjunto de treinamento retirado do ambiente. Em virtude do seu conhecimento prévio, o professor é capaz de fornecer à rede neural a resposta desejada para o conjunto de treinamento. Na verdade, a resposta desejada representa a ação ótima a ser realizada pela rede neural.

Desta forma, os parâmetros livres das redes neurais, pesos sinápticos e bias, são ajustados conforme a regra definida pelo algoritmo de aprendizagem sobre a influência combinada do vetor de treinamento e do sinal de erro, que é calculado pela diferença entre o valor de saída da RNA e valor apresentado pelo professor. Estes ajustes são realizados passo a passo com o objetivo de a rede neural emular o professor até atingir a melhor precisão. A Figura 2.3 representa o esquema em digrama de blocos da aprendizagem supervisionada.

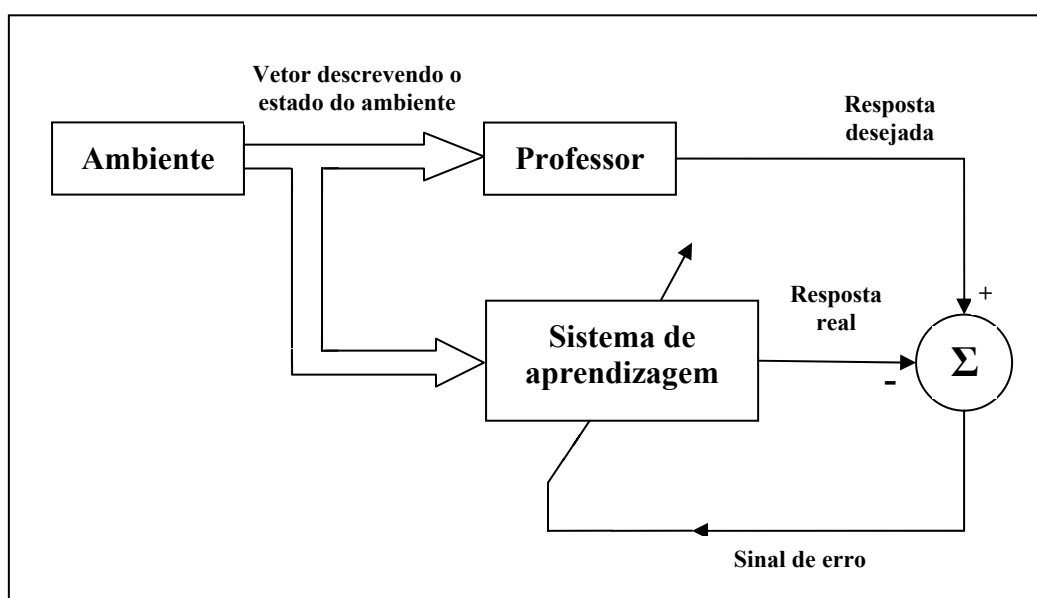


Figura 2.3 Diagramas de Blocos da Aprendizagem com Professor.

O Aprendizado supervisionado pode utilizar várias regras ou algoritmo de aprendizagem com o objetivo de minimizar os erros, ou seja, corrigi-los [20, 21, 23]. A maioria das aplicações de redes neurais utiliza as redes Perceptrons Múltiplas Camadas (MLP) que foram também aplicadas para o desenvolvimento deste trabalho.

### Aprendizado não Supervisionado

Neste paradigma, o aprendizado ocorre sem a tutela do professor. Isto significa que não há exemplos rotulados do problema a ser resolvido pela rede neural. Este paradigma é ilustrado pelo diagrama de blocos da Figura 2.4.




Figura 2.4 Aprendizado não supervisionado

O processo de aprendizagem através deste paradigma consiste em modificar repetidamente os parâmetros livres das redes neurais em resposta as entradas de acordo com a regra ou algoritmo de aprendizagem.

Como exemplo de regra de aprendizagem que utiliza este paradigma, tem-se o aprendizado por competição. A idéia neste processo de aprendizagem consiste em fazer com que os neurônios das unidades de saída disputem entre si para serem ativados. Durante a etapa de treinamento, ajuste dos parâmetros livres, os neurônios que vão se tornando ativos com um determinado padrão de entrada têm seus pesos ajustados, de maneira que este tenha uma maior probabilidade de se tornar ativo quando for estimulado por um padrão semelhante. Já os neurônios que não foram ativados, podem ser ajustados ou não, de acordo com seu grau de vizinhança do neurônio vencedor (ativo).

Os tipos de redes neurais, mais conhecidas, que utilizam estas regras são as Redes Mapas Auto-Organizáveis (SOM – Self-Organizing Maps) desenvolvidas por Teuvo Kohonen [22].

### 2.2.5 Redes Perceptron Múltiplas Camadas

São redes do tipo *feedforward*, ou seja, o processamento da informação se dá no sentido progressivo. Tipicamente, a RNA consiste de um conjunto de unidades sensoriais (nós de fonte) que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais (neurônios) e camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede neural camada por camada. A Figura 2.5 ilustra a rede MLP.

As redes do tipo MLP têm sido aplicadas com sucesso para resolver diversos problemas difíceis. Inicialmente, o que alavancou o uso das redes MLP foi o desenvolvimento do algoritmo de treinamento de retropropagação do erro (*backpropagation*), o qual permite estimar o erro cometido pelos neurônios das camadas

intermediárias e, conseqüentemente, determinar os devidos ajustes dos pesos em todos os neurônios da RNA, a fim de minimizar o erro durante o treinamento da mesma.

### 2.3 Algoritmos de Treinamento

Utilizando como estrutura básica da rede neural o neurônio da Figura 2.1, tipicamente a rede neural possui uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A Figura 2.5 mostra a arquitetura de uma rede perceptron de múltiplas camadas com uma camada de entrada, uma oculta e uma de saída, e totalmente conectada. Isso significa que um neurônio em qualquer camada da rede está conectado a todos os neurônios da camada anterior.

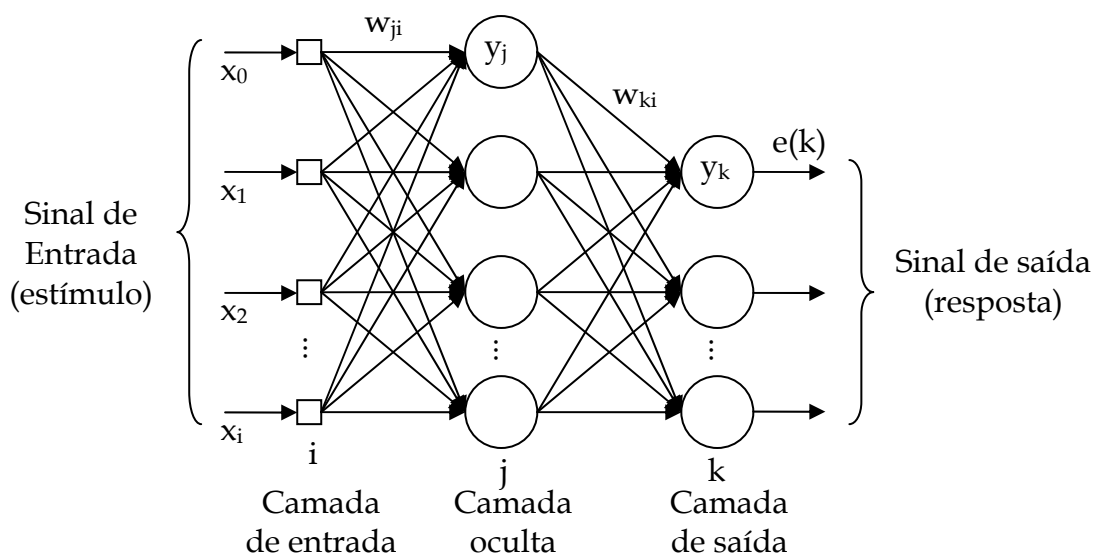


Figura 2.5 Arquitetura perceptron de múltiplas camadas com uma camada oculta.

Para o desenvolvimento deste trabalho foram utilizados dois algoritmos de treinamento para definir a melhor arquitetura da RNA que foram aplicados na previsão de vazão do rio São Francisco. A seguir, são feitas algumas breves considerações sobre os dois tipos de algoritmos utilizados: Gradiente Descendente com Momento e Resilient Propagation.

#### 2.3.1 Gradiente Descendente com Momento (GDM)

O algoritmo de treinamento GDM surgiu com o objetivo de aumentar a taxa de aprendizagem do algoritmo de retropropagação [18], visto que o algoritmo de retropropagação fornece uma aproximação para a trajetória no espaço de pesos calculada pelo método da descida mais íngreme, ou seja, quanto menor for o parâmetro

da taxa de aprendizagem  $\eta$ , menor será a variação dos pesos sinápticos da RNA, de uma iteração para a outra, e mais suave será a trajetória no espaço de pesos. Essa melhoria, entretanto, é obtida à custa de uma taxa de aprendizagem lenta. Por outro lado, se o parâmetro da taxa de aprendizagem  $\eta$  for muito grande, para acelerar a aprendizagem, as grandes modificações nos pesos sinápticos resultantes podem tornar a rede instável, isto é, oscilatória. Um método simples de aumentar a taxa de aprendizagem, evitando, no entanto, o perigo de instabilidade, é incluindo um termo de momento [18], como:

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (2.3)$$

onde  $\alpha$  é usualmente um número positivo chamado de constante de momento.

A incorporação do momento no algoritmo de retropropagação representa uma modificação pequena na atualização dos pesos; contudo, pode haver alguns efeitos benéficos sobre o comportamento de aprendizagem do algoritmo. O termo de momento pode também ter o benefício de evitar que o processo de aprendizagem termine em um mínimo local raso na superfície de erro.

Atualmente, o algoritmo de treinamento GDM não é muito utilizado devido a existência de algoritmos de controle mais rápidos e que apresentam erros menores.

### 2.3.2 Algoritmo Resilient Propagation (RPROP)

O algoritmo RPROP (Resilient Propagation) é um tipo de retropropagação que apresenta um eficiente esquema de aprendizagem, o qual tem como característica uma adaptação direta do peso baseada na informação do gradiente local. Diferentemente dos outro algoritmo GDM, a adaptação do RPROP não é interferida pelo comportamento da magnitude do gradiente da função erro [26]. Para conseguir isto, cada peso será alterado individualmente através de um valor adaptativo  $\Delta_{ij}$ . Durante o processo de aprendizagem,  $\Delta_{ij}$  é baseado na função do erro de acordo com a seguinte regra de aprendizagem:

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial \omega_{ij}} \times \frac{\partial E^{(t)}}{\partial \omega_{ij}} > 0 \\ \eta^- \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial \omega_{ij}} \times \frac{\partial E^{(t)}}{\partial \omega_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases}$$

Em que  $0 < \eta^- < 1 < \eta^+$ .

A regra de adaptação deste algoritmo funciona da seguinte maneira: cada vez que a derivada parcial da função erro em relação ao peso  $\omega_{ij}$  muda seu sinal, indicando que a última atualização foi muito grande, tal que fez o erro da função ultrapassar o mínimo local, então o valor  $\Delta_{ij}$  é decrementado pelo fator  $\eta^- \Delta_{ij}$ . Se a derivada mantém seu sinal, o fator individual de ajuste do peso é ligeiramente aumentado por um fator  $\eta^+$  a fim de acelerar a convergência do peso.

Sabendo os valores adaptativos para cada peso, então estes serão alterados da maneira seguinte:

$$\Delta \omega_{ij}^{(t)} = \begin{cases} -\Delta_{ij}, & \text{se } \frac{\partial E^{(t)}}{\partial \omega_{ij}} > 0 \\ +\Delta_{ij}, & \text{se } \frac{\partial E^{(t)}}{\partial \omega_{ij}} < 0 \\ 0, & \text{caso contrário} \end{cases}$$

$$\omega_{ij}^{(t+1)} = \omega_{ij}^{(t)} + \Delta \omega_{ij}^{(t)}$$

se a derivada é positiva (aumentando o erro), o peso é diminuído do seu valor de atualização, caso contrário, o valor será adicionado.

Entretanto, existe uma exceção: se a derivada parcial muda de sinal, ou seja, o passo previsto foi muito grande a ponto de fazer o ponto passar do mínimo desejado, então a atualização do peso deve ser revertida, como segue:

$$\Delta \omega_{ij}^{(t)} = -\Delta \omega_{ij}^{(t-1)}, \text{ se } \frac{\partial E^{(t-1)}}{\partial \omega_{ij}} \times \frac{\partial E^{(t)}}{\partial \omega_{ij}} < 0 \quad (2.4)$$

Conseqüentemente, é de se esperar que no próximo passo essa derivada mude novamente seu sinal. Para que não haja uma segunda “punição”, então se deve prever uma maneira de não fazer a adaptação do peso. Na prática, isto pode ser conseguido fazendo  $\frac{\partial E^{(t-1)}}{\partial \omega_{ij}} = 0$  na regra de adaptação de  $\Delta_{ij}$ .

Uma das principais vantagens do algoritmo RPROP está ligada ao fato de que para a maioria dos problemas não é necessário fazer uma boa escolha dos parâmetros ( $\eta^+$ ,  $\eta^-$ ,  $\Delta_{ij}$ ,  $\Delta_0$ ) a fim de garantir convergência. A seguir encontram-se algumas dicas para a escolha de tais parâmetros:



- Seleciona-se  $\Delta_0$ . Um valor típico é  $\Delta_0 = 0,1$ , mas variações nesta inicialização não são críticas para o algoritmo;
- Satura-se o valor máximo e mínimo de  $\Delta_{ij}$  ( $\Delta_{\max}$  e  $\Delta_{\min}$ ) para evitar problemas de overflow e underflow;
- Experimentalmente, determinou-se  $\eta^+ = 1,2$  e  $\eta^- = 0,5$  como bons valores para estes parâmetros.

O RPROP é um algoritmo muito rápido e apresenta erros muito pequenos.

### **2.4 Conclusões do Capítulo**

Neste capítulo, atenção especial foi dada as RNAs. Sendo assim, foi apresentada a base teórica necessária para o desenvolvimento e implementação de um modelo para previsão de vazão na bacia do rio São Francisco tão importante para o sistema hidroelétrico brasileiro e mais especificamente do Nordeste.

Desta forma, os conhecimentos adquiridos são de grande utilidade para um melhor desenvolvimento deste trabalho.

# CAPÍTULO 3

## 3 LÓGICA FUZZY

---

### 3.1 Introdução

Este capítulo tem como objetivo apresentar uma introdução à Lógica Fuzzy e sua importância para o desenvolvimento deste trabalho, principalmente no que diz respeito ao sistema Fuzzy e Neuro-Fuzzy aplicado em previsão. Sendo assim, é mostrado um breve histórico da lógica fuzzy e os sistemas de previsão, como também o Adaptive Neuro-Fuzzy Inference System (ANFIS) utilizado para o desenvolvimento deste trabalho.

Por fim, mostra-se a importância da aplicação da lógica fuzzy para previsão de vazão.

### 3.2 Histórico da Lógica Fuzzy

No início dos anos 60, Lotfi A. Zadeh, um professor da Universidade da Califórnia em Berkeley, internacionalmente conhecido por suas contribuições para o desenvolvimento das teorias de sistemas, vislumbrou que as técnicas tradicionais para análise de sistemas eram exageradamente precisas para lidar com grande parte dos problemas complexos do mundo real. A ideia de grau de pertinência, conceito que se tornou a base da teoria dos conjuntos fuzzy, foi formulada em 1964, levando à publicação do seu artigo introdutório sobre os conjuntos fuzzy em 1965 e ao que poderia ser denominado nascimento da tecnologia baseada na lógica nebulosa [28].

Vale assinalar que a teoria da lógica fuzzy enfrentou, no seu início, forte resistência por parte da comunidade científica, principalmente por parte dos estatísticos norte-americanos. Entretanto, a despeito de todo preconceito, muitos pesquisadores vislumbraram as possibilidades que esta teoria oferecia e trabalhos surgiram em todo o

mundo, particularmente no Japão, onde a lógica fuzzy encontrou base cultural para rápido desenvolvimento. Já na primeira década de seu nascimento (1965-1975) os pesquisadores se esforçaram por estender os fundamentos da lógica fuzzy, introduzindo conceitos novos e desenvolvendo outras abordagens da teoria, bem como as relações fuzzy, as variáveis lingüísticas, os processos de decisão fuzzy, a medida fuzzy, sistemas topológicos, álgebra com números fuzzy, entre outros conceitos. Em 1972, formou-se no Japão o primeiro grupo de pesquisas em sistemas fuzzy, coordenado pelo professor Toshiro Terano, e em 1974 iniciou-se um importante capítulo na consolidação da lógica fuzzy, especialmente no aspecto de sua aplicação a processos, sistemas e componentes industriais com a apresentação do primeiro controlador fuzzy, criado por E. Mamdani, no Reino Unido.

A partir de então se pode assinalar o trabalho de vários pesquisadores na aplicação da lógica fuzzy na área de controle de processos e sistemas de engenharia. Tem-se, em 1976, o primeiro desenvolvimento buscando uma aplicação industrial da lógica fuzzy, envolvendo o Circle Cement e SIRA, na Dinamarca, consistindo de um controlador fuzzy que incorporava o conhecimento e a experiência dos operários para controlar fornos industriais, sistema este que entrou em operação industrial em 1982. Didier Dubois, em 1977, utilizou conjuntos fuzzy no desenvolvimento de um estudo sobre condições de tráfego surgindo, neste mesmo ano, o primeiro sistema especialista fuzzy. Vale destacar o desenvolvimento, em 1985, do primeiro circuito integrado fuzzy por Masaki Togai e Hiroyuke Watanabe, no laboratório Bell (EUA).

Em 1987, foi inaugurado, com sucesso, a primeira composição ferroviária com estrutura de controle baseada na lógica fuzzy, no sistema do metrô de Sendai, no Japão. Foi também desenvolvido, neste mesmo ano, pela Yamaha, um helicóptero não-tripulado, Yamaha-50, totalmente controlado por um controlador fuzzy, dando origem, definitivamente, à era do desenvolvimento tecnológico com suporte nesta teoria. Começa a operar, em 1988, no Yamaichi Fuzzy Fund o primeiro sistema de comércio financeiro fuzzy, mostrando toda a potencialidade deste ferramental e expandindo suas aplicações para sistemas não industriais. Mas, foi em 1990 que esta teoria atingiu maior visibilidade com o lançamento no mercado da primeira máquina de lavar roupas, da Matsushita Electric Industrial Co, marcando o início do desenvolvimento de produtos de consumo baseado na lógica fuzzy. Hoje já é possível encontrar, principalmente, no Japão, toda a sorte de eletrodomésticos que operam baseados em controles fuzzy (televisões, câmeras fotográficas, painéis para cozimento, vídeos e muitos outros); em

diversas áreas (economia, computação, medicina, engenharia), os conceitos da lógica fuzzy vêm sendo aplicado de forma crescente e várias empresas (Siemens, Daimler-Benz, Klockner-Moeller, SGS-Thomson, General Motors, Motorola, Hewlett-Packard, etc.) já possuem seus próprios laboratórios para desenvolvimento de produtos com suporte da lógica fuzzy [29].

Verifica-se a utilização crescente de sistemas fuzzy em uma grande variedade de aplicações nas mais diversas áreas, incluindo medicina, psicologia, economia, administração e engenharia. Por exemplo, na engenharia algumas das áreas potenciais de aplicação incluem [30]:

- Aeronáutica: controle de vôo, controle do motor, sistemas de aviação, diagnóstico de falhas, navegação e controle de altitude de satélites [31];
- Sistemas de automação de rodovias: direção automática, controle de frenagem e aceleração para veículos [32];
- Sistemas de manufatura: controle do processo de produção e de armazenagem;
- Indústrias de força: controle de geradores, controle/distribuição de potência e estimação de carga [33];
- Controle de processos: controle de temperatura e pressão, velocidade e nível, diagnóstico de falhas, controle de colunas de destilação e de processos de dessalinização [34];
- Robótica: controle de posição e planejamento de caminho.

### **3.3 Metodologia da Lógica Fuzzy**

Os seres humanos estão acostumados a tomar decisões, onde a resposta para determinado caso não seja totalmente verdadeira. Neste caso, a lógica Fuzzy deriva desta capacidade do ser humano, de inferir conclusões e gerar respostas através de informações vagas, ambíguas e qualitativamente incompletas e imprecisas. Em outras palavras, a lógica fuzzy pode ser vista como uma maneira de expressar incerteza. A lógica fuzzy permite representar valores de pertinência (grau de verdade) intermediários entre os valores de verdadeiro e falso da lógica clássica (bivalente).

Os sistemas fuzzy propõem um cálculo matemático para traduzir e processar o conhecimento subjetivo obtido de um especialista, ou seja, uma maneira de manipular conhecimento com um determinado nível de incerteza.

A Lógica Fuzzy é baseada na teoria dos Conjuntos Fuzzy que foi desenvolvida a partir de 1965 [35]. Esta é uma generalização da teoria dos conjuntos tradicionais para resolver os paradoxos gerados à partir da classificação “verdadeiro ou falso” da Lógica Clássica. Tradicionalmente, uma proposição lógica tem dois extremos: ou “completamente verdadeiro” ou “completamente falso”. Entretanto, na Lógica Fuzzy, uma premissa varia em grau de verdade de 0 a 1, o que leva a ser parcialmente verdadeira ou parcialmente falsa. O comportamento de tais sistemas é descrito por um conjunto de regras fuzzy do tipo: SE <premissa> ENTÃO <conseqüente> que são uma forma clara e eficiente de representar o conhecimento. Estas regras são facilmente entendidas, por serem estruturadas próximas à linguagem usada pelos especialistas. As regras Fuzzy manipulam os termos lingüísticos.


As variáveis de entrada em um sistema fuzzy são mapeadas em conjuntos fuzzy por meio de funções de pertinência. O mapeamento de uma entrada em um conjunto fuzzy gera um grau de pertinência dessa entrada ao conjunto. Por meio de regras SE-ENTÃO o sistema é capaz de expressar condições de pertinência. Tais regras são formuladas da seguinte forma:

SE (ANTECEDENTES) ENTÃO (CONSEQUENTE).

Nessa formulação os ANTECEDENTES expressam as condições a serem satisfeitas que resultam em um desdobramento representado pelo CONSEQUENTE da regra. Porém o grande problema dos sistemas baseados em regras está na quantidade de parâmetros a serem ajustados para o funcionamento adequado do modelo. Esses parâmetros livres se encontram na formação das funções de pertinência dos antecedentes e dos conseqüentes. Em outras palavras para se criar uma regre fuzzy do tipo SE ALGO FOR ALTO ENTAO A SAIDA E BAIXA precisa definir-se que tipo de função e ajustar os parâmetros que indicam o que é ALTO e BAIXO no contexto das regras. Esse procedimento de ajuste não é trivial.

### **3.4 Sistema de Inferência Fuzzy**

Com base nas informações apresentadas, já é possível construir o Sistema de Inferência Fuzzy. Neste sistema, tem-se a conversão dos valores exatos para variáveis lingüísticas. Na Figura 3.1 é mostrado um sistema de inferência fuzzy.



**Figura 3.1 Sistema de Inferência Fuzzy.**

Geralmente os dados de entrada deste sistema são valores precisos, resultados de medições ou observações (conjuntos de dados para previsão, por exemplo), logo, é necessário realizar um mapeamento destes dados precisos para os conjuntos fuzzy de entrada, o que é realizado no estágio de fuzzificação. Neste estágio ocorre também a ativação de algumas regras para uma dada situação. Uma vez obtido o conjunto fuzzy de saída através do processo de inferência, no estágio de defuzzificação é efetuada uma interpretação dessa informação. No estágio de inferência ocorrem as operações com os conjuntos fuzzy: combinação dos antecedentes das regras, implicação e aplicação das regras de inferência do sistema. Os conjuntos fuzzy de entrada, relativos aos antecedentes das regras, e o de saída, referente ao conseqüente, podem ser definidos previamente ou, alternativamente, gerados automaticamente a partir dos dados e utilizando o *grid partition* ou *sub clustering*.

### **3.5 Sistema Híbrido: Lógica Fuzzy + Redes Neurais Artificiais**

Pesquisas feitas têm mostrado que sistemas inteligentes híbridos fornecem métodos eficientes em determinadas aplicações, principalmente no ramo da Engenharia.

O Sistema Híbrido é uma ferramenta poderosa que está sendo cada vez mais utilizada para a solução de problemas. Sendo composto aqui pela combinação de duas ferramentas já conhecidas: Redes Neurais Artificiais e a Lógica Fuzzy, no qual se agregam as características de transparência de raciocínio da lógica fuzzy juntamente com a capacidade de aprendizado e generalização das RNAs. Assim, a união da rede Neural com a lógica Fuzzy vem com o intuito de amenizar a deficiência de cada um destes sistemas fazendo com que tenhamos um sistema mais eficiente, robusto e de fácil entendimento.

### 3.6 Sistema Neuro-Fuzzy: ANFIS

O Sistema de inferência Neuro-Fuzzy adaptativo (Adaptive Neuro-Fuzzy Inference System - ANFIS) é uma rede neural proposta por Jang [36,37], cuja idéia básica é de implementar um sistema de inferência Fuzzy através de uma arquitetura paralela distribuída, neste caso, a de uma RNA, de tal forma que os algoritmos de aprendizado possam ser usados para ajustar o sistema de inferência Fuzzy.

Os sistemas adaptativos neuro-fuzzy unem a flexibilidade dos sistemas fuzzy, provida pelas regras, com a arquitetura de Redes Neurais que propicia o aprendizado adaptativo através de dados de treinamento, ajustando adaptativamente os parâmetros das funções de pertinência. Mais especificamente, o modelo neuro-fuzzy mais difundido na literatura é o sistema ANFIS e que se baseia na equivalência funcional, sob certas restrições, entre as redes RBF (Radial Basis Function) e os sistemas fuzzy do tipo TSK (Takagi-Sugeno-Kang) [38]. A utilização de operadores continuamente diferenciáveis (soma-produto) nos sistemas TSK permite a utilização de algoritmos de otimização baseados no método do gradiente para a adaptação dos parâmetros. Entretanto, a simples utilização de algoritmos de programação não-linear para adaptação de parâmetros não implica necessariamente na fusão de sistemas fuzzy e redes neurais. Além disso, a utilização de técnicas de otimização visando o aumento da precisão numérica dos resultados pode prejudicar a interpretação dos conjuntos fuzzy obtidos após o treinamento.

Os sistemas ANFIS computam os parâmetros das funções de pertinência fuzzy interativamente durante a fase de treinamento calculando a resposta obtida pelo sistema e a resposta esperada. E então pelo erro quadrático entre essas respostas o sistema automaticamente se adapta modificando os parâmetros das funções de pertinência fuzzy relacionadas com os antecedentes e os conseqüentes obtendo assim uma nova resposta para o sistema. Esse procedimento é executado com os dados de treinamento até que não se tenha mais diminuição significativa do erro relativo à saída esperada.

Os parâmetros associados com as funções de pertinência são ajustados via um algoritmo de aprendizado. O ajuste destes parâmetros é efetuado utilizando o algoritmo de retropropagação ou uma combinação deste com um algoritmo do tipo: mínimos quadrados (Least Squares). Esta estrutura implementa sistemas do tipo Takagi-Sugeno [39], com funções lineares ou constantes nos conseqüentes das regras que formam o sistema, tendo estas regras pesos unitários.

Os sistemas ANFIS possuem uma arquitetura em rede similar a arquitetura das redes neurais artificiais, que mapeiam um conjunto de entradas em uma saída. Esse mapeamento é feito através de uma série de cinco camadas intermediárias. Cada camada intermediária tem um papel específico relacionado com o processo de inferência fuzzy. A primeira camada é responsável pelo mapeamento da entrada nos conjuntos fuzzy gerando os antecedentes das regras; na segunda camada, são realizadas as operações t-norm que possibilita a criação de regras com múltiplos antecedentes; na terceira, é realizada apenas uma operação de normalização; na quarta, os consequentes são gerados conforme o modelo linear desenvolvido por Takagi-Sugeno [39]; Finalmente, na última camada, é realizada uma operação T-conorm que possibilita a agregação de múltiplos consequentes para uma única saída do sistema. Na Figura 3.2, tem-se a arquitetura do ANFIS [38].

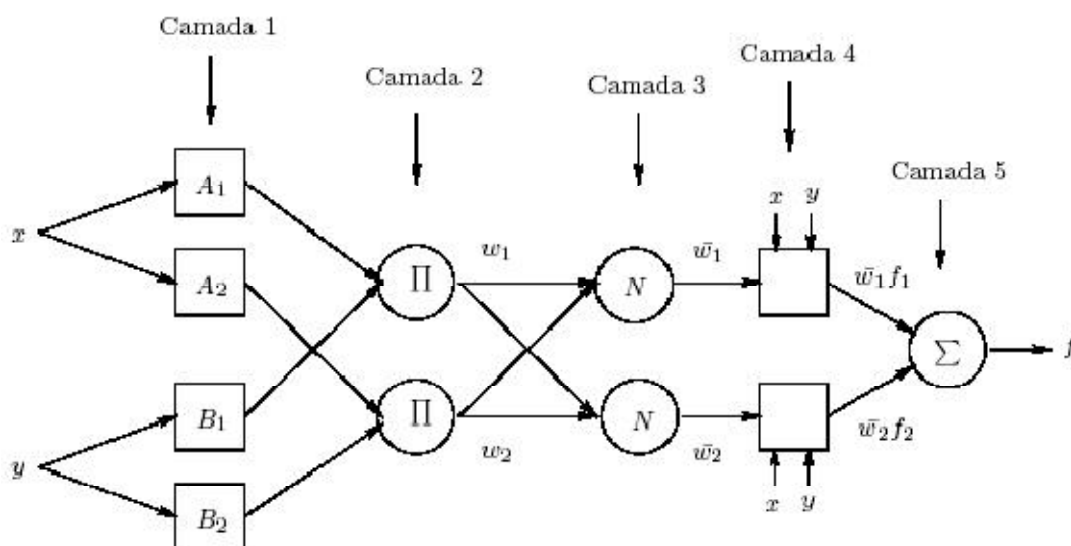


Figura 3.2 Arquitetura Neuro-Fuzzy: ANFIS.

A primeira camada é composta pelo grau de pertinência do padrão de entrada ( $x,y$ ). Nesta camada, calcula-se o grau de pertinência com que as entradas precisas satisfazem os termos lingüísticos associados a estes nós. Na segunda camada, cada nó corresponde a uma regra, nesta calcula-se o grau de ativação de cada regra, ou seja, com que grau o consequente da regra está sendo atendido. Os neurônios desta camada executam a operação de t-norm (geralmente produto). Na terceira camada, é realizada a normalização, onde cada nó calcula a razão entre o nível de disparo da regra  $i$  pela soma dos níveis de disparo de todas as regras. Já na quarta camada, as saídas do neurônio são



calculadas pelo produto entre os níveis de disparo normalizados e o valor do conseqüente da regra em si. A camada 5 calcula a saída precisa.

Este sistema utilizado no trabalho foi o particionamento Fuzzy-grid Adaptativo. Seu aprendizado (identificação da estrutura e parâmetros) é feito em duas etapas que se repetem até que o critério de parada seja alcançado, quais sejam:

ETAPA 1: Os parâmetros dos antecedentes ficam fixos e os conseqüentes são ajustados pelo método MQD- estimacão por Mínimos Quadrados Ordinários.

ETAPA 2: Os parâmetros dos conseqüentes ficam fixos e os antecedentes são ajustados pelo algoritmo Gradiente Descendente.

Dentre as características do sistema neuro-fuzzy tem-se a sua utilização em problemas de previsão, sendo nesse trabalho utilizado na previsão de vazão. Na seção seguinte, uma breve revisão sobre identificação de sistemas é apresentada.

A ferramenta computacional escolhida para a previsão de vazão foi o sistema Fuzzy. Porém, para se trabalhar com esta ferramenta de inteligência artificial é necessária a montagem de uma base de regras que relacionem a entrada com a saída. Isto é muitas vezes um trabalho altamente exaustivo e demorado, visto que é necessário que as regras prevejam todas as entradas e as possíveis saídas, além da preocupação de eliminar qualquer tipo de conflito na parte ENTÃO das regras, o que ocasionaria duas saídas diferentes para uma mesma entrada. Para solucionar este problema, é proposta neste trabalho a utilização de uma rede neuro-fuzzy, onde a rede será treinada utilizando técnicas de redes neurais para a montagem das regras que serão posteriormente utilizadas no sistema fuzzy montado a partir dos coeficientes obtidos no treinamento da rede. Neste caso, o objetivo da rede neural é processar a informação de acordo com seu prévio treinamento com dados de entrada e saída. A escolha da rede neural se deve ao fato das redes neurais serem extremamente paralelas, pois suas numerosas operações são executadas simultaneamente.

O sistema neuro-fuzzy escolhido foi o sistema criado por J. S Roger Jang chamado ANFIS que faz uma adaptação dos valores de entrada e saída para uma base de regra que interliga todas as entradas e saídas, formando assim uma base de regras robusta que cria um sistema de inferência fuzzy que contempla todas as possíveis entradas.

O sistema ANFIS foi escolhido por ser usado para aplicações de previsão e aproximação de funções. Além disso, ele é um sistema de Takagi-Sugeno e se demonstra que seu modelo de primeira ordem é um aproximador universal. Sua

popularidade é tão grande que o levou a ser implementado no MatLab. Um exemplo de sistema de Takagi-Sugeno de primeira ordem pode ser visto na Figura 3.3.

Tendo duas variáveis de entrada  $x$  e  $y$ , uma saída  $z$  determinada pela Equação 3.1 e as regras:

*Regra 1: SE  $x$  é  $A_1$  e  $y$  é  $B_1$  ENTÃO  $f_1 = p_1 \times x + q_1 \times y + r_1$*

*Regra 2: SE  $x$  é  $A_2$  e  $y$  é  $B_2$  ENTÃO  $f_2 = p_2 \times x + q_2 \times y + r_2$*




Figura 3.3 Exemplo do Sistema Takagi-Sugeno de Primeira Ordem.

Então através da Figura 3.3 temos:

$$Z = \frac{W_1 \cdot f_1 + W_2 \cdot f_2}{W_1 + W_2} \quad (3.1)$$

### 3.7 Conclusões do Capítulo

Um sistema de inferência fuzzy neuroadaptativo ANFIS pode ser treinado com um algoritmo de retropropagação para modelar um conjunto de dados entrada/saída. O FIS, permitindo adaptação, contempla o sistema fuzzy com a habilidade de aprender inter-relações embutidas nas entradas e saídas dos dados utilizados.

A estrutura de rede do ANFIS facilita o processo de computação do vetor gradiente que relaciona a redução de uma função erro para uma modificação nos parâmetros de um FIS. Assim que o vetor gradiente é obtido, um número de rotinas de otimização pode ser aplicado para reduzir o erro entre a saída real e a obtida. Na literatura de redes neurais, isto é conhecido como aprender com o exemplo. O modelo do ANFIS utilizado neste trabalho é do tipo Sugeno (conhecido como TSK fuzzy model), proposto por Tagaki & Sugeno [38] e Sugeno & Kang [40].

Toda a abordagem de Lógica Fuzzy tratada neste capítulo será de grande utilidade para a implementação deste trabalho como veremos nos capítulos seguintes.

# CAPÍTULO 4

## 4 METODOLOGIA APLICADA

---

Este capítulo descreve a metodologia aplicada no desenvolvimento deste trabalho no que diz respeito a utilização de inteligência artificial para previsão de vazão. Sendo assim, são descritas todas as etapas a serem seguidas para desenvolvimento dos modelos de previsão descritos no capítulo 5.

A metodologia para tratamento dos dados, os algoritmos de treinamento, escolha da melhor arquitetura, método de validação cruzada e os parâmetros de validação para definir o melhor modelo serão descritos neste capítulo.

### 4.1 Metodologia


O uso de modelos lineares na predição de vazões e de séries temporais, como os modelos clássicos de Box-Jenkins [41], geralmente é motivado pela simplicidade, o que facilita o projeto e a implementação. Entretanto, existem muitas situações reais nas quais se faz necessário um mapeamento não-linear entre as variáveis de entrada e o domínio de resposta do sistema, daí a necessidade de novas técnicas que permitam este mapeamento de forma eficiente.

Com o advento do algoritmo backpropagation, uma grande atenção tem-se dado às redes neurais, especialmente às redes MLP (multilayer perceptron), em função de poder aproximar uma função arbitrária não-linear em muitas variáveis conforme demonstrado no capítulo 2. A capacidade de aproximação delas tem sido provada por vários pesquisadores, como Cybenko [42] e Stinchcomb-White [43]. Eles mostraram que uma rede MLP com uma única camada escondida é capaz de aproximar qualquer função contínua definida sobre um conjunto compacto limitado. Portanto, a rede MLP pode ser considerada uma técnica extremamente poderosa para realizar um mapeamento não-linear. Entretanto, esses pesquisadores não fornecem procedimentos para determinar o número de neurônios necessários na camada escondida para realizar a aproximação de uma dada função. Esse aspecto é de fundamental importância, haja

vista que se o número de neurônios na camada escondida for muito grande, além de se ter um modelo não-parcimonioso, a rede poderá memorizar os dados de treinamento e ficar com uma capacidade de generalização pobre. Por outro lado, se o número de neurônios na camada escondida for pequeno, a rede poderá ficar subajustada e, como consequência, não ser capaz de extrair dos dados todas as informações desejadas.

## 4.2 Tratamento dos Dados

A nossa aplicação está baseada em um histórico de vazões médias mensais no período de 1931 a 2004 para a usina de Sobradinho fornecido pelo ONS [44] que se encontra no apêndice deste trabalho. Com a aquisição dos dados foi esboçado um gráfico em função dos meses do ano com o objetivo de verificar e dividir os meses do ano em dois grupos, conforme Figura 4.1.



**Figura 4.1 Vazão Média do rio São Francisco em função dos meses do ano.**

Na Figura 4.1, é mostrada a vazão média do Rio São Francisco em função dos meses do ano no período de 1931 a 2004 e os anos de 2005 a 2008. A partir desses dados, foi separado o ano em dois grupos: o primeiro grupo formado pelos meses de dezembro de um ano a abril do ano seguinte (5 meses), meses considerados de cheia; e o segundo grupo formados pelos meses de maio a novembro (7 meses) considerados de seca.

A vazão mensal ocorrida nos anos de 2005 a 2008 serão utilizados para validar os modelos de previsão propostos neste trabalho.

Vale salientar também que na Figura 4.1 é apresentada a vazão média anual, pois esta será utilizada como fonte para um dos modelos propostos no capítulo seguinte.

A metodologia aplicada neste trabalho consiste inicialmente no tratamento dos dados e na determinação da melhor arquitetura e algoritmo de treinamento em busca da melhor RNA.

Após a etapa inicial da escolha da melhor RNA, são propostas três diferentes configurações visando o melhor resultado na previsão anual de vazão.

Em uma última etapa, buscou-se reduzir o intervalo de previsão anual para mensal tentando assim minimizar os erros. Nesta etapa, utilizou-se tanto as redes neurais artificiais como também o ANFIS para a previsão.

O tratamento dos dados de 1931 a 2004 foi feito seguindo os procedimentos padrões [45, 46 e 47].

### 4.2.1 Embaralhamento dos Dados

A primeira etapa de tratamento dos dados é o embaralhamento, que significa misturar os dados aleatoriamente. Através deste processo é possível tornar os dados uniformes, evitando assim, tendências a falsos resultados. Terminado o embaralhamento dos dados, segue-se a próxima etapa, a etapa de normalização dos dados.

### 4.2.2 Normalização dos Dados

Observando que as magnitudes das variáveis de entrada da rede são diferentes, deve-se então fazer a normalização por variáveis, que foi realizada conforme a Equação (4.1):

$$x_{(0,1-0,9)}^{norm} = \frac{x - 0,9.x_{min}}{1,1.x_{max} - 0,9.x_{min}} \quad (4.1)$$

Os dados foram normalizados entre 0,1 e 0,9 para evitar que os neurônios das redes saturassem, dificultando o aprendizado durante os treinamentos [18].

### 4.2.3 Separação dos Dados para Treinamento e Validação:

Visto que as redes neurais aprendem a partir de exemplos e que as mesmas são projetadas para serem capazes de generalizar o conhecimento adquirido durante o treinamento, então é necessário dividir a base de dados nos seguintes conjuntos: treinamento, validação e teste.

Neste trabalho, os dados foram separados da seguinte maneira: 50% para formar o conjunto de **treinamento**, 25% para formar o conjunto de **validação** e 25% para formar o conjunto de **teste**.

O conjunto de treinamento deve ser constituído pela maior parte dos dados, pois é a partir deste conjunto que os pesos sinápticos dos neurônios são ajustados durante os treinamentos com objetivo de passar o conhecimento para as redes.

Já o conjunto de validação é usado paralelamente com o conjunto de treinamento. Entretanto, o mesmo não é usado para ajustes dos pesos, mais sim para verificar a capacidade de generalização da rede neural durante o treinamento. Logo, este conjunto é utilizado como critério de parada de treinamento, para evitar o super ajuste da rede, ou seja, para evitar a memorização dos dados de treinamento.

Assim como o conjunto de validação, o conjunto de teste não é utilizado para ajustes dos pesos durante o treinamento, ele só é apresentado à rede para estimar o desempenho das mesmas quando estas estiverem em operação, já que este conjunto jamais fora apresentado à rede.

## 4.3 Experimentos para Escolha da Arquitetura

É sabido que o desempenho dos modelos de previsões criados a partir das redes neurais artificiais é função de várias variáveis, e a arquitetura é uma delas. Diante disso, é importante criar alguma estratégia para selecionar uma arquitetura ideal. Com esse objetivo, foram utilizados procedimentos padrões vastamente utilizados na literatura e aplicados em [45, 46 e 47].

O critério aqui adotado é de treinar várias redes neurais modificando os números de neurônios na camada intermediária na rede neural MLP que variou de 3 a 20. Sendo, portanto, selecionada a arquitetura que obtiver menor erro médio quadrático (MSE) durante os treinamentos sobre o conjunto de validação.

Assim como a arquitetura, a inicialização dos pesos sinápticos que é realizada aleatoriamente pode influenciar a performance dos treinamentos. Portanto, para cada arquitetura testada os pesos são inicializados dez vezes para garantir que a seleção da melhor arquitetura não tenha sido ocasionada por uma inicialização ótima dos pesos.

### 4.3.1 Avaliação de Desempenho

Durante os treinamentos das redes neurais, o erro calculado foi o erro médio quadrático (MSE), dos conjuntos de treinamento e validação, conforme Equação (4.2).

$$MSE = \frac{L_{máx} - L_{mín}}{N \cdot P} \sum_{p=1}^P \sum_{i=1}^N (L_{pi} - T_{pi})^2 \quad (4.2)$$

Os resultados das simulações das redes neurais serão avaliados a partir do cálculo da percentagem do erro médio absoluto (MAPE) calculado pela Equação (4.3).

$$MAPE(\%) = \frac{1}{N \cdot P} \sum_{p=1}^P \sum_{i=1}^N \frac{|L_{pi} - T_{pi}|}{T_{pi}} \times 100 \quad (4.3)$$

Onde  $L_{máx}$  e  $L_{mín}$  são os valores de máximo e mínimo dos coeficientes de saída na representação do problema, respectivamente.  $N$  é o número de unidades de saída da rede neural,  $P$  é o número de padrões da base de dados considerada,  $L_{pi}$  é a saída calculada por cada unidade de saída da rede e  $T_{pi}$  a saída desejada da rede para cada unidade.

### 4.3.2 Critérios de Parada dos Treinamentos

Em geral, não se pode demonstrar que o algoritmo de treinamento convergiu e não existem critérios bem definidos para encerrar a sua operação. Em vez disso, há vários métodos particulares, cada um com o seu mérito que pode ser usado para finalizar os treinamentos das redes neurais. Todos os critérios de parada têm objetivo de evitar *overfitting* dos pesos, o que prejudica a capacidade de generalização das redes.

Os critérios de parada do treinamento utilizado neste trabalho são apresentados a seguir.

#### 4.3.2.1 Números de Épocas

É estipulado um número máximo de épocas de treinamentos nos projetos dos modelos de previsões, onde se define época como sendo o número de vezes que o conjunto de treinamento é passado para RNA. Foram utilizadas 10000 épocas como número máximo neste trabalho.



### 4.3.2.2 Early Stop

O critério de *Early Stop* tem o objetivo de aumentar a capacidade de generalização das redes neurais através do erro no conjunto de validação. Este erro, geralmente, diminui durante a fase inicial do treinamento, porém quando a rede neural começa a memorizar, ele aumenta. Portanto, quando o erro deste conjunto aumenta em um número específico de épocas, o treinamento é interrompido, e os pesos e bias são retornados aos seus valores do momento de menor erro sobre o conjunto de validação.

### 4.3.2.3 Desempenho mínimo de Treinamento

Neste critério, a parada do treinamento é determinada quando o erro sobre o conjunto de treinamento atingir o limite de erro especificado. Neste trabalho o limite adotado foi do erro médio quadrado (MSE) igual à zero. Este valor foi escolhido para permitir que as redes treinem o máximo possível, desde que não infrinja os outros dois critérios.

Os critérios de parada citados anteriormente são utilizados simultaneamente durante o treinamento, devendo este ser encerrado caso qualquer um dos critérios seja atingido.

## 4.4 Seleção de Arquitetura

No projeto de RNA existe uma dependência entre o número de padrões usados no conjunto de treinamento, a dificuldade do problema a ser tratado, o número de parâmetros livres (pesos e bias) e o processo de aprendizagem. No entanto, não existe nenhuma regra determinística que relacione estas variáveis, apesar de alguns pesquisadores citarem algumas regras práticas. Neste trabalho, estas variáveis são restringidas ao número de parâmetros livres, ou melhor, a arquitetura da RNA, pois o número de padrões de treinamento está limitado pelo tamanho da base de dados, enquanto que a dificuldade do problema é inerente à aplicação.

Sabe-se que a rede MLP é considerada uma técnica extremamente poderosa para realizar um mapeamento não-linear. Porém, se os procedimentos para determinar o número de neurônio necessários na camada escondida não forem seguidos; a rede poderá memorizar os dados de treinamento e ficar com uma pobre capacidade de generalização, ou ainda a rede poderá ficar subajustada e, como consequência, não ser capaz de extrair dos dados as informações desejadas [48]. Desta forma, para se

selecionar a arquitetura da RNA foi adotada a regra utilizada nos trabalhos [45, 46 e 47]. Nestes trabalhos, as arquiteturas são definidas mediante a variação do número de neurônios na camada oculta, sendo selecionada a que apresentar o melhor desempenho, ou seja, menor MSE durante os treinamentos.

No desenvolvimento dos modelos neurais deste trabalho, para cada número de neurônios ocultos, determinado entre a faixa de variação de seleção, os treinamentos das redes são inicializados dez vezes com pesos aleatórios. No final de cada processo de dez inicializações, é anotado o erro médio MSE no conjunto de validação. Este erro é utilizado como balizador na definição da arquitetura, pois a arquitetura selecionada deverá apresentar o menor MSE.

### **4.5 Algoritmo de Treinamento**

O algoritmo de aprendizagem *backpropagation* tem diversas variações, uma vez que o algoritmo padrão *backpropagation* se torna muito lento para várias aplicações, e seu desempenho piora sensivelmente para problemas maiores e mais complexos. Desta forma, foi avaliado outro algoritmo de treinamento.

Devido à necessidade de rapidez no algoritmo de treinamento e pelo fato de se treinar um grande número de redes, o RPROP foi escolhido. Este é um algoritmo com taxa de aprendizagem adaptativa, ou seja, o ajuste dos pesos depende do sinal da derivada do erro com relação ao peso a ser ajustado, sendo normalmente de 1,2 para aumentar e de 0,5 para diminuir. Os ajustes dos pesos são feitos na fase *backward* do treinamento a cada época com o objetivo de minimizar a função erro.

O RPROP procura eliminar a influência negativa do valor da derivada parcial na definição dos ajustes dos pesos, pois utiliza apenas o sinal da derivada e não o seu valor. O sinal indica a direção do ajuste dos pesos, enquanto que o tamanho do ajuste é dado por um valor de atualização.

### **4.6 Validação Cruzada: Usando o Método 10-fold**

Após a seleção da topologia da rede que obteve melhor desempenho durante o treinamento, utilizou-se o método 10-fold para obter uma estimativa do erro mais próximo do verdadeiro. A técnica de k-fold consiste em criar partições da série temporal em vários subconjuntos e, a partir destes, formar diversos conjuntos de treinamento,

validação e teste, onde cada um deste é criado através de permutações das partições da série, conforme indicado na Tabela 4.1.

**Tabela 4.1 Formação dos conjuntos**

Experimento	Rede	Treinamento	Validação	Teste
1	De 1 a 10	5, 6, 7, 8, 9, 10	2, 3, 4	1
2	De 11 a 20	1, 6, 7, 8, 9, 10	3, 4, 5	2
3	De 21 a 30	1, 2, 7, 8, 9, 10	4, 5, 6,	3
4	De 31 a 40	1, 2, 3, 8, 9, 10	5, 6, 7	4
5	De 41 a 50	1, 2, 3, 4, 9, 10	6, 7, 8	5
6	De 51 a 60	1, 2, 3, 4, 5, 10	7, 8, 9	6
7	De 61 a 70	1, 2, 3, 4, 5, 6	8, 9, 10	7
8	De 71 a 80	2, 3, 4, 5, 6, 7	9, 10, 1	8
9	De 81 a 90	3, 4, 5, 6, 7, 8	1, 2, 10	9
10	De 91 a 100	4, 5, 6, 7, 8, 9	1, 2, 3	10

Esta técnica possibilita ainda encontrar uma melhor distribuição dos dados nos conjuntos de treinamento, validação e teste, pois cada um destes conjuntos deve representar bem a série temporal de vazão. Assim, com a aplicação da validação cruzada, são criados dez experimentos durante as simulações (testes) da melhor arquitetura de rede, sendo que para cada experimento, os pesos são inicializados dez vezes conforme apresentado na Tabela 4.1, pelos mesmos motivos que estes são inicializados nos treinamentos.

## 4.7 Conclusões do Capítulo

Neste capítulo foi apresentada a metodologia a ser desenvolvida neste trabalho, ou seja, foram apresentadas todas as etapas para implementação dos modelos mostrados no capítulo seguinte.

# CAPÍTULO 5

## 5 MODELOS DE PREVISÃO

---

Com o objetivo de conseguir o menor erro possível foram propostos alguns modelos para previsão de vazão na bacia do rio São Francisco. Neste trabalho, quatro modelos de previsão de vazão foram desenvolvidos: o primeiro, denominado de modelo para previsão utilizando RNA representado por três configurações com horizontes de longo prazo; o segundo, denominado de modelo para previsão utilizando RNA e ANFIS representado por duas configurações com horizontes de médio prazo; o terceiro, denominado modelo híbrido RNA-ANFIS para previsão, utilizando as melhores configurações da RNA e do ANFIS; e por fim, o quarto modelo, denominado sistema híbrido RNA-Fragmentos, modelo para previsão baseado em RNA e no Método dos Fragmentos.

### 5.1 Horizontes para Previsão de Vazão

As previsões de vazão permitem que os diferentes modelos de operação, otimização e simulação energética possam avaliar as condições operacionais das usinas hidroelétricas no futuro, propiciando subsídios para a tomada de decisões, explorando toda sua complementariedade hidrológica e propiciando ganhos significativos. Estas previsões de afluências podem permitir também uma tomada de decisão no sentido de minimizar os efeitos de uma cheia excepcional ou um racionamento inesperado, desde que feita com relativa precisão e antecedência.

As previsões de afluências servem como subsídio a outros setores usuários da água como a irrigação, a pesca, o turismo, o lazer e a navegação. Estes setores se utilizam destas previsões de afluências para programar suas atividades à luz dos recursos hídricos disponíveis nas diferentes bacias hidrográficas. Conforme o uso que se faça das previsões de vazão, trabalha-se com diferentes horizontes e diferentes

intervalos de discretização. Há três horizontes de previsões, a saber: previsões de longo prazo, previsões de médio prazo e previsões de curto prazo.

Na previsão de vazão de longo prazo, a partir de um histórico de vazões naturais médias mensais e de diferentes modelagens, geralmente utilizando técnicas de hidrologia estocástica, realizam-se estimativas de vazões médias mensais para os meses seguintes, normalmente abrangendo um horizonte de até um ano.

No horizonte de previsão de médio prazo, a partir de um histórico de vazões naturais médias mensais e utilizando modelagem estocástica são realizadas estimativas de vazões naturais médias mensais com horizonte de um mês. Estas previsões tem por objetivo auxiliar no processo de tomada de decisão operativa para a otimização dos recursos naturais nos reservatórios, no uso múltiplo dos reservatórios, como navegação, controle de eventos extremos, abastecimento, turismo e lazer. Acredita-se que possa haver um ganho bastante elevado nos resultados das previsões de vazão mensal, posteriormente incorporando essa informação aos modelos estocásticos existentes, ou até mesmo, no uso de modelos determinísticos chuva-vazão para os primeiros meses à frente.

No horizonte de previsão de curto prazo, a partir de um histórico de vazões médias semanais ou diárias, em sua grande maioria baseado em dados de balanço hídrico, são realizadas estimativas de vazões médias diárias para um horizonte de até 14 dias à frente. Isto pode ser feito utilizando tecnologia determinística com modelos chuva-vazão, ou até mesmo, utilizando modelos estocásticos, acredita-se que também possa haver um ganho bastante elevado nos resultados das previsões de vazões diárias, sempre que houver uma evolução nas tecnologias de previsão de precipitação que permita ampliar o horizonte atual de alguns dias a duas ou três semanas.

Os modelos de previsão de vazão descritos nesse capítulo são divididos em dois tipos de horizonte de previsão: de longo prazo e médio prazo. A seguir são descritos os modelos utilizando-se das ferramentas mais conhecidas atualmente que são as Redes Neurais e o ANFIS.

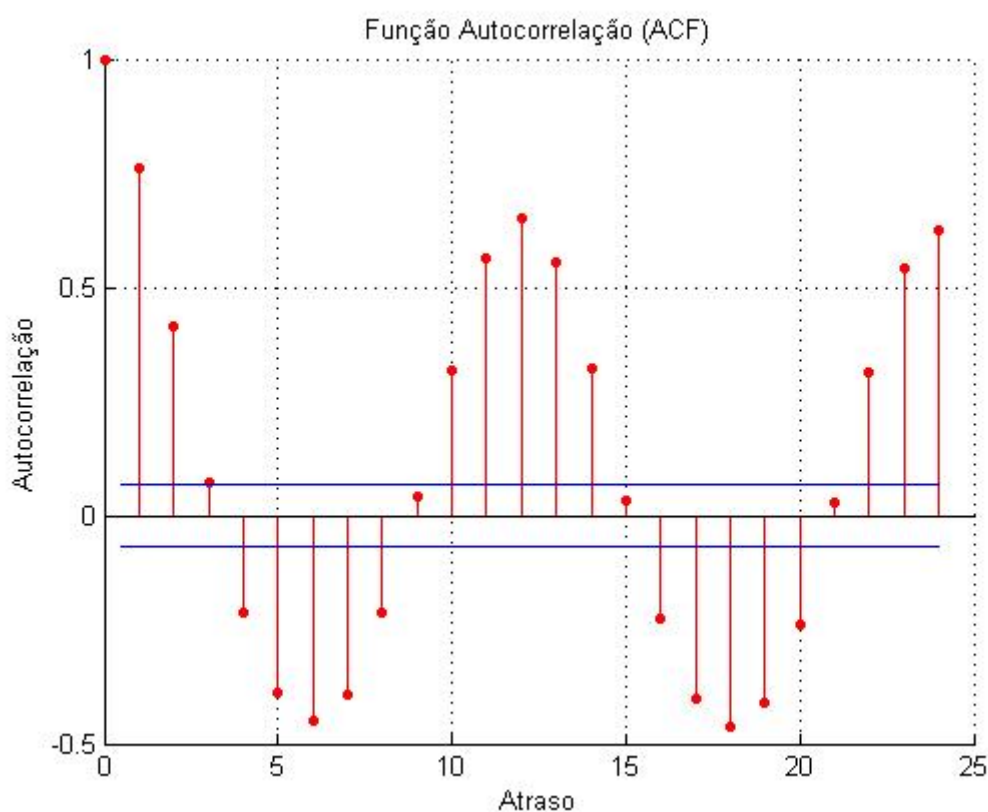
### **5.2 Função Autocorrelação (ACF)**

No intuito de melhor embasar os modelos de previsão de vazão a serem desenvolvidos nesta dissertação, a função autocorrelação foi aplicada à base de dados

com o objetivo de verificar a correlação mensal e anual dos dados de vazão do Rio São Francisco ao longo de todos esses anos (1931 a 2004). Dessa forma, pode-se verificar a importância da vazão atual em relação às anteriores, e assim, desenvolver modelos coerentes e consistentes com a realidade da sazonalidade do rio.

Constata-se observando a Figura 5.1 que existe uma autocorrelação positiva com os três meses anteriores. A partir dessa análise, foi desenvolvido um modelo no qual se tem como entrada três meses anteriores.

Percebe-se também que a cada 12 meses, a autocorrelação se repete. Ou seja, o mesmo mês do ano anterior tem uma autocorrelação positiva (superior a 0,5) com o do ano seguinte, o que levou a propor modelo sazonal para período seco e úmido de acordo com a sazonalidade das vazões para um horizonte anual.



**Figura 5. 1 Função Autocorrelação Mensal.**

Em busca de novos modelos e baseado na Figura 5.2, onde se percebe a autocorrelação anual com quatro anos anteriores, foram desenvolvidos modelos com RNAs, cuja entrada é a média anual de quatro anos anteriores e a saída é a previsão da média anual do ano seguinte.

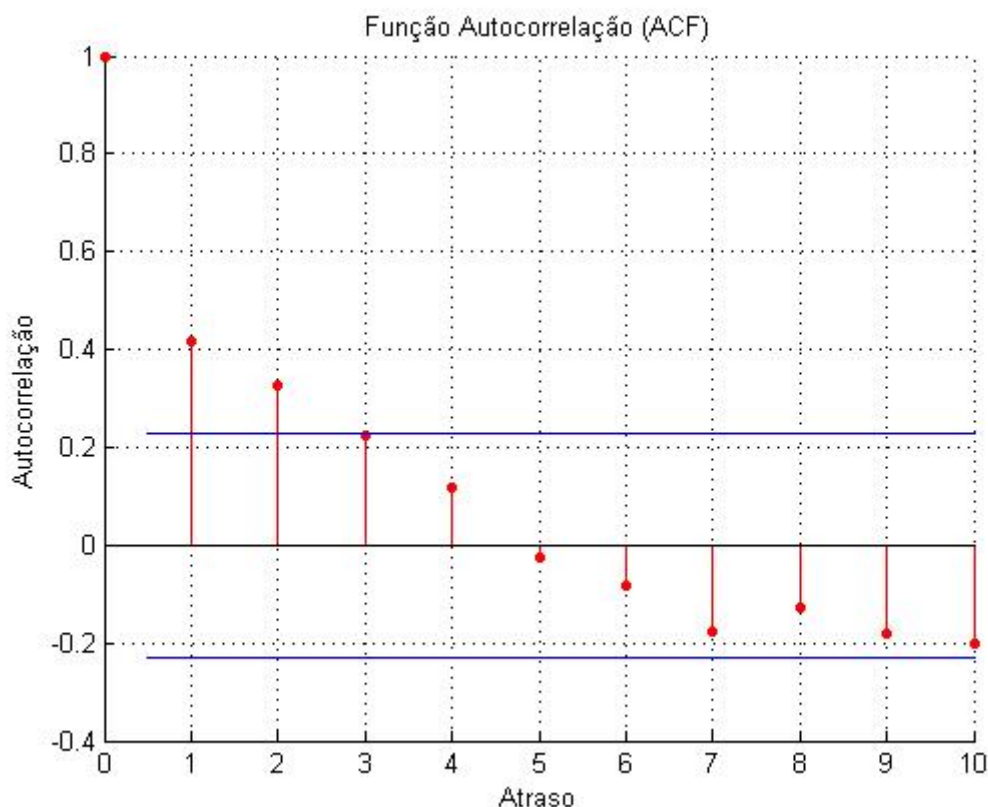


Figura 5. 2 Função Autocorrelação Anual.

### 5.3 Modelos para Previsão Utilizando RNA

No intuito da busca de melhores resultados para previsão de vazão na bacia do São Francisco são propostas três diferentes configurações para a previsão anual utilizando redes neurais artificiais. Estas configurações são:

#### Configuração 1:

12 x 12 para prever um mês com horizonte de um ano. Entra-se com a vazão dos doze meses e obtém-se como saída a vazão dos doze meses do ano seguinte.

#### Configuração 2:

Rede 1: 5 x 5 para prever um mês com horizonte de um ano. Entra-se com a vazão dos meses de dezembro até abril (meses de chuva) e obtém-se como saída a vazão dos meses de dezembro a abril do ano seguinte.

Rede 2: 7 x 7 para prever um mês com horizonte de um ano. Entra-se com a vazão dos meses considerados seco (maio até novembro) e obtém-se como saída a vazão dos meses de maio até novembro do ano seguinte.

**Configuração 3:**

3 x 1: para prever um mês com horizonte de um ano. Entra-se com a vazão do mês e obtém-se como saída a vazão do mesmo mês no ano seguinte. Para identificar os meses do ano, utiliza-se também como entrada a representação dos meses em senos e cossenos, resultando em um total de três entradas nesta configuração.

**5.3.1 Primeira Configuração**

A idéia da primeira configuração é entrar com a vazão dos doze meses de um ano e prever a vazão dos doze meses do ano seguinte.

A Figura 5.3, ilustra a primeira configuração.




Figura 5.3 Elementos básicos da primeira configuração.

**5.3.2 Segunda Configuração**

A idéia da segunda configuração utilizando a rede 1, é entrar com a vazão dos cinco meses de cheia (dezembro a abril) para prever a vazão dos cinco meses de cheia do ano seguinte; e utilizando a rede 2, é entrar com a vazão dos sete meses considerados seco (maio a novembro) de um ano e prever a vazão dos sete meses seco do ano seguinte. Desta forma, estar-se prevendo um ano completo.

A Figura 5.4, ilustra a segunda configuração.






Figura 5.4 Elementos básicos da segunda configuração: (a) 5 meses de cheia (dezembro a abril); (b) 7 meses considerados secos (maio a novembro).

### 5.3.3 Terceira Configuração

A idéia da terceira configuração é entrar com a vazão do mês para prever a vazão do mesmo mês no ano seguinte. Para isso, teve-se que utilizar a sazonalidade, representada pelos meses codificados em senos e cossenos.

A Figura 5.5 apresenta a terceira configuração.




Figura 5. 5 Elementos básicos da terceira configuração: usando senos e cossenos.

### 5.3.3.1 Representação dos meses

Nessa forma de representação dos meses, consideram-se dois neurônios com funções de seno e cosseno, cujos valores são fixados pelas seguintes expressões:

$$Neur\hat{o}nio1 = Seno(2,0 * \pi * N / T) \quad (5.1)$$

$$Neur\hat{o}nio2 = Cosseno(2,0 * \pi * N / T) \quad (5.2)$$

Onde N varia de 1(janeiro) a 12 (dezembro) e T é o período que, nesse caso, é 12.

## 5.4 Modelos para Previsão Utilizando RNA e ANFIS

No intuito de minimizar os erros obtidos na previsão com horizonte anual, são propostas novas configurações buscando a previsão no horizonte de um e dois meses à frente. Vale salientar que para as seguintes configurações, foram feitas as previsões tanto utilizando RNA como o ANFIS.

### 5.4.1 Configuração Um Mês à Frente para o Treinamento com RNA e ANFIS

Essa configuração é chamada de um mês à frente e utiliza três meses anteriores ao mês que se deseja prever. Ou seja, três meses de entrada e uma saída. Os meses de entrada são meses sucessivos/seguidos, conforme Tabela 5.1.

**Tabela 5.1 Configuração Um Mês à Frente Utilizada para o Treinamento da RNA e ANFIS**

Entrada 1	Entrada 2	Entrada 3	Saída
Outubro	Novembro	Dezembro	Janeiro
Novembro	Dezembro	Janeiro	Fevereiro
Dezembro	Janeiro	Fevereiro	Março
Janeiro	Fevereiro	Março	Abril
Fevereiro	Março	Abril	Maio
Março	Abril	Maio	Junho
Abril	Maio	Junho	Julho
Maio	Junho	Julho	Agosto
Junho	Julho	Agosto	Setembro
Julho	Agosto	Setembro	Outubro
Agosto	Setembro	Outubro	Novembro
Setembro	Outubro	Novembro	Dezembro

#### 5.4.2 Configuração Dois Meses à Frente para o Treinamento com RNA e ANFIS

Essa configuração é chamada de dois meses à frente e utiliza três meses anteriores sucessivos como entrada, intercalado de um mês anterior ao mês de previsão. Ou seja, três meses de entrada e uma saída. Os meses de entrada são seguidos, depois, pula-se um, e o próximo é a saída desejada, conforme Tabela 5.2.

**Tabela 5.2 Configuração Dois Meses à Frente Utilizada para o Treinamento da RNA e ANFIS**

Entrada 1	Entrada 2	Entrada 3	Saída
Setembro	Outubro	Novembro	Janeiro
Outubro	Novembro	Dezembro	Fevereiro
Novembro	Dezembro	Janeiro	Março
Dezembro	Janeiro	Fevereiro	Abril
Janeiro	Fevereiro	Março	Maio
Fevereiro	Março	Abril	Junho
Março	Abril	Maio	Julho
Abril	Maio	Junho	Agosto
Maio	Junho	Julho	Setembro
Junho	Julho	Agosto	Outubro
Julho	Agosto	Setembro	Novembro
Agosto	Setembro	Outubro	Dezembro

Vale salientar que o sistema ANFIS disponibilizado no MatLab<sup>®</sup> permite várias entradas, porém, apenas uma saída. A preparação deste arquivo foi feita utilizando a planilha eletrônica Microsoft Excel. Após a conversão, os dados são carregados no editor do ANFIS no MatLab<sup>®</sup>, onde são selecionados para gerar o sistema de inferência inicial, o tipo de particionamento que, neste trabalho, é o Grid partition; o número de funções para a camada de entrada; o tipo da função de pertinência, bem como o número

de regras. O ANFIS é treinado até satisfazer um critério de parada que pode ser o número de épocas ou o valor do erro (MSE) ou pela parada antecipada quando o conjunto de validação for informado; ou seja, o critério de parada que for atingido primeiro pára o treinamento do ANFIS. Para se chegar a um resultado satisfatório na previsão de vazão, foram necessários diversos testes, já que foi notada a existência de um ponto de saturação para a redução do erro, o qual depende diretamente do número de regras desejadas. Então, para que o valor mínimo do erro fosse atingido, foram realizados vários testes até se obter um número de regra adequado.

Em todos os casos, foi utilizado o tipo de função de pertinência na forma Gaussiana e o Takagi-Sugeno de primeira ordem como método de inferência fuzzy.

### **5.5 Modelos para Previsão Utilizando o Sistema Híbrido RNA-ANFIS**

Nesta etapa, foram feitas as previsões anuais dos anos 2005, 2006, 2007 e 2008 usando de RNA e ANFIS. O método consiste em, a partir de uma base de dados construída da média anual de cada ano (de 1931 a 2004), se utilizar das RNAs para previsão, sendo fornecidos para a rede quatro anos anteriores para ela prever o ano seguinte.

Em uma etapa posterior, utiliza-se do ANFIS para calcular a vazão de cada mês desse ano, tendo inicialmente como entrada: o mês que se deseja (1 a 12), dois anos anteriores e a previsão anual do ano seguinte realizada pela RNA, como visualizado na Figura 5. 6. Têm-se um ANFIS para cada mês e através dele obtemos um fator denominado fator mensal; com esses resultados obtemos a previsão mensal do ano que quisermos, utilizando-se da Equação (5.3). Em seguida, calculado o erro da previsão, conforme a Equação (4.3).

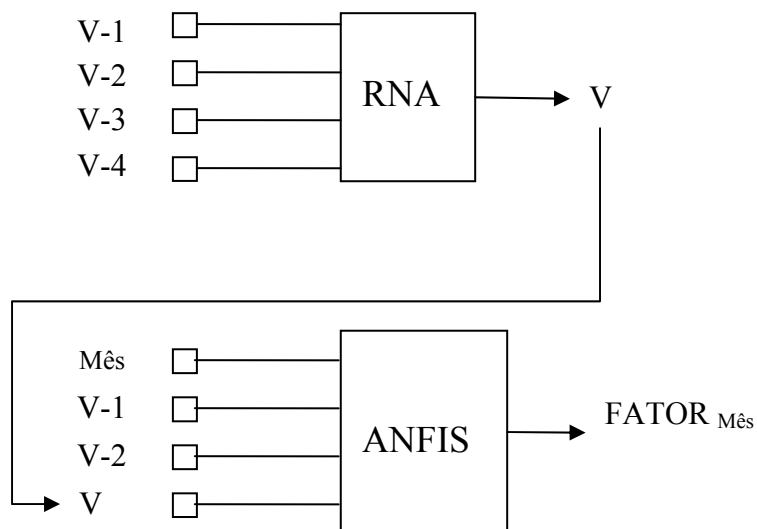


Figura 5.6 Modelo de previsão Híbrido RNA-ANFIS.

$$V_{Mês} = V \times FATOR_{Mês} \quad (5.3)$$

Onde:

FATOR<sub>Mês</sub> é o fator para cada mês do ano;


V<sub>Mês</sub> é a vazão prevista mensal;

V é a vazão média anual.

## 5.6 Modelos para Previsão Utilizando o Sistema Híbrido RNA-Fragmentos

Ao se trabalhar a nível mensal, há que se desagregar as vazões anuais em mensais. Sendo assim, tem sido freqüente o uso do método dos fragmentos, o qual, produz vazões mensais por desagregações de vazões anuais pré-geradas por um modelo apropriado. Percebe-se que este método tem produzido bons resultados para os rios intermitentes do Semi-Árido Nordestino [49].

Da mesma forma que no modelo anterior, inicialmente foi construída uma base de dados a partir da média anual de cada ano (de 1931 a 2004) para realizar a previsão da vazão anual para os anos de 2005, 2006, 2007 e 2008, conforme Figura 5.7.



**Figura 5.7** Previsão de vazão anual utilizando redes neurais.

Em seguida foi calculado um fator para cada mês do ano. Esse fator é calculado dividindo a média de cada mês, e.g., média de todas as vazões de janeiro de 1931 a 2004 pela média das médias dos anos (de 1931 a 2004), conforme Equação (5.4). A partir desses dados é feita a previsão mensal dos anos de 2005, 2006, 2007 e 2008, conforme Equação (5.5), e calculado o erro da previsão, conforme a Equação (4.3).

$$FATOR_{MêsFragmentos} = \frac{Média_{Mês}}{Média_{MédiasAnual}} \quad (5.4)$$

$$V_{Mês} = V \times FATOR_{MêsFragmentos} \quad (5.5)$$

Onde:

$FATOR_{MêsFragmentos}$  é o fator para cada mês do ano;

$V_{Mês}$  é a vazão prevista mensal;

$V$  é a vazão anual prevista pela rede neural, conforme Figura 5.7.

## 5.7 Conclusões do Capítulo

Neste capítulo, foram apresentados os modelos de previsão desenvolvidos, os diferentes tipos de configurações, os diferentes horizontes de previsão e as diferentes ferramentas de previsão de vazão da grande área de inteligência artificial: RNA e ANFIS.

# CAPÍTULO 6

## 6 RESULTADOS

---

Este capítulo apresenta os resultados dos modelos de previsão de vazão obtidos durante o desenvolvimento deste trabalho com o objetivo de compará-los e finalmente encontrar aquele mais eficiente na bacia do rio São Francisco no posto de Sobradinho.

Ressalta-se que estes resultados são frutos da metodologia exposta no Capítulo 5 e foram embasados em conceitos mostrados anteriormente.

Dividiu-se o resultado em três partes conforme a metodologia, sendo separados por modelos.

### 6.1 Resultados da Previsão Utilizando RNA: Horizonte Anual

#### 6.1.1 Resultados do Treinamento


Com o objetivo de determinar a melhor configuração entre as três configurações propostas neste trabalho, é realizada a comparação entre estas configurações com o objetivo de estimar o desempenho das mesmas quando estas estiverem em operação. Vale salientar que esta comparação é feita com o conjunto de teste, já que este conjunto jamais fora apresentado para rede durante o treinamento.

Vale ressaltar que 10 experimentos com 10 inicializações cada totalizam 100 redes. As melhores redes de cada configuração são apresentadas na Tabela 6.1, juntamente com o número de neurônios na camada oculta. Nesta tabela se observa que a melhor configuração foi a Configuração 1, cujo MAPE é de 18,99%.

**Tabela 6.1 Comparação entre os resultados das três configurações**

Configuração	Rede	MAPE	Melhor rede
1 (12x7x12)		18,99	96
2 (5x4x5)	Úmido	22,54	52
2 (7x14x7)	Seco	17,66	94
Resultado	Úmido+Seco	19,69	
3 (3x7x1)		24,84	90

Os resultados do treinamento também são apresentados na Figura 6.1, detalhando-se o MAPE mensal para cada configuração.



**Figura 6.1 MAPE das três configurações.**

### 6.1.2 Avaliação das Previsões

Nesta etapa são avaliadas as previsões para cada uma das configurações propostas anteriormente utilizando redes neurais artificiais. Salienta-se que o objetivo é a comparação de cada uma delas, buscando sempre os melhores resultados.

#### a. Simulação da Melhor Rede para Primeira Configuração

O resultado da simulação para os anos de 2005, 2006, 2007 e 2008 com a configuração 1 (12x7x12) forneceu um MAPE de 17,15%, 30,11%, 40,52% e 77,62%, respectivamente, conforme Figura 6.2.






Figura 6.2 Erro da previsão dos anos de 2005, 2006, 2007 e 2008 com a Configuração 1.

Como se pode observar na Figura 6.2, os resultados da previsão são bastante satisfatórios de uma forma geral. Porém, a previsão de fevereiro de 2006, final do ano de 2007 (novembro e dezembro) e o ano 2008 são bem atípicos, pelo fato de serem meses com vazões muito abaixo da média histórica (1931 a 2004) em relação à base de dados utilizada para treinamento das redes neurais, como observado na Figura 4.1.

**b. Simulação da Melhor Rede para Segunda Configuração**

O resultado da simulação para os anos de 2005, 2006, 2007 e 2008 com a configuração 2 (5x4x5 e 7x14x7) forneceu um MAPE de 12,88%, 22,66%, 29,57% e 70,26% respectivamente, conforme Figura 6.3.




Figura 6.3 Erro da previsão dos anos de 2005, 2006, 2007 e 2008 com a Configuração 2.

A previsão de vazão utilizando a Configuração 2 apresenta resultados melhores do que a Configuração 1 para os anos apresentados, conforme Figura 6.3. Salienta-se ainda a anormalidade de fevereiro do ano de 2006, do final do ano de 2007 e do ano de 2008 como comentado no modelo anterior.

**c. Simulação da Melhor Rede para Terceira Configuração**

Para simular os anos de 2005, 2006, 2007 e 2008, o resultado foi obtido a partir da melhor rede para terceira configuração (3x7x1) que forneceu um MAPE de 52,32%, 42,21%, 74,05% e 108,42% respectivamente, conforme Figura 6.4.





Figura 6.4 Erro da previsão do ano de 2005, 2006, 2007 e 2008 com a Configuração 3.

Como apresentado na Figura 6.4, a Configuração 3 é a que apresenta resultados piores se comparado com as outras duas configurações mostradas anteriormente. Ratificando também aqui a atipicidade para fevereiro do ano de 2006, final do ano de 2007 e de todo o ano de 2008.

**d. Erro Calculado com Relação à Média**

Para se ter uma idéia da capacidade de previsão dos modelos desenvolvidos, foi avaliado o erro em cada ano de 2005 a 2008 caso tivesse sido usado como previsão a média histórica de 1931 a 2004. Esta é uma maneira simplificada de realizar a previsão. A Figura 6.5 apresenta o erro calculado em relação à média.



**Figura 6. 5 Erro Calculado com Relação à Média.**

Observou-se que o erro médio mensal da previsão realizada pela Configuração 2 (Figura 6.3) foi 33,84%, sendo portanto menor que o erro usando o valor médio histórico como previsão que foi de 38,45%.

**e. Avaliação da Melhor Configuração Simulada**


Constata-se que dentre as três configurações desenvolvidas neste trabalho utilizando apenas redes neurais, foi verificado que as Configurações 1 e 2 foram as que forneceram melhores resultados, sendo as mesmas bastante semelhantes. Contudo, no conjunto de teste (2005 a 2008) a Configuração 2 é a que fornece melhor resultado, sendo portanto selecionada para a comparação com os outros modelos de previsão no horizonte anual que serão analisados nos itens 6.3 e 6.4.

A Tabela 6.2 mostra um resumo das médias das previsões realizadas com as Configurações 1, 2, 3 e com o erro calculado com relação à média.

**Tabela 6.2 Resumo das Previsões com as Configurações 1, 2 e 3 e o Erro com Relação à Média.**

ANO	MAPE%			
	Horizontes Anual			
	RNA			ERRO R Média
	Conf. 1	Conf. 2	Conf. 3	
2005	17,15	12,88	52,32	15,54
2006	30,11	22,66	42,21	27,93
2007	40,52	29,57	74,05	37,56
2008	77,62	70,26	108,42	72,77
MÉDIA	41,35	33,84	69,25	38,45

Na Figura 6.6, são apresentadas a vazão média mensal para os anos de 1931 a 2004 e a vazão mensal dos anos de 2005 a 2008 previsto pelo modelo da Configuração 2.



**Figura 6.6 Vazão calculada na Configuração 2.**

Comparando-se a vazão mensal dos anos de 2005 a 2008 na Figura 6.6 (saída do modelo) e Figura 4.1 (realizado), constata-se que a Configuração 2 apresenta erros menores nos meses de maio a novembro (secos) mostrando uma melhor eficiência das RNA para prever este período do ano.

## 6.2 Resultados da Previsão Utilizando RNA e ANFIS: Horizonte Mensal

### 6.2.1 Resultados do Treinamento com RNA na Configuração Um Mês à Frente

Com o objetivo de minimizar os erros apresentados pela Configuração 2 com horizonte anual utilizando RNA, é realizada a comparação entre novas configurações, diminuindo-se o horizonte de previsão anual para mensal. Os resultados do treinamento com RNA na configuração um mês à frente, são apresentados na Tabela 6.3. Vale salientar que este resultado é do conjunto de teste, já que este conjunto jamais fora apresentado à rede durante o treinamento.

**Tabela 6.3 MAPE para a Configuração Um Mês à Frente**

	MAPE MÉDIO
JAN	26.21%
FEV	45.60%
MAR	29.68%
ABR	25.22%
MAI	14.35%
JUN	15.01%
JUL	17.53%
AGO	35.72%
SET	25.71%
OUT	21.19%
NOV	37.26%
DEZ	41.84%
MÉDIA	27.94%

A seguir, são apresentadas as previsões para os anos de 2005, 2006, 2007 e 2008 realizadas por este modelo.

### 6.2.2 Resultados da Previsão com RNA na Configuração Um Mês à Frente

O resultado da simulação para os anos de 2005, 2006, 2007 e 2008 com a configuração um mês à frente forneceu um MAPE médio de 17,39%, 37,78%, 18,60% e 18,57% respectivamente, conforme Figura 6.7. Nesta figura, observa-se que os resultados obtidos por este modelo foram satisfatórios. Percebe-se também que, no geral, este tipo de previsão apresenta erros bem menores quando comparados com os modelos anteriores. Ressalta-se ainda que para alguns meses do ano, no qual a previsão com horizonte anual não apresentou um bom desempenho, esse modelo de previsão com horizonte mensal cumpre com o objetivo, podendo ser utilizado para corrigir esses meses.




Figura 6.7 MAPE da Previsão na Configuração Um mês à Frente com RNA.

### 6.2.3 Resultados do Treinamento com RNA na Configuração Dois Meses à Frente

Em busca de minimizar mais os erros até aqui já apresentados, é realizada a comparação entre novas configurações, diminuindo-se a previsão anual para uma previsão mensal, sendo que dessa vez de forma intercalada, ou seja, dois meses à frente. Na Tabela 6.4, são apresentados os resultados do treinamento com RNA na configuração dois meses à frente. Semelhantemente ao caso anterior, esta comparação é feita com o conjunto de teste.

**Tabela 6.4 MAPE para a Configuração Dois Meses à Frente**

	MAPE MÉDIO
JAN	18.14%
FEV	47.70%
MAR	37.76%
ABR	41.98%
MAI	30.28%
JUN	20.89%
JUL	10.31%
AGO	10.51%
SET	18.04%
OUT	26.03%
NOV	38.41%
DEZ	58.51%
MÉDIA	29.88%

Comparando os resultados da Tabela 6.4 (dois meses à frente) com os resultados da Tabela 6.3 (um mês à frente), percebe-se que este tipo de configuração apresenta erros ligeiramente maiores no conjunto de teste.

#### **6.2.4 Resultados da Previsão com RNA na Configuração Dois Meses à Frente**

O resultado da simulação para os anos de 2005, 2006, 2007 e 2008 com a configuração dois meses à frente forneceu um MAPE médio de 24,73%, 36,48%, 26,08% e 25,07% respectivamente, conforme Figura 6.8.

Como era esperado do resultado do treinamento para este tipo de configuração, a previsão da vazão anual apresentou erros ligeiramente maiores que os apresentados na Figura 6.7 (um mês à frente).

Na Figura 6.8, tem-se uma melhor visualização e descrição dos resultados mês a mês para os anos de 2005 a 2008.




Figura 6.8 MAPE da Previsão na Configuração Dois Meses à Frente com RNA.

### 6.2.5 Conclusão dos Resultados com RNA para o Horizonte Mensal

A previsão utilizando-se da rede um mês à frente apresenta melhores resultados. Essa análise já era esperada, pois como se observa, a Tabela 6.3 apresenta o resultado para o treinamento melhor que a Tabela 6.4, confirmando-se nas previsões mostradas nas Figuras 6.7 e 6.8. Tomando como exemplo o mês de dezembro, quando se utiliza a rede dois meses à frente, está-se dando como entrada os meses de agosto, setembro e outubro. Pode-se observar no gráfico que esses meses têm como características valores de vazões baixas, enquanto dezembro já apresenta uma vazão mais elevada. Apesar da previsão com a rede um mês à frente para o mês de dezembro também não apresentar bons resultados, essa previsão é um pouco melhor. A previsão utilizando meses anteriores, apresenta o problema da mudança das estações do ano que influencia bastante; é o caso do mês de dezembro.

### 6.2.6 Resultados do Treinamento com o ANFIS na Configuração Um Mês à Frente

Com o objetivo de melhorar os resultados apresentados até aqui, é desenvolvido o sistema ANFIS aplicando as mesmas estratégias anteriores. Na Tabela 6.5, são apresentados os resultados do treinamento ANFIS na configuração um mês à frente.



**Tabela 6.5 MAPE para a Configuração Um Mês à Frente**

	MAPE MÉDIO
JAN	25.43%
FEV	41.64%
MAR	38.15%
ABR	21.84%
MAI	8.41%
JUN	11.11%
JUL	6.39%
AGO	8.32%
SET	14.26%
OUT	15.12%
NOV	21.60%
DEZ	42.50%
MÉDIA	21.23%

Comparando a Tabela 6.5 e a Tabela 6.3, verifica-se que o sistema ANFIS apresenta erros de treinamento inferiores ao sistema utilizando apenas a RNA. Na etapa seguinte, é feita a previsão para os anos 2005, 2006, 2007 e 2008.

#### **6.2.7 Resultados da Previsão com o ANFIS na Configuração Um Mês à Frente**

O resultado da simulação para os anos de 2005, 2006, 2007 e 2008 com a configuração um mês à frente apresentou um MAPE médio de 12,00%, 24,98%, 21,63% e 27,24% respectivamente, conforme Figura 6.9.

De acordo com a Figura 6.9, o MAPE anual para a configuração um mês à frente utilizando o ANFIS apresenta resultados bem melhores do que os apresentados na previsão anual com as redes neurais artificiais. Além do mais, a previsão do ano de 2008 nessa configuração apresenta erros significativamente menores do que as outras configurações com RNA.




Figura 6.9 MAPE da Previsão na Configuração Um Mês à Frente com o ANFIS.

### 6.2.8 Resultados do Treinamento com o ANFIS na Configuração Dois Meses à Frente

Na Tabela 6.6, é apresentado os resultados do treinamento com o ANFIS na configuração dois meses à frente.

Tabela 6.6 MAPE para a Configuração Dois Meses à Frente

	MAPE MÉDIO
JAN	21.00%
FEV	50.84%
MAR	42.12%
ABR	43.47%
MAI	23.48%
JUN	7.53%
JUL	8.52%
AGO	7.21%
SET	5.78%
OUT	15.05%
NOV	38.69%
DEZ	55.43%
MÉDIA	26.59%

Os erros de treinamento apresentados na Tabela 6.6 estão dentro da média dos erros já apresentados pelas configurações anteriores.

**6.2.9 Resultados da Previsão com o ANFIS na Configuração Dois Meses à Frente**

O resultado da simulação para os anos de 2005, 2006, 2007 e 2008 com a configuração dois meses à frente resultou em um MAPE médio de 27,63%, 47,43%, 44,21% e 31,16% respectivamente, conforme Figura 6.10.

Como era esperado do resultado do treinamento para este tipo de configuração, a previsão de vazão anual apresentou erros ligeiramente maiores que os apresentados pela configuração um mês à frente com ANFIS (Figura 6.9). Porém, comparando este modelo com os resultados anteriores (previsão anual), percebe-se que, no geral, este tipo de previsão apresentou erros bem menores; entretanto, para o ano de 2006, apresentou erros maiores.




Figura 6.10 MAPE da Previsão na Configuração Dois Meses à Frente com o ANFIS.

**6.2.10 Conclusão dos Resultados com o ANFIS**

A previsão utilizando-se da rede um mês à frente apresenta melhores resultados. Essa análise já era esperada, pois como se pode observar, a Tabela 6.5 apresenta o resultado para o treinamento melhor que a Tabela 6.6, confirmando-se nas previsões mostradas nas Figuras 6.9 e 6.10.

### 6.3 Resultados da Previsão Utilizando o Sistema HÍBRIDO RNA-ANFIS

Outras tentativas de modelos de previsão foram baseadas em modelos híbridos que realiza a previsão da média anual utilizando RNA e posteriormente desagrega esta previsão em mensal. Neste modelo, o horizonte é de um ano à frente, tomando como entrada a vazão média de quatro anos anteriores. Primeiramente, a base de dados foi construída calculando a média anual para cada ano de 1931 até 2004, após essa etapa foi realizado o treinamento das RNAs que apresentou um MAPE igual a 12,85%. Posteriormente ao treinamento, foi realizada a previsão da vazão média anual dos anos de 2005, 2006, 2007 e 2008 que apresentou resultados satisfatórios mostrados na Tabela 6.7.

**Tabela 6.7 Previsão da média anual utilizando RNA**

Ano	Vazão calculada (m <sup>3</sup> /s)	Vazão desejada (m <sup>3</sup> /s)	Erro (%)
2005	2762,962	2649	4,12%
2006	2533,131	2445	3,48%
2007	2344,354	2642	12,70%
2008	2302,098	1572	31,71%

O erro apresentado na Tabela 6.7 é calculado conforme Equação (4.3).

Com a previsão média anual realizada, é feita a previsão utilizando-se o ANFIS para calcular o fator do mês, conforme Figura 5. 6. Esses resultados da Tabela 6.7, foram utilizados na previsão dos anos de 2005, 2006, 2007 e 2008.

A Tabela 6.8, apresenta os erros do sistema Híbrido RNA-ANFIS. Percebe-se que este modelo apresenta erros maiores que algumas das configurações dos modelos de previsão com horizonte anual, pois o erro médio da previsão realizado pela Configuração 2 foi 33,84%, sendo menor que o valor apresentado pelo sistema híbrido RNA-ANFIS que foi de 34,79%. Salienta-se que em alguns pontos específicos, como o mês de dezembro, por exemplo, essa configuração apresenta resultados melhores que a previsão anual com as RNAs. Para o ano de 2008, o sistema híbrido apresentou um erro inferior aos encontrados pelas configurações de horizonte anual (Tabela 6.2).

A Tabela 6.8 apresenta o erro da previsão pelo sistema híbrido RNA-ANFIS, conforme esquema mostrado na Figura 5.4. Este modelo híbrido RNA-ANFIS foi

desenvolvido como forma de encontrar erros menores. Porém, os erros apresentados na Figura 6.3 correspondentes a Configuração 2 ainda são menores, salvo o ano de 2008.

**Tabela 6.8 Erro pelo Sistema Híbrido RNA-ANFIS**

Mês\Ano	2005	2006	2007	2008
JAN	19,12%	6,44%	26,54%	135,22%
FEV	2,44%	126,93%	38,99%	37,43%
MAR	2,02%	17,48%	44,70%	21,33%
ABR	2,12%	20,86%	15,15%	5,09%
MAI	27,96%	13,41%	18,54%	47,99%
JUN	10,04%	14,37%	3,62%	9,73%
JUL	4,11%	6,70%	24,68%	10,83%
AGO	12,89%	8,71%	4,48%	16,45%
SET	34,29%	28,11%	11,39%	49,73%
OUT	66,86%	8,37%	38,29%	73,85%
NOV	76,53%	28,04%	100,95%	121,97%
DEZ	17,45%	17,23%	87,64%	152,76%
<b>MÉDIA</b>	<b>22,99%</b>	<b>24,72%</b>	<b>34,58%</b>	<b>56,87%</b>

#### 6.4 Sistema Híbrido RNA-Fragmentos

Para realizar o modelo híbrido RNA-Fragmentos, foi feita a previsão da vazão anual nos anos de 2005, 2006, 2007 e 2008, utilizando-se a mesma rede do modelo híbrido anterior, cujo MAPE foi igual a 12,85%. Em seguida, foi aplicado o método dos fragmentos descrito no Capítulo 5.

A Tabela 6.9 apresenta os erros das previsões calculados pelo método dos fragmentos.

**Tabela 6.9 Erro pelo Sistema Híbrido RNA-Fragmentos**

Mês\Ano	2005	2006	2007	2008
JAN	11,34%	0,11%	30,10%	120,80%
FEV	3,59%	131,35%	36,14%	41,23%
MAR	4,62%	27,44%	37,19%	34,27%
ABR	0,85%	19,55%	25,83%	10,79%
MAI	7,80%	0,00%	15,94%	38,31%
JUN	5,71%	14,92%	11,13%	20,85%
JUL	17,21%	13,49%	3,90%	20,58%
AGO	15,81%	8,30%	0,13%	21,00%
SET	16,09%	8,46%	4,77%	24,08%
OUT	44,63%	5,91%	19,85%	41,13%
NOV	57,33%	34,71%	82,20%	87,94%
DEZ	28,83%	27,38%	64,80%	111,16%
<b>MÉDIA</b>	<b>17,82%</b>	<b>24,30%</b>	<b>27,66%</b>	<b>47,68%</b>

De acordo com a Tabela 6.9, observa-se que os erros apresentados por este modelo foram bastante satisfatórios quando comparado aos outros modelos com horizonte anual (Tabela 6.2 e 6.8). Ressalta-se, mais uma vez, que em alguns meses específicos, outros modelos apresentaram resultados superiores.

## 6.5 Análise Final dos Resultados

Neste tópico, pretendem-se analisar todos os resultados da previsão dos anos de 2005, 2006, 2007 e 2008 com o objetivo de comparar os modelos desenvolvidos neste trabalho.

Os resultados estão divididos em quatro grandes grupos: modelos de previsões com horizontes de um ano utilizando RNA; modelo Híbrido RNA-ANFIS; o modelo Híbrido utilizando RNA-Fragmentos; e por fim, modelos de previsões mensal utilizando-se RNA e ANFIS. Para facilitar o entendimento das tabelas que serão apresentadas, os modelos de previsão desenvolvidos são apresentados através de abreviações:

RNA – Representa os Modelos de Redes Neurais Artificiais;

ANFIS – Representa o Sistema Fuzzy de Inferência Adaptativo com previsão mensal;

RNA-ANFIS – Modelo híbrido utilizando RNA e o ANFIS;

RNA-Fragmentos – Modelo híbrido utilizando RNA e o método dos fragmentos;

## CAPÍTULO 6 – RESULTADOS

Conf. 2 – Configuração 2 com horizonte de previsão anual;

1 Mês e 2 Meses – Previsão com um mês à frente e dois meses à frente, respectivamente.

Inicia-se a comparação com o ano 2005, conforme Tabela 6.10, onde são mostrados de forma resumida os resultados dos modelos de previsão desenvolvidos.

Analisando a Tabela 6.10, percebe-se que o melhor desempenho para a previsão com horizonte anual foi com a Configuração 2, apresentando um erro médio de 12,88%. A previsão com horizonte mensal, cujo objetivo é corrigir a previsão feita com o horizonte anual, apresentou um erro de 12,00% pelo modelo “ANFIS Um Mês à Frente”. Destaca-se que a Configuração 2 apresenta resultados melhores que todos os outros modelos para uma maior quantidade de meses no ano de 2005.

**Tabela 6.10 Resultados de Teste dos Modelos de Previsões Desenvolvidos para 2005**

<b>Resultados de Teste dos Modelos de Previsões desenvolvidos para 2005</b>							
<b>MAPE (%)</b>							
	<b>Horizontes Anual</b>			<b>Horizontes Mensal</b>			
	RNA	RNA-	RNA-	RNA		ANFIS	
	Conf. 2	ANFIS	Fragmentos	1 Mês	2 Meses	1 Mês	2 Meses
JAN	9,75	19,12	11,34	47,22	48,72	16,57	27,89
FEV	10,28	2,44	3,59	1,82	49,52	14,41	38,80
MAR	29,03	2,02	4,62	2,92	34,14	10,51	14,17
ABR	17,05	2,12	0,85	21,53	21,60	2,63	2,93
MAI	3,13	27,96	7,80	25,43	5,49	3,58	15,65
JUN	2,64	10,04	5,71	7,48	7,90	3,97	30,50
JUL	3,34	4,11	17,21	5,67	9,25	11,08	39,78
AGO	4,96	12,89	15,81	14,32	14,78	2,78	30,20
SET	0,66	34,29	16,09	8,32	10,32	9,90	29,90
OUT	26,11	66,86	44,63	10,67	26,11	23,22	41,71
NOV	40,48	76,53	57,33	1,79	5,91	1,99	12,10
DEZ	7,18	17,45	28,83	61,54	62,96	43,42	46,75
MÉDIA	12,88	22,99	17,82	17,39	24,73	12,00	27,53

A Tabela 6.11, mostra resumidamente os resultados dos modelos de previsão de vazão para o ano de 2006. De acordo com esta tabela, o melhor resultado para a previsão com horizonte anual para o ano de 2006 foi o modelo da Configuração 2, com um erro de 22,66%. Por outro lado, a previsão com horizonte mensal utilizando o modelo “ANFIS Um Mês à Frente” apresenta resultado bem próximo com um erro de 24,98%. Novamente a Configuração 2, apresenta melhores resultados.

Tabela 6. 11 Resultados de Teste dos Modelos de Previsões Desenvolvidos para 2006

Resultados de Teste dos Modelos de Previsões desenvolvidos para 2006							
MAPE (%)							
	Horizontes Anual			Horizontes Mensal			
	RNA	RNA-	RNA-	RNA		ANFIS	
	Conf. 2	ANFIS	Fragmentos	1 Mês	2 Meses	1 Mês	2 Meses
JAN	1,34	6,44	0,11	15,77	46,83	35,65	29,44
FEV	133,73	126,93	131,35	147,38	65,16	111,06	233,85
MAR	7,35	17,48	27,44	51,58	22,55	26,27	32,85
ABR	19,91	20,86	19,55	55,78	60,12	27,80	52,79
MAI	0,28	13,41	0,00	52,15	15,13	1,33	11,80
JUN	17,75	14,37	14,92	5,47	58,10	20,77	42,53
JUL	12,70	6,70	13,49	0,97	26,15	6,86	39,95
AGO	8,92	8,71	8,30	17,50	14,88	3,76	8,88
SET	7,07	28,11	8,46	7,91	10,73	7,39	23,73
OUT	8,58	8,37	5,91	22,13	12,89	14,49	7,01
NOV	35,25	28,04	34,71	48,37	52,92	35,45	49,17
DEZ	19,07	17,23	27,38	28,36	52,27	8,89	37,12
MÉDIA	22,66	24,72	24,30	37,78	36,48	24,98	47,43

Na Tabela 6.12, são mostrados resumidamente os resultados dos modelos de previsão de vazão para o ano de 2007. Nela, observa-se que o melhor desempenho entre as previsões com horizonte anual, de uma forma geral, foi o apresentado pelo modelo “Híbrido RNA-Fragmentos”, apresentando um erro de 27,66%. Já a Configuração 2 apresentou um erro muito próximo, no valor de 29,57%, e para a maior parte dos meses desse ano ela revela melhores resultados (janeiro, fevereiro, março, abril, maio, junho, setembro, outubro e novembro). Para previsão com horizonte mensal, o modelo “RNA Um Mês à Frente” com erro de 18,60% foi o que apresentou melhor desempenho. Entretanto, o modelo “ANFIS Um Mês à Frente” apresenta resultado bem próximo com um erro de 21,63%. De forma geral, os modelos de previsão com um mês à frente têm apresentado erros menores se comparado com os modelos de previsão com dois meses à frente; comportamento já esperado devido à distância do horizonte de previsão.



**Tabela 6. 12 Resultados de Teste dos Modelos de Previsões Desenvolvidos para 2007**  
**Resultados de Teste dos Modelos de Previsões desenvolvidos para 2007**

MAPE (%)							
	Horizontes Anual			Horizontes Mensal			
	RNA	RNA-	RNA-	RNA		ANFIS	
	Conf. 2	ANFIS	Fragmentos	1 Mês	2 Meses	1 Mês	2 Meses
JAN	18,79	26,54	30,10	23,17	47,81	4,84	29,02
FEV	36,04	38,99	36,14	23,06	48,58	17,69	23,35
MAR	32,98	44,70	37,19	27,17	42,12	3,24	8,25
ABR	2,98	15,15	25,83	35,18	29,07	89,65	89,89
MAI	6,40	18,54	15,94	17,11	66,70	2,80	117,44
JUN	9,33	3,62	11,13	12,39	2,69	23,40	65,36
JUL	5,64	24,68	3,90	7,41	5,78	2,23	37,54
AGO	8,52	4,48	0,13	10,13	0,78	5,10	9,35
SET	1,27	11,39	4,77	12,90	3,04	1,81	13,09
OUT	19,43	38,29	19,85	8,10	19,40	16,45	27,72
NOV	59,75	100,95	82,20	38,87	44,68	46,88	60,20
DEZ	153,69	87,64	64,80	7,68	2,33	45,46	49,32
MÉDIA	29,57	34,58	27,66	18,60	26,08	21,63	44,21

Na Tabela 6.13, são mostrados resumidamente os resultados dos modelos de previsão de vazão para o ano de 2008. Nesta tabela, observa-se que o melhor desempenho apresentado pela previsão com horizonte anual foi com o modelo “Híbrido RNA-Fragmentos”, onde o erro encontrado foi de 47,68%. De uma forma geral, as previsões com horizonte anual apresentaram erros elevados para o ano de 2008, ano bem atípico, como já foi comentado anteriormente, devido às vazões bem abaixo da média (Figura 4.1). Porém, a previsão com horizonte mensal pelo modelo “RNA Um Mês à Frente” apresentou erro de 18,57%.

Tabela 6. 13 Resultados de Teste dos Modelos de Previsões Desenvolvidos para 2008

Resultados de Teste dos Modelos de Previsões desenvolvidos para 2008							
MAPE (%)							
	Horizontes Anual			Horizontes Mensal			
	RNA	RNA-	RNA-	RNA		ANFIS	
	Conf. 2	ANFIS	Fragmentos	1 Mês	2 Meses	1 Mês	2 Meses
JAN	156,16	135,22	120,80	25,17	13,49	92,66	63,99
FEV	61,55	37,43	41,23	33,93	18,30	13,30	2,36
MAR	15,20	21,33	34,27	0,65	31,19	12,89	24,98
ABR	15,62	5,09	10,79	4,69	25,36	9,78	8,55
MAI	56,23	47,99	38,31	21,59	34,01	13,06	11,81
JUN	40,94	9,73	20,85	6,78	9,56	12,05	38,95
JUL	34,66	10,83	20,58	11,75	21,85	11,05	21,40
AGO	37,31	16,45	21,00	30,23	18,73	9,20	28,43
SET	39,01	49,73	24,08	14,12	32,02	19,91	35,28
OUT	57,31	73,85	41,13	24,17	37,57	23,73	38,66
NOV	121,81	121,97	87,94	35,56	35,69	22,83	24,15
DEZ	207,35	152,76	111,16	14,26	23,11	86,42	75,38
MÉDIA	70,26	56,87	47,68	18,57	25,07	27,24	31,16

## 6.6 Comentários dos Resultados Finais

A Tabela 6.14 mostra os erros médios para o período de 2005 a 2008 dos modelos de previsões de vazão desenvolvidos neste trabalho.

Tabela 6. 14 Resultados de Teste dos Modelos de Previsões de Vazão

ANO	MAPE(%)						
	Horizontes Anual			Horizontes Mensal			
	RNA	RNA-	RNA-	RNA		ANFIS	
	Conf. 2	ANFIS	Fragmentos	1 Mês	2 Meses	1 Mês	2 Meses
2005	12,88	22,99	17,82	17,39	24,73	12,00	27,53
2006	22,66	24,72	24,30	37,78	36,48	24,98	47,43
2007	29,57	34,58	27,66	18,60	26,08	21,63	44,21
2008	70,26	56,87	47,68	18,57	25,07	27,24	31,16
MÉDIA	33,84	34,79	29,37	23,09	28,09	21,46	37,58

No que diz respeito às previsões de vazão, os resultados comprovam a eficácia dos modelos de inteligência artificial.

Constatou-se que na previsão anual quando o valor ocorrido fica muito distante da média, resulta-se em erros bastante elevados; Segundo Meuser [55], a previsão para o ano de 2001 (período do racionamento) o sistema Prevaz, modelo estocástico com base mensal, apresentou erro de 71% e a sua rede proposta apresentou erro de 55%.

Por outro lado, neste trabalho a previsão mensal para o posto de Sobradinho, utilizando-se dos modelos de inteligência artificial com 3 meses anteriores resultou-se em erros com RNA (2005-2008) de 23,09% e com o sistema ANFIS um erro de 21,46%, semelhantemente ao mostrado por Ballini [11] um erro de 21,1% para o mesmo posto de Sobradinho porém para períodos diferentes (período de 1986 a 1990). Porém, neste trabalho apresenta o erro mês a mês constatando-se as dificuldades pontuais ao longo dos meses do ano.

Luna et al [27] realizou experimento de previsão com RNA para a usina de Furnas. Devido à sazonalidade no período de 12 meses, usou 12 modelos diferentes, um para cada mês do ano, onde o número de entradas para cada mês variou de 1 a 5. Foram mostrados erros globais para previsões com um passo à frente e com doze passos à frente. O erro relativo médio percentual foi de 23,50% com um passo à frente e 37,30% com doze passos à frente. Esses valores são compatíveis com os apresentados neste trabalho.

A previsão mensal melhorou os resultados de previsão anual que era objetivo desse trabalho.

### **6.7 Conclusões do Capítulo**

Neste capítulo, foram apresentados os resultados das diversas simulações realizadas com o objetivo de comparar as três configurações desenvolvidas. A Configuração 2 se destacou pelos melhores resultados apresentados. Também foram realizadas simulações com horizonte mensal, utilizando-se de redes neurais artificiais e ANFIS, tendo como entrada três meses anteriores e uma única saída, podendo ser um mês à frente ou dois meses à frente. Os modelos com “Um Mês à Frente” se mostram melhores. Em seguida, foram comparados os resultados entre os diferentes modelos de previsão com horizonte anual com configurações baseadas em RNA, o sistema híbrido RNA-ANFIS e RNA-Fragmentos. Este último se destacou apresentando um erro de 29,37%.

As previsões de vazões afluentes médias mensais apresentaram resultados significativos para o posto hidrológico de Sobradinho do rio São Francisco, e nota-se que os melhores resultados de previsão de vazões estão relacionados aos períodos de baixa estação chuvosa, ou seja, períodos de menores vazões.

# CAPÍTULO 7

## 7 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

### 7.1 Conclusões

O principal objetivo deste trabalho foi desenvolver modelos de previsão aplicando técnicas de inteligência artificial a fim de encontrar um modelo mais eficiente e robusto de previsão de vazão na bacia do rio São Francisco.

A análise das séries históricas de vazão é o primeiro passo de grande importância para um modelo de previsão de vazão. É a partir dela que se chega a uma definição dos modelos a serem empregados. A partir dessa análise, foram desenvolvidos vários modelos de previsões com técnicas e horizontes diferentes, a fim de avaliar e desenvolver ferramentas mais poderosas.

É importante frisar que a previsão de vazão aqui explorada tem a finalidade de subsidiar o planejamento da operação dos sistemas hidroelétrico, uma vez que essa informação é de suma importância para a operação do Sistema Elétrico.

Com relação aos modelos desenvolvidos, pode-se concluir através dos resultados apresentados no decorrer do trabalho que todos eles têm eficácia comprovada em previsão de vazão, em síntese, pode-se perceber que:

- As redes neurais comprovaram sua capacidade de previsão, mostrando bom desempenho nas previsões;
- O ANFIS, apesar de mostrar bons resultados, pode ser melhorado, adicionando-se à sua entrada outros fatores;
- Por fim, o sistema Híbrido mostrou capacidade de extração de conhecimento a partir dos dados fornecidos, conseguindo melhorar bastante as previsões feitas pelas redes neurais, com o auxílio do ANFIS.

As previsões de vazões afluentes médias mensais apresentaram resultados significativos para o posto hidrológico da Usina Hidrelétrica de Sobradinho, e nota-se

que os melhores resultados da previsão de vazão estão relacionados aos períodos de baixa estação chuvosa.

De forma geral, foram obtidos resultados satisfatórios com erros relativamente pequenos. Assim, fica constatada a eficiência dos modelos desenvolvidos baseados em ferramentas de inteligência artificial, sendo de grande utilidade para o planejamento e operação do sistema hidroelétrico brasileiro, mitigando assim possíveis déficits de energia em períodos de estiagem.

### **7.2 Trabalhos Futuros**

Os sistemas de previsão apresentados neste trabalho têm o objetivo de colaborar com o ONS evitando que surpresas desagradáveis venham a acontecer por falta de uma previsão confiável. Apesar dos bons resultados apresentados pelos modelos, a perspectiva que eles sejam estendidos/ampliados continua. Desta forma, propõem-se os seguintes trabalhos futuros:

- Quanto aos modelos utilizados nesse trabalho, sabe-se que eles podem ser melhorados em busca de erros menores;
- É possível ainda fazer a previsão com outros horizontes de previsão com o intuito de obter erros ainda menores;
- Estudo/pesquisa de novas configurações com RNAs e outras técnicas de ajustes;
- Estudo de outros tipos de rede e algoritmos de treinamento aplicado em previsão;
- Avaliar capacidade de previsão dos modelos desenvolvidos em reservatórios de outras bacias hidrográficas;
- Avaliação do impacto da previsão junto com ONS.

# APÊNDICE

- **BASE DE DADOS**

ANO	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1931	4676	4805	6630	7333	4467	2397	1870	1619	1448	1376	1935	2207
1932	4036	4531	3214	1976	1425	1292	1176	995	905	982	2107	3594
1933	5014	5516	3429	2692	1905	1357	1250	1072	915	1194	1799	3336
1934	6110	4222	2298	1615	1785	1167	997	897	799	877	905	1605
1935	4519	5442	5408	4716	3740	2010	1557	1237	1055	1079	1178	2585
1936	2696	2664	4174	2764	2109	1300	1092	934	861	887	1597	2724
1937	4643	5598	4242	2888	2237	1454	1231	1036	900	920	2395	4703
1938	6307	4237	3850	2372	1613	1419	1157	1033	956	914	1538	2957
1939	5096	5897	4891	2156	1627	1258	1107	1035	936	1285	1020	1707
1940	3103	4739	5500	4297	1914	1416	1187	1055	861	926	2138	3793
1941	5004	4423	4132	4791	2721	1658	1423	1260	1022	1137	1670	2315
1942	4624	4420	5277	3360	2274	1547	1300	1117	1024	1324	2274	5170
1943	6185	9469	7966	5097	2881	2113	1774	1522	1290	1394	2205	5150
1944	6328	4864	4749	3729	2518	1738	1468	1278	1102	962	1651	3848
1945	5632	6944	7973	7150	8764	3939	2591	2078	1703	1978	3267	5593
1946	7284	10080	4595	5591	3581	2453	2009	1724	1497	1518	2171	3769
1947	3749	5142	5706	7283	4318	2353	1942	1626	1613	1436	3112	4248
1948	6343	4520	5422	4016	2210	1846	1581	1359	1207	1323	1504	5155
1949	7850	9219	13034	7136	3499	2589	2155	1820	1547	1464	2929	2944
1950	4451	4716	3461	3784	2620	1742	1515	1305	1076	1266	2138	4127
1951	4179	4156	4439	4855	2522	1846	1487	1276	1103	1027	942	1641
1952	3310	4717	5792	6938	3257	1971	1605	1312	1192	1136	1782	3393
1953	3563	1792	2684	3741	1934	1308	1108	972	858	1161	1411	3189
1954	4405	2779	2780	2429	1444	1201	979	852	715	645	880	3544
1955	2310	4051	2165	2616	1437	1072	900	788	678	661	1977	3305
1956	5370	2215	4585	2543	1773	1640	1325	1067	903	841	1468	3687
1957	5948	7119	6903	7965	5817	2769	2033	1644	1373	1522	1416	4341
1958	3623	5212	3385	3104	2421	1697	1413	1421	1128	1518	1838	1798
1959	3601	3660	3495	2708	1364	1139	1015	906	820	847	1600	2711
1960	3291	5729	6124	6060	2468	1764	1388	1151	979	902	1076	4172
1961	5755	7765	6407	3479	2328	1737	1389	1188	993	883	1098	1680
1962	3616	5406	4433	3161	2003	1476	1260	993	844	1173	1967	3057
1963	5658	6556	3462	1684	1401	1119	991	898	801	712	946	1106
1964	3543	7732	5284	2569	1566	1166	1019	924	734	878	2855	4250
1965	5188	5056	5560	5836	2872	1837	1510	1269	1053	1430	2663	4170
1966	4402	6188	6708	4287	2625	1908	1513	1330	1081	1200	1911	2532
1967	5105	4685	4016	3596	2453	1537	1296	1135	968	887	1703	3911
1968	5561	4444	6495	5090	2309	1641	1430	1307	1238	1298	1760	4453
1969	2837	3950	3851	2322	1656	1233	1107	987	841	905	2631	4879
1970	5959	6441	4717	2574	1899	1428	1273	1098	1060	1561	2982	2702

1971	1650	1436	1755	1407	1122	913	827	722	743	1182	2377	6411
1972	4959	2886	3381	2972	1785	1250	1143	1021	863	1418	1969	3790
1973	4644	3784	3607	4402	2054	1443	1253	1001	836	1341	3233	4492
1974	4561	3046	3222	5184	2872	1718	1397	1233	1046	1116	1868	2410
1975	4301	4111	2392	2446	1924	1233	1133	961	780	1033	2358	2727
1976	2007	1927	2107	1765	1037	1015	796	772	985	1442	2187	4818
1977	4701	5751	2163	2131	1797	1294	1091	955	912	1149	1477	2873
1978	5872	5145	6259	4019	2490	2221	1526	1458	1187	1614	2055	4045
1979	5929	9409	15676	7174	3610	2745	2267	1949	2034	1992	3305	3333
1980	6347	9918	10490	4684	3388	2359	2220	1875	1669	1808	2380	4856
1981	5974	4916	3817	5781	2728	2026	1637	1509	1342	1960	4448	6170
1982	6811	7990	7135	6885	3678	2536	2131	1765	1586	1618	1481	1701
1983	5072	7258	9245	6550	4189	2510	2070	1748	1441	2050	3720	5827
1984	6328	2999	2686	3469	1773	1328	1158	1059	1270	1314	1691	3888
1985	5566	7789	6701	5015	2432	1773	1423	1259	1235	1636	2148	3265
1986	6332	7556	4732	2140	1753	1283	1230	1230	1128	1056	1117	1872
1987	3150	2606	2604	2759	1701	1159	1071	840	800	920	1325	3709
1988	5163	3829	4116	2843	1852	1173	1033	979	767	989	1566	2619
1989	3601	2715	3018	1672	1142	1030	1013	858	893	996	1883	5073
1990	9467	3681	3101	1975	1359	1060	1130	987	968	984	1355	1617
1991	3742	5138	4639	5139	2340	1470	1222	1125	1031	1323	2095	3057
1992	4651	9244	12915	3754	2614	1765	1444	1283	1384	1860	4269	4814
1993	5840	4644	3943	2590	1801	1439	1245	1105	981	1214	1180	2046
1994	5366	4689	4993	4521	2154	1470	1378	1081	1022	782	989	3062
1995	2872	3220	2837	2587	1731	1188	1087	851	672	895	1651	3244
1996	4478	2180	2234	1593	1184	934	785	668	699	730	1702	3317
1997	6202	4622	4461	4053	2438	1747	1294	1197	1047	1052	1343	3446
1998	3343	3360	3096	1536	1122	950	838	751	620	704	1994	3241
1999	3013	1827	4212	2245	1201	874	787	663	695	570	1601	2990
2000	4169	5271	4455	3316	1730	1188	930	923	918	703	1823	3655
2001	3158	1695	1719	1096	845	824	645	632	659	714	1201	2187
2002	4440	4761	3516	2234	1074	883	851	644	506	665	936	1871
2003	4118	4387	2737	2604	1374	983	890	747	680	506	843	1611
2004	3233	5002	6786	5329	2737	1493	1304	1010	899	889	1063	1841

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] MARINHO, M. H. N., AQUINO, R. R. B., “Redes Neurais Multicamadas para Previsão de Vazões Afluentes Vários Passos à Frente”. IX Simpósio de Recursos Hídricos do Nordeste”, Salvador-BA, 2008.
- [2] MAIER, H. and DANDY, G., “Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications,” *Environmental Modelling & Software*, vol. 15, pp. 101–124, 2000.
- [3] BOX, G. E. P., JENKINS, G. M. REINSEL, G. C., *Time Series Analysis: “Forecasting and Control”*, Holden Day, 3th Edição, 1994.
- [4] WEIGEND, A. S. and GERSHENFELD., N. A. *Time Series Prediction: “Forecasting the Future and Understanding the Past”*, Reading, Massachusetts, Addison-Wesley, 1992.
- [5] CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA (CEPEL)., “Modelo de Previsão de Vazões Semanais Aplicado ao Sistema Hidroelétrico Brasileiro-PREVIVAZ”, Relatório Técnico 125/97, 1997.
- [6] BALLINI, R. ; GUILHON, L. G. F. ; SOARES, S. ; GOMIDE, F., “Previsão de Vazões Semanais Utilizando Redes Neurais Nebulosas”. In: VII Congresso Brasileiro de Redes Neurais, 2005, Natal. p. 1-6
- [7] RUMELHART, D., HINTON, G. E. WILLIAMS, R., “Learning representations by back-propagating errors”. *Nature (London)*, vol. 323, pp. 533.536, 1986.
- [8] WEIGEND, A. S., RUMELHART, D. E. HUBERMAN, B. A., “Generalization by weight-elimination application to forecasting”,. in *Advances in Neural Information Processing Systems 3*, 1991, pp. 875.882.
- [9] BAKIRTZIS, A. G., THEOCHARIS, J. B., KIARTZIS, S. J. SATSIOS, K. J., Short term load forecasting using fuzzy neural networks, *IEEE Transactions on Power Systems* 10(3): 1518-1524, 1995.
- [10]MARINHO, M. H. N. (2005) *Previsão de Vazões Afluentes Vários Passos à Frente Via Agregação de Vazões para o Planejamento Energético da Operação de Sistemas Hidrotérmicos de Potência*, FEEC-UNICAMP, Brasil: Tese de Doutorado, Campinas, 2005.
- [11]BALLINI, R. ; ANDRADE, M. G. ; SOARES, S. . *Previsão de Vazões Médias Mensais Usando Redes Neurais Nebulosas*. In: *Revista Controle & Automação/Vol.14 no.3/Julho, Agosto e Setembro 2003*.
- [12]AQUINO, R. R. B., CARVALHO Jr., M. A. e SOUZA, B. A. (1999). *Redes Neurais Artificiais : Uma Aplicação ao Planejamento da Operação de Sistemas Hidrotérmicos de Geração*, *Proceedings of the IV Brazilian Conference on*



- Neural Networks - IV Congresso Brasileiro de Redes Neurais pp. 164-169, July 20-22, 1999 - ITA, São José dos Campos - SP – Brazil.
- [13] ATIYA, A. F., EL-SHOURA, S. M., SHAHEEN, S. I. EL-SHERIF, M. S. (1999). A comparison between neural-network forecasting techniques - case study: River flow forecasting, *IEEE Transactions on Neural Networks* 10(2): 402-409.
- [14] ZEALAND, C. M., BURN, D. H. SIMONOVIC, S. P. (1999). Short term streamflow forecasting using artificial neural networks, *Journal of Hydrology* 214: 32-48.
- [15] AQIL, M., KITA, I., YANO, A., NISHIYAMA, S., “Neural Networks for Real Time Catchment Flow Modeling and Prediction”. *Water Resour Manage* (2007) 21:1781–1796.
- [16] LACHTERMACHER, G. and FULLER, J. D. (1995) . Backpropagation in time-series forecasting, *Journal of Forecasting* 14(4): 381-393.
- [17] LIMA, C. H. R., LALL, U., “Análise e Previsões de Afluências ao Reservatório Sobradinho Utilizando um Modelo Periodico Autoregressivo Exógeno (Parx)”. XVII Simpósio Brasileiro De Recursos Hídricos, 2007, São Paulo”.
- [18] HAYKIN, S. “Redes neurais: princípios e prática” . Porto Alegre – RS: 2 edição BOOKMAN Editora S.A, 2001.
- [19] MCCULLOCH, W. S. e Pitts, W. “A logical calculus of the ideas immanent in nervous activity”. *Bulletin of Mathematical Biophysics*, vol. 5, pp.115-133, 1943.
- [20] ROSENBLATT, F., “The Perceptron: A probabilistic model for information storage and organization in the brain”. *Psychological Review*, v65, No. 6, pp. 386-408, 1958.
- [21] WINDROW, Bernard and HOFF JR., Marcian.Edward. “Adaptive switching circuits”. Institute of radio engineers, Western electronic show and convention, 1960.
- [22] KOHONEN, T., “Self-organized formation of topologically correct feature maps”, *Biological Cybernetics*, 43, 1982.
- [23] RUMELHART, D. E., HINTON, G. E., and WILLIAMS, R. J., “Learning representations by back-propagating errors”. *Nature*, 323:533-536, 1986.
- [24] BRAGA, A., CARVALHO, A., LUDERMIR, T., “Redes Neurais Artificiais: Teoria e Aplicações”. Rio de Janeiro - RJ: LTC, 2000.
- [25] MENDEL, J.M. and MCLAREN, R. W., “Adaptive, Learning, and Patten , Learning, and Patten Recognition; Theory and application, chapter

- reinforcement-learning control and pattern recognition systems”, pages 287-318. New York: Academic press, 70.
- [26]RIEDMILLER, M., BRAUN, H., “A direct adaptive method for faster backpropagation learning: The RPROP algorithm”, IEEE International Conference on Neural Networks, vol.1, 1993, pp.586-591.
- [27]LUNA, I., SOARES, S., MAGALHÃES, M. H., BALLINI, R., “Previsão de Vazão utilizando Redes Neurais Dinâmicas do Tipo FIR”. In: VII Congresso Brasileiro de Redes Neurais, 2005, Natal. p. 1-6
- [28]YEN, J., “Logic Fuzzy: a Modern Perspective”. IEEE Transactions on knowledge and Data Engineering, Vol. 11, nº 1, pp. 153-165, 1999.
- [29]ORTEGA, N. R. S., “Aplicação da Teoria de Conjuntos Fuzzy a Problemas da Biomedicina”. Tese de Doutorado, USP, 2001.
- [30]PASSINO, K. M., YURKOVICH, S., “Fuzzy Control”. Addison- Wesley, 1998.
- [31]EDISBURY, B., “Fuzzy Logic Predicts Aircraft Flight Path”. Npower Ltd, 1999.
- [32]ALTROCK, C., “Fuzzy Logic in Automotive Engineering”, Circuit Cellar Ink: Issue 88, 1997.
- [33]SHAW, I. S., SIMÕES, M. G., “Controle e Modelagem Fuzzy”. Editora Edgard Blucher, 1999.
- [34]ALTROCK, C., “A Fuzzy Logic Thermostat”, Circuit Cellar Ink: Issue 75, 1996.
- [35]ZADEH, L., “Fuzzy Sets, Information and Control”, IEEE Transactions on Systems, Man and Cybernetics 8: 338–353, 1965.
- [36]JANG, J. S. R., “ANFIS: Adaptive-Network-Based Fuzzy Inference System”. IEEE Transactions on Systems Man and cybernetics vol. 23, 1993.
- [37]JANG, J. S. R., SUN, C. T. “Neuro-Fuzzy Modeling and Control”. Proceedings of the IEEE, vol. 83, 1995.
- [38]JANG, J. S. R., “ANFIS: Adaptive-Network-Based Fuzzy Inference System”, IEEE Transactions on Systems, Man and Cybernetics 23(3): 665–685, 1993.
- [39]TAKAGI, T., SUGENO, M., “Fuzzy Identification of Systems and Its Applications to Modeling and Control”, IEEE Transactions on Systems, Man and Cybernetics, 1985.
- [40]SUGENO, M., KANG, G. T., “Structure identification of fuzzy model. Fuzzy Sets System”, Elsevier North-Holland, Inc., Amsterdam, The Netherlands, The Netherlands, v. 28, n. 1, p. 15–33, 1988.ISSN 0165-0114, 1988.

- [41]BOX, G. E. P., JENKINS, G. M., “Time Series Analysis -Forecasting and Control”, Holden-Day Inc, California, 1976.
- [42]CYBENKO, G., “Approximation by superpositions of a sigmoid function”, *Mathematics of Control, Signal and Systems*, 2:303-314, 1989.
- [43]STINCHCOMB, M., WHITE, H., “Universal approximation using feedforward networks with non-sigmoid hidden layer activation functions”, In proceedings of the International Joint Conference on Neural Networks (IJCNN), 1:613-617, Washington D.C., June 1989.
- [44]Site do ONS – “Operador Nacional do Sistema Elétrico”. [www.ons.org.br](http://www.ons.org.br)
- [45]NÓBREGA, O., “Aplicação de redes neurais artificiais e algoritmos genéticos na previsão de carga elétrica em médio prazo”. Recife – PE, 2006 Dissertação de mestrado, UFPE.
- [46]AQUINO, R., SILVA, G., LIRA, M., FERREIRA, A., CARVALHO JR, M., OLIVEIRA, J., “Combined Artificial Neural Network and Adaptive Neuro-Fuzzy Inference System for Improving a Short-Term Electric Load Forecasting”. *Lecture Notes in Computer Science*, v. 4669, p. 779/1611-3349-788, 2007.
- [47]PRECHELT, L. “Proben1 – A Set of Neural Network Benchmark Problems and Benchmarking Rules”. Technical Report, 1994, pp. 21-94.
- [48]VALENÇA, M. J. S., “Redes Neurais Construtivas uma Alternativa para Previsão de Vazões Médias Mensais”. Natal. VII Congresso Brasileiro de Redes Neurais, 2005.
- [49]CAMPOS, J. N. B., NASCIMENTO, L. S. V.,; BARCELOS, D. G., Studart, T. M. C., “Influência do Regime Sazonal de Vazões nas Disponibilidades Hídricas de Reservatórios”. XV Simpósio Brasileiro de Recursos Hídricos. Curitiba : ABRH, 2003.