

UNIVERSIDADE FEDERAL DE GOIÁS  
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE  
COMPUTAÇÃO

CARLOS DA COSTA FERREIRA

**Previsão de Vazões Naturais Diárias  
Afluentes ao Reservatório da UHE  
Tucuruí Utilizando a Técnica de Redes  
Neurais Artificiais**

Goiânia  
2012

CARLOS DA COSTA FERREIRA

# **Previsão de Vazões Naturais Diárias Afluentes ao Reservatório da UHE Tucuruí Utilizando a Técnica de Redes Neurais Artificiais**

Dissertação apresentada ao Programa de Pós-Graduação da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica e de Computação.

**Área de concentração:** Engenharia de Computação.

**Orientador:** Prof. Gélson da Cruz Júnior

Goiânia  
2012

**Dados Internacionais de Catalogação na Publicação (CIP)**  
**GPT/BC/UFG mr**

F383p Ferreira, Carlos da Costa.  
Previsão de vazões naturais diárias afluentes ao reservatório da UHE Tucuruí utilizando a técnica de redes neurais artificiais [manuscrito] / Carlos da Costa Ferreira. – 2012.  
xiii, 99 f. : il., figs, tabs.

Orientador: Prof. Dr. Gélson da Cruz Júnior.  
Dissertação (Mestrado) – Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação, 2012.  
Bibliografia.  
Inclui lista de figuras, tabelas, siglas, símbolos e unidades.  
Apêndices.

1. Previsão de Vazões – UHE Tucuruí. 3. Redes Neurais Artificiais. I. Título.

CDU:621.311.21:004.032.26

---

## Agradecimentos

---

Primeiramente a Deus,

pelos dons da vida e da sabedoria, pela proteção e por abençoar sempre a minha vida.

Aos meus pais Geraldo Avelar e Antônia Ferreira,

pelo exemplo de pessoas cujos valores me fizeram a cada dia uma pessoa melhor.

Aos meus irmãos Jhonys e Carla Helena,

pelo companheirismo e incentivo em mais esta jornada.

Ao orientador Gélson,

pela atenção e conhecimentos divididos com tamanha disposição ao longo deste tempo.

Aos colegas de trabalho e profissão Admir Conti, Jamil Freitas, Luana Gomes e Mêuser Valença

por aumentarem meu horizonte de conhecimento, auxiliando com críticas, sugestões e dicas para meus trabalhos.

Aos meus amigos,

por serem meu suporte neste atual momento da minha vida.

E a todos outros colegas,

que se fizeram presentes, apoiando e ajudando a garantir o sucesso deste trabalho.

---

## Resumo

---

Ferreira, Carlos da Costa. **Previsão de Vazões Naturais Diárias Afluentes ao Reservatório da UHE Tucuruí Utilizando a Técnica de Redes Neurais Artificiais**. Goiânia, 2012. 99p. Dissertação de Mestrado. Escola de Engenharia Elétrica, Mecânica e de Computação, Universidade Federal de Goiás.

A previsão de vazões naturais aos reservatórios das usinas hidrelétricas é insumo fundamental para o planejamento e operação do SIN. Diversos modelos são utilizados na determinação dessas previsões, entre os quais podem ser citados os modelos físicos, os estatísticos e aqueles baseados na técnica de Redes Neurais Artificiais.

Atualmente, o ONS realiza as previsões diárias de vazões naturais para a Usina Hidrelétrica Tucuruí com base no modelo estocástico univariado denominado PREVIVAZH, desenvolvido pelo CEPEL.

Ao longo da última década, muitos trabalhos têm mostrado a evolução da aplicação da metodologia de Redes Neurais Artificiais em diversas áreas e em particular na previsão de vazões naturais, para intervalos de tempo diários, semanais e mensais.

O objetivo deste trabalho foi calibrar e avaliar um modelo de previsão de vazões naturais, utilizando a metodologia de RNA, mais especificamente as redes construtivas do tipo NSRBN (*Non-Linear Sigmoidal Regression Blocks Networks*) (VALENCA; LUDERMIR, 2001), no horizonte de 1 até 12 dias à frente, para a Usina Hidrelétrica Tucuruí, considerando as informações advindas de postos hidrométricos localizados à montante do seu reservatório. Adicionalmente, foi realizada uma análise comparativa dos resultados encontrados pela rede neural calibrada e aqueles obtidos e divulgados pelo ONS.

Os resultados obtidos mostram a vantagem da metodologia de redes neurais artificiais sobre os modelos auto-regressivos. Os valores do Erro Percentual Médio Absoluto - MAPE foram, em média, 48% inferiores aos divulgados pelo ONS.

### Palavras-chave

previsão de vazões naturais, redes neurais artificiais, usinas hidrelétricas, planejamento da geração, redes neurais por combinação de blocos de regressões sigmóides não-lineares

---

## Abstract

---

Ferreira, Carlos da Costa. T. Goiânia, 2012. 99p. MSc. Dissertation. Escola de Engenharia Elétrica, Mecânica e de Computação, Universidade Federal de Goiás.

The forecast of natural flows to hydroelectric plant reservoirs is an essential input to the planning and programming of the SIN's operation. Various computer models are used to determine these forecasts, including physical models, statistical models and the ones developed with the RNA's techniques.

Currently, the ONS performs daily forecasts of natural flows to the UHE Tucuruí based on the univariate stochastic model named PREVIVAZH, developed by Electric Energy Research Center - Eletrobras CEPEL.

Throughout the last decade, several papers have shown evolution in the application of neural networks methodology in many areas, specially in the prediction of flows on a daily, weekly and monthly basis.

The goal of this dissertation is to present and calibrate a model of natural flow forecast using the RNA's methodology, more specifically the NSRBN (Non-Linear Sigmoidal Regression Blocks Networks) (VALENCA; LUDERMIR, 2001), on a time lapse from 1 to 12 days forward to the Tucuruí Hydroelectric Plant, considering the hydrometric stations' data located upstream from it's reservoir. In addition, a comparative analysis of results found throughout the calibrated neural network and the ones released by ONS is performed.

The results show the advantage of the methodology of artificial neural networks on autoregressive models. The Mean Absolute Percentage Error - MAPE values obtained were, on average, 48 % lower than those released by the ONS.

### Keywords

forecasting, artificial neural networks, hydroelectric power generation, power generation planning, non-linear sigmoidal regression blocks networks

---

## Sumário

---

<b>Lista de Figuras</b>	<b>vi</b>
<b>Lista de Tabelas</b>	<b>ix</b>
<b>Lista de Siglas</b>	<b>xi</b>
<b>Lista de Símbolos e Unidades</b>	<b>xiii</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Contextualização das Previsões de Vazões no Setor Elétrico Brasileiro . . .	1
1.2 Objetivos da Pesquisa . . . . .	4
1.2.1 Geral . . . . .	4
1.2.2 Específicos . . . . .	4
1.3 Organização da Dissertação . . . . .	5
<b>2 Revisão Bibliográfica</b>	<b>6</b>
<b>3 Modelos Computacionais de Previsão de Vazões no Setor Elétrico Brasileiro</b>	<b>17</b>
3.1 O Processo de Previsão de Vazões . . . . .	17
3.2 Os Modelos Auto-Regressivos . . . . .	19
3.2.1 O Modelo PREVIVAZ . . . . .	19
3.2.2 O Modelo PREVIVAZM . . . . .	21
3.2.3 O Modelo PREVIVAZH . . . . .	22
3.3 Modelos Baseados na Técnica de Redes Neurais Artificiais . . . . .	26

---

3.3.1	Fundamentos das Redes Neurais . . . . .	26
3.3.2	Redes Perceptron . . . . .	29
3.3.3	Redes MLP . . . . .	30
3.3.4	Redes NSRBN . . . . .	38
<b>4</b>	<b>Descrição da Área em Estudo</b>	<b>44</b>
4.1	Caracterização da Bacia Hidrográfica . . . . .	44
4.2	Usina Hidrelétrica Tucuruí . . . . .	51
<b>5</b>	<b>Análise e Tratamento dos Dados de Entrada</b>	<b>54</b>
5.1	Considerações Iniciais . . . . .	54
5.2	Informações Fluviométricas . . . . .	58
5.2.1	Rede de Postos Fluviométricos Considerada . . . . .	58
5.2.2	Análise de Correlação e Preenchimento de Falhas . . . . .	63
5.2.3	Análise de Consistência dos Dados . . . . .	64
5.3	Informações Pluviométricas . . . . .	65
5.3.1	Rede de Postos Pluviométricos Considerada . . . . .	65
5.3.2	Análise de Correlação e Preenchimento de Falhas . . . . .	67
5.3.3	Análise de Consistência dos Dados . . . . .	68
<b>6</b>	<b>Simulações com Redes Neurais - Estudo de Caso</b>	<b>69</b>
6.1	Configuração da Rede Neural . . . . .	69
6.2	Treinamento da Rede Neural . . . . .	71
6.3	Resultados Obtidos . . . . .	72
<b>7</b>	<b>Conclusões e Trabalhos Futuros</b>	<b>80</b>
7.1	Trabalhos Futuros . . . . .	83
	<b>Referências Bibliográficas</b>	<b>84</b>
	<b>Anexo A – Mapa Hipsométrico da Bacia Hidrográfica Tocantins-Araguaia</b>	<b>89</b>

---

<b>Anexo B – Curvas de Descarga dos Postos Fluviométricos Considerados</b>	<b>90</b>
<b>Anexo C – Configuração Isoietal das Chuvas Médias Anuais</b>	<b>94</b>
<b>Anexo D – Previsões de Vazões Semanais para a UHE Tucuruí</b>	<b>95</b>

---

## Lista de Figuras

---

Figura 1.1	Esquema de elaboração das previsões para o PMO (ONS, 2010). . . . .	2
Figura 3.1	Interação entre os modelos hidrológicos e a cadeia de planejamento da operação do SIN (ONS, 2010). . . . .	19
Figura 3.2	Abordagem da estrutura de correlação - Adaptado (ONS, 2010) . . . . .	21
Figura 3.3	Neurônio biológico . . . . .	27
Figura 3.4	Neurônio artificial - Adaptado McCullough e Pitts (1943) . . . . .	28
Figura 3.5	Perceptron - Adaptado Rosenblatt (1958) . . . . .	29
Figura 3.6	Estrutura da rede MLP - Adaptado Marinho et al. (2004) . . . . .	31
Figura 3.7	Validação cruzada - Adaptado (VALENCA, 2010) . . . . .	36
Figura 3.8	Arquitetura combinatorial . . . . .	40
Figura 3.9	Arquitetura de um bloco polinomial . . . . .	41
Figura 4.1	Mapa de Localização da bacia hidrográfica dos rios Tocantins e Araguaia . . . . .	45

---

Figura 4.2	Bacia hidrográfica dos rios Tocantins e Araguaia	50
Figura 4.3	Percentual de Volume útil do reservatório da UHE Tucuruí - ano 2011	52
Figura 4.4	Hidrograma sazonal - UHE Tucuruí (1931 - 2009)	53
Figura 5.1	Rede de Postos Fluviométricos Pesquisada - Adaptada de (ONS, 2004)	56
Figura 5.2	Rede de Postos Pluviométricos Pesquisada - Adaptada de (ONS, 2004)	57
Figura 5.3	Rede de Postos Fluviométricos Considerada - Adaptada de (ONS, 2004)	62
Figura 5.4	Rede de Postos Pluviométricos Considerada - Adaptada de (ONS, 2004)	66
Figura 5.5	Polígono de Thiessen dos postos pluviométricos selecionados	68
Figura 6.1	Previsão de Vazões Semanais - UHE Tucuruí - 2008 (ONS, 2010).	74
Figura 6.2	Previsão de Vazões Semanais - UHE Tucuruí - 2008 (NRSBN)	74
Figura A.1	Mapa Hipsométrico da Bacia Hidrográfica do Tocantins-Araguaia - Fonte: (ANA, 2009)	89
Figura B.1	Curva Chave - Posto Itupiranga (29200000) - Fonte: (ONS, 2004)	90
Figura B.2	Curva Chave - Posto Marabá (29050000) - Fonte: (ONS, 2004)	90
Figura B.3	Curva Chave - Posto Fazenda Alegria (29100000) - Fonte: (ONS, 2004)	91

---

Figura B.4	Curva Chave - Posto Conceição do Araguaia (27500000) - Fonte: (ONS, 2004)	91
Figura B.5	Curva Chave - Posto Tocantinópolis (23600000) - Fonte: (ONS, 2004)	92
Figura B.6	Curva Chave - Posto Descarreto (23700000) - Fonte: (ONS, 2004)	92
Figura B.7	Curva Chave - Posto Araguatins (28850000) - Fonte: (ONS, 2004)	93
Figura B.8	Curva Chave - Posto Xambioá (28850000) - Fonte: (ONS, 2004)	93
Figura C.1	Configuração Isoietal das Chuvas Médias Anuais - Fonte: (ANA, 2009)	94
Figura D.1	Previsão de Vazões Semanais - UHE Tucuruí - 2000 (NRSBN)	95
Figura D.2	Previsão de Vazões Semanais - UHE Tucuruí - 2001 (NRSBN)	95
Figura D.3	Previsão de Vazões Semanais - UHE Tucuruí - 2002 (NRSBN)	96
Figura D.4	Previsão de Vazões Semanais - UHE Tucuruí - 2003 (NRSBN)	96
Figura D.5	Previsão de Vazões Semanais - UHE Tucuruí - 2004 (NRSBN)	97
Figura D.6	Previsão de Vazões Semanais - UHE Tucuruí - 2005 (NRSBN)	97
Figura D.7	Previsão de Vazões Semanais - UHE Tucuruí - 2006 (NRSBN)	98
Figura D.8	Previsão de Vazões Semanais - UHE Tucuruí - 2007 (NRSBN)	98
Figura D.9	Previsão de Vazões Semanais - UHE Tucuruí - 2009 (NRSBN)	99

---

## Lista de Tabelas

---

Tabela 5.1	Postos Fluviométricos Considerados	58
Tabela 5.2	Coefficientes de Correlação entre os Postos Fluviométricos	63
Tabela 5.3	Postos Pluviométricos Considerados	65
Tabela 5.4	Coefficientes de Correlação entre os Postos Pluviométricos	67
Tabela 5.5	Coefficientes de proporção dos postos pluviométricos seleccionados	68
Tabela 6.1	Defasagem Temporal dos Postos Fluviométricos Considerados	69
Tabela 6.2	Variáveis de entrada consideradas na Rede Neural NSRBN	70
Tabela 6.3	Resultados das Simulações para as Vazões Altas	75
Tabela 6.4	Resultados das Simulações para as Vazões Baixas	76
Tabela 6.5	Resultados das Simulações - <i>TimingCorrection</i>	77
Tabela 6.6	Resultados das Simulações - <i>ENSEMBLES</i>	78
Tabela 6.7	Resultado da Previsão de Vazões para o Conjunto de Verificação	78

---

Tabela 6.8	Resultado da Previsão de Vazões Semanais na UHE Tucuruí - PREVIVAZ x Rede Neural NRSBN .....	79
------------	---	----

---

## Lista de Siglas

---

SIN	Sistema Interligado Nacional
ONS	Operador Nacional do Sistema Elétrico
CEPEL	Centro de Pesquisas de Energia Elétrica
NSRBN	Non-Linear Sigmoidal Regression Blocks Networks
MAPE	Erro Percentual Médio Absoluto
PMO	Programa Mensal de Operação
SEB	Setor Elétrico Brasileiro
PREVIVAZM	Modelo de Previsão de Vazões Mensais
PREVIVAZ	Modelo de Previsão de Vazões Semanais
PREVIVAZH	Modelo de Previsão de Vazões Diárias
RNA	Redes Neurais Artificiais
UHE	Usina Hidrelétrica
ARMAX	Modelo Auto-Regressivo de Médias Móveis com Variáveis Exógenas
FNN	Feed-forward Multi-layer
PMSE	Pooled Mean Squared Error
PARMA	Modelos Auto-regressivos de Média-móvel Periódico
ANFIS	Adaptive Network based Fuzzy Inference System
OMM	Organização Mundial de Meteorologia
MIP	Modelo Inteligente de Previsão
VE	Valor Esperado
LI	Limite Inferior
LS	Limite Inferior
AR	Modelos Auto-regressivos
ARMA	Modelos Auto-regressivos de Média-móvel

---

PAR	Modelos Auto-regressivos Periódicos
ADALINE	Adaptive Linear Neuron
MLP	Multilayers Perceptron
EP	Erro Padrão de Predição
CE	Coefficiente da Eficiência
$r^2$	Coefficiente da Determinação
IDH	Índice de Desenvolvimento Humano
SIPOT	Sistema de Informações do Potencial Hidrelétrico Brasileiro
ELETRONORTE	Centrais Elétricas do Norte do Brasil S.A.
ANA	Agência Nacional de Águas
INMET	Instituto Nacional de Meteorologia
CPRM	Companhia de Pesquisa de Recursos Minerais
Thi	Chuva Média de Thiessen
Tuc	Posto UHE Tucuruí - Barragem
Itu	Posto Itupiranga
Mar	Posto Marabá
Des	Posto Descarreto
Toc	Posto Tocantinópolis
FazAle	Posto Fazenda Alegria
Ara	Posto Araguatins
Xam	Posto Xambioá
ConAra	Posto Conceição do Araguaia
Erro mín	Erro Mínimo
EMQ	Erro Médio Quadrático
CLAGTEE	Congreso Latinoamericano de Generación y Transportede Energía Eléctrica

---

## Lista de Símbolos e Unidades

---

$t$	tempo
$Q$	vazão ( $m^3/s$ )
$\lambda$	taxa de recessão
$\varepsilon(t)$	ruído normal padrão
$\rho$	correlação <i>lag-1</i>
$\theta(\cdot)$	distribuição acumulada norma
$w_{ij}$	pesos sinápticos
$\theta$	limiar
$\sigma_{net(h)}$	função tangente hiperbólica
$km^2$	quilômetro quadrado
$hab./km^2$	densidade demográfica
km	quilômetro
m	metro
mm	milímetro
$m^3/s$	metro cúbico por segundo
$L/s.km^2$	vazão específica média
GW	Giga Watt
MW	Mega Watt
NA	nível d'água
$hm^3$	hectômetro cúbico
$km^3$	quilômetro cúbico
kV	quilo volts

## Introdução

---

### 1.1 Contextualização das Previsões de Vazões no Setor Elétrico Brasileiro

A capacidade brasileira de geração de energia elétrica é fortemente influenciada pelas usinas hidrelétricas instaladas e operantes no país. Segundo dados do Operador Nacional do Sistema Elétrico (ONS), a geração proveniente das usinas hidrelétricas correspondeu a aproximadamente 91% da produção de energia gerada no Brasil no ano de 2011. Devido a esta preponderância, a previsão de vazões naturais afluentes aos reservatórios das usinas hidrelétricas apresenta-se como insumo fundamental para o planejamento e programação da operação das unidades pertencentes ao Sistema Interligado Nacional (SIN).

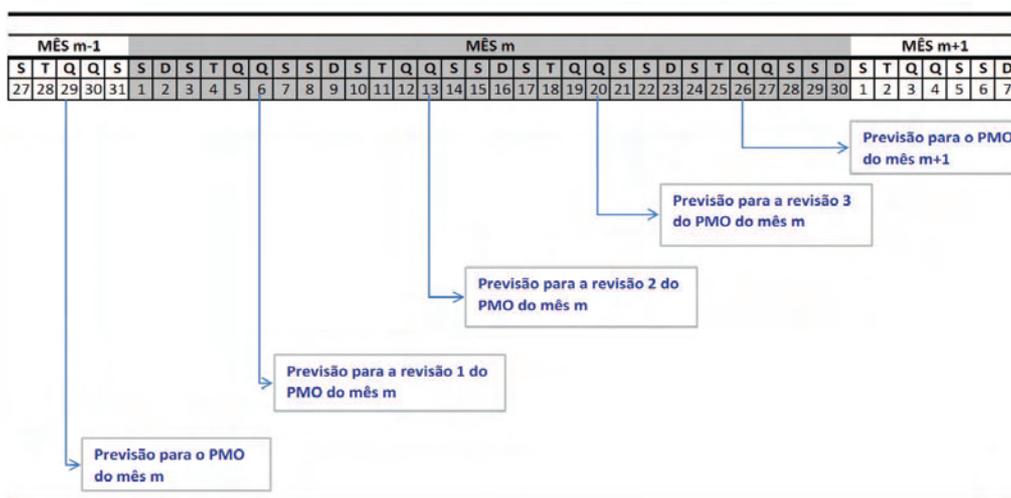
O plano de operação de um sistema hidrotérmico de energia elétrica deve definir, para cada instante, a geração de cada unidade de tal forma que a demanda seja atendida a um custo mínimo. A capacidade de geração futura do sistema também é influenciada pelas afluências hidrológicas futuras, cuja natureza intrinsecamente aleatória deve ser considerada no planejamento da operação do sistema. Sendo assim, a obtenção de previsão de vazões naturais permite que os diferentes modelos de operação, otimização e simulação energética possam avaliar as condições operacionais futuras das usinas hidrelétricas, subsidiando a tomada de decisões quanto ao melhor desempenho do sistema, de forma a explorar toda a sua capacidade hidrológica, aumentar sua confiabilidade e reduzir custos.

Adicionalmente, estas previsões hidrológicas permitirão antecipar a tomada de decisão no sentido de minimizar os efeitos danosos de uma cheia excepcional aos reservatórios hidrelétricos, aumentando assim a segurança na operação da barragem. Os demais setores usuários da água também poderão utilizar as previsões de afluências como insumos para programar suas atividades referentes ao uso dos recursos hídricos.

“Vazões naturais afluentes a um determinado aproveitamento são aquelas que ocorreriam em uma seção do rio caso não houvesse a operação de reservatórios a montante, nem a vazão evaporada pelos lagos artificiais, nem mesmo retiradas de água consumidas com abastecimento e irrigação a montante. Em síntese, são as vazões providas pela própria natureza.” (ONS, 2010).

O ONS utiliza e elabora periodicamente, em conjunto com os agentes de geração, as previsões de vazões naturais médias diárias, semanais e mensais, para todos os locais de aproveitamento hidrelétrico do SIN. Esta atribuição tem o objetivo de subsidiar a tomada de decisão para o planejamento e programação da operação eletroenergética do SIN, no âmbito do Programa Mensal de Operação (PMO) e de suas revisões semanais, bem como promover o despacho centralizado das usinas de forma otimizada e propiciar as informações necessárias ao processo de formação de preço de energia elétrica no mercado de curto prazo.

As previsões no ONS são elaboradas semanalmente, no dia imediatamente anterior ao PMO ou a qualquer de suas revisões semanais. Como regra geral, a previsão do PMO é elaborada nas quartas-feiras da semana operativa que antecede à primeira semana operativa do mês <sup>1</sup> e as previsões para as revisões às quintas-feiras da semana operativa anterior, conforme mostra o esquema da Figura 1.1.



**Figura 1.1:** Esquema de elaboração das previsões para o PMO (ONS, 2010).

Dependendo do uso e aplicação das previsões de vazões, o Setor Elétrico Brasileiro (SEB) trabalha com três horizontes de previsão de vazões, a saber: previsões de longo, médio e curto prazo.

<sup>1</sup> As semanas operativas têm início às 00:00h de sábado e terminam às 24:00h da sexta-feira posterior. A primeira semana operativa do mês é aquela que contém o 1º dia do referido mês

As previsões de médio prazo são realizadas utilizando Modelo de Previsão de Vazões Mensais (PREVIVAZM), desenvolvido com o objetivo de obter as previsões mensais, até 12 (doze) meses à frente. Este modelo, para cada aproveitamento hidrelétrico, analisa a sua série histórica de aflúncias mensais e seleciona, para cada mês, um modelo estocástico entre diversas alternativas de modelagem estocástica de vazões mensais. A escolha entre as modelagens é feita objetivando o uso mais eficiente e robusto da informação contida nos registros recentes de aflúncias mensais ao aproveitamento. O modelo estocástico escolhido para a previsão será aquele que apresentar a menor média de desvio-padrão do erro de previsão.

No horizonte de previsão de curto prazo, analisa-se o histórico de vazões naturais médias semanais e utiliza-se o Modelo de Previsão de Vazões Semanais (PREVIVAZ), desenvolvido visando a obtenção das previsões das aflúncias semanais, até 6 (seis) semanas à frente. Esse modelo segue a mesma abordagem do modelo mensal PREVIVAZM, sendo que para cada aproveitamento hidrelétrico, o modelo analisa a sua série histórica de aflúncias semanais e seleciona, para cada semana, um modelo estocástico entre diversas alternativas de modelagem semanal. Estas previsões tem por objetivo subsidiar o PMO e quaisquer de suas revisões semanais.

No horizonte de previsão de curtíssimo prazo, a partir de um histórico de vazões naturais médias diárias, utiliza-se modelos físicos e determinísticos baseados na relação entre chuva e vazão, bem como os modelos estocásticos. O ONS calibra, anualmente, o Modelo de Previsões de Vazões Diárias (PREVIVAZH), que visa a obtenção das previsões das vazões diárias, até 14 (quatorze) dias à frente. Previsões estas, baseadas na desagregação, em intervalos diários, das previsões de aflúncias semanais obtidas pelo Modelo PREVIVAZ, e uma metodologia de desagregação não paramétrica destas aflúncias em valores diários que faz uso das últimas aflúncias diárias e de séries sintéticas de vazões diárias. Por meio da metodologia adotada para a geração das sequências de aflúncia diárias, utilizadas no processo de desagregação das vazões semanais, garante-se a preservação das características hidrológicas diárias que apresentam estrutura complexa de dependência temporal, com diferenças marcantes entre os períodos de ascensão e recessão das aflúncias, além de distribuições marginais significativamente assimétricas.

Atualmente, o ONS realiza as previsões de vazões naturais diárias para a UHE Tucuruí com base no modelo estocástico univariado PREVIVAZH. Este modelo apresenta erros percentuais médias absolutos consideráveis, para até 14 dias à frente, quando comparados com os valores observados. Devido à característica estratégica que a UHE Tucuruí tem para o SIN, é importante que sejam envidados esforços na pesquisa de novos modelos de previsão, de forma a reduzir os desvios no processo de elaboração do PMO e de suas revisões semanais.

## 1.2 Objetivos da Pesquisa

### 1.2.1 Geral

O objetivo deste trabalho é calibrar um modelo de previsão de vazões médias diárias, utilizando a metodologia de Redes Neurais Artificiais (RNA), mais especificamente as redes construtivas do tipo NSRBN (*Non-Linear Sigmoidal Regression Blocks Networks*), no horizonte de 1 até 12 dias à frente, para a Usina Hidrelétrica (UHE) Tucuruí, considerando a informação advinda de diferentes postos pluviométricos e fluviométricos, localizados a montante do seu reservatório.

### 1.2.2 Específicos

Este trabalho tem os seguintes objetivos específicos:

- selecionar e analisar as informações dos postos hidrométricos (fluviométricos e pluviométricos) da área localizada a montante do reservatório da UHE Tucuruí.
- definir qual a melhor topologia de rede neural para a previsão de vazões naturais diárias afluentes ao reservatório da UHE Tucuruí.
- comparar os resultados obtidos com o modelo baseado em redes neurais e aqueles obtidos com o modelo estocástico atualmente utilizado pelo ONS.

## 1.3 Organização da Dissertação

Os capítulos desta dissertação serão organizados da seguinte forma:

No capítulo 2 será apresentada a revisão bibliográfica sobre a pesquisa e a aplicação das técnicas de Redes Neurais Artificiais para a previsão de vazões naturais.

O capítulo 3 apresentará os modelos computacionais utilizados no Setor Elétrico Brasileiro para previsão de vazões naturais, com ênfase nos modelos estocásticos auto-regressivos e aqueles baseados na técnica de redes neurais artificiais.

No capítulo 4 será descrita a área em estudo, caracterizando a bacia hidrográfica quanto aos aspectos hidrológicos, climatológicos e geomorfológico e apresentando a Usina Hidrelétrica Tucuruí.

O capítulo 5 terá o propósito de apresentar as redes fluviométricas e pluviométricas pesquisadas na área em estudo, destacando a análise e o tratamento dos dados de entrada para a rede neural, de acordo com as séries históricas disponíveis.

No capítulo 6 serão apresentadas as simulações realizadas com as redes neurais, destacando no estudo de caso a configuração utilizada e o processo de treinamento realizado. Ao final serão apresentados e comparados os resultados obtidos com aqueles considerados e obtidos pelo ONS no PMO.

O capítulo 7 apresentará as conclusões do presente estudo, bem como as recomendações para futuros trabalhos.

Em seguida serão listadas as referências bibliográficas utilizadas nos capítulos anteriores.

E, finalmente, apresentados os apêndices e anexos utilizados pelo autor durante o processo de elaboração da dissertação.

---

## Revisão Bibliográfica

---

A Hidrologia trabalha com diversas classificações para os modelos hidrológicos, baseadas na diferenciação dos modelos determinísticos e estocásticos. Segundo [Chow \(1964\)](#), os modelos estocásticos (ou estatísticos) são aqueles em que as variáveis consideradas estão associadas a uma probabilidade de ocorrência, enquanto os modelos determinísticos são aqueles que seguem uma lei definida, que não seja a da probabilidade.

Modelos hidrológicos denominados chuva-vazão são largamente aplicados no planejamento de gestão dos recursos hídricos, objetivando simular a resposta da bacia hidrográfica em termos de vazão a partir da precipitação conhecida. No entanto, estes modelos apresentam desvantagens em sua implementação e calibração, uma vez que requerem sofisticadas ferramentas matemáticas, quantidade significativa de parâmetros de calibração e vasta experiência com o modelo.

Segundo [Valenca e Valenca \(2005\)](#), na aplicação estatística destacam-se os modelos de séries temporais do tipo ARMAX (Auto-Regressivo de Médias Móveis com Variáveis Exógenas), desenvolvidos por [Box e Jenkins \(1976\)](#), de fáceis desenvolvimento e calibração. Entretanto, tais modelos apresentam determinadas limitações, por não serem capazes de representar a não-linearidade e a variabilidade espacial e temporal, características do processo chuva-vazão.

Os modelos ARMAX são capazes de representar o comportamento de um sistema cujas características de entrada e saída são aproximadamente lineares. Desta forma, podem ser vistos como uma versão simplificada de uma Rede Neural Artificial com função de ativação linear e nenhuma camada escondida. Espera-se que com o uso da Rede Neural o processo estocástico seja melhor representado, uma vez que este tipo de rede possui uma estrutura matemática flexível capaz de identificar as relações complexas não-lineares entre um conjunto de dados de entrada e saída.

Uma aplicação atual do uso das Redes Neurais Artificiais envolve o desenvolvimento dos modelos de previsão, onde para prever o valor de uma variável particular de

---

saída, utiliza-se um conjunto de variáveis independentes.

As Redes Neurais Artificiais são uma técnica integrante dos Sistemas Inteligentes, inspirados no comportamento humano ou da natureza. As RNAs vêm sendo sugeridas para análise de séries temporais devido à sua capacidade de tratar com relações de entrada-saída de dados não-lineares, destacando sua habilidade de aprendizado e capacidade de generalização, associação e busca paralela. Estas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries, tais como sazonalidade, periodicidade, tendência, entre outras, muitas vezes camufladas por ruídos (GOMES, 2006).

O conceito de rede neural artificial advém do funcionamento do neurônio biológico, que recebe uma série de dados de entrada oriundas do corpo humano ou do ambiente externo a ele, convertendo os dados ou informações de entrada em uma outra informação ou dado de saída (ALBANO; VALENCA; PORTO, 2007). O entendimento do comportamento do neurônio biológico para caracterizar o neurônio artificial é o passo inicial para se compreender as redes neurais.

Dentre as importantes características de similaridade destas redes com o cérebro humano, está a capacidade de aprender. Portanto, essas redes neurais artificiais possuem alguma forma de regra de aprendizagem que são responsáveis pela modificação dos pesos sinápticos, em função dos exemplos de entrada que lhe são apresentados. Assim, pode-se dizer que as RNAs aprendem por exemplos (VALENCA; VALENCA, 2005). Essas redes são do tipo *feedforward*, ou seja, o processamento da informação se dá no sentido progressivo, através das ligações sinápticas entre os neurônios das camadas adjacentes.

Para intervalos diários, os modelos Box-Jenkins (estocásticos) não apresentam resultados tão satisfatórios quanto os modelos baseados em redes neurais. A grande vantagem da técnica de redes neurais está na sua versatilidade de permitir que o processo chuva-vazão incorpore a representatividade de cada posto pluviométrico em vez de se trabalhar, como por exemplo, com a chuva média por Thiessen.

Ao longo das últimas décadas, muitos trabalhos têm mostrado a prosperidade da aplicação da metodologia de redes neurais em diversas áreas e em particular na previsão de vazões, para intervalos temporais diários, semanais e mensais. Muitos dos quais comparam as aplicações dos tradicionais modelos estatísticos com os modelos que utilizam a técnica de redes neurais, com estes sempre apresentando resultados bem superiores àqueles.

As etapas que devem ser seguidas no desenvolvimento dos modelos baseados em Redes Neurais incluem: a escolha de critérios de desempenho, a divisão e o pré-processamento dos dados disponíveis, a seleção e a análise das variáveis de entrada,

---

a arquitetura da rede, o treinamento para determinação dos pesos das conexões e a verificação para avaliar o desempenho do modelo após o treinamento (VALENCA; LUDERMIR, 2007).

Dentre as principais características das Redes Neurais Artificiais pode-se citar: não linearidade (permite resolver problemas que não sejam linearmente separáveis; adaptatividade (capacidade de reaprender de forma a se adequar a um novo conjunto de exemplos); aprendizagem (o seu conhecimento é extraído de exemplos); modelagem de sistemas complexos (permite trabalhar com uma grande quantidade e diversidade de dados); processamento paralelo (capacidade de receber diversas informações e testar todas as possibilidades ao mesmo tempo); tolerância a falhas (a rede pode perder alguns neurônios e ainda apresentar um desempenho satisfatório) e a capacidade de generalização (fornecer resposta satisfatória quando processa um novo conjunto de exemplos) (VALENCA, 2005).

Os estudos recentes mostram que a consideração de técnicas estatísticas no processo de modelagem das RNAs bem como o desenvolvimento de sistemas híbridos, que integram redes neurais e estatísticas, pode melhorar substancialmente o desempenho dos modelos de previsão (CHENG; TITTERINGTON, 1994).

É de suma importância adotar-se um procedimento consistente para o uso das redes neurais, levando-se em conta fatores do modelo tais como o pré-processamento dos dados, a seleção das variáveis de entrada do modelo, a determinação da arquitetura ótima, o treinamento para determinação dos pesos, a validação cruzada e a verificação do desempenho do modelo (VALENCA, 2005).

Em 1995, Hsu et al. (1995) utilizaram redes neurais artificiais na modelagem do processo chuva-vazão diária na bacia do rio *Leaf*, localizada no *Mississipi*, EUA. Os autores avaliaram um algoritmo de treinamento para as RNAs e confrontaram os resultados com os obtidos pelo modelos SAC-SMA (conceitual) e ARMAX (estatístico auto-regressivo). Neste trabalho, o algoritmo analisado mostrou-se como uma ferramenta eficaz no treinamento da rede e os resultados obtidos com as redes neurais apresentaram menores erros e menores diferenças de volume do que os resultados obtidos com os demais modelos analisados.

Em 1997, Shamseldin (1997) trabalhou na modelagem dos processos chuva x vazão com a técnica de redes neurais. O autor usou diferentes informações como entrada da rede neural, quais sejam: chuva, histórico sazonal e informações de postos hidrométricos próximos. Os resultados foram comparados com outros três diferentes modelos: o modelo simples linear (SLM), o modelo sazonal baseado na perturbação linear (LMP) e o modelo linear de perturbação (NNLPM). Os resultados mostraram que as redes neurais são promissoras no contexto da modelagem dos processos chuva x vazão, porém,

como os demais modelos analisados, apresenta resultados variáveis.

Uma aplicação de redes neurais do tipo *Perceptron* de múltiplas camadas na área de recursos hídricos foi realizada em 1997 por [Valenca \(1997\)](#), em especial na simulação do processo de transformação de chuva em vazão e, conseqüentemente, na previsão de vazões médias mensais. Os resultados obtidos no processo foram comparados com os obtidos por meio dos modelos conceituais MOHTSAR e SMAP, estudados por [Lopes et al. \(1981\)](#). Adicionalmente, as previsões de vazões foram comparadas com aquelas obtidas dos modelos que utilizam a técnica de regressão múltipla e metodologia [Box e Jenkins \(1976\)](#). Os resultados encontrados pelo autor, quando comparados com aqueles obtidos pelas metodologias tradicionais, foram de ótima qualidade. Na oportunidade, mostrou-se que a grande vantagem da técnica de redes neurais está na versatilidade de permitir que o processo chuva-vazão incorpore a representatividade de cada posto pluviométrico em vez de se trabalhar, por exemplo, com a chuva média de Thiessen.

[Sperb et al. \(1999\)](#) demonstraram em 1999 a aplicabilidade das redes neurais na previsão de enchentes para a bacia hidrográfica do rio Itajaí-Açu até a cidade de Blumenau - SC, propondo um modelo de transformação de chuva em vazão para a previsão de vazões em tempo real. O modelo utilizou como entrada os dados de precipitação de diversas estações pluviométricas distribuídas na bacia de contribuição para previsão de descarga no ponto de interesse. Em função da não linearidade entre as variáveis, o algoritmo de treinamento escolhido foi o de Levenberg-Marquardt. Embora tenham utilizado uma modelagem bastante simples, os autores obtiveram resultados bastante satisfatórios, com índice de acerto das previsões em torno de 93%, indicando assim as redes neurais como uma técnica promissora no processo de previsão de vazões.

[Sajikumar e Thandaveswara \(1999\)](#) calibraram em 1999 um modelo baseado no processo chuva x vazão utilizando a técnica de redes neurais para os rios Lee (no Reino Unido) e Thuthapuzha (em Kerala - Índia). O autor obteve bons e importantes resultados que mostraram a eficiência das redes neurais para a modelagem do processo chuva x vazão para rios que dispõem de poucas informações hidrométricas, neste caso para a série histórica inferior a 6 anos.

Também no ano de 1999, [Tokar e Johnson \(1999\)](#) utilizaram RNAs para a previsão de vazões diárias em função da precipitação diária, temperatura e degelo, para a bacia hidrográfica do rio Little Patuxent, em Maryland - EUA. A fim de validar o estudo, os autores compararam os resultados com aqueles obtidos por meio de outras técnicas existentes, incluindo regressão estatística e o modelo conceitual simples SCRR. Os autores concluíram que as RNAs fornecem uma abordagem mais sistemática, uma vez que possibilita a diminuição do tempo gasto na calibração quando se reduz a extensão das séries de dados de entrada, ao mesmo tempo em que observa-se uma melhoria na precisão

da previsão das vazões.

Em 2000, [Coulibaly et al. \(2000\)](#) introduziram um critério de parada, denominado *Early Stopped - STA*, para treinar as redes neurais *Feed-forward Multi-layer* (FNN) para a previsão de vazão em tempo real a um reservatório. O FNN foi treinado utilizando o critério de parada com o método de otimização Levenberg-Marquardt Backpropagation (LMBP). Os autores concluíram que este método apresenta vantagem na validação cruzada, em relação aos demais métodos pesquisados, uma vez que evita sub e super-treinamento nas redes FNN e melhora o desempenho da generalização. A metodologia avaliou a série hidrológica da UHE Chute-du-Diable, localizada ao norte de Quebec, no Canadá. O desempenho do modelo foi comparado com um modelo estatístico (ARMAX-KF) e com um modelo conceitual em operação na hidrelétrica (PREVIS). Após a análise dos resultados obtidos, o método proposto mostrou-se eficaz na previsão da vazão ao reservatório da usina em tempo real. Neste trabalho, o uso do STA reduziu em quatro vezes o tempo de treinamento da rede, fazendo com que seu processo de convergência se tornasse mais rápido.

Também em 2000, [Kyrillos \(2000\)](#) utilizou um modelo baseado na técnica de redes neurais artificiais, denominado Qnet, para a previsão de vazões em tempo real, para o posto fluviométrico de Morpará, localizado na bacia hidrográfica do rio São Francisco. Este estudo mostrou o potencial da utilização dos sistemas integrados de análise hidrológica nos processos de planejamento e tomada de decisão no gerenciamento de recursos hídricos, através de um Sistema de Suporte a Decisão — SSD. O algoritmo utilizado foi o *backpropagation*, com aprendizado supervisionado e função de ativação sigmóide. Como dados de entrada foram utilizados dados diários de vazão dos postos de São Francisco, Carinhanha, Bom Jesus da Lapa e Morpará, e dados de chuva de 6 postos pluviométricos localizados no rio Das Velhas, através da chuva média de Thiessen. As arquiteturas que agregavam mais neurônios na camada de entrada e que se destinavam a simular um horizonte mais próximo foram as que obtiveram melhores resultados. Segundo a autora, as arquiteturas que consideraram apenas a vazão como dado de entrada apresentaram excelentes resultados, já aquelas que introduziram os dados de chuva, trouxeram ruídos na simulação, prejudicando assim a previsão de vazões final.

Ainda no ano de 2000, [Elshorbagy et al. \(2000\)](#) utilizaram um modelo de RNAs para a previsão de vazões na bacia hidrográfica do rio Red River Valley, no Canadá. Diversas estruturas de RNAs foram testadas pelos autores e os resultados foram comparados com aqueles obtidos pelos modelos empíricos, de regressão linear múltipla e não-linear de regressão múltipla. Neste trabalho, os autores propuseram uma nova métrica para avaliação dos resultados, denominada PMSE (*Pooled Mean Squared Error*). As RNAs apresentaram melhores desempenhos comparativamente aos demais modelos

analisados e estes resultados se mostraram independentes da estrutura de dados de entrada da rede.

Valenca e Ludermir (2001) avaliaram, em 2001, a viabilidade do uso das redes neurais na previsão de vazões semanais afluentes ao reservatório da UHE de Sobradinho, localizada no rio São Francisco. Para isso, os autores ajustaram os 52 melhores tipos de modelos auto-regressivos de média-móvel periódico PARMA(p,q) e compararam os resultados com os obtidos com os seguintes modelos baseados em redes neurais: *Multilayer Perceptron* — MLP, Redes Recorrentes de Elman e Jordan, Redes GMDH e as Redes NSRBN (*Non-Linear Sigmoidal Regression Blocks Networks*). Nos testes realizados foram analisados os critérios de seleção e a sensibilidade dos pesos iniciais. Adicionalmente, os autores analisaram a sensibilidade quanto à mudança da taxa de aprendizagem e do termo momento e não obtiveram nenhum ganho de precisão. Em termos de erro percentual médio absoluto, as redes com melhores desempenho foram, nessa ordem: NSRBN, GMDH, MLP, Jordan e Elman e Box-Jenkins. A principal contribuição deste trabalho consistiu no desenvolvimento das redes NSRBN. Estas redes são simples por possuírem apenas uma camada escondida, no entanto apresentam uma excelente capacidade de aproximação de funções por realizarem uma regressão sigmóide não-linear nas unidades de saída.

Ainda em 2001, Ramos e Galvao (2001) apresentaram uma metodologia para determinação da melhor arquitetura de redes neurais. Neste trabalho, os autores ressaltam que, para uma melhor definição da arquitetura da rede, são elementos importantes o processo de reinicialização dos pesos, a mudança de certas funções de transferência e a extensão das séries de dados.

Em 2002, Olivo et al. (OLIVO et al., 2002) apresentaram os resultados obtidos para a previsão de cheias fluviais utilizando redes neurais artificiais. O sistema foi construído na forma de “caixa-preta” e a estrutura da rede escolhida foi do tipo *Multilayer Perceptron*. O estudo de caso considerou como entrada 13 eventos de cheias observados no rio Itajaí - SC e o nível do rio em uma seção de interesse através da observação do nível do mesmo rio em uma seção a montante. Os resultados mostraram a potencialidade do uso desta ferramenta para resolver problemas hidrológicos.

Também no ano de 2002, Paz et al. (2002) analisaram a aplicação do método de diferenças (Modelo Prev) e da técnica de redes neurais artificiais, nas bacias hidrográficas do rio Doce (MG) e do rio Uruguai (RS), para a previsão de vazões em tempo real, decorrentes de grandes cheias. Na tentativa de verificar o desempenho das RNAs frente a uma atualização de seus parâmetros, os autores adotaram um processo de re-treinamento sequencial das redes, denominado de atualização por eventos. Nesse processo, a rede passa por um novo treinamento ao final de cada evento, onde são recalculados os pesos

---

das ligações entre os seus neurônios. Apesar do melhor desempenho das redes neurais em relação ao Modelo Prev, ambas as metodologias tiveram seus desempenhos limitados pelas informações disponíveis e pelas simplificações nos processos que envolveram o escoamento natural do curso d'água.

Em 2003, [Lima e Ferreira \(2003\)](#) analisaram diversos modelos baseados na técnica de redes neurais para a previsão de vazões mensais no posto fluviométrico Fazenda Cajazeiras, no Estado do Ceará, no período de Janeiro/1963 a Dezembro/2000. As diversas configurações de redes neurais foram obtidas alterando-se o número de neurônios na camada de entrada e na camada intermediária, bem como o número de anos utilizados para treinamento e validação da rede. Neste estudo, os autores concluíram que o período ideal de treinamento da rede correspondeu a primeira metade da série histórica, sendo a outra metade destinada à validação. Concluíram também que mais importante que o número de neurônios na camada de entrada é a qualidade destes dados, que podem alterar significativamente os resultados finais. Neste trabalho, os melhores resultados nas previsões de vazões mensais foram obtidos quando da consideração dos dados de entrada da vazão do mês anterior e das precipitações médias mensais do mês atual, do mês anterior e de dois meses anteriores à ocorrência das vazões.

Um modelo de rede neural nebulosa foi desenvolvido em 2003 por [Ballini et al. \(2003\)](#) com o objetivo de prever vazões sazonais. A construção deste modelo foi baseada em um método de aprendizado construtivo onde grupos de neurônios competem entre si quando a rede recebe um novo dado de entrada, onde as regras nebulosas e as funções de pertinência para cada variável de entrada são definidas por meio de parâmetros fundamentais aprendidos pela rede. Para efeito de estudos de casos, o modelo foi aplicado para a obtenção da previsão de vazões médias mensais das usinas de Furnas e Emborcação, localizadas na bacia do rio Paraná e da usina de Sobradinho, localizada na bacia do rio São Francisco. Os resultados da aplicação deste modelo foram comparados com os resultados obtidos pelos modelos de redes neurais e modelos de séries temporais, fornecendo uma melhor previsão 1 passo à frente, com erros em torno de 40% menores que os modelos periódicos auto-regressivos.

Em 2004, [Marinho et al. \(2004\)](#) compararam os resultados obtidos com os modelos *Adaptive Network based Fuzzy Inference System*, conhecido como ANFIS, modelos periódicos auto-regressivos e modelo baseado na técnica de Redes Neurais Artificiais Multi-Camadas (MLP), para a previsão de vazões sazonais. O trabalho também propôs o estudo da relação entre o modelo periódico auto-regressivo e o número de neurônios na camada de entrada dos modelos ANFIS e MLP, baseado no critério BIC. Nestes modelos foi realizada a previsão 1 passo à frente, para a previsão de vazões afluentes aos reservatórios das usinas hidrelétricas Tucuruí (rio Tocantins) e Boa Esperança (rio Parnaíba). Os

---

resultados mostraram que o modelo ANFIS apresentou erros menores comparados com as outras metodologias, para a previsão de vazões afluentes mensais 1 passo à frente.

Também no ano de 2004 [Méndez et al. \(2004\)](#) trabalharam com os modelos estatísticos Box-Jenkins e com modelos baseados na técnica de redes neurais para a previsão de vazões mensais e diárias. O estudo foi realizado com os dados de 3 pontos de medição na calha do rio Xallas, localizado na região nordeste da Espanha, compreendendo o período de 1992 a 1999. Os autores concluíram que os modelos Box-Jenkins são mais adequados para as análises a nível mensal do comportamento chuva x vazão na bacia. Já para a previsão de vazões diárias, os modelos Box-Jenkins não apresentaram resultados satisfatórios e o modelo de redes neurais apresentou-se adequado para esta análise.

Ainda em 2004 [Rajurkar et al. \(2004\)](#) utilizaram a técnica de Redes Neurais Artificiais para modelar as vazões diárias durante eventos de cheias. Os autores analisaram o processo de transformação da chuva em vazão por meio da associação de uma metodologia linear simples com um modelo de redes neurais. O estudo utilizou como dados de entrada informações hidrológicas de duas grandes áreas da Índia e outras cinco áreas pesquisadas pela Organização Mundial de Meteorologia (OMM). O resultado do estudo demonstrou que o modelo considerado é eficiente para locais em diferentes posições geográficas, provando assim sua versatilidade. A rede neural apresentou um desempenho melhor após a substituição de dias anteriores de vazão por um termo que representa a vazão estimada pelo modelo linear simples.

Em 2005, [Lima et al. \(2005\)](#) avaliaram como os modelos baseados na técnica de Redes Neurais Artificiais se adequam ao processo de transformação chuva-vazão e compararam seu desempenho com a performance do modelo hidrológico conceitual MODHAC. Esta adequabilidade, bem como a influência nos parâmetros de ajustes da rede, foram testadas por meio de diversas tipologias de rede consideradas. O estudo considerou como entrada os dados fluviométricos dos postos Icó e Podimirim, localizados na bacia do rio Jaguaribe (CE). Durante as simulações foram alterados os seguintes parâmetros: número de nós nas camadas de entrada e intermediária, período de calibração e a função de transferência. Os resultados constataram a superioridade da modelagem por redes neurais sobre a modelagem hidrológica conceitual, para os dois postos analisados.

[Silva e Silva \(2005\)](#) também em 2005, avaliaram um modelo baseado em redes neurais para a previsão mensal de consumo de água para os sistemas de abastecimento e distribuição de água das cidades do litoral norte do estado de São Paulo. Dentre as redes testadas, a RNA Universal-Região apresentou o melhor desempenho para a previsão mensal do consumo de água, devido o mesma ter sido treinada com um volume maior de dados, o que fez com que aprendesse melhor o comportamento das variações do consumo de água das cidades e, conseqüentemente, realizado o cálculo das previsões

com maior precisão. Já as RNAs de Ubatuba, Caraguatatuba e Ilhabela apresentaram os piores resultados, com taxas elevadas de erro percentual médio. No entanto, os autores concluíram que a metodologia de redes neurais artificiais atendeu o objetivo esperado nesta aplicação.

Os princípios básicos de uma rede neural, as arquiteturas mais comuns e o algoritmo de treinamento foram apresentados por [Valenca e Valenca \(2005\)](#) em 2005 na modelagem do processo chuva x vazão e vazão x vazão. Os autores utilizaram como entrada as informações hidrológicas do posto de Guarapiranga, no período de Janeiro/1978 a Outubro/1986, para a previsão de vazões naturais médias mensais afluentes ao reservatório da UHE Boa Esperança, localizada no rio Parnaíba. Neste trabalho, os autores mostram que para obter um bom resultado com a utilização da técnica de redes neurais alguns aspectos são importantes durante a modelagem da rede e podem ser determinantes na qualidade dos resultados obtidos. Dentre estes aspectos destacam-se: escolha dos conjuntos de treinamento, validação cruzada e verificação; a função objetivo a ser utilizada, tanto para o treinamento (ajuste dos pesos sinápticos) quanto para a validação cruzada e a escolha das métricas para avaliação do desempenho. O modelo utilizado, denominado NeuroHidro ([VALENCA, 2005](#)), mostrou-se como uma ferramenta de fácil utilização e didática para o tratamento destes processos.

Ainda em 2005, [Machado \(2005\)](#) também modelou a relação entre chuva e vazão, em base mensal, através da técnica de Redes Neurais Artificiais. Neste trabalho, o autor considerou durante o treinamento da rede as influências da arquitetura da rede, do número de épocas, da inicialização dos pesos sinápticos e da extensão das séries de dados. Foi desenvolvido um algoritmo computacional que ao final do processo de treinamento gerou 1.296 resultados. O resultado das três melhores RNAs foram confrontados com os resultados calculados pelo modelo conceitual IPHMEN ([TUCCI, 1998](#)) e, em todas as comparações, as RNAs apresentaram desempenho melhor.

Em 2007, [Figueiredo et al. \(2007\)](#) apresentaram modelos de previsão de vazão natural para a bacia do rio Iguaçu, baseados em Redes Neurais Artificiais e métodos estatísticos. O modelo de redes neurais utilizou como entrada medidas de vazão e precipitação observadas e previsões de precipitação utilizando o modelo ETA. Foram avaliadas as MLP-LM e MPL-Bayesiana. Os métodos estatísticos utilizados foram de análise multivariada com incorporação de informações hidrometeorológicas e de regressão dinâmica. O melhor desempenho, tanto no modelo semanal quanto no modelo diário, foi para o modelo com algoritmo *Backpropagation*. A explicação para isto é que a bacia do rio Iguaçu, por ser uma bacia com comportamento complexo, se adequa melhor a modelos de redes neurais (modelos não lineares), apresentando melhores resultados que os modelos estatísticos. O trabalho evidenciou a importância do uso e consideração de variáveis exógenas

nestes estudos, neste caso as chuvas observada e prevista.

Em 2008, [Bravo et al. \(2008\)](#) utilizaram RNAs para estimar a vazão afluente ao reservatório da UHE Furnas, localizada no rio Grande, para o horizonte de 12 dias, com base em previsões quantitativas de chuvas do modelo regional ETA. Os autores apresentaram uma metodologia de treinamento e validação da rede utilizando previsões perfeitas de chuva e o maior número de dados disponíveis. Os resultados do modelo desenvolvido, apresentaram melhores índices de desempenho que os obtidos com o modelo matemático atualmente utilizado operacionamente. Estes resultados mostraram que a consideração de previsões quantitativas de chuva pode aprimorar as previsões de curto prazo de vazão afluentes.

Também em 2008, [Fayal \(2008\)](#) desenvolveu um modelo de previsão de vazões baseado em Redes Neurais Artificiais, denominado MIP (Modelo Inteligente de Previsão), empregando Transformadas Wavelets como ferramenta de pré-processamento de dados. Estas transformadas filtram os dados históricos de vazão, ou seja, as entradas das redes neurais de previsão, dividindo estes dados de entrada (sinais) em diversas escalas, no intuito de que as redes neurais possam melhor analisá-los. O estudo de caso deste trabalho realizou a previsão de vazões naturais incrementais médias diárias e semanais no trecho incremental entre as UHEs Porto Primavera, Rosana e Itaipu, localizadas na bacia hidrográfica do rio Paraná. Além do uso de dados históricos de vazão, analisou-se a eficiência de incorporar ao modelo informações de precipitação observadas na bacia e precipitações previstas para a bacia pelo modelo de previsão climática ETA. Após análise dos resultados, os autores concluíram que a transformação wavelet das séries históricas foi benéfica, pois propiciou consideráveis melhorias nas previsões das redes, diminuindo o MAPE — Erro Percetual Médio Absoluto. Por outro lado, a introdução das chuvas previstas pelo modelo ETA, de modo geral, não agregou valor às previsões.

Em 2009, [Luna et al. \(2009\)](#) propuseram um modelo adaptativo baseado em regras nebulosas, o qual se encontra implementado no módulo de previsão de vazões do HydroPrev, para a previsão de vazões médias semanais das usinas de Ilha Solteira e Três Irmãos, respectivamente localizadas nos rios Paraná e Tietê. Os resultados mostraram a aplicabilidade dos modelos propostos na modelagem de séries de vazões semanais, obtendo modelos de previsão adequados e eficientes, através de um sistema de suporte ao usuário (HydroPrev) e obtendo modelos com desempenho equivalente ou superior ao apresentado pelo PREVIVAZ ([CEPEL, 1997](#)).

Em 2010, [Sousa e Sousa \(2010\)](#) modelaram a relação não-linear entre a chuva e a vazão na bacia hidrográfica do rio Piancó, no semiárido paraibano, por meio da técnica de Redes Neurais Artificiais. Neste trabalho os autores avaliaram a capacidade da RNA de modelar o processo chuva-vazão com discretização mensal, considerando a influência

da arquitetura da rede e da inicialização dos pesos. Ao final do treinamento escolheu-se a melhor arquitetura para modelar as vazões médias mensais na bacia estudada, com base no desempenho do modelo. A melhor arquitetura de RNA apresentou para o coeficiente de determinação, de eficiência e erro padrão os valores de 92, 77% e 8,29, respectivamente.

Nos últimos anos foram desenvolvidas diferentes tecnologias de modelagem do processo de previsão de vazões, dentre as quais destacam-se aquelas com consideração e estimativas climáticas de chuvas, o que tem contribuído para melhorar a qualidade das previsões. Em geral, para simular a previsão do estado atmosférico, utiliza-se o modelo regional ETA, apresentado por [Chou \(1996\)](#). De acordo com [Guilhon et al. \(2007\)](#) o principal motivo de incluir estas últimas informações é o de aproximar ao máximo o ambiente de desenvolvimento às condições reais de dados que estarão disponíveis no ambiente de operação, no qual estes modelos estarão inseridos.

---

## Modelos Computacionais de Previsão de Vazões no Setor Elétrico Brasileiro

---

### 3.1 O Processo de Previsão de Vazões

As previsões de vazões naturais, para todos os locais de aproveitamento hidrelétrico do SIN<sup>1</sup>, são obtidas, com a participação e interação com os agentes de geração, para dois horizontes temporais de previsão: de curtíssimo prazo, até 12 (doze) dias à frente, com discretização em valores médios diários, para fins de programação diária; e de curto prazo, até 6 (seis) semanas à frente, com discretização em valores médios semanais, para o planejamento e programação da operação eletroenergética.

Com o objetivo de atribuir responsabilidades e estabelecer processos para a obtenção e avaliação destas previsões, foi criado o Submódulo 9.5 dos Procedimentos de Rede do ONS, denominado Previsão de Vazões e Geração de Cenários de Afluências (ONS, 2009). Este documento relaciona quais as ferramentas e sistemas computacionais serão utilizados para obtenção destas previsões e define como deverão ser realizadas as análises de consistência dos resultados.

Atualmente, o ONS utiliza diversos modelos computacionais para a obtenção das previsões de vazões. Os principais modelos utilizados são os modelos estocásticos PREVIVAZ (MACEIRA et al., 1999) e PREVIVAZH (CARVALHO et al., 2001), respectivamente, para o horizonte semanal e diário. Outras metodologias e ferramentas computacionais são utilizadas, como: o modelo CPINS para as duas primeiras semanas operativas, para o reservatório da UHE Sobradinho utilizando-se o PREVIVAZ para a terceira semana em diante; o modelo NEURO3M utilizado para a UHE Três Marias (rio São Francisco), baseado na técnica de Redes Neurais Construtivas NSRBN; o modelo MGB-IPH para o trecho incremental entre a UHE Itumbiara e a UHE São Simão (rio

---

<sup>1</sup>A cada local de aproveitamentos hidrelétricos está associado um posto fictício localizado no eixo do barramento.

Paranaíba), que incorpora a previsão de precipitação; o modelo FUZZY para a bacia do rio Iguaçu; o modelo SMAPMEL para o trecho incremental à UHE Itaipu (rio Paraná); o modelo SMAP para a bacia do alto/médio rio Grande até a UHE Porto Colômbia e para a bacia do rio Paranapanema e o modelo MPCV para a bacia do rio Uruguai. Estes últimos são utilizados apenas para a primeira semana do PMO, sendo o modelo PREVIVAZ utilizado para a segunda semana em diante.

Para cada aproveitamento, a cada semana, são fornecidos três valores de previsão, um deles referente ao Valor Esperado - VE da previsão, outro referente ao Limite Inferior - LI de um intervalo de confiança e um terceiro correspondente ao Limite Superior - LS. Estes limites inferiores e superiores destinam-se à realização de análises de sensibilidade para vazões mais elevadas e mais baixas e estão associados a um intervalo de confiança de 95% (equivalente a dois desvios padrão), com exceção das bacias do Jacuí e Uruguai, cuja série histórica possui maior dispersão, nas quais o intervalo de confiança adotado é de 68% (um desvio padrão) (ONS, 2010).

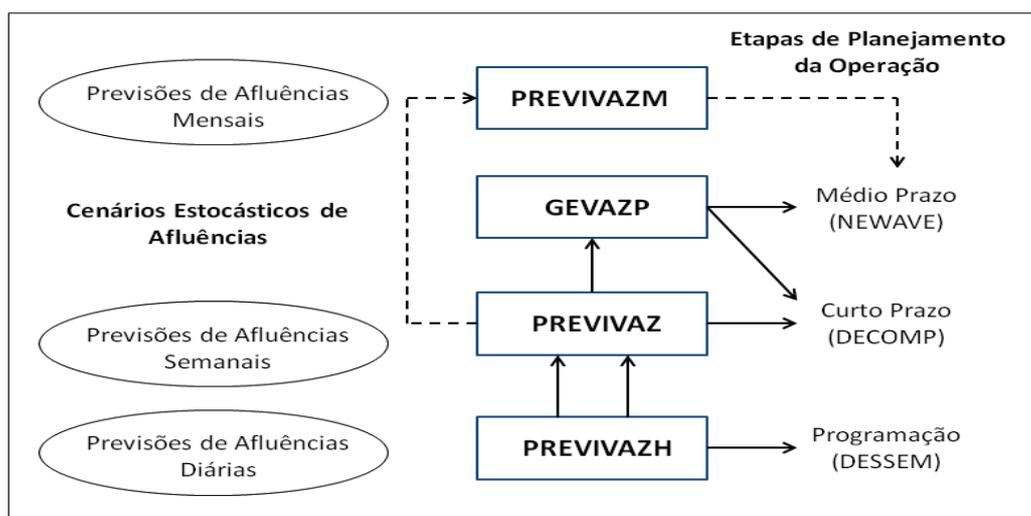
Segundo o Submódulo 9.5 do ONS (ONS, 2009), os valores de previsão de vazões naturais médias diárias são analisados e consolidados pelo ONS com base nos seguintes critérios de consistência:

- (a) inexistência de valores negativos de vazões naturais incrementais médias diárias;
- (b) inexistência de incompatibilidade entre, por um lado, as previsões de vazões naturais médias diárias e, por outro lado, os valores de vazões observadas e os valores de previsão de precipitação na área incremental da bacia hidrográfica.
- (c) inexistência de incompatibilidade nas parcelas relativas às vazões de uso consuntivo e de evaporação líquida que foram adicionadas às vazões previstas.

Na Eletrobras Eletronorte, a previsão de vazões diárias para a UHE Tucuruí é realizada utilizando-se o programa SOH, com o horizonte de 7 dias a frente. Os dados disponíveis são os dados de leitura de régua da rede telemétrica formada pelos postos Marabá, Fazenda Alegria, Conceição do Araguaia, Carolina e Porto Nacional, este último influenciado pela defluência da UHE Lajeado. Após a geração da vazão afluyente ao reservatório, prevista pelo modelo SOH, é realizada a propagação das vazões defluentes dos reservatórios à montante, compondo a vazão natural afluyente prevista.

## 3.2 Os Modelos Auto-Regressivos

Atualmente, o planejamento e programação da operação do SIN é realizado em etapas com o auxílio da cadeia de modelos desenvolvidos pelo CEPEL. Para cada etapa, estes modelos utilizam discretizações do tempo com diferentes graus de detalhamento e horizontes de planejamento. A Figura 3.1 apresenta a interação entre os modelos hidrológicos e a cadeia de planejamento da operação do SIN.



**Figura 3.1:** Interação entre os modelos hidrológicos e a cadeia de planejamento da operação do SIN (ONS, 2010).

Estes modelos adotam uma abordagem que consiste no uso do valor esperado de modelos de séries temporais. Assim sendo, a previsão considera não apenas o comportamento sazonal, como também a tendência hidrológica da série histórica. A tendência hidrológica é o termo utilizado para se referir à tendência observada nas séries históricas de vazões fluviais naturais, de valores superiores/inferiores ao valor normal do período serem seguidos e precedidos por valores também superiores/inferiores ao valor normal (COSTA; MACEIRA; DAMAZIO, 2007).

### 3.2.1 O Modelo PREVIVAZ

O modelo PREVIVAZ (CEPEL, 1997) foi desenvolvido visando a obtenção das previsões de afluências semanais, até 6 (seis) semanas à frente, para serem utilizadas no primeiro mês do planejmaneto de curto prazo (PMO e suas revisões). Esse modelo, para cada aproveitamento hidrelétrico, analisa a sua série histórica de afluências semanais e seleciona, para cada semana, um modelo estocástico entre diversas alternativas de modelagem estocástica de vazões semanais. As alternativas de modelagem estocástica de vazões semanais são:

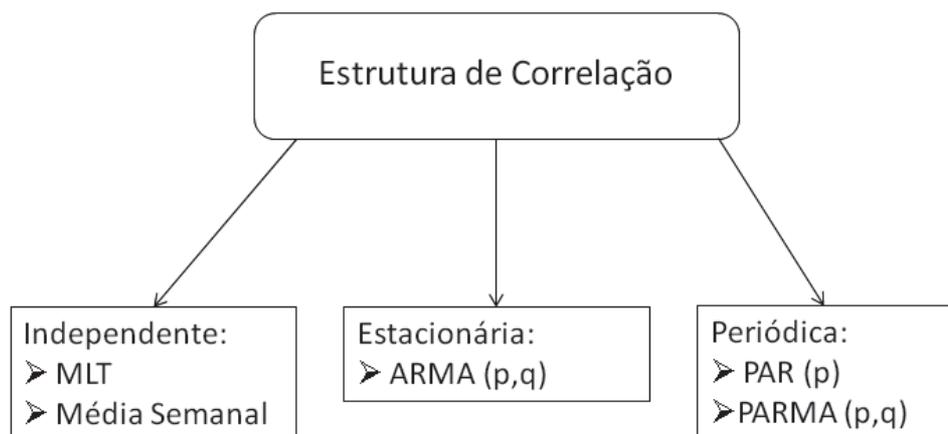
- modelos auto-regressivos  $AR(p)$  ( $1 \leq p \leq 4$ ), estimação dos parâmetros pelo método dos momentos e estrutura de correlação estacionária.
- modelos auto-regressivos média-móvel  $ARMA(p,1)$  ( $1 \leq p \leq 3$ ), estimação dos parâmetros pelo método dos momentos e estrutura de correlação estacionária.
- modelos auto-regressivos periódicos  $PAR(p)$  ( $1 \leq p \leq 4$ ), estimação dos parâmetros pelo método dos momentos, agrupamento da estrutura de autocorrelação por semana, por mês, por trimestre e por semestre.
- modelos auto-regressivos periódicos  $PAR(p)$  ( $1 \leq p \leq 4$ ), estimação dos parâmetros por regressão linear com respeito à origem da previsão e estrutura de correlação sazonal.
- modelos auto-regressivos médias-móveis periódicos  $PARMA(p,1)$  ( $1 \leq p \leq 3$ ), estimação dos parâmetros pelo métodos dos momentos, agrupamento da estrutura de autocorrelação por semana, por mês, por trimestre e por semestre.
- modelos auto-regressivos médias-móveis periódicos  $PARMA(p,1)$  ( $1 \leq p \leq 3$ ), estimação dos parâmetros por regressão linear e estrutura de correlação sazonal.
- modelos auto-regressivos médias-móveis periódicos  $PARMA(p,1)$  ( $1 \leq p \leq 3$ ), estimação dos parâmetros por regressão linear com respeito a origem da previsão e estrutura de correlação sazonal.
- modelo média sazonal, estimação dos parâmetros pelo método dos momentos e previsão pela média da semana.
- modelo constante, estimação dos parâmetros pelo método dos momentos e previsão pela média anual <sup>2</sup>.

Na abordagem clássica de uso dos modelos estocásticos, desenvolvida por [Box e Jenkins \(1976\)](#), as previsões de vazões são obtidas por meio de equações matemáticas cujas estruturas e números de termos foram estatisticamente identificados e os coeficientes eficientemente estimados, utilizando toda a informação disponível ([COSTA; MACEIRA; DAMAZIO, 2007](#)). A Figura 3.2 apresenta a abordagem da estrutura de correlação.

A escolha entre as modelagens é feita objetivando o uso mais eficiente e robusto da informação contida nos registros recentes de aflúncias semanais ao aproveitamento analisado. Isso é feito tendo como base a média dos desvios-padrão dos erros de previsão das alternativas de modelagem calculados para a primeira metade da série histórica, tendo-se estimado os parâmetros com a segunda metade e, para a segunda metade da série

---

<sup>2</sup>O modelo de previsão constante corresponde à média anual das 52 (ou 53) semanas



**Figura 3.2:** Abordagem da estrutura de correlação - Adaptado (ONS, 2010)

histórica, tendo-se estimado os parâmetros com a primeira metade. O modelo estocástico escolhido será aquele que apresentar a menor média de desvio-padrão do erro da previsão. Os parâmetros do modelo são, então, obtidos por meio da utilização de toda a série (CEPEL, 1997).

### 3.2.2 O Modelo PREVIVAZM

O modelo PREVIVAZM (COSTA et al., 2003) tem como objetivo fornecer previsões mensais de afluências a aproveitamentos hidroelétricos do SIN para um horizonte de até 12 meses, sendo uma ferramenta para estudos especiais de verificação das condições de atendimento da demanda energética no horizonte anual (COSTA; MACEIRA; DAMAZIO, 2007). Esse modelo segue a mesma abordagem do modelo PREVIVAZ, adaptando-a ao intervalo mensal e ao horizonte de 12 meses, mantendo-se o procedimento de estimação e escolha do melhor algoritmo de previsão.

As alternativas de modelagem estocástica de vazões mensais são as mesmas adotadas no modelo semanal PREVIVAZ, excluindo-se os modelos auto-regressivos médias-móveis periódicos PARMA( $p,1$ ) ( $1 \leq p \leq 3$ ), estimação dos parâmetros por regressão linear com respeito à origem da previsão.

A escolha entre as modelagens também é feita objetivando o uso mais eficiente e robusto da informação contida nos registros recentes de afluências mensais ao aproveitamento analisado e segue o mesmo procedimento do modelo PREVIVAZ. A sequência abaixo apresenta cada passo do algoritmo de previsão:

- **Passo 1:** calcular as estatísticas amostrais da série total e de cada metade da série (parte 1 e parte 2).

- **Passo 2:** calcular os parâmetros para cada modelo (140 para o PREVIVAZ e 90 para o PREVIVAZM) das 3 séries (série total, parte 1 e parte 2) utilizando as estatísticas calculadas no passo anterior.
- **Passo 3:** fazer a previsão utilizando todos os modelos definidos com a parte 1 da série (primeira metade).
- **Passo 4:** fazer a previsão utilizando todos os modelos definidos com a parte 2 da série (segunda metade).
- **Passo 5:** fazer a verificação utilizando a 1<sup>a</sup> e a 2<sup>a</sup> partes da série calculando o erro médio de previsão padrão dentre os dois erros definidos anteriormente.
- **Passo 6:** ordenar os  $N$  modelos para cada semana (ou mês) em ordem crescente da média dos erros.
- **Passo 7:** fazer a previsão com o modelo de 1<sup>a</sup> ordem, ou seja, utilizar o modelo que apresentou o menor erro médio de previsão padrão para a semana (mês) a ser prevista. Utilizar a tendência hidrológica (últimos valores observados).
- **Passo 8:** utilizar a previsão do passo  $t$  para fazer a previsão do passo  $t+1$  e utilizar o modelo que para essa semana (mês) apresentou o menor erro médio de previsão padrão.

### 3.2.3 O Modelo PREVIVAZH

O modelo PREVIVAZH (CARVALHO et al., 2001) é um modelo de natureza estocástica, desenvolvido visando a obtenção de vazões diárias, até 14 dias à frente. As previsões são baseadas na desagregação, em intervalos diários, das previsões de afluência semanais obtidas pelo modelo PREVIVAZ e uma metodologia de desagregação não paramétrica dessas afluências em valores diários que faz uso das últimas afluências diárias e de séries sintéticas de vazões diárias.

O resultado das previsões obtidas do modelo PREVIVAZH pode ser utilizado em diferentes etapas, dentre as quais cita-se: na etapa de programação diária, na programação da operação de controle de cheias, para completar os últimos dias da afluência semanal da semana em curso, usada como “última vazão observada” para realizar a previsão semanal no PMO e como previsão semanal, considerando a média das previsões dos 7 dias da semana.

A geração de séries sintéticas de afluências diárias se baseia no modelo DIANA (KELMAN; DAMASIO; COSTA, 1983), alterado para condicionar a geração de sequências às informações hidrológicas recentes, ou seja, às duas últimas afluências diárias ob-

servadas. Esse modelo considera que as vazões diárias ( $Q$ ) podem ser decompostas em duas parcelas: uma parcela dependente de fatores externos (por exemplo, a precipitação) e outra que representa o contínuo esvaziamento da bacia. A vazão no dia  $t$  da hidrógrafa de um dado posto fluviométrico é dada pela soma de dois componentes:

$$Q(t) = U(t) + O(t), t = 1, 2, 3, \dots \quad (3.1)$$

Idealmente,  $U(t)$  dependeria principalmente de fatores externos (por exemplo, a precipitação), cuja natureza intermitente ocasionaria na hidrógrafa pulsos irregularmente espaçados no tempo e  $O(t)$  representaria o contínuo esvaziamento da água armazenada na bacia. Considera-se a ocorrência de  $u(t)$  positivo sempre que  $q(t) > \lambda q(t-1)$ , onde  $0 \leq \lambda \leq 1$  é uma taxa de recessão característica do posto fluviométrico. Assim, para qualquer  $\lambda$  teríamos:

$$u(t) = 0 \quad \text{se} \quad q(t) \leq \lambda q(t-1) \quad (3.2)$$

$$u(t) = q(t) - \lambda q(t-1) \quad \text{se} \quad q(t) > \lambda q(t-1) \quad (3.3)$$

$$q(t) = \lambda q(t-1) + u(t), \quad u(t) > 0 \quad (3.4)$$

Nos dias em que os fatores externos não atuam ( $u(t) = 0$ ), a vazão total é dada simplesmente por  $O(t)$ , a qual pode ser considerada como a soma das defluências de dois reservatórios lineares, cada parcela dependendo de  $q(t-1)$  através de uma equação probabilística. Esta abordagem pode ser simplificada considerando-se apenas um reservatório linear de comportamento estocástico. Assim, quando  $u(t) = 0$ ,  $O(t)$  e  $q(t)$  são uma fração  $k(t) \leq \lambda$  da vazão anterior:

$$q(t) = O(t) = k(t)q(t-1), \quad k(t) \leq \lambda; \quad u(t) = 0 \quad (3.5)$$

Juntando-se as equações (3.1), (3.4) e (3.5) o modelo pode ser escrito pelas equações:

$$q(t) = u(t) + k(t)q(t-1) \quad (3.6)$$

$$u(t) = 0 \rightarrow k(t) \leq \lambda \quad u(t) > 0 \rightarrow k(t) = \lambda \quad (3.7)$$

Na modelagem do processo  $U(t)$  dois aspectos devem ser considerados: a forma como a sua distribuição de probabilidade marginal é definida, já que existe uma probabilidade finita  $p$  de que  $U(t)$  seja exatamente igual a zero e a preservação da eventual dependência entre valores sucessivos de  $U(t)$ .

Com relação à dependência entre  $U(t-1)$  e  $U(t)$ , o modelo assume que existe um processo auto-regressivo normal de ordem 1 com censura, cujo coeficiente de preservação  $\rho$  deve ser preservado. Por meio de uma transformação não-paramétrica de  $U(t)$  este processo é mapeado de forma a preservar as distribuições empíricas. Seja o processo markoviano  $Z(t)$  definido pela Equação (3.8), onde  $\varepsilon(t)$  é um ruído normal padrão e  $\rho$  a correlação *lag-1* do processo.

$$z(t) = \rho z(t-1) + \varepsilon(t) \sqrt{1 - \rho^2} \quad (3.8)$$

Seja o processo  $Y(t)$  resultado de uma censura imposta ao processo  $Z(t)$  definido pela Equação (3.9), onde  $\beta$  define o intervalo de censura  $(\infty, \beta)$ ,  $\theta(\cdot)$  é a distribuição acumulada normal e  $p = P[u(t) = 0]$ . A relação entre  $U(t)$  e  $Y(t)$  é obtida resolvendo-se  $F_U(u) = \theta(y(t))$ .

$$Y(t) = Z(t) \quad \text{se} \quad Z(t) > \beta \quad (3.9)$$

$$Y(t) = \beta \quad \text{se} \quad Z(t) \leq \beta \quad (3.10)$$

$$\beta = \theta^{-1}(p) \quad (3.11)$$

Para a modelagem da série de  $k(t)$  assume-se que seja suficiente simplesmente usar para a geração de valores sintéticos a distribuição empírica de  $k(t)$  menor que  $\lambda$ ,  $FK(\cdot)$ , sempre que  $u(t) = 0$  e  $k(t) = q(t)/q(t-1)$ .

O processo de desagregação da previsão da afluência semanal  $QS_1$ , em previsões para os 7 dias da semana, pode ser descrito, resumidamente, da seguinte forma:

Consideram-se disponíveis a vazão semanal prevista para a semana que se inicia no dia  $i = 1$ ,  $QS_1$ , e as duas últimas vazões diárias observadas, referentes aos dias  $i = 1$  e  $i = 0$ , respectivamente  $QD_1$  e  $QD_0$ .

- **Passo 1:** Gera-se um conjunto de  $M$  sequências sintéticas de 7 vazões diárias,  $QD_1^m; i = 1, \dots, 7; m = 1, \dots, M$ .

- **Passo 2:** do conjunto de  $M$  seqüências, seleciona-se aquela cuja vazão média semanal seja a mais próxima à  $QS_1$  para formar a previsão das vazões dos dias  $i = 1, 2, \dots, 7$ .

Cabe ressaltar que a previsão semanal  $QS_1$  é obtida a partir de valores médios de aflúências para semanas anteriores. É possível que as últimas aflúências diárias observadas,  $QD_1$  e  $QD_0$ , estejam sinalizando que a previsão  $QS_1$  esteja bastante deslocada da realidade. Eventuais discrepâncias devem ser consideradas no processo de escolha de seqüência sintética a ser utilizada como previsão das aflúências diárias para os dias da semana em curso.

No modelo PREVIVAZH o grau de discrepância entre  $QS_1$  e as aflúências diárias observadas é avaliado localizando o valor de  $QS_1$  na distribuição de frequência das  $M$  médias semanais,  $\overline{QD}^m, m = 1, \dots, M$ , correspondentes às seqüências sintéticas geradas no passo 1. Sempre que os valores de  $QS_1$  estiver contido num intervalo de aceitação de  $QS_1$  formado, por exemplo pelos quantis 5% ( $\overline{QD}_{5\%}$ ) e 95% ( $\overline{QD}_{95\%}$ ), nível de confiança de 90%, considera-se que não há discrepância entre  $QS_1$  e as aflúências diárias já ocorridas e o passo 2 é executado normalmente. Se o valor de  $QS_1$  estiver fora deste intervalo, considera-se que há grande discrepância entre  $QS_1$  e o conjunto formado pelas aflúências diárias já ocorridas. Neste caso, o valor médio utilizado para a seleção da seqüência sintética é a média das  $M$  médias semanais ( $media\overline{QD}^m$ ). Caso  $QS_1 \leq \overline{QD}_{5\%}$ , no passo 2, o valor de média utilizado para a seleção da seqüência sintética é obtido interpolando-se na reta definida pelos pontos ( $min\overline{QD}^m, media\overline{QD}^m$ ) e ( $\overline{QD}_{5\%}, \overline{QD}_{5\%}$ ). Finalmente, no caso  $QS_1 \geq \overline{QD}_{95\%}$ , interpola-se na reta definida pelos pontos ( $max\overline{QD}^m, media\overline{QD}^m$ ) e ( $\overline{QD}_{95\%}, \overline{QD}_{95\%}$ ). O nível de confiança do intervalo de aceitação de  $QS_1$  deve ser ajustado de acordo com as características de previsibilidade da vazão semanal da bacia em estudo.

Esta modelagem apresentada no PREVIVAZH, além da vantagem da menor complexidade em relação aos modelos chuva-vazão, garante a preservação da estrutura de dependência temporal das previsões semanais utilizadas no planejamento de curto prazo e incorpora as características do processo natural a nível diário. No entanto, tais modelos apresentam determinadas limitações, por não serem capazes de representar a não-linearidade e a variabilidade espacial e temporal, características deste processo.

## 3.3 Modelos Baseados na Técnica de Redes Neurais Artificiais

### 3.3.1 Fundamentos das Redes Neurais

Os primeiros estudos que estabeleceram as bases da neurocomputação foram desenvolvidos, em 1943, pela dupla formada pelo neurofisiologista Warren McCulloch e o matemático Walter Pitts (MCCULLOUGH; PITTS, 1943). Os autores sugeriram a construção de uma máquina inspirada no cérebro humano, que consistia em um modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio.

Em 1949, o psicólogo Donald Hebb (HEBB, 1949) apresentou em seu livro *The Organization of Behavior* as regras de aprendizagem das redes neurais. Pela primeira vez foi explicado o que ocorre no cérebro, no nível celular, durante o processo de aprendizado, com ênfase na forma como a informação é armazenada e recuperada. O autor propôs a utilização de pesos como uma ferramenta capaz de fazer com que uma rede neural artificial assimile o conhecimento.

A implementação das regras de aprendizagem ficou a cargo de Frank Rosenblatt (ROSENBLATT, 1958). Em 1958, o pesquisador apresentou a rede neural denominada *Perceptron* de uma camada com capacidade de aprender e identificar padrões conforme as regras propostas por Hebb.

Em 1960, Widrow e Hoff (??) apresentaram uma regra de aprendizagem para uma extensão da rede *Perceptron*, denominada ADALINE (*Adaptive Linear Neuron*). Esta regra ficou conhecida como regra delta e baseia-se no método dos mínimos quadrados.

Em 1969, com a publicação do livro denominado “*PERCEPTRON*” pelos autores Marvin Minsky e Seymour Papert (MINSKY; PAPERT, 1969) os investimentos em pesquisas para esta tecnologia diminuíram, uma vez que os autores criticaram seriamente as redes *Perceptron*, alegando que elas utilizavam processos de aproximação empíricos e apenas eram capazes de distinguir padrões linearmente separáveis.

Os estudos das RNA ressurgiram em 1974 com o desenvolvimento do algoritmo *backpropagation* pelo pesquisador Paul Werbos (WERBOS, 1974), apresentado à comunidade científica apenas em 1986, por meio da publicação feita por Rumelhart e McClelland (RUMELHART; MCCLELLAND, 1986).

As Redes Neurais Artificiais são uma técnica integrante dos Sistemas Inteligentes, inspirados no comportamento humano ou da natureza, basicamente do exame das estruturas do cérebro, em particular dos neurônios. Este conceito advém do funcionamento do neurônio biológico, que recebe uma série de dados de entrada advindos do corpo hu-

mano ou do ambiente externo a ele, convertendo os dados ou informações de entrada em uma outra informação ou dado de saída (ALBANO; VALENCA; PORTO, 2007).

O neurônio biológico é formado pelas seguintes partes: o corpo celular (onde se encontra o núcleo celular), os dendritos (prolongamentos numerosos e curtos do corpo celular, receptores de mensagens), o axônio (prolongamento que transmite o impulso nervoso vindo do corpo celular) e os telodendritos (terminais do axônio), como mostra a Figura 3.3. A comunicação entre o dendrito de um neurônio e os telodendritos de outro é denominado sinapse. O cérebro humano é formado por cerca de 10 bilhões de neurônios que se interconectam formando uma rede capaz de aprender, de indentificar padrões de comportamento, de executar operações e comparações e de processar milhões de informações em paralelo.

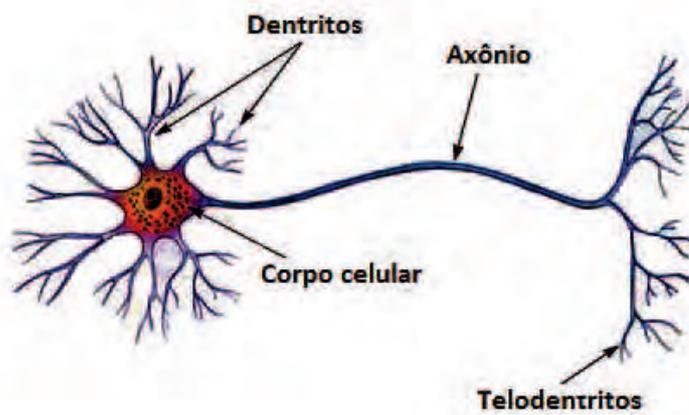


Figura 3.3: Neurônio biológico

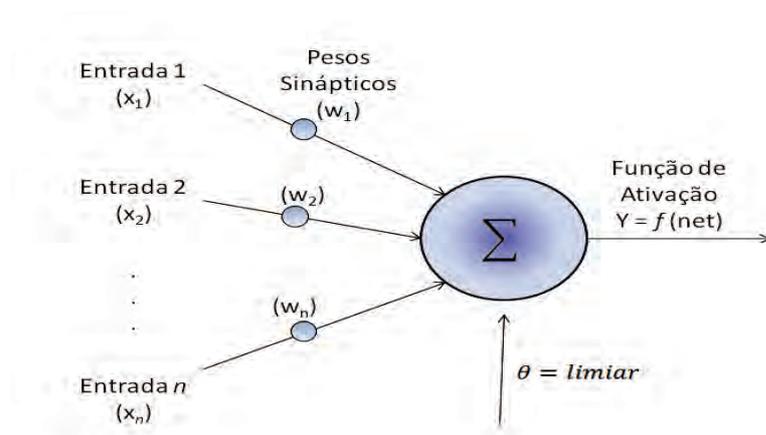
Valenca (2005) define uma Rede Neural Artificial como um sistema constituído por elementos de processamento interconectados, chamados de neurônios, os quais estão dispostos em camadas (uma camada de entrada, uma ou várias camadas intermediárias e uma camada de saída) e são responsáveis pela não-linearidade e pela memória da rede.

O neurônio artificial, utilizado para caracterizar o neurônio biológico, constitui o elemento básico de uma Rede Neural Artificial. A primeira proposta de uma representação matemática para representar o neurônio biológico foi feita por (MCCULLOUGH; PITTS, 1943), conforme apresentado na Figura 3.4.

Considere as variáveis de entrada  $x_1, x_2, x_3, \dots, x_n, x_j (j = 1, \dots, n)$  do neurônio de saída  $i$ . A entrada líquida  $net_i$  é dada pela seguinte regra de propagação:

$$net_i = \sum_{j=1}^n w_{ij}x_j - \theta \quad (3.12)$$

onde:  $w_{ij}$  são os pesos sinápticos e  $\theta$  é o limiar.



**Figura 3.4:** Neurônio artificial - Adaptado McCullough e Pitts (1943)

A função de ativação  $f(net_i)$  é a própria unidade de processamento que recebe o estímulo, resultado do somatório, e transfere a resposta aos neurônios adjacentes. No modelo matemático, a função de ativação limita a amplitude do neurônio no intervalo entre  $[0,1]$ . Logo, a função de ativação é uma função degrau definida como:

$$y = \begin{cases} 1, & \text{se } \forall net_i \geq 0 \\ 0, & \text{se } \forall net_i < 0 \end{cases}$$

A utilização da função de ativação permite que as redes neurais identifiquem relações lineares e não lineares entre as variáveis de entrada e de saída. Essas funções poderão possuir características restritivas. Isto acontece quando um estímulo for inferior a determinado valor mínimo e não produzirá efeito no neurônio seguinte, prejudicando toda a rede.

É mais adequado considerar o limiar implicitamente nos algoritmos de aprendizagem. Para isto, é necessário fazer duas modificações:

- adicionar uma nova entrada de valor fixo  $x_0 = +1$ .
- acrescentar um novo peso sináptico  $w_{10} = -\theta$  (limiar).

Assim, tem-se:

$$net_i = \sum_{j=1}^n w_{ij}x_j + (+1) \cdot (-\theta) \quad (3.13)$$

Substituindo-se  $w_{10} = -\theta$  e  $x_0 = +1$ :

$$net_i = \sum_{j=1}^n w_{ij}x_j + w_{10}x_0 \quad (3.14)$$

E finalmente,

$$net_i = \sum_{j=0}^n w_{ij}x_j \quad (3.15)$$

### 3.3.2 Redes Perceptron

*Perceptron* é o modelo mais simples de rede neural, no qual várias unidades de processamento estão conectadas unicamente a uma unidade de saída, através dos pesos sinápticos (ROSENBLATT, 1958), conforme apresentado na Figura 3.5. Essas Redes Neurais Artificiais têm a capacidade de aprender por meio de uma regra de aprendizagem responsável pela modificação dos pesos sinápticos, em função dos exemplos repetidamente apresentados.

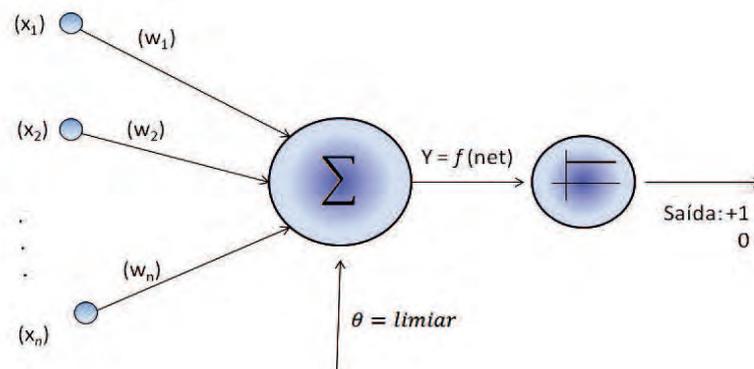


Figura 3.5: Perceptron - Adaptado Rosenblatt (1958)

(VALENCA, 2010) define o *Perceptron* como uma rede neural que é composta por uma camada de entrada onde estão as informações que alimentam a rede (as variáveis de entrada), uma função soma (entrada líquida) que pondera estas entradas através de pesos (chamados pesos sinápticos) e uma função de saída (função degrau), também chamada de função de ativação que fornece o sinal emitido pelo neurônio da camada de saída.

Uma vez que as RNA aprendem por exemplos, para a sua utilização é necessário que ela passe por um processo de treinamento. Esse processo consiste em ajustar os pesos entre as conexões até que se minimize o erro na camada de saída. Os dois tipos de treinamento são:

- **Treinamento Supervisionado:** o treinamento da rede é realizado com o conhecimento prévio do resultado desejado, assim são fornecidos para a rede os pares de entrada e saídas. Se a diferença entre a saída obtida e a saída desejada estiver fora dos limites satisfatórios, os pesos entre as conexões são ajustados. Este processo é repetido até a obtenção de um erro mínimo aceitável.
- **Treinamento Não-Supervisionado:** também conhecido por auto-supervisionado, neste treinamento a rede aprende com os próprios dados de entrada, ou seja, o algoritmo não requer o conhecimento das saídas.

As RNA do tipo *Perceptron* são treinadas por meio do método de treinamento supervisionado. O algoritmo de treinamento do *Perceptron*, sugerido por Widron e Hoff (WIDROW; HOFF, 1960), é conhecido como regra delta, vide (3.16). Atribui-se aos pesos valores aleatórios, calcula-se a resposta e o erro na saída da rede, caso este erro seja inaceitável, faz-se o ajuste dos pesos proporcionalmente ao erro.

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n) \quad (3.16)$$

onde,  $w_{ij}(n+1)$  é o valor do peso corrigido na conexão  $ij$  na iteração  $(n+1)$ .  $w_{ij}(n)$  é o valor antigo do peso na conexão  $ij$  na iteração  $(n)$ .  $\Delta w_{ij}(n)$  é a variação do valor do peso na conexão  $ij$  proporcional ao erro na iteração  $(n)$ .

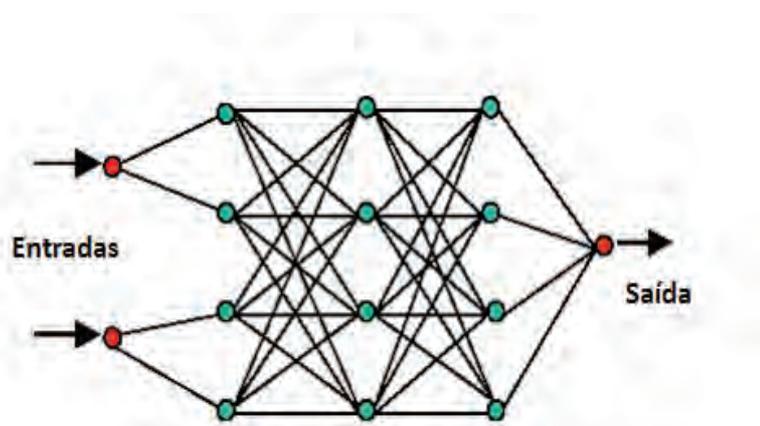
Este algoritmo garante que o valor do erro diminua ao longo das iteração, por meio dos ajustes dos pesos, garantindo que a convergência seja atingida com um número finito de iterações. No entanto, o *Perceptron* apresenta duas limitações:

- capacidade de classificar apenas padrões linearmente separáveis.
- ao utilizar uma função de ativação do tipo degrau, o *Perceptron* fornece como saída apenas um sinal discreto (sim ou não), de tal forma que possui dificuldade de trabalhar com padrões ruidosos. A solução para este problema seria a utilização de uma função de ativação contínua na camada de saída, obtida apenas com o desenvolvimento das redes ADALINE.

### 3.3.3 Redes MLP

A rede *Perceptron* Multicamadas ou *Multilayers Perceptron* — MLP é uma generalização da rede *Perceptron* proposta por Rumelhart, com a adição de uma ou mais camadas intermediárias, também conhecidas como camadas escondidas. Desta forma, os neurônios da rede neural serão dispostos nas camadas, descritas abaixo e apresentadas na Figura 3.5:

- **camada de entrada:** recebe os dados de entrada e não realiza nenhum processamento, servindo apenas para distribuí-los na camada subsequente.
- **camada intermediária:** onde os neurônios realizam o processamento dos dados, por meio de regras de propagação e funções de ativação sigmoidal (logística ou tangente hiperbólica), suas entradas e saídas permanecem dentro do sistema.
- **camada de saída:** responsável pela resposta da rede e representa a variável desejada. Os neurônios também possuem uma função de ativação (logística ou tangente hiperbólica) ou uma simples função linear.



**Figura 3.6:** Estrutura da rede MLP - Adaptado *Marinho et al. (2004)*

O número de neurônios na camada intermediária é definido empiricamente, os melhores resultados são obtidos por meio do processo de tentativa e erro. A utilização de um grande número de camadas não é recomendável, uma vez que o erro médio se torna menos útil e preciso cada vez que o treinamento é utilizado para atualizar os pesos das sinapses das camadas anteriores.

A função de ativação é responsável por solucionar a não linearidade das redes neurais. Conforme citado, elas podem ser de dois tipos:

- Função Sigmóide Logística:

$$\vartheta(v) = \frac{1}{1 + e^{-v}} \quad (3.17)$$

- Função Sigmóide Tangente Hiperbólica:

$$\vartheta(v) = \frac{2}{1 + e^{-2v}} - 1 \quad (3.18)$$

Para o treinamento de uma rede neural é necessário que se defina um algoritmo que permita estabelecer o conjunto de pesos ótimos a serem ajustados. O algoritmo tradicionalmente utilizado para o treinamento das redes MLP é o algoritmo *backpropagation*, desenvolvido pelo pesquisador Paul Werbos (WERBOS, 1974). As redes neurais do tipo MLP são treinadas de maneira supervisionada, ou seja, o algoritmo *backpropagation* é capaz de resolver problemas encontrados durante o treinamento da rede, propagando de forma recursiva os erros nas camadas intermediárias.

Dentro de uma rede do tipo MLP o fluxo de informações ocorre em uma única direção, denominado *feedforward*, o que significa que os dados de entrada propagam-se através da rede, camada por camada, em sentido progressivo, com o posterior cálculo do erro de saída. Em seguida, por meio do reajuste dos pesos sinápticos, ocorre a retropropagação do erro de forma a minimizá-lo.

Várias etapas deverão ser analisadas durante o processo de modelagem de uma rede neural do tipo MLP. Estas etapas incluem: a divisão dos dados, a normalização dos dados, a seleção das variáveis de entrada e de saída do modelo, a determinação da arquitetura ótima, o processo de treinamento e a verificação do desempenho da rede neural.

#### (a) Divisão dos Dados

Segundo (VALENCA, 2005), o conjunto de dados deve ser dividido em três subconjuntos independentes, isto é, um conjunto para ajustar os pesos durante o treinamento, um conjunto para a validação cruzada e um conjunto para a verificação.

- conjunto para o treinamento: conjunto de dados utilizado para ajustar os pesos da rede neural, normalmente corresponde a 50% da amostra de dados.
- conjunto para a validação cruzada: conjunto de dados utilizado para informar à rede o momento de parar o treinamento, de forma a evitar que a mesma perca a sua capacidade de generalização, normalmente corresponde a 25% da amostra de dados. Estes dados são utilizados na etapa de cálculo da função erro, de forma a interromper o treinamento quando esta atingir seu ponto de mínimo global.
- conjunto para a verificação: conjunto de dados utilizado para avaliar o desempenho da rede neural, normalmente corresponde aos 25% restantes da amostra de dados.

Esta divisão dos dados pode ter impacto significativo nos resultados. Quando os dados não são divididos adequadamente e possuem intervalos distintos de variação para os subconjuntos a modelagem ficará prejudicada, uma vez que as redes neurais serão inábeis

para generalizar quando utilizadas em um conjunto com intervalo de variação diferente ao do treinamento, ou seja, quando submetida a um conjunto de verificação para o qual não são estatisticamente compatíveis com os de treinamento, (FLOOD; KARTAN, 1994), (MINNS; HALL, 1996).

### (b) Normalização dos Dados

Segundo (VALENCA, 2010) todas as variáveis de entrada deverão ser normalizadas para assegurar que elas recebam igual atenção durante o processo de treinamento. Se os dados não forem divididos adequadamente e possuírem diferentes intervalos de variação, a modelagem poderá ser prejudicada, uma vez que as redes neurais não serão capazes de generalizar quando submetida a um conjunto de verificação.

Outrossim, as variáveis devem ser normalizadas de tal maneira que seus valores sejam proporcionais aos limites das funções de ativação utilizadas na camada de saída. Caso utilizemos na saída a função logística como função de ativação, seus valores estarão limitados entre [0,00-1,00], assim os dados serão geralmente normalizados entre os intervalos [0,10-0,90] e [0,15-0,85].

Os principais tipos de normalização são:

- transformação linear:  $y = (b - a)(x_i - x_{min}) / (x_{max} - x_{min}) + a$ .
- normalização estatística:  $y = (x_i - \bar{x}) / s$ .
- normalização simples:  $y = x_i / x_{max}$ .

onde:  $y$  é o valor normalizado,  $x_i$  é o valor original,  $x_{min}$  é o valor mínimo da variável,  $x_{max}$  é o valor máximo da variável,  $\bar{x}$  é o valor médio da variável,  $a$  e  $b$  são os limites e  $s$  o desvio padrão.

### (c) Seleção das Variáveis de Entrada

A seleção correta das variáveis de entrada é uma das tarefas mais importantes enfrentadas quando do projeto de uma rede neural.

Segundo Valença e Ludermir (VALENCA; LUDERMIR, 2007), quando se aplica rede neural para resolver problemas em sistemas ambientais complexos, o número de entradas potenciais pode ser grande, particularmente quando o processo em estudo é dinâmico e requer a inclusão de variáveis auto-regressivas como entrada. Apresentar todas as entradas potenciais a uma RNA aumenta o tamanho e a complexidade da rede, o que

pode retardar o treinamento e aumentar a quantidade de dados requeridos para estimar os parâmetros livres ou pesos da rede. Somado a isso, a inclusão de entradas irrelevantes pode prejudicar o processo de treinamento, tendo por resultado correlações indevidas nos dados que estão sendo modelados.

Em alguns exemplos as variáveis de entrada são selecionadas com base em análises estatísticas, tais como: a análise de correlação, a técnica *stepwise*, a análise de componentes principais, pelo processo de tentativa e erro ou pelo uso de uma rede polinomial do tipo GMDH (VALENCA; VALENCA, 2005). A vantagem dessa última técnica é que ela pode captar características de dependência linear e não linear entre as diferentes variáveis, o que não ocorre com as técnicas estatísticas lineares tradicionalmente utilizadas. Técnicas de otimização em conjunto com as rede neurais também podem ser utilizadas, dentre as quais cita-se: algoritmos genéticos, colônia de formigas e enxame de partículas.

#### **(d) Inicialização dos Pesos**

Os pesos das conexões sinápticas são responsáveis por armazenar o conhecimento da rede neural e, matematicamente, definem um ponto na superfície da função objetivo. Se os pesos definidos forem os pesos ótimos, o conjunto dos pesos representará o ponto de mínimo da superfície. Entretanto, é comum que o processo de otimização conduza a solução para um mínimo local, (MACHADO, 2005) diz que as redes neurais do tipo MLP geram superfícies muito irregulares e que o risco de chegar em uma solução ótima local é muito alto. Desta forma, evitar que a solução do problema recaia em um mínimo local está diretamente correlacionada com a escolha dos pesos iniciais.

O trabalho de (TAFNER; XEREZ; FILHO, 1996) alerta também quanto à escala de valores dos pesos iniciais. Os autores citam que pesos iniciais com valores muito altos tornam a ação das funções de ativação restritivas, fazendo com que os gradientes locais assumam valores pequenos e que diminua a velocidade do processo de aprendizagem. Por outro lado, quando os valores iniciais são muito pequenos, o método de otimização poderá operar em uma região muito plana.

#### **(e) Seleção da Arquitetura da Rede Neural**

A definição da arquitetura de uma rede neural fica determinada quando se define o número de camadas intermediárias e a quantidade de neurônios em cada camada. (VALENCA, 2010) sugere que a definição desta rede seja feita com cuidado, pois uma quantidade excessiva de neurônios pode levar a perda de capacidade de generalização da rede. Diz-se neste caso que a rede foi superajustada (*overfitting*). Por outro lado, se

a quantidade de neurônios for pequena, a rede perde sua capacidade de aproximação, ficando subajustada (*underfitting*).

A definição da arquitetura da rede é uma tarefa que depende de vários fatores, entre os quais se destacam: número de neurônios na camada de entrada e na camada de saída, número de exemplos disponíveis para treinamento e a própria complexidade do problema a ser modelado. Na maioria dos trabalhos analisados, inclusive para as redes MLP, o número ótimo de neurônios na camada escondida é obtido por meio do processo de tentativa e erro.

As redes construtivas têm como característica principal a utilização de um algoritmo que aperfeiçoa a arquitetura da rede, ou seja, o número de neurônios na camada intermediária é determinado automaticamente pelo algoritmo de treinamento. Essas redes funcionam como aproximadores universais de funções e de arquitetura o que facilita sua utilização por usuários não especialistas em redes neurais.

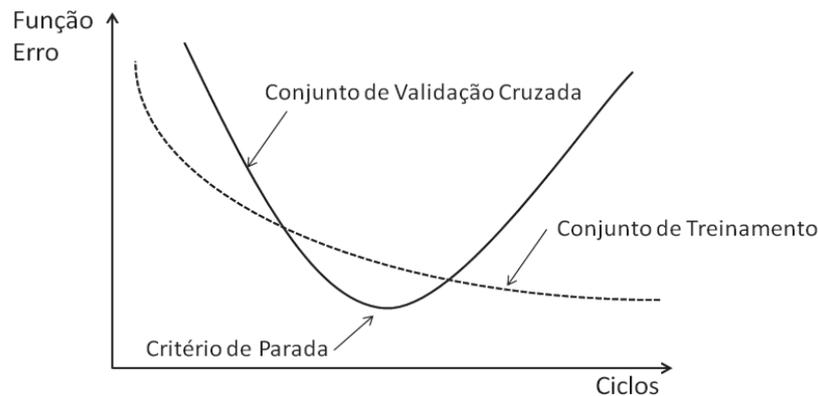
#### **(f) Treinamento da Rede Neural**

Uma das etapas mais importantes no desenvolvimento de um modelo baseado em redes neurais é o treinamento da rede neural. O treinamento de uma rede consiste na determinação dos seus pesos ótimos através da utilização de um algoritmo que procura minimizar uma função objetivo. Em geral, a função objetivo utilizada é o erro médio quadrático, no entanto outras funções podem ser utilizadas, por exemplo, o critério do centro de gravidade (VALENCA; LUDERMIR., 2007).

As vantagens de se utilizar o erro médio quadrático estão relacionadas com as suas principais características matemáticas, dentre as quais podemos citar: a facilidade de cálculo, ser uma métrica que penaliza erros grandes e suas derivadas parciais em relação aos pesos serem calculadas diretamente e de forma bastante fácil.

A cada iteração o algoritmo determina o novo valor da função objetivo, compara o valor atual com o passado e segue na direção de buscar por um menor valor da função objetivo. O processo continua até que um valor mínimo satisfatório da função objetivo seja encontrado. Nos modelos hidrológicos tradicionais, bem como nos modelos estatísticos de previsão, esta fase é conhecida como critério de parada ou validação cruzada. De acordo com (VALENCA, 2010), o treinamento da rede será interrompido quando o valor do erro para a validação cruzada, após atingir seu valor mínimo, começar a crescer ou quando o valor do erro de um ciclo para o outro ficar estacionário, durante um determinado número de ciclos, dentro de uma dada precisão, conforme apresentado na Figura 3.7.

Para o treinamento de uma rede neural, o algoritmo mais utilizado é o *backpropagation*. Na forma mais clássica do algoritmo *backpropagation*, os pesos das conexões



**Figura 3.7:** Validação cruzada - Adaptado (VALENCA, 2010)

são ajustados proporcionalmente à primeira derivada. Este método de ajuste é conhecido como método do gradiente descendente, onde  $\eta$  é a taxa de aprendizagem, conforme mostra a (3.19). Inicialmente, determina-se o valor de  $\eta$ , quando o valor de  $\eta$  é baixo, o processo de aprendizagem pode ser muito lento e possuir uma maior chance de ficar preso a mínimos locais, por outro lado, se seu valor de  $\eta$  for grande ele pode causar instabilidade no treinamento.

$$\omega_{n+1} \leftarrow \omega_n - \eta \cdot \nabla E(\omega) \quad (3.19)$$

onde:  $\omega$  representa o peso a ser ajustado.

Uma forma de minimizar o problema durante o treinamento é incluir outro parâmetro conhecido como momento  $\alpha$ , que permite aumentar os passos de treino sem aumentar as instabilidades do algoritmo (RUMELHART; MCCLELLAND, 1986). A Equação (3.20) mostra a equação de ajuste dos pesos, com o momento introduzido:

$$\omega_{n+1} \leftarrow \omega_n - \eta \cdot \nabla E(\omega) + \alpha \cdot \delta \omega_{old} \quad (3.20)$$

O algoritmo *backpropagation* apresenta excelentes resultados, contudo alguns problemas poderão ocorrer, tais como um processo longo de aprendizado (em virtude da escolha inadequada de  $\beta$  e  $\alpha$ ), fenômenos como a chamada paralisia do treinamento e possibilidade de ficar preso a mínimos locais.

Outro método utilizado para o treinamento de redes neurais do tipo *feedforward* é o algoritmo de Levenberg-Marquardt, o qual consiste em uma extensão do método de Newton-Raphson e utiliza o algoritmo *backpropagation* na determinação das primeiras e segundas derivadas da função. A aproximação da função é obtida a partir da modificação

do método de Gauss-Newton introduzindo-se o parâmetro  $\mu$ , conforme a Equação (3.21).

$$\Delta\omega_{ij} = [J^T(n)J(n) + \mu I]^{-1} J^T(n)\varepsilon \quad (3.21)$$

onde:  $\omega$  representa a diferença entre os pesos inicial e final,  $\mu$  é um escalar que controla a derivação dos erros, permitindo que o termo  $(J^T(n)J(n))$  possa ser invertido,  $J$  é o jacobiano dos erros da camada de saída,  $I$  é a matriz identidade e  $\varepsilon$  é a matriz dos erros calculados.

### (g) Verificação do Desempenho

O conjunto de verificação é aquele que deve ser separado para avaliar o desempenho do modelo ajustado. Este conjunto de dados não deve ser utilizado para o ajuste dos pesos nem para a validação cruzada (VALENCA, 2010).

Em caso de validação dos pesos, considera-se que a rede está treinada, isto é, ela está pronta para receber novos valores de entrada a fim de se prever um valor futuro. Neste passo, os pesos não serão mais modificados.

As medidas de erro mais comumente empregadas são:

- Erro médio Quadrático (EMQ):

$$EMQ = \frac{1}{N} \sum_{p=1}^N (Z_p - Z_o)^2 \quad (3.22)$$

- Erro Médio Absoluto:

$$EMA = \frac{1}{N} \left[ \sum_{p=1}^N |Z_p - Z_o| \right] \quad (3.23)$$

- Erro Percentual Médio Absoluto (MAPE):

$$MAPE = \frac{1}{N} \left[ \sum_{p=1}^N |Z_p - Z_o| / Z_o \right] .100 \quad (3.24)$$

- Erro Padrão de Predição (EP):

$$EP = \left[ \frac{1}{N} \sum_{p=1}^N (Z_p - Z_o)^2 \right]^{0,5} \quad (3.25)$$

- Coeficiente da Eficiência (CE):

$$CE = 1 - \frac{\sum_{p=1}^N (Z_o - Z_p)^2}{\sum_{p=1}^N (Z_o - \bar{Z}_o)^2} \quad (3.26)$$

- Coeficiente da Determinação ( $r^2$ ):

$$r^2 = \frac{\sum_{p=1}^N (Z_o - \bar{Z}_o) \cdot (Z_p - \bar{Z}_p)}{\sqrt{\sum_{p=1}^N (Z_o - \bar{Z}_o)^2 \cdot \sum_{p=1}^N (Z_p - \bar{Z}_p)^2}} \quad (3.27)$$

onde:  $Z_p$  é o valor previsto,  $Z_o$  é o valor ocorrido,  $\bar{Z}_o$  é o valor médio dos valores ocorridos,  $\bar{Z}_p$  é o valor médio dos valores previstos e  $N$  é o número de valores do conjunto de verificação.

### 3.3.4 Redes NSRBN

A arquitetura de uma rede neural, de acordo com a possibilidade de mudanças no seu tamanho durante o processo de treinamento, pode ser classificada como estática ou dinâmica. Segundo (VALENCA; LUDERMIR, 2001), uma rede é dita de arquitetura estática quando o número de camadas e unidades de processamento permanece constante desde a concepção da rede até a finalização do seu treinamento. Por outro lado, uma rede de arquitetura dinâmica tem como característica principal um processo de mudanças no tamanho durante o treinamento.

Redes neurais compostas com blocos de regressões sigmóides não-lineares (NSRBN — *Non-linear Sigmoidal Regression Blocks Networks*) são comumente utilizadas na área de recursos hídricos. Essas redes têm uma poderosa capacidade de mapeamento no sentido de que qualquer função contínua definida em um conjunto compacto em redes neurais pode ser uniformemente aproximada (VALENCA, 1999). Dentre as características principais das Redes NSRBN duas merecem destaque: uma estrutura compacta, por possuir apenas uma camada escondida e um algoritmo construtivo baseado em um método de aprendizado construtivo que é responsável pela definição de sua complexidade ótima.

Segundo (VALENCA; LUDERMIR, 2005), a proposta desta nova classe de redes neurais é utilizar um algoritmo construtivo para incrementar a estrutura da rede, partindo-se de uma rede com estrutura pequena até que a mesma atinja um tamanho ótimo, seguindo critérios estatísticos de seleção adequados. A principal motivação no estabelecimento da arquitetura das redes NSRBN foi a de desenvolver um método sistemático que, construtivamente, estabelecesse um mecanismo natural para incrementar o crescimento da rede, selecionar o modelo de complexidade ótima e possuir capacidade

de mapeamento de uma rede neural de alta ordem. Isso tudo com uma simples camada escondida e evitando o incremento no número de termos requeridos.

O primeiro passo para a construção de um modelo combinatorial consiste em dividir a função  $f(x)$  em blocos compostos de termos de igual grau, conforme mostra a Equação (3.28).

$$f(x) = f_1(x) + f_2(x) + \dots + f_d(x) \quad (3.28)$$

Onde o bloco de grau  $p$  ( $p = 1, 2, \dots, d$ ), de acordo com o polinômio de *kolmogorov-Gabor* (Teorema de Weierstrass), pode ser expresso como uma soma de produtos das entradas, isto é:

$$f_p(x) = \sum_{i_1=1}^N \sum_{i_2=i_1}^N \dots \sum_{i_N}^N a_p(i_1, i_2, \dots, i_N) \cdot x_1^{qp1(i_1)} x_2^{qp2(i_2)} \dots x_N^{qpN(i_N)} \quad (3.29)$$

em que:  $qp1(i_1) + qp2(i_2) + \dots + qpN(i_N) = p$  e  $0 \leq qpm(.) \leq p$  para  $m = 1, 2, \dots, N$ .

Tem-se como objetivo realizar o mapeamento de cada polinômio homogêneo de grau  $p$ . Segundo [Valenca e Ludermir \(2001\)](#), uma forma simples seria realizar todos os produtos das variáveis de entrada procurando aproximar diretamente a hipersuperfície não-linear, entretanto isto não é viável, a menos que  $d$  e  $N$  sejam relativamente pequenos (modelo combinatorial). Assim, para se ter um modelo eficiente, faz-se necessário que ele possua funções de ativação que sejam capazes de realizar vários termos dos polinômios homogêneos de forma otimizada, isto é, sem que ocorra um crescimento explosivo no número de parâmetros necessários para ajustar a função desejada. Com esse objetivo, propõe-se uma nova classe de redes neurais que tenha como fundamento o algoritmo combinatorial com uma estrutura de blocos similar a uma rede MLP, porém, diferentemente destas, os neurônios de saída realizam a técnica estatística de regressão logística não-linear, com relação aos neurônios escondidos ([MORGAN, 1985](#)).

Segundo ([VALENCA, 2010](#)), uma rede NSRBN é uma rede combinatorial composta pela soma de  $p$  blocos  $p = (1, 2, \dots, d)$  com estrutura similar a uma MLP, na qual as unidades escondidas desses blocos realizam uma regressão sigmóide linear das entradas e as unidades de saída realizam uma regressão do tipo sigmóide não-linear das unidades escondidas. Essa nova estrutura, com arquitetura apresentada na Figura 3.8, é considerada um aproximador universal com forte capacidade de mapeamento não-linear.

A estrutura proposta para cada bloco é composta de apenas uma camada escondida

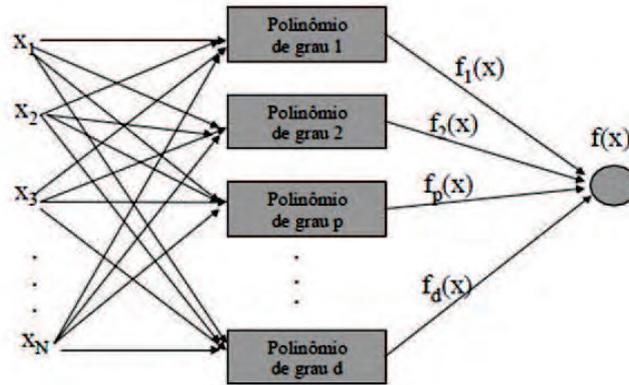


Figura 3.8: Arquitetura combinatorial

didada, tendo  $N$  unidades escondidas em cada bloco com função de ativação do tipo:

$$f(x) = \sigma_{net(h)+\theta_h} \quad (3.30)$$

em que  $net(h)$  é a entrada líquida para cada neurônio escondido,  $h$  é um número inteiro que representa as unidades escondidas em cada bloco (variando de 1 até a ordem  $p$  do bloco),  $\theta_h$  é a tendência e  $\sigma_{net(h)}$  é a função tangente hiperbólica dada por:

$$\sigma_{net(h)} = \frac{e^{net(h)} - e^{-net(h)}}{e^{net(h)} + e^{-net(h)}} \quad (3.31)$$

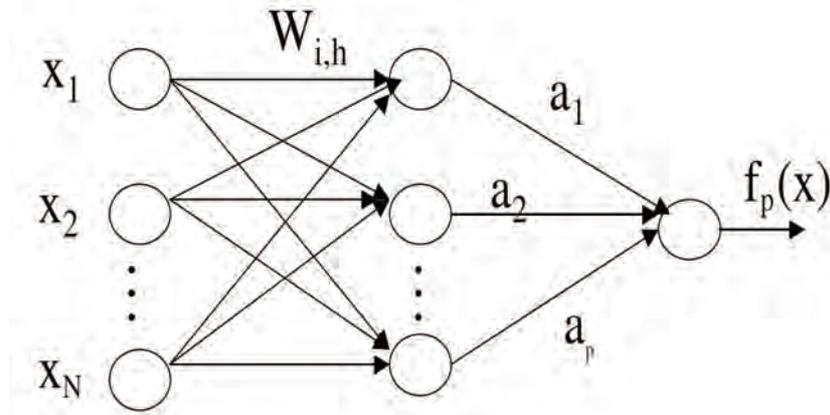
Outras funções também podem ser utilizadas, como por exemplo a função recíproca apresentada na Equação (3.32) abaixo:

$$f_r(x) = \frac{net(h)}{1 + |net(h)|} \quad (3.32)$$

O valor de  $p$ , correspondente ao grau do bloco, define o número de neurônios em cada bloco, ou seja, o bloco de grau 1 ( $p = 1$ ) tem  $h = 1$  e 1 neurônio escondido, o bloco de grau 2 ( $p = 2$ ) tem  $h = 2$  e 2 neurônios escondidos e assim sucessivamente, de tal forma que o bloco de grau  $p$  terá  $h = p$  e  $p$  neurônios escondidos.

A estrutura proposta para cada bloco é similar à apresentada na Figura 3.9 abaixo, a qual apresenta o mapeamento para um bloco de grau  $p$  para  $i$  variáveis de entrada e uma única unidade de saída. Esse bloco é uma rede *feedforward* completamente conectada com uma única camada escondida.

Fazendo-se o uso da Equação (3.33), a função  $f_p(x)$  pode ser escrita da seguinte forma:



**Figura 3.9:** Arquitetura de um bloco polinomial

Seja  $x = [1, x_1, x_2, x_3, \dots, x_N]^T$  o vetor coluna das variáveis de entrada, no qual o elemento  $X_i$  denota um elemento qualquer dele. As entradas são ponderadas pelos vetores de pesos  $\omega = [\omega_{0h}, \omega_{1h}, \omega_{2h}, \dots, \omega_{Nh}, h = 1, 2, \dots, p]$ , nos quais  $p$  é a ordem do bloco. Portanto, utilizando-se a função de ativação estabelecida na Equação (3.30), a saída de cada unidade escondida,  $f(\text{net}(h))$ , desse bloco de grau  $p$  pode ser escrito como:

$$f(x) = \sigma_{\text{net}(h) + \theta_h} \quad (3.33)$$

em que:  $\text{net}(h) = \omega_h^T x$ , ou seja,  $\text{net}(h) = \sum_{i=1}^N \omega_{ih} x_i + \omega_{0h}$ ,  $h = 1, 2, \dots, p$ .

Logo, a unidade de saída desse bloco pode ser representada pela seguinte equação:

$$f_p(x) = a_1 (f(\text{net}(1)))^1 + a_2 (f(\text{net}(2)))^2 + a_3 (f(\text{net}(3)))^3 + \dots + a_p (f(\text{net}(p)))^p \quad (3.34)$$

Sendo,  $a = [a_1, a_2, a_3, \dots, a_p]^T$  o vetor dos pesos das unidades escondidas para a unidade de saída.

$$f_p(x) = a_1 (\sigma_{\text{net}(1) + \theta_1}) + a_2 (\sigma_{\text{net}(1) + \theta_1})^2 + \dots + a_p (\sigma_{\text{net}(p) + \theta_p})^p \quad (3.35)$$

ou

$$f_p(x) = \sum_{h=1}^p a_h (\sigma_{\text{net}(h) + \theta_h})^h \quad (3.36)$$

com  $h$  representando a ordem dos neurônios na camada escondida, ( $h = 1, 2, \dots, p$ ), do

bloco de grau  $p$ .

De acordo com a Figura 3.8, a arquitetura de uma rede NSRBN é composta pela soma de blocos com grau variando de 1 a  $d$ . Aqui, está sendo utilizado o bloco  $p$  da Figura 3.9 para representar qualquer um desses blocos.

Portanto, usando-se esta arquitetura, uma função desconhecida  $f$  em  $R^N$  pode ser aproximada por uma rede NSRBN, através da seguinte expressão:

$$f(x) = \sigma_{net(0)} \left( \sum_{p=1}^d f_p(x) \right) \quad (3.37)$$

em que:  $\sigma_{net(0)}$  é uma função de ativação adequada para a unidade de saída.

Por outro lado, a construção das redes NSRBN é feita de forma incremental, de maneira que pode-se representá-la de forma similar a um bloco. Considere o passo do algoritmo para o qual adiciona-se à rede o bloco de ordem  $d$ ,  $f_d$ , tendo-se anteriormente adicionado os blocos  $f_0, f_1, \dots, f_{d-1}$ . Fazendo-se  $f_0 \equiv 0$ , uma função  $f$  pode ser representada por:

$$f_p(x) = \sigma_{net(0)} \left( \sum_{p=0}^{d-1} f_p(x) + f_d(x) \right) \quad (3.38)$$

na qual os pesos dos blocos  $f_0, f_1, \dots, f_{d-1}$  são congelados ao adicionar-se o bloco de ordem  $d$ ,  $f_d$ .

Desta forma, pode-se escrever  $f(x)$  da seguinte forma:

$$f(x) = \sigma_{net(0)} c_0 + c_1 (\sigma_{net(1)} + \theta_1) + c_2 (\sigma_{net(2)} + \theta_2)^2 + \dots + c_d (\sigma_{net(d)} + \theta_d)^d \quad (3.39)$$

na qual o vetor  $c = [c_1, c_2, \dots, c_d]$  representa os pesos das unidades escondidas para as unidades de saída e a constante  $c_0$  está representando todos os blocos congelados até a ordem  $d - 1$ .

A Equação (3.36) é idêntica a uma regressão logística não-linear quando a função de ativação utilizada é a sigmóide logística tradicional. Segundo Valenca e Ludermir (2001), a potencialidade dessas redes está fundamentada nas características impostas pela regressão sigmóide não-linear na unidade de saída.

O algoritmo construtivo para as redes NSRBN tem como base um método de aprendizagem construtiva (também chamado de auto-organização na teoria das redes GMDH). O princípio construtivo pode ser formulado como segue: quando um modelo in-

crementa gradualmente sua complexidade, certos critérios, que são chamados de critérios de seleção ou função objetivo e que têm a propriedade de complemento externo, passam através de um valor mínimo global. O encontro deste mínimo indicará a existência de um modelo de complexidade ótima (modelo mais parcimonioso).

Portanto, usando-se essa arquitetura proposta, uma função qualquer  $f(x)$  pode ser aproximada pelo uso direto de uma rede NSRBN por dividir em blocos homogêneos de ordem 1 até o bloco de ordem  $d$ . Dessa forma, a função total  $f(x)$  (polinomial completo) pode ser aproximada pela soma das funções parciais  $f_p(x)$ ,  $p = 1, 2, \dots, d$  (polinômios homogêneos), de maneira incremental podendo ser representada matematicamente por:

$$f(x) = g(\hat{f}_1(x) + \hat{f}_2(x) + \dots + \hat{f}_p(x) + \dots + f_d(x)) \quad (3.40)$$

O modelo proposto tem como princípio manter congelados os pesos de todos os blocos anteriores ao atualmente otimizado, de tal forma que o número de pesos a ser otimizado a cada grau de complexidade não aumente explosivamente, como no algoritmo combinatorial tradicional. O algoritmo de abordagem construtiva procede como se descreve a seguir.

Seja  $p$  um passo do algoritmo para o qual o bloco  $f_p(x)$  é adicionado à rede, então uma função qualquer  $f(x)$  é sucessivamente aproximada por:

$$f(x) = g(\hat{f}_1(x)) \quad (3.41)$$

$$f(x) = g(\hat{f}_1(x) + f_2(x)) \quad (3.42)$$

$$f(x) = g(\hat{f}_1(x) + \hat{f}_2(x) + \dots + f_p(x)) \quad (3.43)$$

em que os pesos dos blocos  $\hat{f}_{p-1}(x)$  são congelados quando o bloco de ordem  $p$  é adicionado à rede e  $g$  representa uma função de ativação adequada para a unidade de saída.

---

## Descrição da Área em Estudo

---

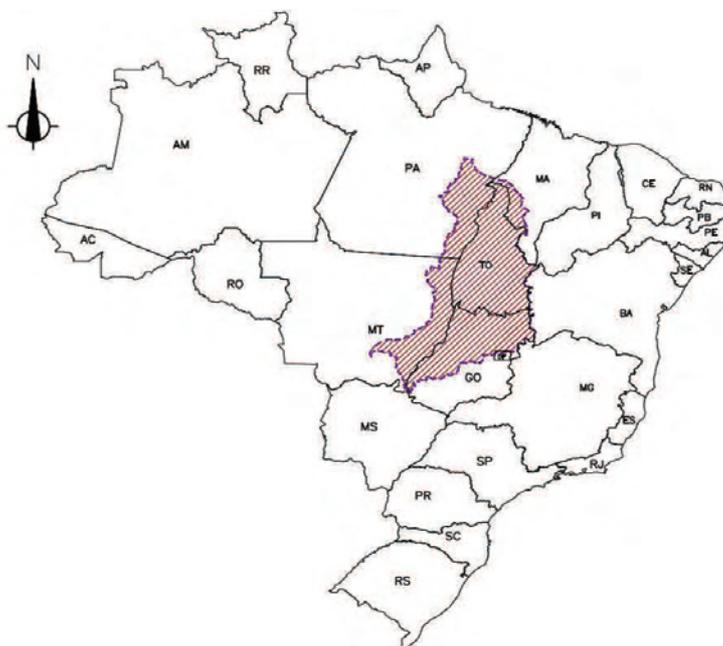
### 4.1 Caracterização da Bacia Hidrográfica

A bacia hidrográfica dos rios Tocantins-Araguaia é a mais extensa em termos de área de drenagem dentro do território brasileiro, totalizando  $918.822 \text{ km}^2$ , o que corresponde a 11% do território nacional, incluindo áreas dos estados do Pará, Tocantins (situado integralmente na região), Goiás, Mato Grosso e Maranhão, além do Distrito Federal, totalizando 409 municípios. Localiza-se entre os paralelos  $0^{\circ}30'$  e  $18^{\circ}05'$  Sul e os meridianos  $45^{\circ}45'$  e  $56^{\circ}20'$  Oeste. Sua configuração é alongada no sentido sul-norte, seguindo a direção dos seus principais cursos d'água, os rios Tocantins e Araguaia. Segundo dados da ANA, a população total da região é de cerca de 7,9 milhões de pessoas (4,7% da população nacional), sendo 72% em áreas urbanas. A densidade demográfica é de  $8,1 \text{ hab./km}^2$ , bem menor que a densidade demográfica do país ( $19,8 \text{ hab./km}^2$ ).

Com a finalidade de realizar a previsão de vazões para a UHE Tucuruí, considera-se como área em estudo, neste trabalho, parte da região hidrográfica da bacia do rios Tocantins-Araguaia, a montante da usina, conforme mostra a Figura 4.1. Esta região apresenta uma área de drenagem de  $763.614 \text{ km}^2$  e extensão total de 2.500 km.

Segundo (ONS, 2004), o rio Araguaia tem suas nascentes na Serra do Caiapó, na divisa de Goiás com Mato Grosso, a cerca de 850 m de altitude, nas proximidades das cabeceiras dos formadores das bacias dos rios Paraguai e Paraná. Apresentando uma extensão de 2.115 km e uma área de drenagem de  $385.060 \text{ km}^2$ , o rio Araguaia desenvolve o seu curso no sentido sul-norte, quase paralelamente ao rio Tocantins, com o qual conflui nas divisas dos Estados de Tocantins, Pará e Maranhão, próximo à localidade de São José do Araguaia.

O Alto Araguaia, considerado como o trecho de rio das nascentes até a cidade de Registro do Araguaia, com 450 km de extensão, desenvolve-se em grande parte no vale da Serra do Caiapó, apresentando nesse trecho a maior declividade de todo o rio



**Figura 4.1:** Mapa de Localização da bacia hidrográfica dos rios Tocantins e Araguaia

Araguaia, onde também são comuns os afloramentos rochosos em seu leito. No seu trecho médio, até a localidade de Santa Isabel, o rio Araguaia se desenvolve através de vasta planície sedimentar, destacando-se nesse trecho a extensa Ilha do Bananal, com aproximadamente 350 km de comprimento e 60 km de largura que, devido à reduzida declividade do terreno, apresenta-se inundável em grande extensão, no período de enchentes, proporcionando assim uma razoável capacidade de regularização natural dos deflúvios. No baixo Araguaia, de Santa Isabel até a confluência com o rio Tocantins, o rio volta a apresentar declividades suaves, ocorrendo, entretanto, alguns acidentes como as corredeiras de Rebojo e São Bento.

Ainda segundo (ONS, 2004), o rio Tocantins possui uma área de drenagem de  $306.310 \text{ km}^2$  antes da confluência com o rio Araguaia, corresponde a quase 50% da bacia total e também desenvolve-se no sentido sul-norte, tendo sua formação a partir dos rios das Almas e Maranhão, cujas nascentes ocorrem no Planalto de Goiás, em altitudes superiores a 1.000 m. A localização da bacia do Tocantins e sua configuração, lhe atribuem um aspecto climatológico de natureza continental com um apreciável grau de homogeneidade.

No trecho denominado Alto Tocantins, com aproximadamente  $128.000 \text{ km}^2$ , limitado pelo paralelo  $12^\circ$  sul, os principais afluentes encontram-se na margem direita, sendo o rio Paranã o de maior porte, que drena em torno de  $65.000 \text{ km}^2$ , enquanto que pela margem esquerda, o mais importante é o rio Santa Tereza. No trecho denominado Médio Tocantins, que se desenvolve do paralelo  $12^\circ 00'$  de latitude sul até a confluência

com o rio Araguaia, correspondendo a  $182.000 \text{ km}^2$ , os principais afluentes estão situados na margem direita, destacando-se os rios Manuel Alves da Natividade, Sono, Farinha, Manoel Alves Grande e Manoel Alves Pequeno entre outros, sendo o rio do Sono o principal deles com um área da ordem de  $48.000 \text{ km}^2$ . O trecho denominado Baixo Tocantins, a partir da localidade de Marabá, apresenta seus principais afluentes pela margem esquerda, destacando-se além do Araguaia, o rio Itacaiúnas com área de drenagem em torno dos  $38.000 \text{ km}^2$ .

O clima na bacia do rio Tocantins é influenciado por sua ampla extensão latitudinal, por sua continentalidade e por seu sistema de circulação atmosférica característico da bacia. Tais fatores proporcionam à bacia uma certa regularidade climática, o que se reflete em estações bem definidas, com pequenas variações de ano para ano e índices pluviométricos e termométricos crescentes no sentido sul-norte. Segundo a metodologia de Köppen, os seguintes tipos climáticos são identificados: Af (úmido megatérmico), Am (tropical úmido megatérmico), Aw (quente e úmido megatérmico) e Cwa (tropical de altitude).

Segundo (ANA, 2009), a precipitação média na região hidrográfica do Tocantins-Araguaia é de 1.744 mm com os totais pluviométricos crescendo de sul para norte - valores próximos de 1.500 mm (Brasília) a 3.000 mm (Belém) - e decrescendo no sentido de oeste a leste - valores da ordem de 1.800 mm a 1.200 mm. Já a evapotranspiração anual média é de 1.276 mm, que corresponde a 73% da precipitação.

Os terrenos mais antigos da região, período pré-Brasiliano, são constituídos por terrenos granitoides e sequências vulcano-sedimentares do tipo *greenstone belt*, representadas por rochas metamórficas e ígneas do Paleoproterozoico e Arqueano (mais de 1,7 bilhões de anos). O período Brasiliano, responsável pela ocupação de 28% da área, formou terrenos compostos por rochas metamórficas e ígneas de idades variadas do Arqueano até o Neoproterozoico (entre 2.900 e 530 milhões de anos). Já o pós-Brasiliano (530 milhões de anos até a presente data) é responsável pela formação das bacias sedimentares do Amazonas, Parnaíba, Paraná, San-franciscana e Parecis, que ocupam 30% da região hidrográfica.

A geomorfologia da bacia mostra o predomínio dos planaltos e das depressões, caracterizando um relevo bastante plano, com diversos degraus. No Planalto Central Goiano, a norte do Distrito Federal, são observadas as maiores altitudes, com a cota chegando a 1.669 m. As altitudes entre 400 e 300 m correspondem a áreas de transição entre as depressões e os planaltos e serras, funcionando como divisores de água dos rios Tocantins e Araguaia. Na porção mais ao norte da bacia, predominam as cotas altimétricas inferiores a 100 m.

O mapa hipsométrico da bacia hidrográfica, apresentado no Anexo A, evidencia

que o rio Tocantins, nos trechos médios alto e médio, apresenta características de rio de planalto, enquanto o rio Araguaia e baixo Tocantins, são tipicamente de planície. Esses aspectos determinam características bastante distintas entre as duas sub-bacias, fazendo com o rio Tocantins concentre o potencial hidroenergético da bacia, enquanto o rio Araguaia o potencial agrícola.

As principais classes de solo da região hidrográfica, são: argissolo vermelho-amarelo, neossolo quartzarênico, latossolo vermelho-amarelo, plintossolo háplico, latossolo amarelo e neossolo litólico. Aproximadamente 79% das terras que integram a região apresentam aptidão para a agricultura, totalizando 5,4 milhões de ha as áreas potencialmente irrigáveis.

Segundo (ANA, 2011) a região hidrográfica Tocantins-Araguaia apresenta vazão média de  $13.799 \text{ m}^3/\text{s}$  e a disponibilidade hídrica de  $5.447 \text{ m}^3/\text{s}$ . A vazão com permanência de 95% ( $Q_{95}$ ), considerada como referência da vazão de estiagem, é de  $2.696 \text{ m}^3/\text{s}$ , já a vazão específica média é de  $15,14 \text{ L/s.km}^2$ . Quanto aos hidrogramas no rio Tocantins, estes apresentam grandes vazões de pico e menores tempos de base que o rio Araguaia, porém suas vazões naturais são significativamente impactadas pelos barramentos implantados.

As principais demandas (vazão de retirada de  $95,1 \text{ m}^3/\text{s}$ ) e usos consuntivos de água na bacia são para irrigação e dessedentação de animais, em seguida aparecem o abastecimento humano e o industrial. Já os usos não consuntivos de água de baseiam na geração de energia, navegação e transportes, pesca e aquicultura e turismo.

As temperaturas máximas ocorrem nos meses de setembro ou outubro (média anual das máximas diárias igual a  $32,5^\circ\text{C}$ ), sendo as mínimas concentradas em julho (média anual das mínimas diárias igual a  $22,1^\circ\text{C}$ ). A média anual da temperatura média mensal compensada é de  $26,4^\circ\text{C}$ .

A Evaporação distribui-se com valores máximos no centro da bacia (80 a 90 mm entre os meses de julho e outubro) e valores decrescentes para Norte, em direção ao equador e para Sul em direção ao Planalto Central (aproximadamente 50 mm entre os meses de fevereiro a abril). A umidade relativa do ar chega a 91% entre os meses de fevereiro e abril, enquanto que em setembro baixa para cerca de 84%.

Em relação aos ventos, não se verificam fenômenos ciclônicos intensos. No entanto, há ocorrência de ventos intensos, normalmente associados a fenômenos convectivos diários, com duração inferior a 60 minutos. A pressão atmosférica se mostra uniforme, com pouca variação em relação à altitude.

A região apresenta dois importantes biomas: a Floresta Amazônica, que ocupa a porção norte/noroeste da região (35% da área total) e o Cerrado (65%). Esses biomas

apresentam grande diversidade de fauna e flora e uma ampla zona de transição (écotono). A principal ameaça a biodiversidade na região é o desmatamento que vem ocorrendo tanto na Amazônia quanto no Cerrado, principalmente para a exploração madeireira, produção de carvão vegetal e agropecuária.

A bacia hidrográfica tem grande vocação mineira com jazidas em exploração e reservas. As principais províncias minerais identificadas são: Província de Carajás, Província de Paragominas, Província Centro-Norte de Goiás e Província Diamantífera de Leste do Mato Grosso.

As unidades de conservação na região totalizam 82.321 km<sup>2</sup>, que correspondem a 9% da área total. A maior parte destas áreas (70,8%) é de uso sustentável, e o restante de proteção integral. A região ainda abriga a Reserva da Biosfera <sup>1</sup>, um sítio Ramsar e três corredores ecológicos que ocupam 34,3% da área total, a saber: Corredor Ecológico Araguaia-Bananal, Corredor Ecológico Jalapão-Mangabeiras e Corredor Ecológico Paranã-Pirineus.

A região abriga 25 distintas etnias em 53 terras indígenas, que totalizam 47.031 km<sup>2</sup>, ou seja, 5,1% da área total. As interferências mais observadas nestas terras incluem a construção de rodovias, linhas de transmissão, usinas hidrelétricas, projetos agropecuários, exploração de minerais e produção madeireira. Já as áreas de remanescentes de quilombos reconhecidas e protegidas por legislação específica totalizam 23 e são distribuídas em 21 municípios. Dentre os principais problemas sofridos por estas comunidades quilombolas destaca-se a violência dos fazendeiros e a discriminação racial.

Segundo (ANA, 2009), os indicadores socioeconômicos da região hidrográfica estão abaixo da média nacional: Índice de Desenvolvimento Humano (IDH) de 0,725 (Brasil, 0,766); renda mensal *per capita* de R\$ 188,62 (Brasil, R\$ 297,23); percentual da população abaixo da linha da pobreza de 47% (Brasil, 33%); mortalidade infantil (até 1 ano) de 33,22 crianças a cada mil nascidos (Brasil, 29,64); e PIB *per capita* de R\$ 5.160 (Brasil, R\$ 6.950). Os indicadores de saneamento da bacia também se encontram abaixo da média nacional, evidenciando condições precárias dos sistemas de abastecimento de água, esgotamento sanitário, coleta e disposição adequada de resíduos sólidos e drenagem urbana.

Segundo dados do SIPOT - Sistema de Informações do Potencial Hidrelétrico Brasileiro (ELETROBRAS, 2012), a bacia hidrográfica dos rios Tocantins e Araguaia apresenta um potencial energético estimado de 26,4 GW. Atualmente, encontram-se em operação nesta bacia as usinas hidrelétricas Tucuruí (8.370 MW), Luís E. Magalhães - Lajeado (902,5 MW), Peixe Angical (452,1 MW), São Salvador (243,2 MW), Cana Brava

<sup>1</sup>A Reserva da Biosfera representa um espaço territorial reconhecido pela Unesco em 1971, que visa a fomentar modelos para a proteção da biodiversidade e o desenvolvimento sustentável

(450,0 MW), Serra da Mesa (1.275 MW) e Estreito Tocantins (1.087,2 MW - em motorização). Encontram-se em fase de projeto as usinas hidrelétricas Santa Isabel (1.087 MW) e Couto Magalhães (150 MW). A Figura 4.2 a seguir apresenta a bacia hidrográfica dos rios Tocantins e Araguaia, bem como todos os aproveitamentos hidrelétricos existentes e projetados.



## 4.2 Usina Hidrelétrica Tucuruí

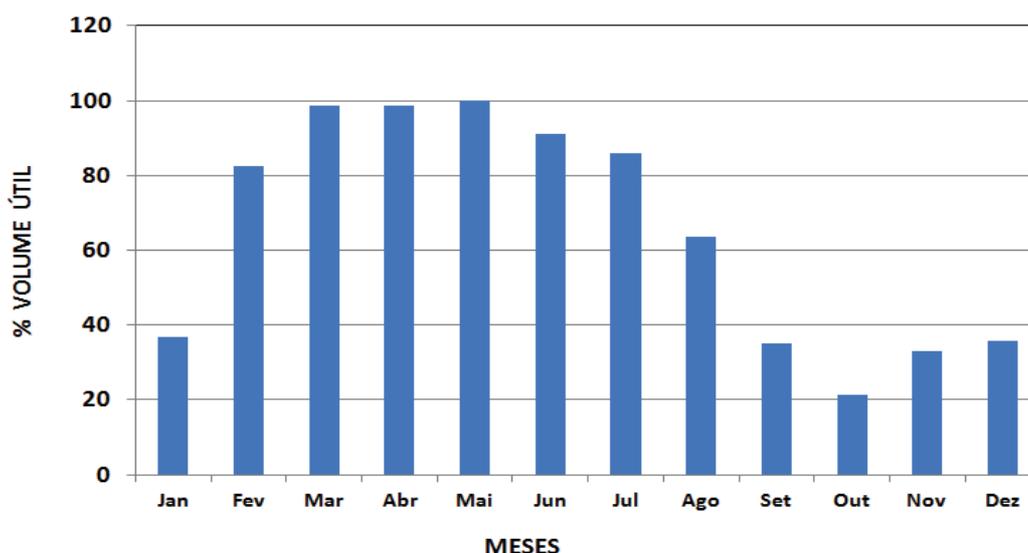
A Usina Hidrelétrica Tucuruí, construída e operada pela Centrais Elétricas do Norte do Brasil S.A. - ELETRONORTE, está situada no rio Tocantins, no Estado do Pará, a cerca de 300 km em linha reta da cidade de Belém.

A usina foi concebida para ser implantada em duas etapas. Na 1ª etapa, cuja operação comercial iniciou-se em novembro de 1984, foram implantadas 12 unidades geradoras de 350 MW e 2 unidades de 22,5 MW cada, totalizando 4.245 MW de potência instalada. Na 2ª etapa, foram instaladas 11 unidades geradoras de 375 MW, o que permitiu a usina atingir uma capacidade total instalada de 8.370 MW, em abril de 2007.

Possui as seguintes características físico-operativas:

- Barragem: do tipo gravidade, em concreto e de terra e enrocamento, com 78 m de altura e 8.005 m de comprimento na crista. Cota da crista 77,50 m.
- Vertedouro: do tipo gravidade, com soleira controlada e salto esqui, possui 23 vãos com comportas tipo segmento de 20,00 m de largura por 21,0 m de altura e soleira na cota 52,00 m. Vazão associada à cheia de projeto  $110.000 \text{ m}^3/\text{s}$ .
- Turbina: 2 máquinas Francis, de 22,5 MW cada, com engolimento máximo de  $37 \text{ m}^3/\text{s}$  e 12 máquinas Francis, de 350 MW cada, com engolimento máximo de  $582 \text{ m}^3/\text{s}$  (Tucuruí 1ª etapa); mais 11 máquinas Francis, de 375 MW cada, com engolimento máximo de  $662 \text{ m}^3/\text{s}$  (Tucuruí 2ª etapa). A queda de referência para os conjuntos de máquinas da 1ª etapa é de 65,5 m e de 61,7 m para a 2ª etapa.
- Rendimento Turbina-Gerador: para todos os conjuntos turbina/gerador o rendimento médio ponderado é igual a 93,6%.
- Reservatório: faixa operativa entre o NA mínimo 51,60 m e NA máximo 74,00 m, correspondentes a área inundada, mínima e máxima, respectivamente, de 761,37 e  $3023,77 \text{ km}^2$  e volumes de 11.293 e  $50.275 \text{ hm}^3$ , o que resulta em um volume útil de  $38.982 \text{ hm}^3$ , a Figura 4.3 apresenta o volume útil do reservatório da UHE Tucuruí ao longo do ano de 2011. O NA máximo maximorum encontra-se na cota 75,30 m.
- Evaporação Líquida: média mensal de evaporação líquida<sup>2</sup> igual a 8,3 mm/mês.
- Taxas de Manutenção: os valores de referência para as taxas de indisponibilidade forçada e programada são, respectivamente, 2,914% e 12,097% ONS (2005).

<sup>2</sup>calculada pela diferença entre os valores de evaporação real e de evapotranspiração real e representam as alterações no balanço hídrico, em termos médios, decorrentes da formação dos reservatórios



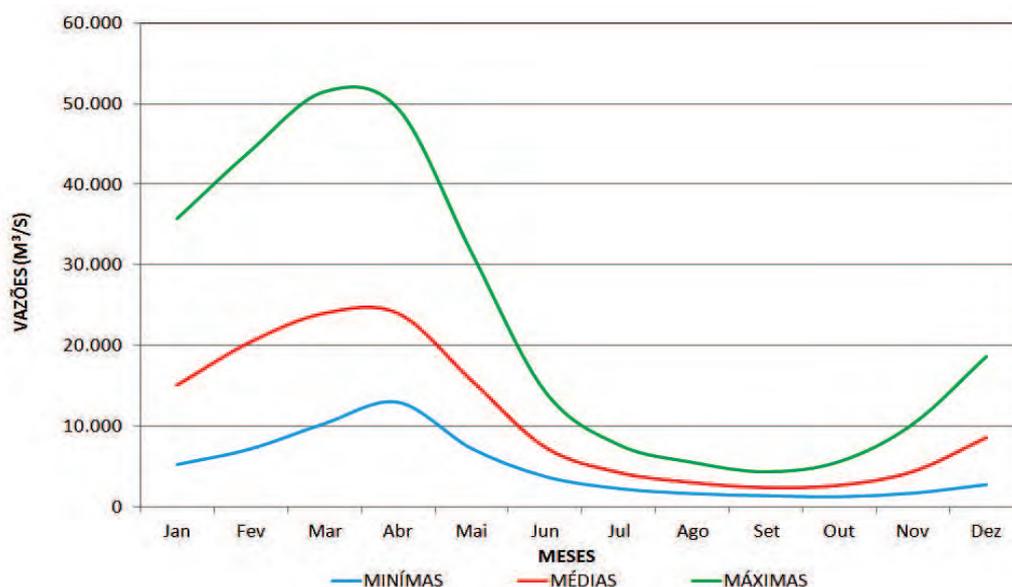
**Figura 4.3:** Percentual de Volume útil do reservatório da UHE Tucuruí - ano 2011

- **Vazões Naturais Afluentes:** o hidrograma sazonal apresenta períodos de cheias e recessão bem definidos (Figura 4.4). A vazão média de longo termo no local do aproveitamento é de aproximadamente  $11.000 \text{ m}^3/\text{s}$ .

Segundo (ONS, 2004), junto ao posto fluviométrico de Tucuruí (código ANA 29700000) a vazão média é de  $11.000 \text{ m}^3/\text{s}$ , o que corresponde a um volume médio anual de  $347 \text{ km}^3$ . Utilizando-se dados da estação climatológica de Tucuruí para o período de 1974 a 1982, estima-se o coeficiente de escoamento superficial em Tucuruí em 0,25. A região da usina apresenta regime fluvial do tipo continental, com períodos de cheias e de recessão bem definidos. Predomina o clima continental úmido megatérmico (Af na classificação de *Koppen*), com período de chuva entre novembro e maio (ELETRONORTE; THEMAG; ENGEVIX, 1996). A Figura 4.4 a seguir apresenta o hidrograma sazonal no local da UHE Tucuruí.

A geologia da região da UHE Tucuruí é representada por rochas do Complexo Xingu, constituído por migmatitos, gnaisses e granitos que ocorrem de forma isolada no limite ocidental do sítio; Grupo Tocantins, composto por filitos e xistos, quartzitos e metabasitos; Formação Tucuruí, constituída por metassedimentos, representados por metagrauvas e metassiltitos e metabasaltos que ocorrem na margem esquerda e leito do rio; metabasaltos que ocorrem na forma de derrames cujas espessuras individuais variam de poucos metros a mais de 40 m; metassedimentos intertrapeanos com até 3 m de espessura que ocorrem de forma localizada.

Tanto as rochas do grupo Tocantins quanto as da Formação Tucuruí se encontram



**Figura 4.4:** Hidrograma sazonal - UHE Tucuruí (1931 - 2009)

cobertas por camadas de solos colúviais e aluvionais, sendo raros os seus afloramentos. Os arenitos, siltitos, argilitos e conglomerados da Formação Barreiras, ocorrem na margem direita do rio, sobrepostos aos metassedimentos do Grupo Tocantins. Depósitos de laterita e concreções lateríticas ocorrem na margem esquerda capeando os metabasaltos da Formação Tucuruí. Aluviões recentes cobrem parcial ou totalmente as rochas no leito e nas margens do rio, estendendo-se, por vezes, até os terraços aluvionares.

Estratégica para o SIN, a UHE Tucuruí, além de atender a região Norte do país, exporta energia para os sistemas Nordeste, Sudeste e Centro-Oeste. Atualmente, a UHE Tucuruí conecta-se à rede básica na SE Vila do Conde (3 circuitos simples de 529 kV) e SE Marabá (4 circuitos simples de 500 kV). Encontra-se em fase de construção a linha de transmissão Tucuruí-Macapá-Manaus, que interligará por meio da SE Xingu a usina ao restante do sistema isolado do país.

No ano de 2011, a energia média mensal na UHE Tucuruí foi de 4.683 MW médios, o que correspondeu neste ano a aproximadamente 9,11% da energia gerada pelas hidrelétricas e 8,3% de toda energia gerada no SIN.

---

## Análise e Tratamento dos Dados de Entrada

---

### 5.1 Considerações Iniciais

Para a realização deste trabalho foram utilizadas informações de estações fluviométricas e pluviométricas de postos hidrométricos localizados na área à montante do reservatório da UHE Tucuruí. Inicialmente, devido à grande extensão territorial da bacia, foram identificados 64 postos fluviométricos, cuja distribuição espacial pode ser vista na Figura 5.1, adaptada de (ONS, 2004). Adicionalmente, considerando as necessidades do estudo, foram pesquisados 69 postos pluviométricos localizados na bacia e entorno, apresentados na Figura 5.2, adaptada de (ONS, 2004).

A rede hidrometeorológica da bacia dos rios Tocantins-Araguaia é bastante ampla, contendo, entre estações extintas e operantes, convencionais e telemétricas, dezenas de postos de medição. No entanto, devido à necessidade de dados de grande abrangência temporal, definida entre Janeiro de 1970 a Dezembro de 2009, admite-se que o suporte desta rede não é satisfatório.

Todo o acervo de dados e informações coletado para o desenvolvimento do estudo foi levantado junto às entidades mais diretamente relacionadas ao assunto, quais sejam: ELETRONORTE, ONS - Operador Nacional do Sistema Elétrico, ANA - Agência Nacional de Águas, INMET - Instituto Nacional de Meteorologia e CPRM - Companhia de Pesquisa de Recursos Minerais.

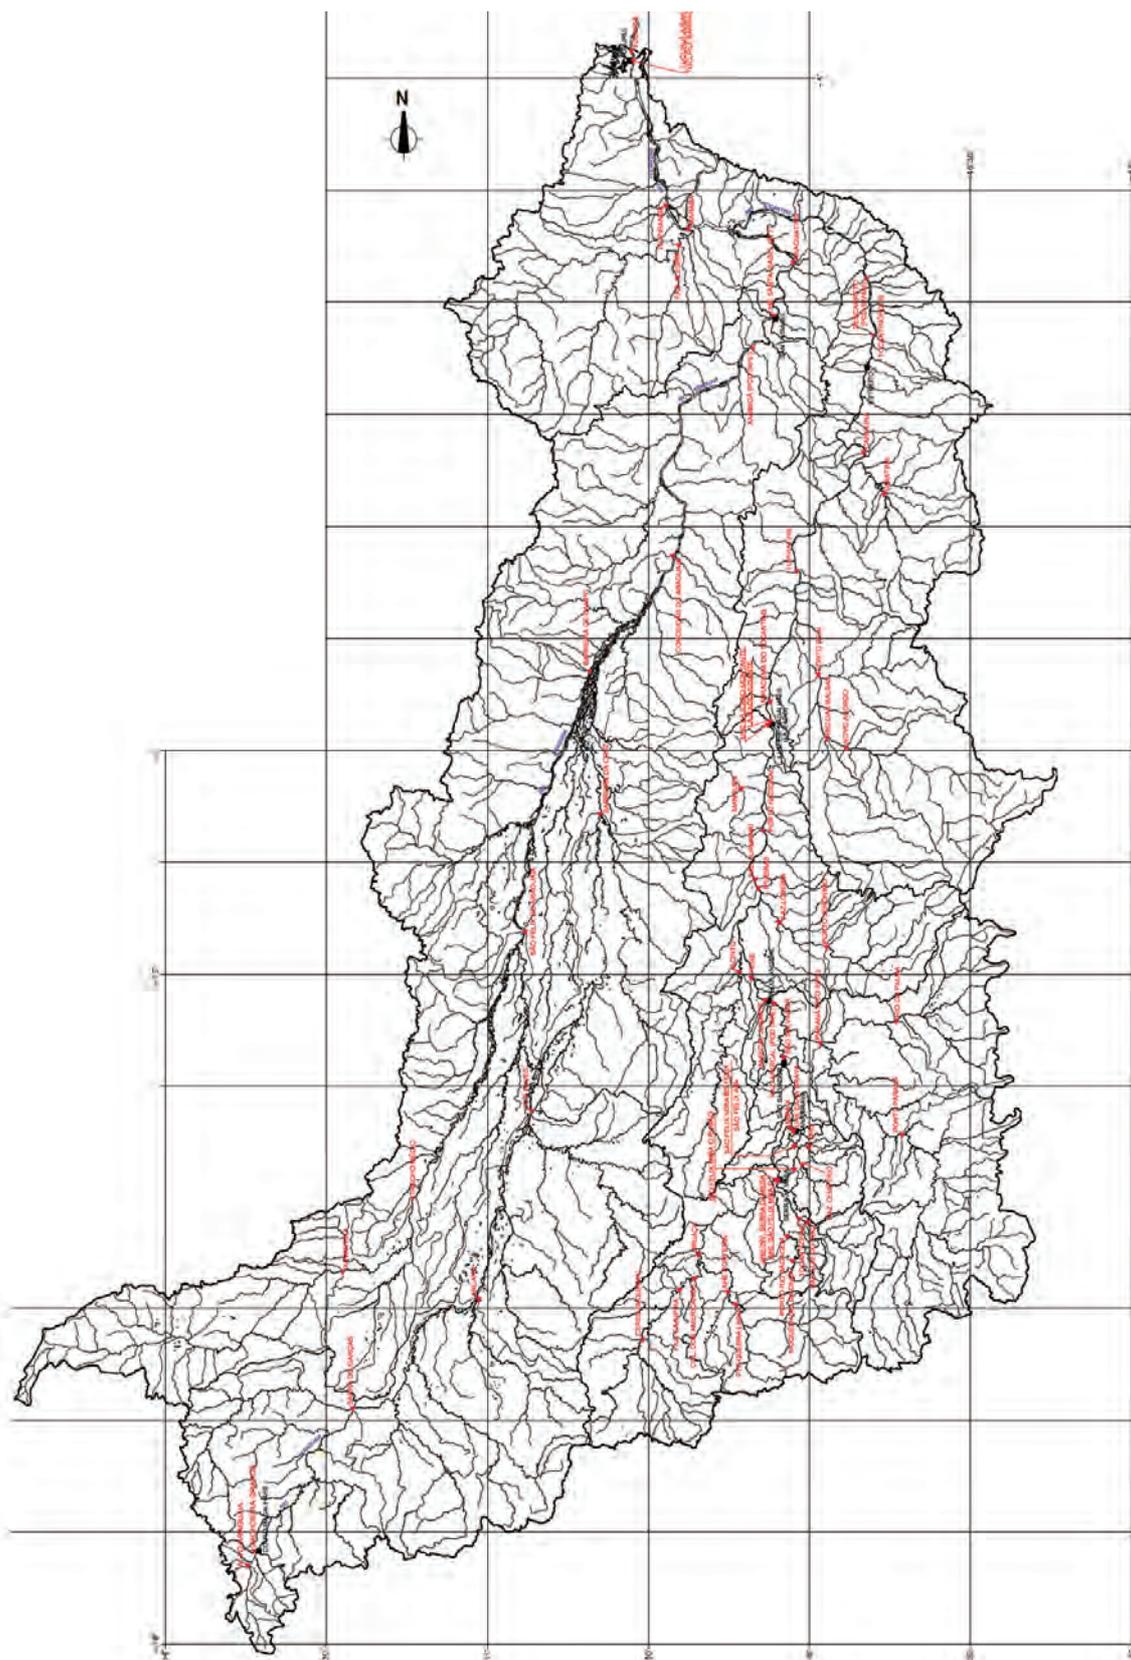
A série de vazões naturais do reservatório da UHE Tucuruí corresponde à existente na base de dados do ONS, obtida no projeto de reavaliação de série de vazões naturais na bacia do rio Tocantins (ONS, 2004).

Segundo (ONS, 2004), após a coleta de dados relativos às estações hidrométricas, concluiu-se que:

- as estações fluviométricas convencionais da ANA são as que dispõem de séries

em melhores condições de utilização, porém abrangem períodos de observação relativamente curtos para o propósito do projeto.

- as estações pluviométricas convencionais da ANA são razoavelmente numerosas, mas também abrangem períodos curtos de observação.
- as estações climatológicas do INMET são as que dispõem de séries pluviométricas mais extensas e adequadas, porém apresentam-se relativamente esparsas na bacia e com dados não prontamente disponíveis.
- as estações fluviométricas dos Agentes de Geração encontram-se, em grande parte, extintas, uma vez que foram implantadas e mantidas para suprir necessidades específicas de estudos e projetos, com durações limitadas.
- as estações telemétricas implantadas pelos Agentes de Geração para atendimento à Resolução ANA nº 396/1998, usualmente plúvio-fluviométricas, apresentam séries pequenas, com muitas falhas de observação e baixo grau de confiabilidade.



**Figura 5.1:** Rede de Postos Fluviométricos Pesquisada - Adaptada de (ONS, 2004)



## 5.2 Informações Fluviométricas

### 5.2.1 Rede de Postos Fluviométricos Considerada

A seleção da rede de interesse resultou de um balanço entre a necessidade e disponibilidade de informações, tendo como balizamento o objetivo do trabalho e o elenco de séries históricas de vazões naturais de estudos anteriores. Desta forma, foram selecionadas inicialmente 9 (nove) estações fluviométricas na área de interesse, cujas características são indicadas na Tabela 5.1 abaixo:

**Tabela 5.1:** *Postos Fluviométricos Considerados*

Código ANA	Nome do Posto	Rio	Área de Drenagem	Entidade Responsável
			(km <sup>2</sup> )	
29680080	UHE Tucuruí - Barragem	Tocantins	757.577	ELN
29200000	Itupiranga	Tocantins	738.519	ANA/CPRM
29050000	Marabá	Tocantins	695.198	ANA/ELN
23700000	Descarreto	Tocantins	296.638	ANA/CPRM
23600000	Tocantinópolis	Tocantins	288.609	ANA/ELN
29100000	Fazenda Alegria	Itacaiúnas	194.413	ANA/ELN
27500000	Conceição do Araguaia	Araguaia	325.434	ANA/ELN
28850000	Araguatins	Araguaia	381.802	ANA/CPRM
28300000	Xambioá	Araguaia	370.452	ANA/INPE

#### **Tucuruí - Barragem - Tuc (Código ANA 29680080)**

Estação situada à montante da barragem (Lat: 03°49'59"Sul - Long: 49°38'43"Oeste), contruída com um conjunto de dispositivos para leitura direta do N.A. do reservatório e equipamentos automáticos de telemedição.

A régua mais antiga, com faixa de variação de 62 a 74 m, localiza-se diretamente no corpo da barragem, junto a uma das tomadas d'água das turbinas. Adicionalmente, existe um conjunto de lances de réguas localizado junto ao trecho residual da ensecadeira das obras da 2ª etapa.

A rede de telemetria da Eletrobras Eletronorte conta com um telelimnómetro à base de pressão (sistema de borbulhamento), localizado junto às tomadas d'água e conectado à sala de comando, e um telelimnómetro à base de célula piezométrica, instalado entre a casa de força e o vertedouro.

**Itupiranga - Itu (Código ANA 29200000)**

Situada na margem esquerda do rio Tocantins (Lat: 17°18'05"Sul - Long: 53°13'00"Oeste), trata-se de uma estação convencional da ANA, cuja operação iniciou-se em 06/07/1969.

A estação é constituída por 9 lances de régua, cobrindo uma faixa de 1 a 16 m, tendo dois RNs com cotas arbitrárias implantados no último lance e seção de medição localizada 500 m a montante das régua.

Por localizar-se dentro do reservatório da UHE Tucuruí, sofre mais acentuadamente os efeitos do seu remanso, prejudicando o estado de conservação das régua.

**Marabá - Mar (Código ANA 29050000)**

Estação telemétrica e convencional, localizada na margem esquerda do rio Tocantins (Lat: 05°20'17"Sul - Long: 49°07'24"Oeste), na área urbana da cidade de Marabá.

A estação é constituída de 7 lances de régua, denteadas, em madeira de lei, fixadas a estacas suporte, também em madeira de lei, solidamente enterradas, para leituras entre 00/200, 200/400, 400/600, 600/800, 800/1000, 1000/1200 e 1200/1400 cm.

Referência de Níveis: RN1 = 13,136 m, (cota arbitrária), calota de alumínio chumbada ao centro de um bloco de concreto a 1,50 m da placa do DNPVN e a 4,00 m do lance 1200/1400 cm. RN2 = 13,714 m, (cota arbitrária), calota de alumínio chumbada ao centro de um bloco de concreto a 13,20 m da RN1.

Seção de Medição: localizada aproximadamente 2 km a montante das miras. Medição detalhada com molinete e auxílio de sextante, cuja operação iniciou-se em 01/10/1971, sob responsabilidade da ANA e da Eletrobras Eletronorte.

Ao lado das régua encontra-se implantada a estação telemétrica de Marabá, que compõe a rede de controle da UHE Tucuruí.

**Fazenda Alegria - FazAle (Código ANA 29100000)**

Estação convencional e telemétrica localizada na margem esquerda do rio Itacaiúnas (Lat: 11°37'14"Sul - Long: 50°39'42"Oeste), cuja operação iniciou-se em 01/08/1969.

A estação convencional é mantida pela ANA e possui 5 lances de miras, esmalgadas, fixadas a estacas suporte, em madeira de lei, solidamente enterradas, para leituras

entre 200/400, 400/600, 600/800, 800/1000 e 1000/1200 cm.

Referência de Níveis: RN1 = 10,754 m, registrado em calota de alumínio, chumbada ao centro de um bloco de concreto a 6,00 m do lance 1000/1200 cm. RN2 = 12,665 m, registrado em calota de alumínio, chumbada ao centro de um bloco de concreto a 9,90 m da RN1.

A seção de medição fica localizada a 100,00 m à jusante das miras. Os pontos PI e PF ficam distanciados entre si 170,10 m.

A estação telemétrica foi instalada pela Eletrobras Eletronorte para controle hidrológico da UHE Tucuruí e conta com equipamentos automáticos de monitoramento pluviométrico e limnimétrico.

### **Conceição do Araguaia - ConAra (Código ANA 27500000)**

Estação telemétrica e convencional situada na margem esquerda do rio Araguaia (Lat: 08°16'10"Sul - Long: 49°15'35"Oeste), implantada e operada pela Eletrobras Eletronorte, desde 18/12/1967.

A estação é composta por réguas (variação de 9 a 13 m), sensor pluviométrico, tipo caçamba basculante e sensor limnimétrico, tipo célula piezométrica.

Referência de Níveis:RN1 = Instalado na cota 13,670 m, e preso com parafusos de ferro em base de concreto a 18,25 m do lance 900/1100 cm. RN3 = 13,044 m, registrado em calota de alumínio em base de concreto a 9,10 m da RN1.

Imediatamente à jusante (aproximadamente 1.500 m), encontra-se a estação convencional da ANA, que realiza medições de descarga por meio da leitura regular dos níveis d'água. Esta estação é composta por 7 lances de réguas fixadas em estacas, cobrindo uma faixa de 2 a 13 m, com seção de medição localizada a 500 m à montante, num trecho mais encaixado e retilíneo.

### **Tocantinópolis - Toc (Código ANA 22600000)**

Estação situada na margem esquerda do rio Tocantins, a jusante da cidade de mesmo nome (Lat: 06°17'20"Sul - Long: 47°23'40"Oeste).

A estação convencional de leitura dos níveis d'água é composta por 5 lances de régua, cobrindo uma faixa de 0 a 10 m e por 3 RNs situados próximos da última régua, solidamente enterradas para leitura entre 00/200, 200/400, 400/600, 600/800 e 800/1000 cm, implantada pela ANA e operada desde 01/01/1955.

No local também se encontra a estação telemétrica implantada pela Eletrobras Eletronorte, composta por sensores de chuva e nível d'água.

Referências de Nível: RN1 = 10,736 m, parafuso de ferro em base de concreto a 6,90 m do lance 800/1000 cm. RN2 = 12,467 m, parafuso de ferro em base de concreto a 3,40 m da RN3. RN3 = 11,658 m, registrado em calota de alumínio, chumbada em base de concreto a 10,20 m da RN1.

Seção de Medição: Localizada a 7 km a montante das miras. Medição com molinete, em 2 pontos, de barco, com auxílio de sextante, definida por PI na margem esquerda e PF na margem direita, distanciados entre si de 997,28 m. Na margem esquerda foi definida uma linha de bases trigonométricas, afastadas do PI de 50, 150 e 450 m respectivamente.

#### **Descarreto - Des (Código ANA 23700000)**

Estação localizada a cerca de 60 km ao norte de Tocantinópolis, na margem esquerda do rio Tocantins, junto à localidade de Descarreto, município de Iguatins (Lat: 05°47'20"Sul - Long: 47°27'08"Oeste).

A seção de medição dos níveis d'água dispõe de lances de régua com leituras de até 7 m e 2 RNs com cotas arbitrárias, tendo a seção de medição de descargas localizada 1 km a montante. Sua operação iniciou-se em 22/05/1973.

A aproximadamente 400 m a montante das réguas, encontra-se implantada a estação telemétrica, dotada de sensores plúvio e limnimétrico.

#### **Araguatins - Ara (Código ANA 28850000)**

Estação localizada no rio Araguaia (Lat: 05°38'38"Sul - Long: 48°07'54"Oeste). Com data de início de operação em 26/08/1974.

#### **Xambioá - Xam (Código ANA 28300000)**

Estação telemétrica e convencional localizada na margem direita do rio Araguaia (Lat: 06°24'40"Sul - Long: 48°32'51"Oeste), nas imediações das cidades de Xambioá e São Geraldo do Araguaia.

A estação de medição dos níveis d'água é composta por 7 lances de réguas, cobrindo uma faixa de 2 a 9 m e 1 RN situado próximo do último lance de réguas. A seção de medição das descargas está situada a montante, a aproximadamente 200 m. Esta estação teve sua operação iniciada em 01/09/1969.



### 5.2.2 Análise de Correlação e Preenchimento de Falhas

Para cada posto fluviométrico selecionado foi realizada uma análise de correlação com os demais postos selecionados da bacia e posteriormente realizado o preenchimento das falhas. Considerou-se, nesta análise, os postos mais correlacionados por meio de uma regressão linear simples ou múltipla.

A Tabela 5.2 apresenta os coeficientes de correlação das vazões dos postos fluviométricos considerados. Observa-se que todos os postos possuem coeficiente de correlação acima de 0,70, considerado suficiente neste trabalho e que leva a concluir que essas informações possuem comportamento análogo. Especificamente para o posto de Tucuruí, objeto de análise desse trabalho, as correlações são superiores a 0,84, sendo os postos de Marabá e Itupiranga os mais bem correlacionados.

**Tabela 5.2:** Coeficientes de Correlação entre os Postos Fluviométricos

Posto	Tuc	Mar	Itu	FazAle	ConAra	Ara	Des	Toc	Xam
Tuc	1,000	0,996	0,996	0,886	0,944	0,966	0,854	0,844	0,963
Mar	0,996	1,000	0,998	0,884	0,946	0,967	0,866	0,855	0,964
Itu	0,996	0,998	1,000	0,893	0,941	0,965	0,865	0,858	0,959
FazAle	0,886	0,884	0,893	1,000	0,779	0,870	0,748	0,716	0,820
ConAra	0,944	0,946	0,941	0,779	1,000	0,989	0,713	0,700	0,995
Ara	0,966	0,967	0,965	0,870	0,989	1,000	0,738	0,727	0,998
Des	0,854	0,866	0,865	0,748	0,713	0,738	1,000	0,998	0,741
Toc	0,844	0,855	0,858	0,716	0,700	0,727	0,998	1,000	0,729
Xam	0,963	0,964	0,959	0,820	0,995	0,998	0,741	0,729	1,000

Tendo em vista que os dados disponibilizados abrangeram apenas o período de Janeiro/1970 a Dezembro/2001, foi necessário estender as séries no período de Janeiro/2002 a Dezembro/2009. Para isso, foram utilizados os dados de cota média diária dos postos fluviométricos constantes do banco de dados da ANA, denominado Hidroweb, e adicionalmente aplicadas as curvas de descarga revalidadas pelo ONS, constantes em (ONS, 2004) e apresentadas no Anexo B.

O período de análise, Janeiro/1970 a Dezembro/2009, corresponde a 14.610 dias. O posto de Tucuruí não possui nenhuma falha nesse período, já os demais possuem as seguintes porcentagens de falhas: Itupiranga (24,2%), Marabá (13,2%), Fazenda Alegria (7,2%), Conceição do Araguaia (3,8%), Tocantinópolis (2,9%), Descarreto (3,2%), Araguatins (6,1%) e Xambioá (3,2%).

### 5.2.3 Análise de Consistência dos Dados

A análise de consistência dos dados fluviométricos foi baseada na metodologia apresentada em (ONS, 2004), a qual reavalia as curvas de descargas disponíveis e define critérios de seleção para novas curvas de descarga adotadas.

Na hipótese de existência de duas curvas-chave (usualmente, uma da ANA e outra da entidade responsável pela operação da estação), ambas são utilizadas para consignar, ao longo da análise, as correções ou os descartes de dados e informações julgados incoerentes. Para subsidiar esta análise as seguintes rotinas foram seguidas:

- análise das eventuais incompatibilidades entre os níveis d'água lidos na rotina do observador e os níveis d'água lidos durante as campanhas hidrométricas.
- análise das eventuais incompatibilidades entre as vazões, as áreas e as velocidades informadas no resumo das medições.
- indicação de eventuais anomalias na relação entre as cotas do N.A. (leituras de régua) e as profundidades médias da seção molhada.
- mostra da evolução temporal dos desvios entre a cota observada na medição e a cota inferida a partir da profundidade média da seção molhada.
- indicação das eventuais anomalias na relação entre as cotas do N.A. e as áreas de seção molhada, assim como entre as cotas do N.A. e as velocidades médias de escoamento.
- mostra das eventuais tendências na evolução temporal das medições de velocidades e áreas.

Concluída a fase de depuração dos dados, analisou-se as curvas-chave existentes por meio de critérios de seleção definidos, o que subsidiou a definição das curvas-chave adotadas neste estudo e apresentadas no Anexo B. Este estágio teve como diretriz a análise comparativa realizada com as séries processadas de vazões médias diárias. Neste caso, identificando-se uma incoerência sistemática entre a série de uma dada estação e as séries de estações vizinhas (a montante ou a jusante), procedeu-se a novas avaliações da curva-chave analisada, até a obtenção de um nível aceitável de compatibilidade, conforme sugerido por (ONS, 2004).

## 5.3 Informações Pluviométricas

### 5.3.1 Rede de Postos Pluviométricos Considerada

A rede hidrometeorológica da bacia do Tocantins-Araguaia é razoavelmente ampla, comportando, entre as estações extintas e operantes, algumas centenas de postos de observação pluviométrica. Para o presente estudo, face principalmente à necessidade de dados de grande abrangência temporal no período de Janeiro/1970 a Dezembro/2009, pode-se afirmar que o suporte fornecido por essa rede não é satisfatório.

Desta forma, na seleção dos postos pluviométricos buscou-se aqueles que se encontram atualmente em operação, com histórico sem muitas falhas, com maiores períodos de dados disponíveis, tendo sido selecionadas inicialmente 8 (oito) estações pluviométricas na área de interesse, conforme apresentado na Tabela 5.3 abaixo.

**Tabela 5.3:** Postos Pluviométricos Considerados

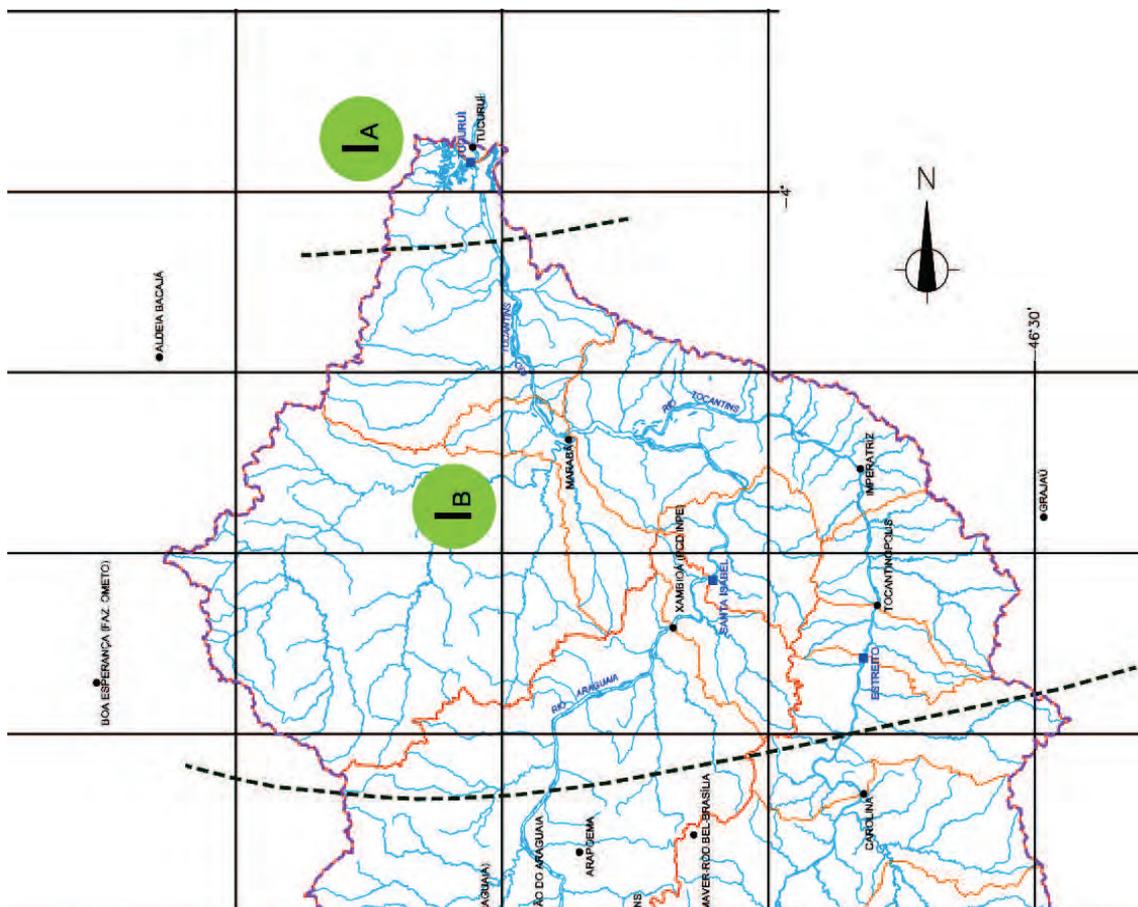
Codigo ANA	Nome do Posto	Coordenadas		Emitide Responsável
		Latitude	Longitude	
00349000	Tucuruí	-03 45 37	-49 40 00	INMET
00549002	Marabá	-05 21 56	-49 07 30	INMET
00547000	Imperatriz	-05 32 06	-47 28 42	INMET
00648000	Xambioá	-06 24 47	-48 32 08	ANA
00647000	Tocantinópolis	-06 17 14	-47 23 31	ANA
00651001	Boa Esperança	-06 43 00	-51 47 00	ANA
00451000	Aldeia Bacajá	-04 54 55	-51 25 46	ANA
00546002	Grajaú	-05 48 00	-46 27 00	INMET

Conforme sugere (ONS, 2004), tendo em vista a vasta extensão territorial da bacia, buscou-se repartir a área em um número mínimo de regiões, tomando-se por base referencial os padrões de sazonalidade das chuvas médias observadas nos vários postos pluviométricos da região. A configuração isoietal das chuvas médias anuais da bacia é apresentada no Anexo C.

Desta forma, definiu-se as Regiões IA e IB, apresentada na Figura 5.4, com as seguintes características:

- Região IA: localizada na porção setentrional da bacia, tendo como único representante dentro da bacia o posto Tucuruí. É a região mais chuvosa da bacia, com uma chuva média anual de 2.200 mm. O bimestre mais chuvoso ocorre em Março/Abril, com a incidência de cerca de 400 mm/mês, enquanto que o mais seco ocorre em Agosto/Setembro, com chuvas da ordem de 20 mm/mês.

- Região IB: caracterizada por uma faixa contígua mais ao sul e que tem como representantes dentro da bacia os postos de Marabá, Xambioá, Tocantinópolis e Imperatriz. A região possui um regime anual parecido com a Região IA, porém cerca de um mês adiantado.



**Figura 5.4:** Rede de Postos Pluviométricos Considerada - Adaptada de (ONS, 2004)

### 5.3.2 Análise de Correlação e Preenchimento de Falhas

Inicialmente, o processo de preenchimento de falhas dos postos pluviométricos seguiria o mesmo princípio adotado para os postos fluviométricos, ou seja, por meio de uma correlação múltipla com os três postos melhores correlacionados na bacia. No entanto, analisando os coeficientes de correlação dos dados dos postos pluviométricos selecionados, observa-se que os mesmos apresentam uma correlação baixa, com coeficientes de correlação sempre inferiores a 0,40, como mostra a Tabela 5.4 abaixo.

**Tabela 5.4:** *Coefficientes de Correlação entre os Postos Pluviométricos*

Posto / Posto	Tuc	Alt	Mar	Gra	Imp	Xam	Toc	AldBac	BoaEsp
Tuc	1,000	0,309	0,275	0,209	0,227	0,181	0,195	0,302	0,195
Alt	0,309	1,000	0,202	0,145	0,176	0,156	0,171	0,280	0,172
Mar	0,275	0,202	1,000	0,252	0,279	0,259	0,252	0,260	0,203
Gra	0,209	0,145	0,252	1,000	0,379	0,185	0,310	0,183	0,130
Imp	0,227	0,176	0,279	0,379	1,000	0,237	0,332	0,229	0,159
Xam	0,181	0,156	0,259	0,185	0,237	1,000	0,313	0,159	0,133
Toc	0,195	0,171	0,252	0,310	0,332	0,313	1,000	0,227	0,165
AldBac	0,302	0,280	0,260	0,183	0,229	0,159	0,227	1,000	0,220
BoaEsp	0,195	0,172	0,203	0,130	0,159	0,133	0,165	0,220	1,000

Por meio do exposto na tabela acima, conclui-se que os postos envolvidos na análise, embora estejam localizados em uma mesma região pluviologicamente homogênea, notadamente no que tange ao sincronismo das chuvas ao longo do tempo, o mesmo não ocorre no espaço. Os baixos valores de coeficientes de correlação mostram que as informações não possuem comportamento análogo, fato que se justifica pela disposição dos postos na bacia, em que devido a grande abrangência espacial, a precipitação ocorre de forma isolada.

Assim sendo, para realizar o preenchimento de falhas das séries de dados pluviométricos calculou-se a chuva média diária de todo o histórico considerado, ou seja de Janeiro/1970 a Dezembro/2009, que corresponde a 14.610 dias. O postos pluviométricos analisados possuíam as seguintes porcentagens de falhas: Tucuruí (13,2%), Altamira (6,8%), Marabá (10,3%), Grajaú (38,4%), Imperatriz (19,6%), Xambioá (5,0%), Tocantinópolis (5,3%), Aldeia Bacajá (61,5%) e Boa Esperança (30,0%).

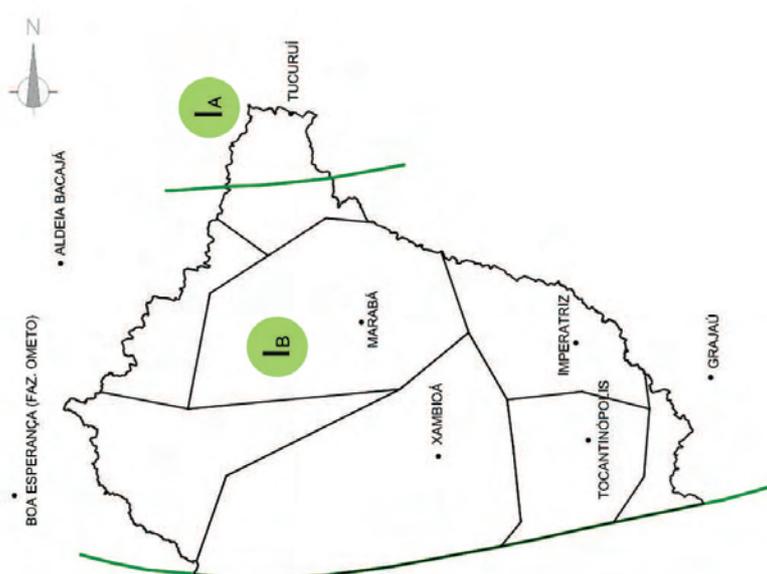
### 5.3.3 Análise de Consistência dos Dados

Conforme apresentado em (ONS, 2004), a metodologia utilizada para a análise de consistência dos dados foi o emprego do Método do Vetor Regional, a nível mensal. A aplicação deste método pressupõe que todos os postos envolvidos estejam localizados numa mesma região pluviologicamente homogênea, aspecto já explicitado na seção 5.3.1.

Para o cálculo da precipitação média da área de influência foi utilizada a metodologia do Polígono de Thiessen. Por meio desta metodologia é determinado o coeficiente proporcional de influência de cada posto dentro da sub-bacia considerada, utilizando o software Autocad. Desta forma, a Tabela 5.5 abaixo apresenta os coeficientes de proporção de cada posto sob a área de influência da sub-bacia e a Figura 5.5 apresenta o Polígono de Thiessen para os postos pluviométricos considerados.

**Tabela 5.5:** Coeficientes de proporção dos postos pluviométricos selecionados

Nome do Posto	Coef. de Proporção (%)
Tucuruí	7,11
Marabá	22,43
Imperatriz	10,28
Xambioá	28,16
Tocantinópolis	9,88
Boa Esperança	13,14
Aldeia Bacajá	6,23
Grajaú	2,77



**Figura 5.5:** Polígono de Thiessen dos postos pluviométricos selecionados

## Simulações com Redes Neurais - Estudo de Caso

### 6.1 Configuração da Rede Neural

Neste trabalho, a previsão de vazões médias diárias afluentes ao reservatório da UHE Tucuruí, de 1 até 12 dias à frente, foi realizada através da metodologia baseada nas redes construtivas NSRBN, implementada em uma versão do modelo NeuroHidro, disponível em (UFG; ELETRONORTE, 2011).

Como dados de entrada para as redes neurais, foram consideradas as informações dos postos fluviométricos, pluviométricos (por meio da chuva média de Thiessen - Thi) e a vazão natural verificada no reservatório da UHE Tucuruí - Tuc. Para as variáveis de entrada fluviométricas foram consideradas diferentes defasagens temporais, de modo que refletissem o tempo de viagem da água de um posto até o local do aproveitamento, ponderadas por meio da área de drenagem de cada posto, como mostra a Tabela 6.1.

**Tabela 6.1:** Defasagem Temporal dos Postos Fluviométricos Considerados

Nome do Posto	Sigla	Área de Drenagem	Defasagem Temporal
		(km <sup>2</sup> )	(dias)
UHE Tucuruí - Barragem	Tuc	757.577	-
Itupiranga	Itu	738.519	0
Marabá	Mar	695.198	0
Descarreto	Des	296.638	5
Tocantinópolis	Toc	288.609	5
Fazenda Alegria	FazAle	194.413	1
Araguatins	Ara	381.802	6
Xambioá	Xam	370.452	6
Conceição do Araguaia	ConAra	325.434	7

A série de dados foi dividida em 3 (três) subconjuntos distintos e independentes: a) um conjunto para ajustar os pesos da rede neural durante o treinamento (Janeiro/1970 a Dezembro/1989), b) um conjunto de validação cruzada, usado principalmente para mini-

mizar o super/sub-ajustamento do modelo para os dados (Janeiro/1990 a Dezembro/1999) e c)um conjunto para verificação do desempenho do modelo (Janeiro/2000 a Dezembro/2009). Esta divisão dos dados pode ter impacto significativo nos resultados, pois quando os dados não são divididos adequadamente e possuem comportamentos hidráulicos distintos para os subconjuntos, a modelagem e o resultado podem ficar prejudicados.

A fim de evitar erros de sazonalidade, foi ajustada uma rede para o período úmido da área em estudo (novembro a abril) e outra para o período seco (maio a outubro). A saída obtida da combinação das redes para as vazões altas e baixas previstas, servem de entrada para uma terceira rede neural, implementada com base no conceito de redes neurais recorrentes, responsável pela ação de correção do erro de defasagem.

A Tabela 6.2 apresenta as variáveis de entrada simuladas tanto no período úmido quanto no período seco, onde  $t$  corresponde à variável no dia da previsão e  $t-n$  a variável com  $n$  dias de defasagem.

**Tabela 6.2:** Variáveis de entrada consideradas na Rede Neural NSRBN

Sim.	Nº Entradas	Variáveis de Entrada
A	14	Tuc-t-14
B	15	Tuc-t-14; Thi
C	23	Tuc-t-14; CoaAra-t-7; Thi
D	28	Tuc-t-14; Itu-t; Mar-t; Des-t-5; Toc-t-5
E	30	Tuc-t-14; Itu-t; Mar-t; Des-t-5; Toc-t-5; FazAle-t-1
F	37	Tuc-t-14; Itu-t; Mar-t; Des-t-5; Toc-t-5; FazAle-t-1; Ara-t-6
G	44	Tuc-t-14; Itu-t; Mar-t; Des-t-5; Toc-t-5; FazAle-t-1; Ara-t-6; Xam-t-6
H	45	Tuc-t-14; Itu-t; Mar-t; Des-t-5; Toc-t-5; FazAle-t-1; Ara-t-6; Xam-t-6; Thi

## 6.2 Treinamento da Rede Neural

Uma das etapas mais importantes no desenvolvimento de um modelo baseado em redes neurais é o treinamento da rede neural. O treinamento de uma rede consiste na determinação dos seus pesos ótimos através da utilização de um algoritmo que procura minimizar uma função objetivo. Um fator importante a ser considerado durante o treinamento de uma rede neural é o critério de parada. O número máximo de ciclos ou a fixação de um erro mínimo para o conjunto de treinamento são critérios de parada que têm sido utilizados com frequência, apesar de não ser a forma mais adequada.

Assim, a cada iteração o algoritmo determina o novo valor da função objetivo, compara o valor atual com o passado e segue na direção de buscar por um menor valor da função objetivo. O processo continua até que um valor mínimo satisfatório da função objetivo seja encontrado. De acordo com (VALENCA, 2010), o treinamento da rede será interrompido quando o valor do erro para a validação cruzada, após atingir seu valor mínimo, começar a crescer ou quando o valor do erro de um ciclo para o outro ficar estacionário, dentro de uma dada precisão, durante um determinado número de ciclos.

Os dois principais parâmetros do algoritmo *backpropagation* são: a taxa de aprendizagem ( $\alpha$ ) e o momentum ( $\beta$ ). Quando o valor da taxa de aprendizagem é muito baixo o processo de aprendizagem pode ser muito lento, além de ter uma maior chance de ficar preso a mínimos locais. Por outro lado, se seu valor for muito elevado, pode causar instabilidade numérica durante o treinamento. Assim, uma forma proposta para minimizar este problema foi incluir outro parâmetro conhecido como momentum que permite aumentar os passos de treinamento sem aumentar as instabilidades do algoritmo (VALENCA, 2010).

## 6.3 Resultados Obtidos

Neste trabalho, foram estudadas diversas configurações de redes neurais NSRBN, alterando-se os seguintes parâmetros do algoritmo: taxa de aprendizagem ( $0% < \alpha < 100%$ ) e o momentum ( $0% < \beta < 100%$ ). A semente para geração dos pesos utilizada pelo algoritmo foi mantida constante e igual a 987654.

Com relação aos parâmetros utilizados no critério de parada, após alguns testes, adotou-se o *default* do programa, com os seguintes valores: EPOCASMIN = 200 ciclos e EPOCASMAX = 20.000 ciclos.

Com o objetivo de reduzir a variabilidade das informações, aos dados de vazão natural foi aplicada a função logarítmica natural. o conjunto de validação cruzada (4.5%) é a rede H, formada pelos postos fluviométricos Tucuruí, Itupiranga, Marabá, Descarreto, Tocantinópolis, Araguatins, Xambioá e a chuva média de Thiessen (Simulação H), perfazendo um total de 45 variáveis na camada de entrada, respeitados os devidos tempos de viagem da água até o reservatório da UHE Tucuruí, conforme apresentado na entrada para os dados de precipitação foi sem esta transformação.

A Tabela 6.3 e a Tabela 6.4 apresentam os parâmetros  $\alpha$  e  $\beta$  alterados durante cada simulação da rede neural NSRBN, bem como os resultados obtidos para os conjuntos de verificação e validação cruzada, em termos do Erro Percentual Médio Absoluto - MAPE, do Erro Padrão - EP e do Erro Mínimo - Erro mín.

Após vários testes para as VAZÕES ALTAS utilizando a rede de postos considerada, verifica-se que a rede que apresenta o menor erro paraa Tabela 6.3.

Já nos testes para as VAZÕES BAIXAS, utilizando a rede de postos considerada, verifica-se que a rede que apresenta o menor erro para o conjunto de validação cruzada (2,7%) é a rede G, formada pelos postos fluviométricos Tucuruí, Itupiranga, Marabá, Descarreto, Tocantinópolis, Araguatins e Xambioá, perfazendo um total de 44 variáveis na camada de entrada, respeitados os devidos tempos de viagem da água até o reservatório da UHE Tucuruí, conforme apresentado na Tabela 6.4.

Com os arquivos de saída gerados após a calibração da rede para as VAZÕES ALTAS e BAIXAS, faz-se necessária a agregação dos resultados obtidos para todo o período do histórico de dados considerado, para isto utiliza-se o programa NeuroHidro-TimingCorrection, alterando-se também os parâmetros  $\alpha$  e  $\beta$  do algoritmo. Ao final deste processo, a melhor rede calibrada será aquela que apresentar o menor Erro mín para o conjunto de validação cruzada, neste estudo a rede G, conforme apresentado na Tabela 6.5.

O programa NeuroHidroELNENSEMBLES é executado sem a necessidade de visualização pelo usuário e o seu arquivo de saída fornece as informações de Erro Percentual Médio Absoluto - MAPE e Erro Médio Quadrático - EMQ, obtidos com os valores observados e previstos para os três conjuntos de dados analisados, conforme apresentado na Tabela 6.6.

Após a calibragem da melhor rede neural NSRBN é possível avaliar o desempenho obtido com a metodologia em termos do Erro Percentual Médio Absoluto. A Tabela 6.7 apresenta os resultados para a previsão de 1 à 12 dias à frente, considerando o conjunto de dados utilizados para verificação.

Por meio dos resultados apresentados na Tabela 6.7, pode-se inferir que as melhores previsões ocorrem para os primeiros dias de análise, piorando os resultados com o decorrer dos dias, como era esperado.

As previsões de vazões são elaboradas semanalmente pelo ONS, no dia imediatamente anterior ao PMO ou a quaisquer de suas revisões. Como regra geral, a previsão é elaborada nas quartas-feiras da última semana operativa do mês e as previsões para as revisões às quintas-feiras da semana operativa anterior. A análise de desempenho disponível destes modelos ao longo dos últimos anos apresenta índices MAPE para a previsão de vazões semanais na UHE Tucuruí, variando de 9,0% a 14,8%, para o período de 1997 a 2009, como mostra a Tabela 6.8<sup>1</sup>.

Nesta mesma Tabela 6.8 é apresentado o desempenho das previsões semanais para a UHE Tucuruí, para o conjunto de dados da verificação, selecionando o melhor modelo para as VAZÕES ALTAS e BAIXAS e apresentando o resultado na mesma base de dados adotada no PMO.

Comparando os resultados apresentados na Tabela 6.8, percebe-se que as redes neurais construtivas NSBRN apresentam MAPEs bastante inferiores aos obtidos com o modelo PREVIVAZ pelo ONS, para os anos analisados.

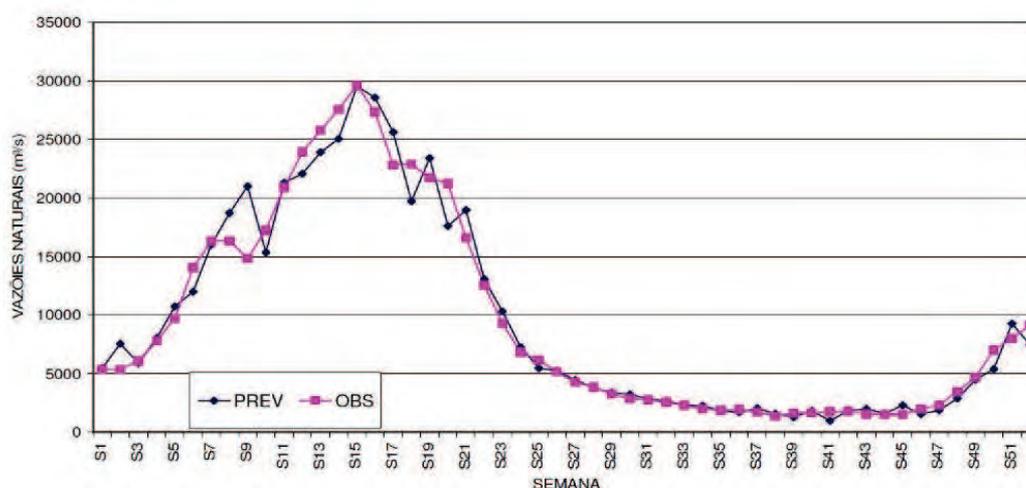
Os valores do MAPE foram, em média, 48% inferiores aos divulgados pelo ONS, mostrando assim a vantagem da metodologia proposta neste trabalho. Destacam-se os resultados para os anos de 2000 e 2001, cujas reduções no valor do MAPE foram, respectivamente, de 73,8% e 62,4%. Em contrapartida, a menor redução ocorreu no ano de 2009, cujo MAPE reduziu 25,6%.

Os modelos de redes neurais fornecem uma boa aproximação do hidrograma, mas as previsões geralmente apresentam-se com um erro de defasagem temporal, ou seja,

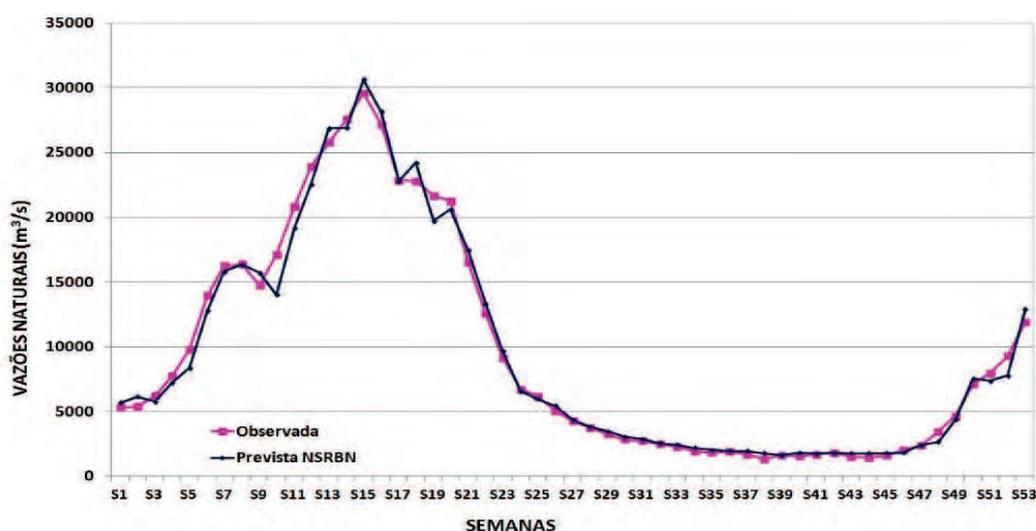
<sup>1</sup>Constata-se que para os anos de 1998, 2005 e 2006 o ONS não disponibilizou em sua página eletrônica na internet o relatório anual de avaliação das previsões, o que impossibilita comparações de desempenho dos modelos de previsão nestes anos.

o modelo só é capaz de prever a ascensão depois que ela ocorre (o que é conhecido como efeito sombra) (VALENCA; LUDERMIR., 2007). Nesse aspecto, a melhor metodologia será aquela que apresentar uma previsão da ascensão com maior sintonia temporal em relação aos dados observados.

A Figura 6.1 e a Figura 6.2, a seguir, apresentam as previsões de vazões semanais para a UHE Tucuruí, respectivamente, obtidas pelo ONS e por meio da Rede NSRBN, para o ano de 2008. Por meio delas é possível observar o quanto é melhor a previsão no período da ascensão quando se utiliza a rede NSRBN.



**Figura 6.1:** Previsão de Vazões Semanais - UHE Tucuruí - 2008 (ONS, 2010).



**Figura 6.2:** Previsão de Vazões Semanais - UHE Tucuruí - 2008 (NRSBN)

Para dar uma visão geral dos resultados obtidos para a UHE Tucuruí, o Anexo D apresenta as previsões de vazões semanais para os demais anos considerados no conjunto de verificação.

**Tabela 6.3:** Resultados das Simulações para as Vazões Altas

Parâmetros de Entrada				Resultados - NeuroHidroELNALTAS		
Simulação	Tipo	Alfa	Beta	Conjunto de Verificação		Validação Cruzada
				MAPE (%)	EP ( $m^3/s$ )	Erro mín (%)
<b>A</b>	A1	30	50	10,93	1.816,2	8,79
	<b>A2</b>	<b>30</b>	<b>60</b>	<b>10,63</b>	<b>1.737,9</b>	<b>7,80</b>
	A3	30	65	15,06	3.584,0	8,07
	A4	35	55	12,85	1.842,1	8,20
	A5	30	70	11,19	1.821,2	8,53
	A6	30	55	10,36	1.741,8	8,02
<b>B</b>	B1	30	50	10,84	1.733,8	8,24
	B2	30	60	10,32	1.753,1	8,19
	B3	30	65	10,40	1.735,3	8,29
	B4	35	55	10,47	1.790,6	8,64
	<b>B5</b>	<b>30</b>	<b>70</b>	<b>10,89</b>	<b>1.710,4</b>	<b>7,57</b>
	B6	30	55	10,50	1.766,9	8,38
<b>C</b>	C1	30	50	11,54	1.663,6	7,47
	C2	30	60	10,57	1.749,8	7,39
	C3	30	65	10,88	1.843,3	8,20
	<b>C4</b>	<b>30</b>	<b>70</b>	<b>10,12</b>	<b>1.710,0</b>	<b>7,25</b>
	C5	40	40	13,99	1.890,6	9,83
	C6	30	55	10,71	1.765,6	8,01
<b>D</b>	D1	30	50	12,43	1.843,3	6,29
	<b>D2</b>	<b>30</b>	<b>60</b>	<b>11,57</b>	<b>1.824,0</b>	<b>6,05</b>
	D3	30	70	18,43	2.016,6	10,80
	D4	35	55	17,89	1.964,7	6,84
	D5	35	65	20,27	2.049,9	9,24
	D6	30	55	12,52	1.868,4	6,92
<b>E</b>	E1	30	50	12,59	1.966,6	7,69
	E2	30	60	16,82	2.027,6	9,86
	E3	30	40	19,84	2.097,2	11,74
	<b>E4</b>	<b>40</b>	<b>50</b>	<b>10,64</b>	<b>1.895,1</b>	<b>6,37</b>
	E5	50	50	15,21	2.071,7	10,23
<b>F</b>	F1	30	50	12,40	1.956,2	5,72
	F2	20	50	16,86	2.122,8	11,63
	F3	40	50	14,96	2.083,1	8,61
	F4	30	55	19,60	2.611,1	18,81
	<b>F5</b>	<b>30</b>	<b>70</b>	<b>11,45</b>	<b>1.810,7</b>	<b>5,62</b>
<b>G</b>	G1	30	50	13,54	2.118,8	10,62
	<b>G2</b>	<b>30</b>	<b>60</b>	<b>11,70</b>	<b>1.904,9</b>	<b>5,10</b>
	G3	20	50	13,54	2.118,6	10,61
	G4	40	50	13,54	2.119,4	10,63
	G5	30	55	13,72	2.131,4	10,97
	G6	30	70	11,17	1.828,0	5,34
<b>H</b>	<b>H1</b>	<b>30</b>	<b>50</b>	<b>10,73</b>	<b>1.652,8</b>	<b>4,45</b>
	H2	30	60	11,10	1.703,1	4,82
	H3	40	50	9,40	1.758,2	5,02
	H4	30	55	12,64	1.688,5	5,87
	H5	30	70	11,88	2.565,53	4,85

**Tabela 6.4:** Resultados das Simulações para as Vazões Baixas

Parâmetros de Entrada				Resultados - NeuroHidroELNBAIXAS		
Simulação	Tipo	Alfa	Beta	Conjunto de Verificação	Validação Cruzada	
				EP (%)	EP (%)	Erro mín (%)
<b>A</b>	<b>A1</b>	<b>20</b>	<b>20</b>	<b>3,91</b>	<b>2,53</b>	<b>8,45</b>
	A2	20	30	3,95	2,57	8,72
	A3	20	50	4,06	2,60	8,83
	A4	20	60	4,17	2,64	8,65
	A5	15	20	3,93	2,54	8,53
	A6	25	25	3,93	2,55	8,61
<b>B</b>	B1	20	20	4,34	2,72	9,28
	B2	20	30	3,81	2,45	8,00
	B3	20	50	3,90	2,48	8,16
	<b>B4</b>	<b>15</b>	<b>20</b>	<b>3,79</b>	<b>2,40</b>	<b>7,67</b>
	B5	25	25	3,79	2,42	7,77
<b>C</b>	C1	20	20	4,60	2,75	8,65
	C2	20	30	4,63	2,75	8,59
	C3	20	50	4,11	2,54	7,73
	<b>C4</b>	<b>20</b>	<b>60</b>	<b>4,02</b>	<b>2,54</b>	<b>7,72</b>
	C5	20	15	4,61	2,75	8,62
	C6	25	25	4,31	2,62	8,03
<b>D</b>	D1	20	20	5,32	2,58	7,87
	D2	15	20	5,39	2,59	8,02
	D3	20	15	5,26	2,54	7,88
	D4	20	30	5,47	2,47	6,97
	<b>D5</b>	<b>30</b>	<b>30</b>	<b>4,49</b>	<b>2,13</b>	<b>5,33</b>
	D6	35	40	5,34	2,41	6,60
<b>E</b>	E1	20	20	4,63	2,26	6,02
	E2	20	30	4,85	2,28	5,98
	E3	30	30	4,97	2,18	5,53
	E4	35	35	4,43	2,19	5,64
	<b>E5</b>	<b>40</b>	<b>40</b>	<b>4,72</b>	<b>2,19</b>	<b>5,49</b>
	E6	50	50	4,97	2,23	5,58
<b>F</b>	F1	20	20	7,07	3,71	8,85
	F2	25	25	6,77	3,64	8,99
	F3	30	30	5,68	2,74	5,42
	F4	20	30	6,57	3,63	9,13
	<b>F5</b>	<b>35</b>	<b>35</b>	<b>5,13</b>	<b>2,50</b>	<b>4,59</b>
	F6	40	40	5,68	2,63	5,84
<b>G</b>	G1	20	20	4,58	2,96	5,31
	G2	25	25	4,56	2,97	5,31
	G3	30	30	4,64	3,07	5,74
	G4	20	30	4,55	2,99	5,39
	<b>G5</b>	<b>40</b>	<b>40</b>	<b>4,03</b>	<b>2,18</b>	<b>2,70</b>
	G6	50	50	4,65	2,66	4,09
<b>H</b>	H1	20	20	5,60	3,07	9,72
	H2	25	25	4,60	2,49	6,89
	<b>H3</b>	<b>30</b>	<b>30</b>	<b>4,08</b>	<b>2,16</b>	<b>5,19</b>
	H4	40	40	4,38	2,24	5,49
	H5	50	50	5,52	2,90	8,75

**Tabela 6.5:** Resultados das Simulações - TimingCorrection

Parâmetros de Entrada				Resultados - NeuroHidroTimingCorrection		
Simulação	Tipo	Alfa	Beta	Validação Cruzada	Conjunto de Verificação	
				Erro mín ( $m^3/s$ )	MAPE (%)	EP ( $m^3/s$ )
A	A1	60	60	232,59	8,76	1.756,3
	A2	50	60	234,47	8,76	1.758,4
	A3	60	50	232,69	8,87	1.788,9
	A4	55	55	239,76	8,82	1.769,1
B	B1	60	60	257,83	8,34	1.667,3
	B2	50	60	254,40	8,35	1.671,9
	B3	60	50	255,87	8,32	1.670,3
	B4	55	55	250,64	8,33	1.668,7
C	C1	60	60	375,89	8,66	1.608,8
	C2	50	60	381,77	8,64	1.608,9
	C3	60	50	379,15	8,61	1.602,4
	C4	55	55	376,96	8,66	1.608,9
D	D1	60	60	276,83	9,30	1.695,8
	D2	50	60	277,73	9,30	1.692,1
	D3	60	50	275,29	9,31	1.691,8
	D4	70	60	277,61	9,27	1.699,0
E	E1	60	60	293,00	9,57	1.744,6
	E2	50	60	292,13	9,57	1.746,1
	E3	60	50	292,56	9,56	1.744,9
	E4	40	40	292,60	9,56	1.743,7
	E5	70	70	294,13	9,57	1.744,2
F	F1	60	60	309,00	9,66	1.748,9
	F2	50	60	310,96	9,63	1.746,9
	F3	60	50	311,04	9,62	1.748,8
	F4	40	40	311,95	9,60	1.741,0
	F5	70	70	312,20	9,68	1.757,3
	F6	65	65	316,34	9,62	1.749,7
G	<b>G1</b>	<b>60</b>	<b>60</b>	<b>206,25</b>	<b>8,92</b>	<b>1.752,3</b>
	G2	50	60	224,12	9,02	1.754,9
	G3	60	50	226,84	8,96	1.753,6
	G4	70	60	221,38	9,01	1.753,5
	G5	70	70	222,29	9,01	1.752,6
	G6	50	50	222,17	9,04	1.757,2
H	H1	60	60	226,90	8,96	1.636,6
	H2	50	60	222,37	9,08	1.654,1
	H3	60	50	222,01	9,07	1.633,4
	H4	70	60	227,00	8,97	1.629,8
	H5	70	70	221,50	9,01	1.641,2
	H6	50	50	221,00	9,21	1.678,4

**Tabela 6.6:** Resultados das Simulações - ENSEMBLES

Simulação	Resultados - NeuroHidroELNENSEMBLES - EMQ ( $m^3/s$ ) - MAPE (%)		
	Treinamento	Validação Cruzada	Verificação
A	1.840	1.527	1.892
	8,42	4,29	10,30
B	1.751	1.490	1.820
	8,16	4,15	9,96
C	1.703	1.373	1.764
	8,40	4,03	10,25
D	1.435	1.135	1.850
	6,61	3,12	10,78
E	1.448	1.095	1.892
	6,69	3,21	11,05
F	1.424	1.108	1.908
	7,49	3,70	11,35
<b>G</b>	<b>1.370</b>	<b>1.022</b>	<b>1.899</b>
	<b>6,70</b>	<b>3,28</b>	<b>10,32</b>
H	1.298	1.055	1.760
	6,73	3,64	10,23

**Tabela 6.7:** Resultado da Previsão de Vazões para o Conjunto de Verificação

Dias a Frente	EPMA (%)
1	4,72
2	5,29
3	6,10
4	7,02
5	9,74
6	10,34
7	11,01
8	11,62
9	12,45
10	13,35
11	14,27
12	17,42

**Tabela 6.8:** *Resultado da Previsão de Vazões Semanais na UHE Tucuruí - PREVIVAZ x Rede Neural NRSBN*

Ano	PREVIVAZ MAPE (%)	NSRBN MAPE (%)
1997	11,3	-
1999	9,4	-
2000	13,4	3,51
2001	12,8	4,81
2002	14,8	6,94
2003	13,0	8,20
2004	11,6	6,05
2005	-	6,31
2006	-	6,51
2007	13,9	7,00
2008	12,5	7,84
2009	9,0	6,70

---

## Conclusões e Trabalhos Futuros

---

Muitos trabalhos têm sido desenvolvidos buscando obter previsões de vazões naturais cada vez melhores para os reservatórios que compõem as usinas hidrelétricas do SIN, de forma a avaliar as condições operacionais futuras dessas usinas e subsidiar a tomada de decisão quanto a melhor forma de otimização do despacho das gerações, melhorando o desempenho do sistema elétrico, de forma a explorar toda a sua capacidade hidrológica, aumentar sua confiabilidade e reduzir custos.

Desta forma, foi proposto neste trabalho calibrar um modelo de previsão de vazões médias diárias, utilizando a metodologia de Redes Neurais Artificiais, mais especificamente as redes construtivas do tipo NSRBN (*Non-Linear Sigmoidal Regression Blocks Networks*), no horizonte de 1 até 12 dias à frente, para a UHE Tucuruí, considerando a informação advinda de diferentes postos pluviométricos e fluviométricos, localizados a montante do seu reservatório.

Os dados de entrada para este tipo de modelo devem ser de boa qualidade e representativos das características da bacia hidrográfica estudada. Para isto, foi realizada uma exaustiva pesquisa na rede hidrometeorológica da bacia hidrográfica dos rios Tocantins/Araguaia. Para o presente estudo, face à necessidade de dados de grande abrangência temporal, definida de Janeiro de 1970 a Dezembro de 2009, pode-se afirmar que o suporte fornecido por essa rede é insatisfatório.

Para a rede de postos fluviométricos e pluviométricos considerada foram realizadas a análise de correlação e preenchimento de falhas, bem como a análise de consistência dos dados, conforme sugrido em (ONS, 2004). Com relação a estes estudos, destaca-se que os postos fluviométricos apresentaram excelentes coeficientes de correlação, superiores a 0,70, diferente dos postos pluviométricos, cujos coeficientes de correlação foram inferiores a 0,40, o que demonstra a grande variabilidade espacial da chuva na bacia. Para a análise de consistência dos dados pluviométricos, adotou-se a o Método do Vetor Regional, a nível mensal, e o emprego do Polígono de Thiessen para o cálculo da chuva média da bacia.

A série de dados foi dividida em 3 (três) subconjuntos distintos e independentes: a) um conjunto para ajustar os pesos da rede neural durante o treinamento (Janeiro/1970 a Dezembro/1989), b) um conjunto de validação cruzada, usado principalmente para evitar superajustamento dos dados (Janeiro/1990 a Dezembro/1999) e c) um conjunto para verificação do desempenho do modelo (Janeiro/2000 a Dezembro/2009).

Foram simuladas diversas configurações de redes neurais NRSBN, alterando as variáveis de entrada, utilizando os dados de vazões dos postos fluviométricos considerados e a chuva média de Thiessen. O treinamento da rede neural foi realizado separadamente para as VAZÕES ALTAS e VAZÕES BAIXAS, de forma a verificar qual rede de postos melhor representa os períodos úmidos e secos da bacia.

Para as VAZÕES ALTAS, verifica-se que a rede que apresenta o menor erro para o conjunto de validação cruzada (4,5%) é a rede H, formada pelos postos fluviométricos Tucuruí, Itupiranga, Marabá, Descarreto, Tocantinópolis, Araguatins, Xambioá e a chuva média de Thiessen (Simulação H), perfazendo um total de 45 variáveis na camada de entrada, respeitados os devidos tempos de viagem da água até o reservatório da UHE Tucuruí. Este resultado demonstra a importância da consideração dos dados de chuva para a calibração e previsão de vazões no período úmido.

Já nos testes para as VAZÕES BAIXAS, verifica-se que a rede que apresenta o menor erro para o conjunto de validação cruzada (2,7%) é a rede G, formada pelos postos fluviométricos Tucuruí, Itupiranga, Marabá, Descarreto, Tocantinópolis, Araguatins e Xambioá, perfazendo um total de 44 variáveis na camada de entrada, respeitados os devidos tempos de viagem da água até o reservatório da UHE Tucuruí.

Após a calibragem da melhor rede neural NSRBN foi possível avaliar o desempenho obtido para a UHE Tucuruí, para o conjunto de dados da verificação, selecionando o melhor modelo para as VAZÕES ALTAS e BAIXAS e apresentando o resultado na mesma base de dados adotada no PMO. No que diz respeito às previsões de vazões em nível diário e semanal, os resultados apresentados neste trabalho comprovam a eficácia das redes neurais construtivas, especificamente as redes NSRBN, que apresentaram resultados superiores aos modelos estocásticos atualmente utilizados no Setor Elétrico Brasileiro, para a métrica de erro utilizada para análise do desempenho.

Os valores do MAPE foram, em média, 48% inferiores aos divulgados pelo ONS, mostrando assim a vantagem da metodologia proposta neste trabalho. Destacam-se os resultados para os anos de 2000 e 2001, cujas reduções no valor do MAPE foram, respectivamente, de 73,8% e 62,4%, provavelmente influenciado pelas baixas afluências nestes anos que provocaram o racionamento de energia no Brasil. Em contrapartida, a menor redução ocorreu no ano de 2009, cujo MAPE reduziu 25,6%.

Em geral, à medida em que se aumentam o número de dados de entrada, ou seja, o número de postos considerados, diminui-se os valores do MAPE encontrados.

Adicionalmente, percebe-se que as previsões realizadas por meio da rede neural NSRBN apresentaram um menor erro de defasagem temporal, quando comparada com as previsões realizadas pelo PREVIVAZ, isto mostra que o modelo adotado neste estudo fornece uma melhor aproximação do hidrograma real, prevendo a ascensão com maior sintonia temporal em relação aos dados observados.

Utilizou-se neste trabalho o modelo NeuroHidro, cujo tempo de calibração tanto para as vazões baixas quanto para as vazões altas, durou em torno de 30 minutos.

Os resultados deste trabalho foram apresentados no IX Congreso Latinoamericano de Generación y Transporte de Energía Eléctrica - CLAGTEE, realizado entre os dias 6 a 9 de novembro de 2011, na cidade de Mar Del Plata, Argentina.

## 7.1 Trabalhos Futuros

Entre os possíveis trabalhos futuros a serem realizados, podem ser enumeradas os seguintes:

1. melhor adequação dos postos hidrometeorológicos, acompanhamento das medições e consolidação dos dados;
2. consideração da chuva real, considerando a defasagem temporal em relação ao posto analisado, em detrimento da chuva média;
3. consideração de previsões de chuva como dados de entrada;
4. análise de sensibilidade por meio da alteração na divisão dos dados de entrada da rede e nos percentuais de distribuição desses dados;
5. aumentar o número de calibrações: período úmido, seco e de transição;
6. utilizar de outras métricas para avaliação dos resultados;
7. verificar no PMO a operação da UHE Tucuruí considerando as previsões de vazões da rede NRSBN.
8. estender a metodologia utilizada no presente trabalho para as demais usinas hidrelétricas da Eletronorte.

---

## Referências Bibliográficas

---

ALBANO, G. D.; VALENCA, M. J. S.; PORTO, R. L. L. Previsão de vazões médias mensais afluentes com o uso de redes neurais construtivas — alternativa de planejamento operacional de represas. *Anais do XVII Simpósio Brasileiro de Recursos Hídricos*, São Paulo - SP, 2007.

ANA. *Plano Estratégico de Recursos Hídricos da Bacia Hidrográfica dos rios Tocantins e Araguaia: relatório síntese*. Brasília, DF: ANA - Agência Nacional de Águas, 2009. 256 p.

ANA. *Conjuntura dos Recursos Hídricos no Brasil: informe 2011*. Brasília, DF: ANA - Agência Nacional de Águas, 2011. 112 p.

BALLINI, R. et al. Previsão de vazões médias mensais usando redes neurais nebulosas. *Revista Brasileira de Controle & Automação*, v. 14, n. 3, p. 286–297, Julho, Agosto e Setembro 2003.

BOX, G. E. P.; JENKINS, G. M. *Time Series Analysis - Forecasting and Contrl*. California, EUA: [s.n.], 1976.

BRAVO, J. M. et al. Previsões de curto prazo de vazão afluente ao reservatório de furnas utilizando redes neurais artificiais. *Revista Brasileira de Recursos Hídricos - RBRH*, v. 13, n. 2, p. 77–88, Abril/Junho 2008.

CARVALHO, A. R. L. de et al. Previsão de vazões diárias através de uma abordagem estocástica - modelo previvazh. *Anais do XIV Simpósio Brasileiro de Recursos Hídricos*, Aracajú - SE, v. 14, 2001.

CEPEL. *Modelo de Previsão de Vazões Semanais Aplicado ao Sistema Hidrotérmico Brasileiro - PREVIVAZ, Relatório Técnico DPP/PEL 125/97*. Rio de Janeiro, RJ: CEPEL, 1997.

CHENG, B.; TITTERINGTON, D. M. Neural network: A review from a statistical perspective. *Statistical Science*, v. 9, n. 1, p. 2–54, Fevereiro 1994.

CHOU, S. C. *Climanálise - Boletim de Monitoramento e Análise Climática*. Cachoeira Paulista, SP: Instituto Nacional de Pesquisas Espaciais - INPE/CPTEC, 1996.

CHOW, V. T. *Handbook of Applied Hydrology*. New York, EUA: MacGraw-Hill Book Co., 1964.

COSTA, F. da S.; MACEIRA, M. E. P.; DAMAZIO, J. M. Modelos de previsão hidrológica aplicados ao planejamento da operação do sistema elétrico brasileiro. *Workshop de Previsão de Vazões*, Setembro 2007.

- COSTA, F. da S. et al. Modelagem estocástica de previsão de vazões mensais: Previvazm. *Anais do XV Simpósio Brasileiro de Recursos Hídricos*, Curitiba - PR, 2003.
- COULIBALY, P. et al. Daily reservoir inflow forecasting using artificial neural network with stopped training approach. *Journal of Hydrology*, v. 230, p. 244–257, Maio 2000.
- ELETROBRAS. *Sistema de Informações do Potencial Hidrelétrico Brasileiro - SIPOT*. Rio de Janeiro, RJ: EGPB - Divisão de Estudos de Inventário e Hidrologia, 2012.
- ELETRONORTE; THEMAG; ENGEVIX. *Projeto Básico - Usina Hidrelétrica Tucuruí*. Brasília - DF: Eletrobras Eletronorte, 1996.
- ELSHORBAGY, A. et al. Performance evaluation of artificial neural networks for runoff prediction. *Journal of Hydrologic Engineering*, v. 5, n. 4, p. 424–427, Outubro 2000.
- FAYAL, M. A. de A. *Previsão de Vazão por Redes Neurais Artificiais e Transformada Wavelet*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro - RJ, Fevereiro 2008.
- FIGUEIREDO, K. et al. Modelo de previsão de vazão com informação de precipitação utilizando redes neurais. *Revista Brasileira de Recursos Hídricos - RBRH*, v. 12, n. 3, p. 69–82, Julho/Setembro 2007.
- FLOOD, I.; KARTAN, N. Neural networks in civil engineering. i: Principles and understanding. *Journal of Computing in Civil Engineering*, v. 8, n. 2, p. 131–148, 1994.
- GOMES, L. F. C. *Previsão de Vazões Naturais Diárias ao Reservatório de Três Marias Usando a Técnica de Redes Neurais*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife - PE, Julho 2006.
- GUILHON, L. G. F. et al. Comparação de métodos de previsão de vazões naturais afluentes a aproveitamentos hidrelétricos. *Revista Brasileira de Recursos Hídricos - RBRH*, v. 12, n. 3, p. 13–20, Julho/Setembro 2007.
- HEBB, D. O. *The Organization of Behavior: A Neuropsychological Theory*. New York, EUA: Wiley, 1949.
- HSU, K. L. et al. Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research*, v. 31, n. 10, p. 2517–2530, Outubro 1995.
- KELMAN, J.; DAMASIO, J. M.; COSTA, J. P. Geração de séries sintéticas de vazões diárias - modelo diana. *Caderno de Recursos Hídricos, Brasil*, v. 1, n. 2, 1983.
- KYRILLOS, D. de S. *Sistema de Suporte ao Planejamento dos Recursos Hídricos. Estudo de caso: bacia do rio São Francisco*. Dissertação (Mestrado) — Departamento de Engenharia Civil - Universidade Federal de Pernambuco, Recife - PE, 2000.
- LIMA, C. H. R.; FERREIRA, W. M. F. Análise de modelos de redes neurais aplicados ao processo de chuva-deflúvio no semi-árido. *Anais do XV Simpósio Brasileiro de Recursos Hídricos*, Curitiba - PR, 2003.
- LIMA, H. V. C. et al. Modelagens hidrológica conceitual e por redes neurais artificiais aplicadas ao processo chuva-vazão: Uma análise comparativa. *Anais do XVI Simpósio Brasileiro de Recursos Hídricos*, João Pessoa - PB, 2005.

- LOPES, J. ao E. G. et al. Simulação hidrológica: Aplicação de um modelo simplificado. *Anais do III Simpósio Brasileiro de Recursos Hídricos*, Fortaleza - CE, v. 2, p. 42–62, 1981.
- LUNA, I. et al. Sistema baseado em regras nebulosas para previsão de vazões semanais. *XX SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica*, Recife - PE, p. 1–8, Novembro 2009.
- MACEIRA, M. E. P. et al. Models applied to weekly streamflow forecast. *Proceedings of the 1999 IEEE Powertech*, Budapest, 1999.
- MACHADO, F. W. *Modelagem Chuva-Vazão Mensal Utilizando Redes Neurais Artificiais*. Dissertação (Mestrado) — Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental - Universidade Federal de Paraná, Curitiba - PA, 2005.
- MARINHO, M. H. da N. et al. Previão de vazões afluentes utilizando modelos periódicos auto-regressivos, redes neurais e redes neurais nebulosas. *VII Simpósio de Recursos Hídricos do Nordeste*, São Luís - MA, VII, p. 94–94, 2004.
- MCCULLOUGH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, n. 5, p. 115–133, 1943.
- MÉNDEZ, M. C. et al. Modelling of the monthly and daily behaviour of the runoff of the xallas river using box-jenkins and neural networks methods. *Journal of Hydrology*, v. 296, p. 38–58, Março 2004.
- MINNS, A. W.; HALL, M. J. Artificial neural networks as rainfall-runoff models. *Hydrological Sciences Journal*, v. 41, n. 3, p. 399–417, 1996.
- MINSKY, M. L.; PAPERT, S. A. *Perceptrons*. Cambridge - Massachusetts: MIT Press, 1969.
- MORGAN, B. J. T. The cubic logistic model for quantal assay data. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, University of Kent - UK, v. 34, n. 2, p. 105–113, 1985.
- OLIVO, A. A. et al. Previsão de cheias fluviais usando redes neurais artificiais. *Anais do VI Simpósio de Recursos Hídricos do Nordeste*, Maceió - AL, 2002.
- ONS. *Reavaliação de Séries de Vazões Naturais - Bacia do Tocantins*. Rio de Janeiro, RJ: ONS, 2004.
- ONS. *Informação de Taxas de Indisponibilidade Forçada e Programada - Carta ONS - 039/300/2005*. Rio de Janeiro, RJ: ONS, 2005.
- ONS. *Submódulo 9.5 - Previsão de Vazões e Geração de Cenários de Afluências*. Rio de Janeiro, RJ: ONS, 2009. 1-10 p.
- ONS. *Relatório Anual de Avaliação das Previsões de Vazões*. [S.l.]: ONS, 2010. 8 p.
- PAZ, A. R. da et al. Análise de metodologias de previsão de vazões em tempo real. estudos de casos: bacias do rio doce e do rio uruguai. *Anais do II Simpósio de Recursos Hídricos do Centro-Oeste*, Campo Grande - MS, v. 1, 2002.

RAJURKAR, M. P. et al. Modelling of the daily rainfall-runoff relationship with artificial neural networks. *Journal of Hydrology*, v. 285, p. 96–113, Outubro 2004.

RAMOS, A. M.; GALVAO, C. de O. Estabilidade de redes neurais em modelagem hidrometeorológicas. *Anais do XIV Simpósio Brasileiro de Recursos Hídricos*, Aracaju - SE, v. 14, 2001.

ROSENBLATT, F. Perceptron simulation experiment. *Proceedings of the Inst. of radio Eng.*, n. 48, p. 301–309, 1958.

RUMELHART, D. E.; MCCLELLAND, J. *Parallel Distributed Processing: Exploration in the microstructure of cognition, 1,2,3*. Bradford book. Cambridge, Massachusetts: MIT Press, 1986.

SAJIKUMAR, N.; THANDAVESWARA, B. S. A non-linear rainfall-runoff model using an artificial neural network. *Journal of Hydrology*, v. 216, p. 32–55, Outubro 1999.

SHAMSELDIN, A. Y. Application of a neural network technique to rainfall-runoff modelling. *Journal of Hydrology*, v. 199, p. 272–294, Novembro 1997.

SILVA, T. G. de Souza e; SILVA, J. D. S. da. Projeto água viva: um estudo para aplicação de redes neurais artificiais na previsão de consumo de água das cidades do litoral norte do estado de São Paulo. *Anais do XVI Simpósio Brasileiro de Recursos Hídricos*, v. 1, p. 1–20, Outubro 2005.

SOUSA, W. dos S.; SOUSA, F. de A. S. de. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio Piancó. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 14, n. 2, p. 173–180, 2010.

SPERB, R. M. et al. Prevent: Protótipo de um sistema de previsão de enchentes baseado em redes neurais. *Anais do XIII Simpósio Brasileiro de Recursos Hídricos*, Belo Horizonte - MG, 1999.

TAFNER, M. A.; XEREZ, M. de; FILHO, I. W. R. *Redes Neurais, introdução e princípios de neurocomputação*. Blumenau-SC: Editora Eko, 1996.

TOKAR, A. S.; JOHNSON, P. A. Rainfall-runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, v. 4, n. 3, p. 232–239, Julho 1999.

TUCCI, C. E. M. *Modelos Hidrológicos*. Porto Alegre: Ed. da Universidade: ABRH, 1998. 669 p.

UFG; ELETRONORTE, E. *Modelo de Previsão NeuroHidro - Manual de Utilização*. Goiânia, GO: UFG, 2011.

VALENCA, M. J. S. Aplicação de redes neurais na área de recursos hídricos. *Anais do XII Simpósio Brasileiro de Recursos Hídricos*, Vitória - ES, 1997.

VALENCA, M. J. S. *Análise e projeto de redes neurais com abordagem construtiva para modelagem de sistemas complexos*. Tese (Doutorado) — Departamento de Informática - Universidade Federal de Pernambuco, Recife - PE, 1999.

VALENCA, M. J. S. *Aplicando Redes Neurais: um guia completo*. Editora livro rápido — Elógica. 1. Olinda - PE: v.800, 2005. 284 p.

VALENCA, M. J. S. *Fundamentos das Redes Neurais: exemplos em Java*. 2 ed. rev. ampl.. ed. Olinda - PE: Editora Livro Rápido — Elógica, 2010. 310 p.

VALENCA, M. J. S.; LUDERMIR, T. Neurodiano - um modelo multivariado para previsão de vazões médias diárias. *Anais do XVI Simpósio Brasileiro de Recursos Hídricos*, João Pessoa - PB, 2005.

VALENCA, M. J. S.; LUDERMIR, T. B. Redes compostas por blocos de regressões sigmóides não-lineares: Uma eficiente rede de alta ordem com aplicações na previsão de séries temporais. *Anais do V Congresso Brasileiro de Redes Neurais*, Rio de Janeiro - RJ, p. 67–72, Abril 2001.

VALENCA, M. J. S.; LUDERMIR, T. B. Explicando a relação entre as variáveis de uma rede neural — iluminando a caixa preta. *Anais do XVII Simpósio Brasileiro de Recursos Hídricos*, São Paulo - SP 2007.

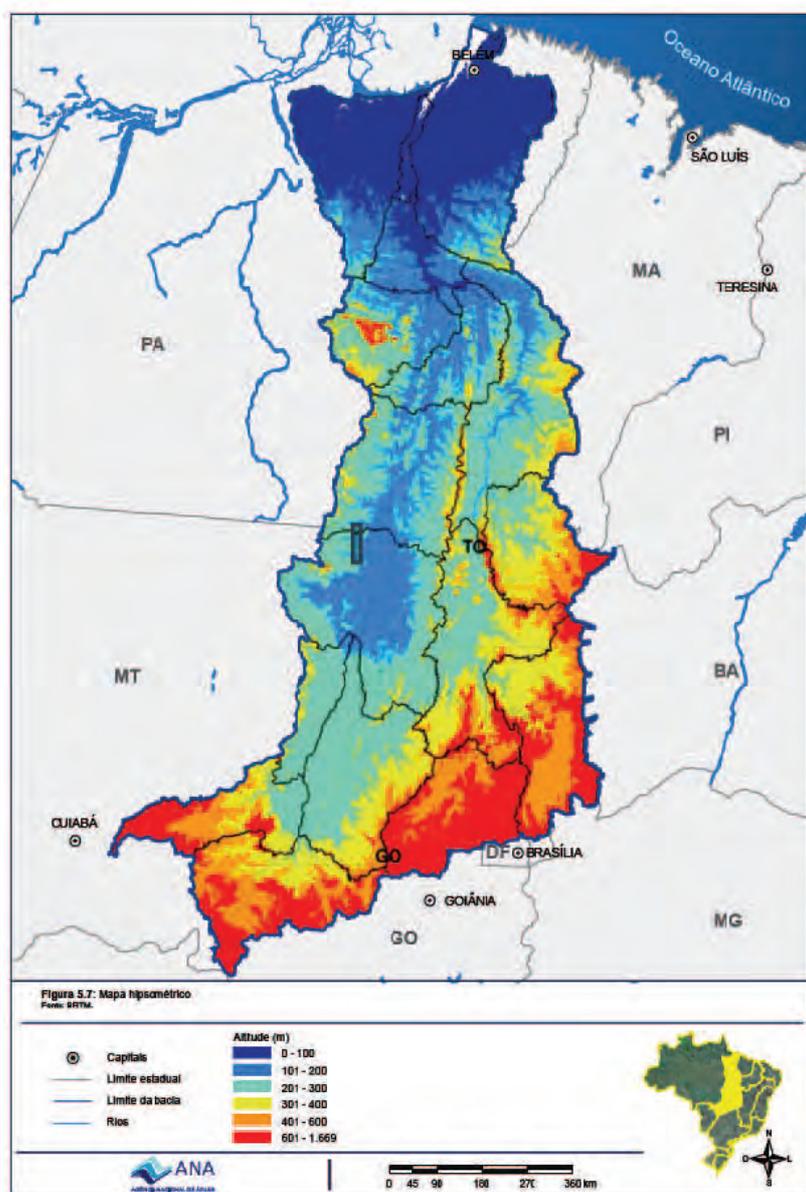
VALENCA, M. J. S.; LUDERMIR., T. B. Proposta de uma função objetivo para ajuste dos parâmetros de modelos de previsão. *Anais do XVII Simpósio Brasileiro de Recursos Hídricos*, São Paulo - SP 2007.

VALENCA, M. J. S.; VALENCA, A. Modelagem do processo chuva x vazão e vazão x vazão utilizando redes neurais. *Anais do XVI Simpósio Brasileiro de Recursos Hídricos*, João Pessoa - PB, 2005.

WERBOS, P. J. *Beyond Regression: New tools for prediction and analysis in behavioral sciences*. Tese (Doutorado) — Harvard university, Cambridge, Massachusetts, 1974.

WIDROW, B.; HOFF, M. E. Adaptive switching circuits. *IRE WESCON Convention Record*, p. 96–104, 1960.

## *ANEXO A – Mapa Hipsométrico da Bacia Hidrográfica Tocantins-Araguaia*



**Figura A.1:** *Mapa Hipsométrico da Bacia Hidrográfica do Tocantins-Araguaia - Fonte: (ANA, 2009)*

## ANEXO B – Curvas de Descarga dos Postos Fluviométricos Considerados

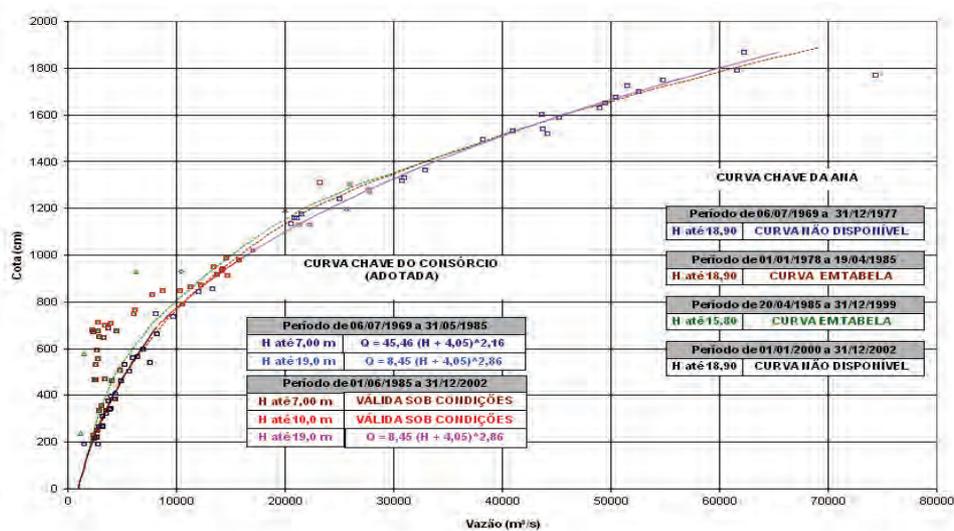


Figura B.1: Curva Chave - Posto Itupiranga (29200000) - Fonte: (ONS, 2004)

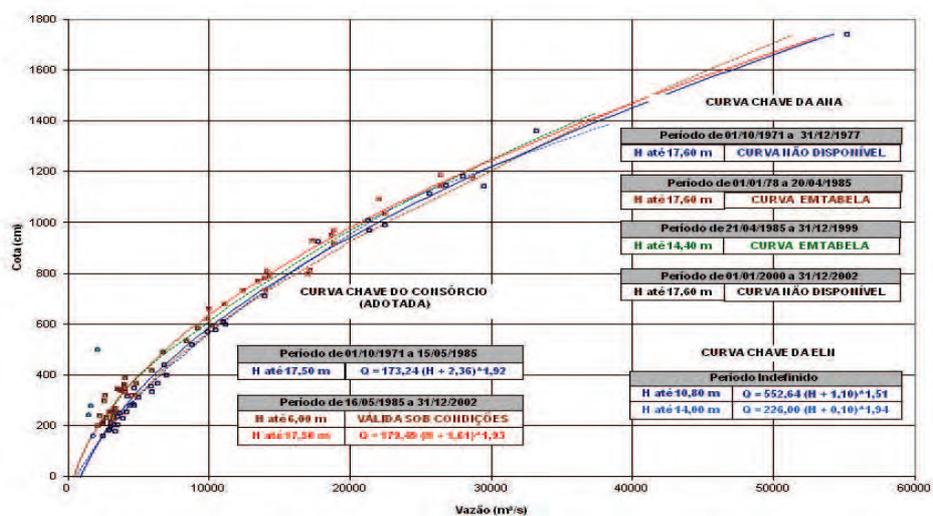


Figura B.2: Curva Chave - Posto Marabá (29050000) - Fonte: (ONS, 2004)

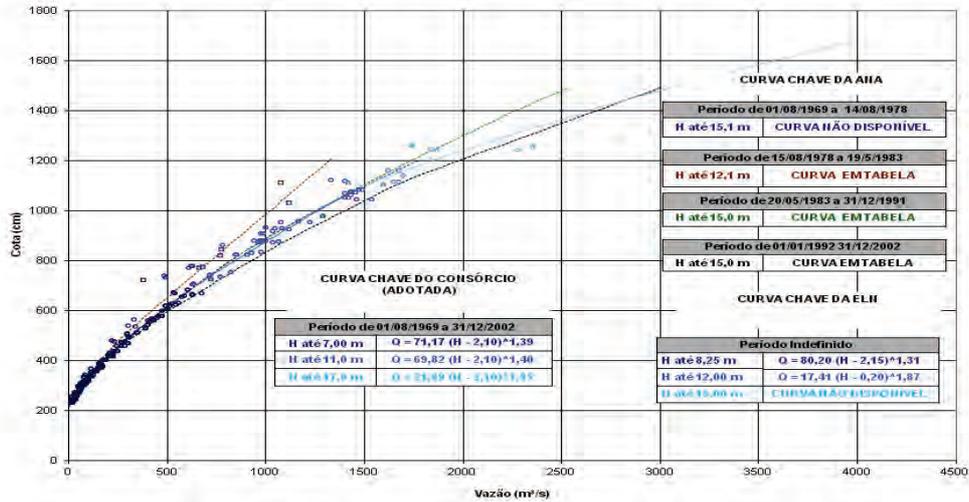


Figura B.3: Curva Chave - Posto Fazenda Alegria (29100000) - Fonte: (ONS, 2004)

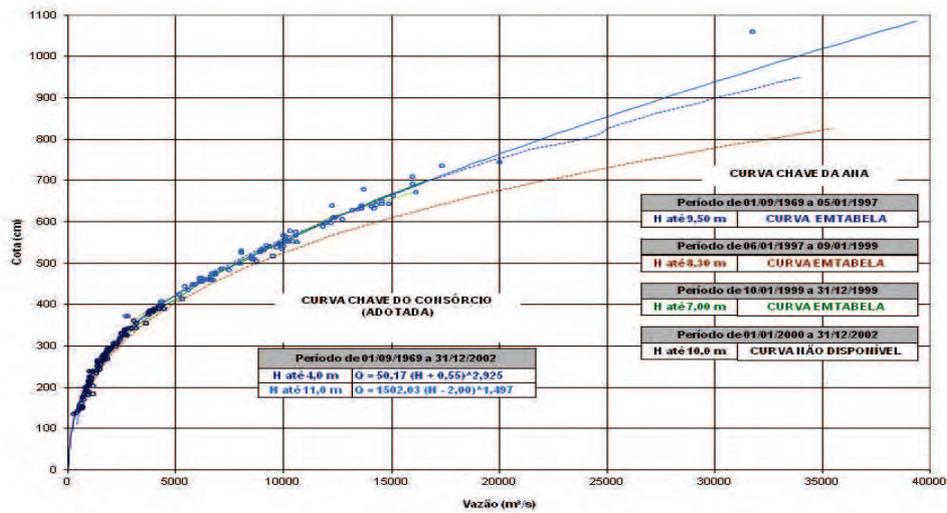


Figura B.4: Curva Chave - Posto Conceição do Araguaia (27500000) - Fonte: (ONS, 2004)

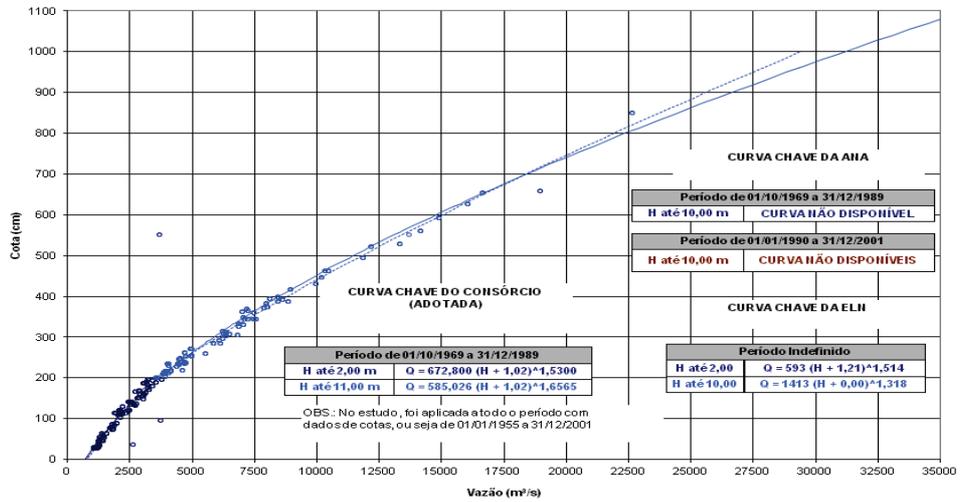


Figura B.5: Curva Chave - Posto Tocantinópolis (23600000) - Fonte: (ONS, 2004)

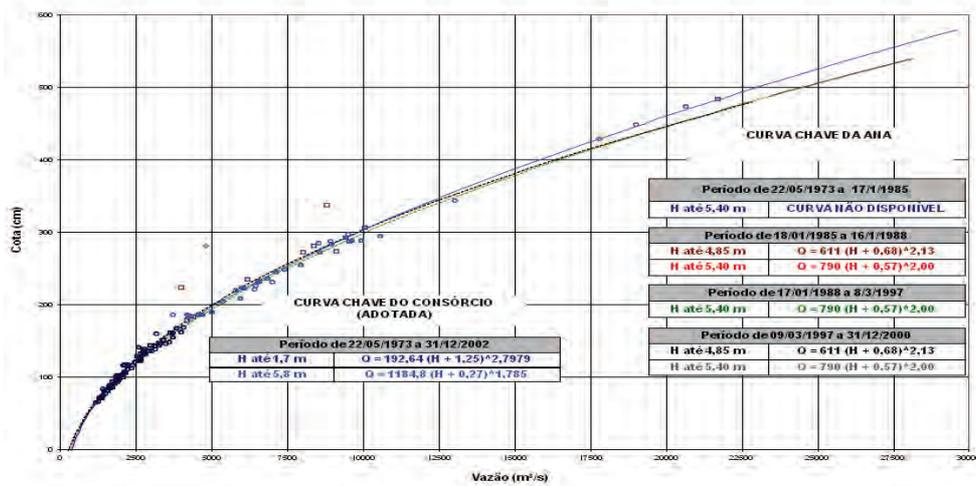


Figura B.6: Curva Chave - Posto Descarreto (23700000) - Fonte: (ONS, 2004)

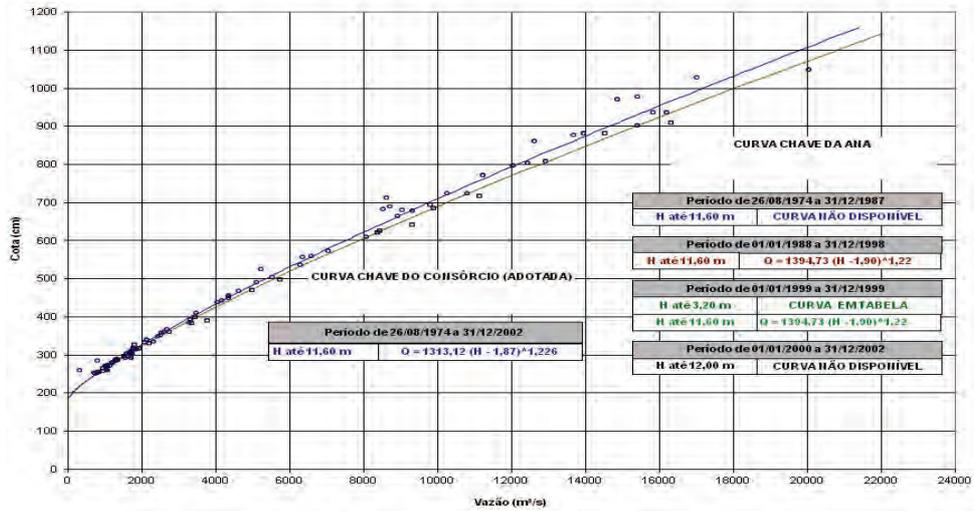


Figura B.7: Curva Chave - Posto Araguatins (28850000) - Fonte: (ONS, 2004)

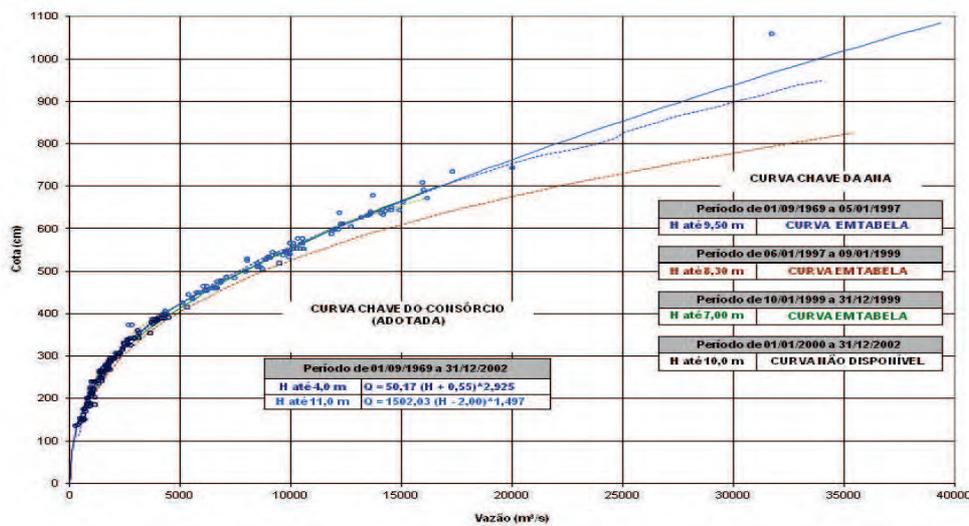
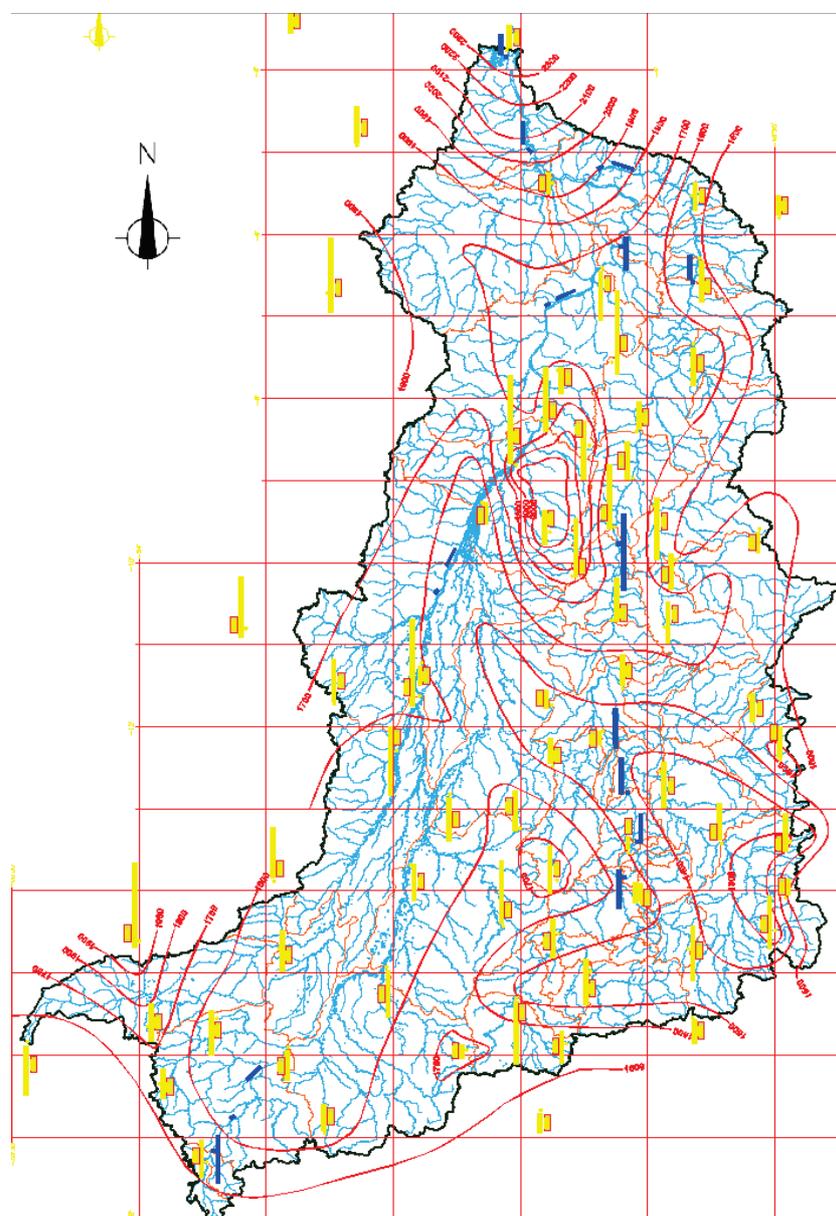


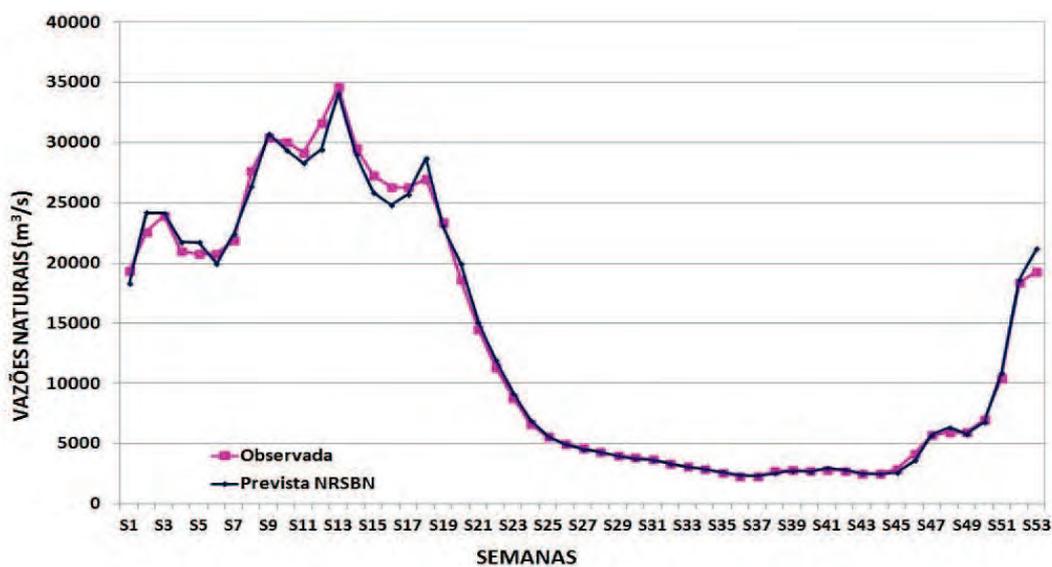
Figura B.8: Curva Chave - Posto Xambioá (28850000) - Fonte: (ONS, 2004)

## *ANEXO C – Configuração Isoietal das Chuvas Médias Anuais*

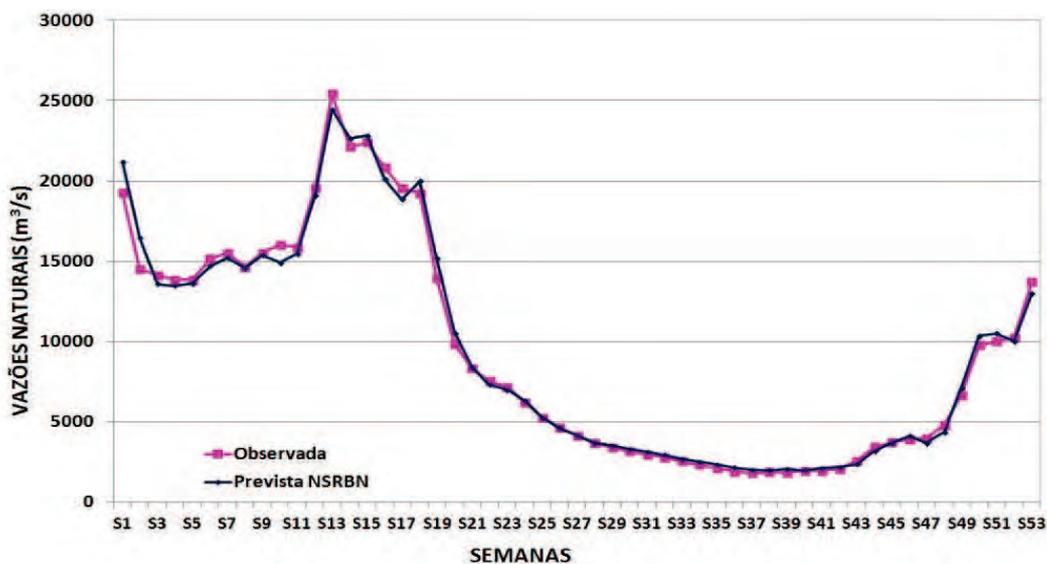


**Figura C.1:** Configuração Isoietal das Chuvas Médias Anuais - Fonte: (ANA, 2009)

## *ANEXO D – Previsões de Vazões Semanais para a UHE Tucuruí*



**Figura D.1:** *Previsão de Vazões Semanais - UHE Tucuruí - 2000 (NRSBN)*



**Figura D.2:** *Previsão de Vazões Semanais - UHE Tucuruí - 2001 (NRSBN)*

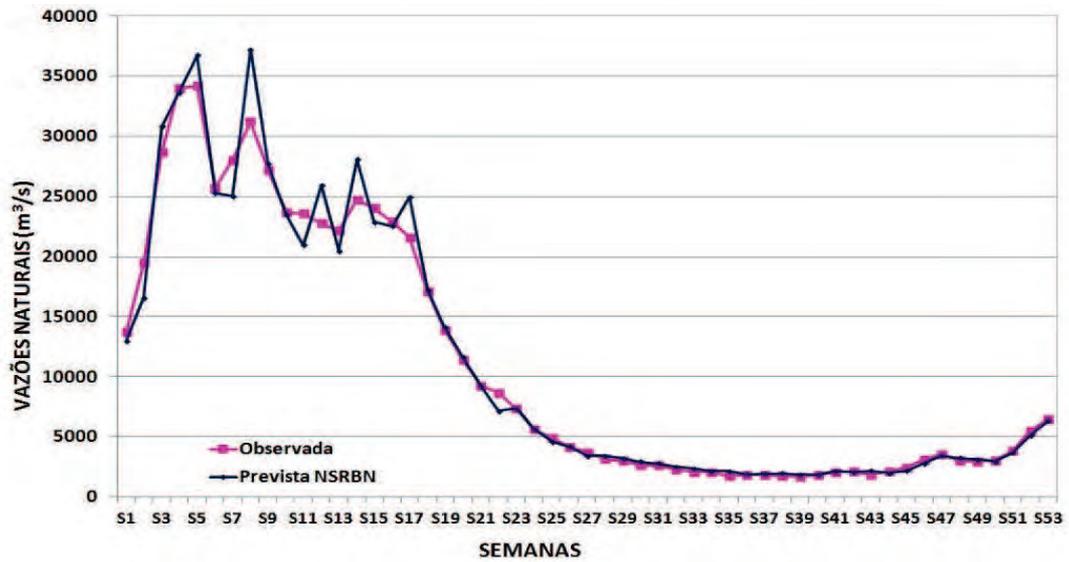


Figura D.3: Previsão de Vazões Semanais - UHE Tucuruí - 2002 (NRSBN)

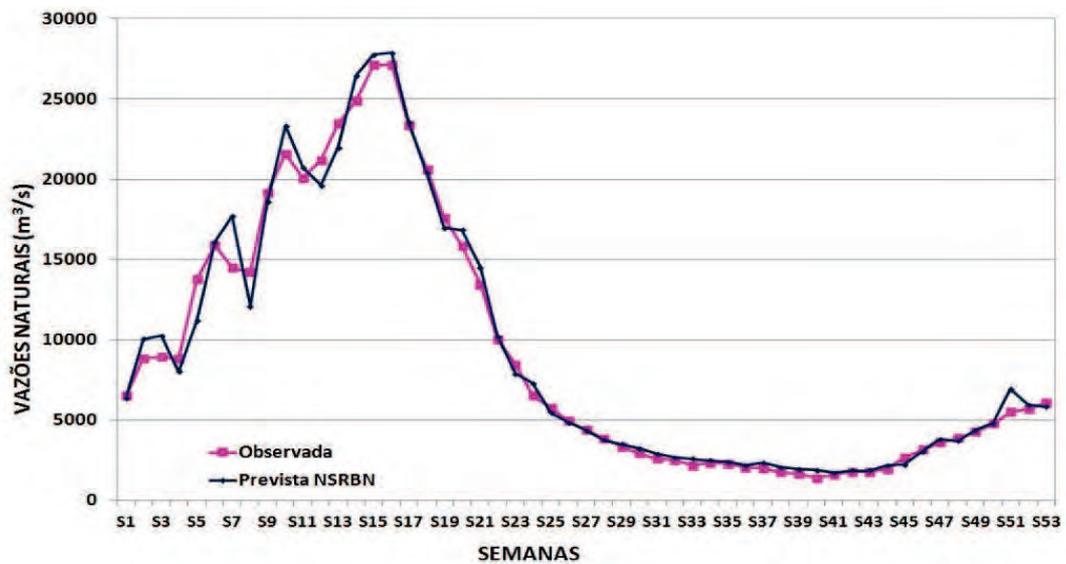


Figura D.4: Previsão de Vazões Semanais - UHE Tucuruí - 2003 (NRSBN)

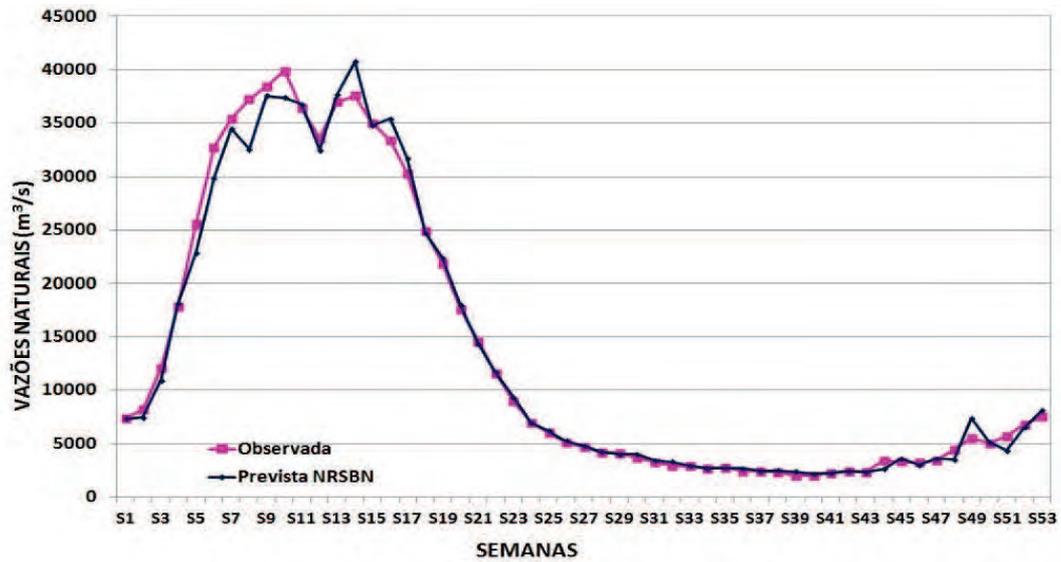


Figura D.5: Previsão de Vazões Semanais - UHE Tucuruí - 2004 (NRSBN)

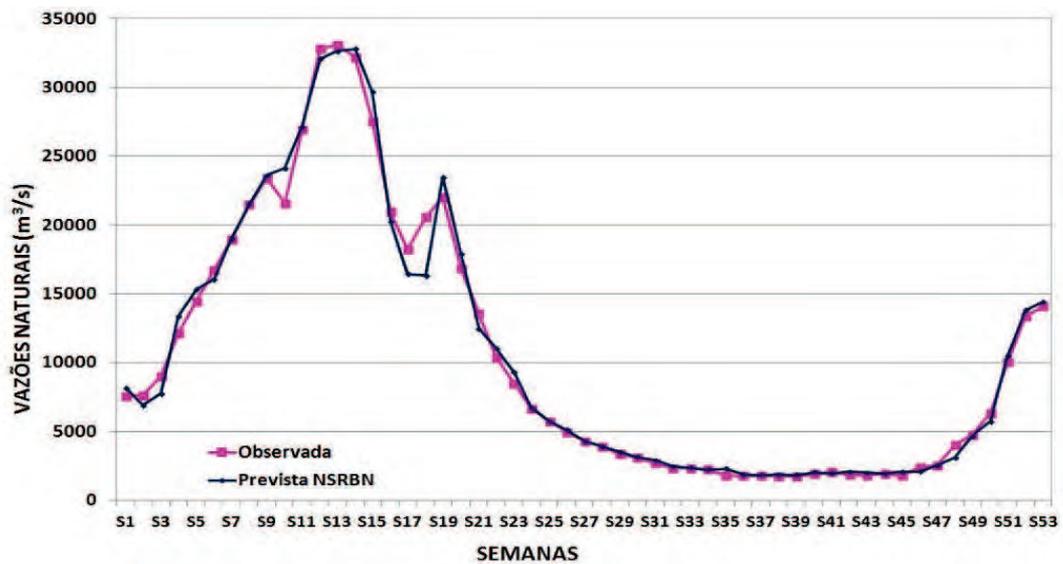


Figura D.6: Previsão de Vazões Semanais - UHE Tucuruí - 2005 (NRSBN)

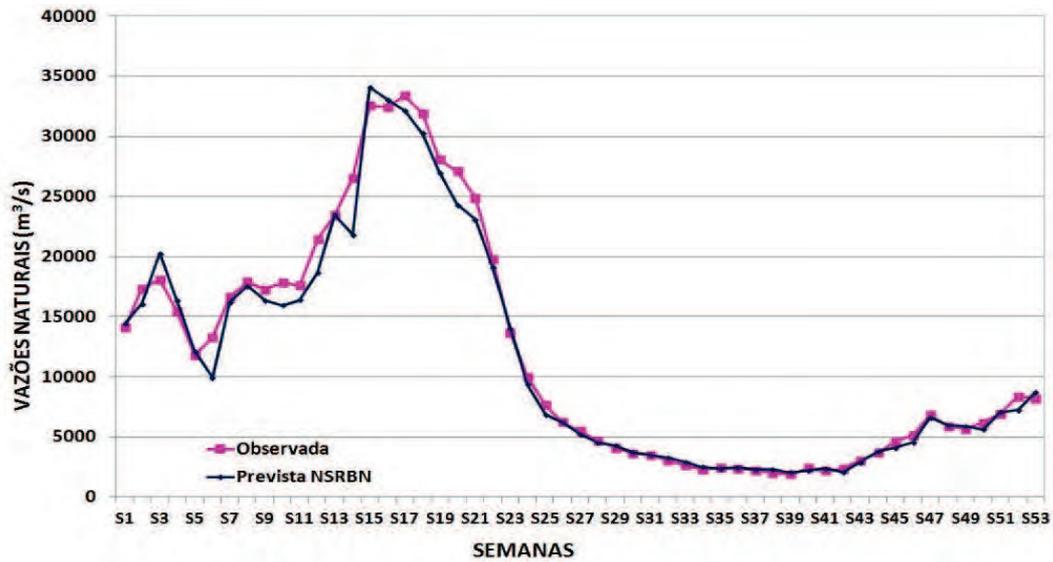


Figura D.7: Previsão de Vazões Semanais - UHE Tucuruí - 2006 (NRSBN)

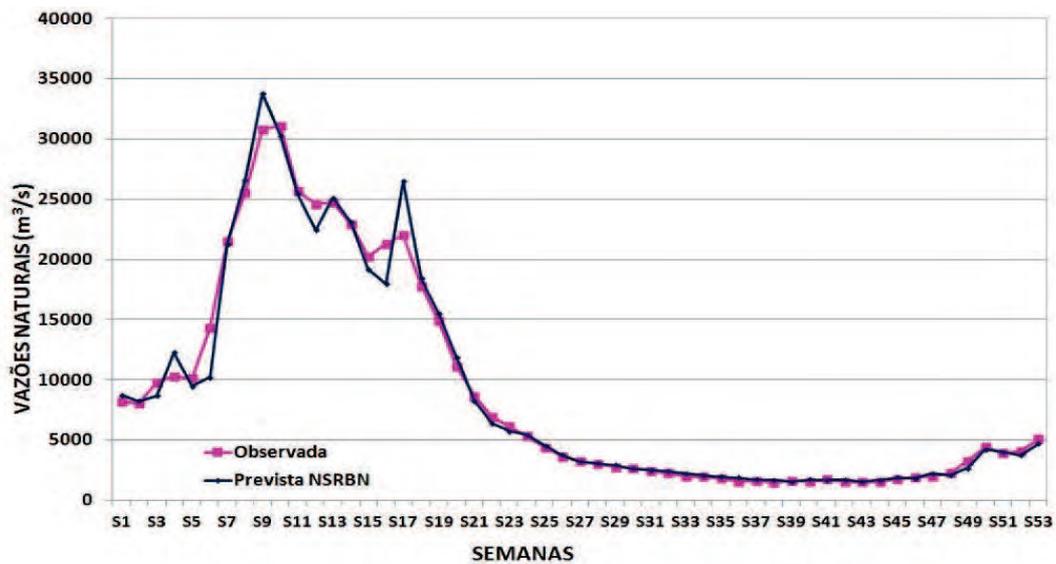
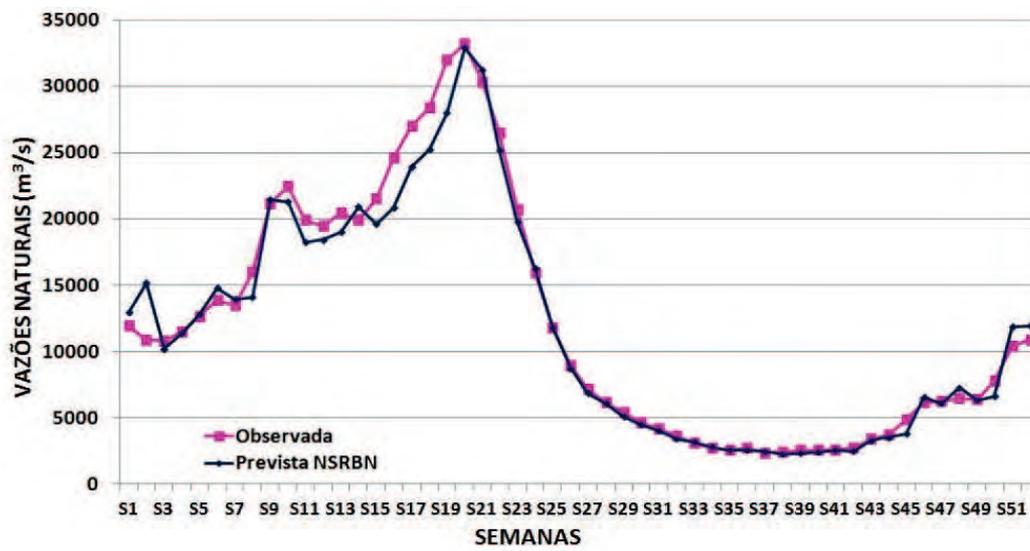


Figura D.8: Previsão de Vazões Semanais - UHE Tucuruí - 2007 (NRSBN)



**Figura D.9:** *Previsão de Vazões Semanais - UHE Tucuruí - 2009 (NSRBN)*

