



# SELECIONANDO VARIÁVEIS DE INFORMAÇÃO DE TENDÊNCIA PARA A PREVISÃO DE VAZÕES UTILIZANDO REDES NEURAIS

**Trabalho de Conclusão de Curso**

**Engenharia da Computação**

**Myllena Mylle Cardoso da Fonseca de Souza Neto**  
**Orientador: Prof. Mêuser Jorge Silva Valença**



UNIVERSIDADE  
DE PERNAMBUCO



**Universidade de Pernambuco  
Escola Politécnica de Pernambuco  
Graduação em Engenharia de Computação**

**MYLLENA MYLLE CARDOSO DA  
FONSECA DE SOUZA NETO**

**SELECIONANDO VARIÁVEIS DE  
INFORMAÇÃO DE TENDÊNCIA PARA A  
PREVISÃO DE VAZÕES UTILIZANDO  
REDES NEURAIS**

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Recife, junho de 2016.



## MONOGRAFIA DE FINAL DE CURSO

### Avaliação Final (para o presidente da banca)\*

No dia 30 de junho de 2016, às 8:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente MYLLENA MYLLE CARDOSO DA FONSECA DE SOUZA NETO, orientado pelo professor Mêuser Jorge Silva Valença, sob título Selecionando variáveis de informação de tendência para a previsão de vazões utilizando redes neurais, a banca composta pelos professores:

**Sérgio Mario Lins Galdino**

**Mêuser Jorge Silva Valença**

Após a apresentação da monografia e discussão entre os membros da Banca, a mesma foi considerada:

Aprovada       Aprovada com Restrições\*       Reprovada

e foi-lhe atribuída nota: 9,0 (note)

\*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

O discente terá 7 dias para entrega da versão final da monografia a contar da data deste documento.

SÉRGIO MARIO LINS GALDINO

MÊUSER JORGE SILVA VALENÇA

*Dedico este trabalho a Deus e à minha mãe, Jacqueline.*

# Agradecimentos

Agradeço primeiramente a Deus. Com muita fé consegui chegar até aqui e realizei um sonho. Escrevo com plena certeza de que exatamente todos os benefícios alcançados do início ao fim do curso foram graças a ele.

Agradeço especialmente à minha mãe, Jacqueline, que desde sempre é minha base e força nas mais diversas etapas da vida, além de nunca deixar de acreditar em mim e no meu potencial.

Agradeço imensamente às minhas tias, aos primos, aos sogros e aos meus parentes mais próximos, que apesar de fisicamente não participarem da luta comigo, me deram muito apoio psicológico e emocional, a todo o momento em orações e torcendo pelo meu sucesso.

Agradeço ao meu namorado Bruno, que desde o primeiro momento esteve comigo nos momentos bons e ruins. Seu companheirismo fiel me motivou e me trouxe até aqui.

Agradeço aos meus amigos, tanto de escola quanto de faculdade, por me ajudarem com conselhos e dicas, e que também estudaram e lutaram junto a mim para concluírem mais um ciclo.

Agradeço aos bons professores que tive na POLI - especialmente ao meu orientador - que puderam me proporcionar uma formação acadêmica digna; e a todos os funcionários da Escola.

Por fim, meus sinceros agradecimentos a todas as pessoas que, com um simples ato ou palavra que eu precisava escutar contribuíram de alguma forma para fomentar o meu conhecimento e profissionalismo.

# Resumo

A produção de energia hidrelétrica no Brasil é superior a qualquer outro tipo de energia produzida no país. Acontece que existem os recursos hídricos para atender o alto consumo, mas esses não são utilizados ainda de maneira eficiente. A previsão de vazão é uma técnica usada nas usinas hidroelétricas para tentar progressivamente aproveitar da melhor forma os recursos, produzindo mais e gastando menos. Atualmente existem diversos métodos de previsão de vazão utilizando redes neurais artificiais *Multi-Layer Perceptron* que as usinas hidroelétricas fazem, mas que já são tradicionais, com modelos de regressão linear. Nesse contexto, foram realizados experimentos a fim de aplicar a metodologia descrita, através do uso de uma nova rede neural, o *Reservoir Computing*, e dessa forma constatou-se a redução do erro de defasagem do pico de previsão de vazão em aproximadamente 17% comparado ao uso do MLP. Assim os testes estatísticos comprovaram que o RC apresentou melhor desempenho que o MLP na previsão de vazão, e após novos experimentos de confirmação da superioridade do RC, ele pode ser futuramente adotado pelas usinas hidroelétricas de modo oficial para prever vazões.

**Palavras-chave:** Previsão de vazão, MLP, *Reservoir Computing*, Redes Neurais Artificiais.

# Abstract

The production of hydroelectricity in Brazil is superior to any other type of energy produced in the country. It turns out that there are water resources to meet the high consumption, but these are not used efficiently. The water flow prediction is a technique used in hydroelectric power plants to try to progressively make the most of the resources, producing more and spending less. Currently there are several water flow prediction methods using artificial neural networks *Multi-Layer Perceptron* that hydroelectric power plants do, but they are already traditional, with linear regression models. In this regard, experiments were conducted to apply the methodology described, through the use of a new neural network, the *Reservoir Computing*, and thus it was found a reduction of the flow prediction peak delay error by approximately 17% compared to the use of MLP. So the statistical tests showed that the RC showed better performance than the MLP in predicting water flow, and after new RC superiority confirmation experiments, it may in future be adopted officially by hydroelectric power plants to predict water flow.

**Keywords:** Water Flow Prediction, MLP, *Reservoir Computing*, Artificial Neural Networks.

# Sumário

<b>Capítulo 1 Introdução</b>	<b>1</b>
1.1 Caracterização do Problema	1
1.2 Objetivos	3
1.2.1 Objetivos Gerais	3
1.2.2 Objetivos Específicos	3
1.3 Estrutura da Monografia	4
<b>Capítulo 2 Fundamentação Teórica</b>	<b>5</b>
2.1 Energia Hidrelétrica	5
2.1.1 Introdução	5
2.1.2 Potencial Hidrelétrico	7
2.1.3 Potencial Hidrelétrico Brasileiro	8
2.1.4 A Previsão de Vazões	10
2.1.5 Modelos de Médio Prazo	10
2.1.6 Modelos de Curto Prazo	11
2.1.7 Modelo diário de operação	11
2.2 Redes Neurais Artificiais	12
2.2.1 Introdução	12
2.2.2 O neurônio biológico	13
2.2.3 O neurônio artificial	14
2.2.4 MLP	16
	ix

2.2.5	Algoritmo Backpropagation	17
2.2.6	Critério de Parada: validação cruzada	18
2.2.7	RC	19
<b>Capítulo 3 Metodologia</b>		<b>21</b>
3.1	Base de dados	21
3.2	Normalização dos dados	21
3.3	Seleção de variáveis	23
3.4	Análise e tratamento dos dados	23
3.5	Previsão de vazão utilizando o RC	26
3.6	Testes estatísticos	27
3.6.1	Teste de Shapiro-Wilk	27
<b>Capítulo 4 Resultados</b>		<b>29</b>
<b>Capítulo 5 Conclusão e Trabalhos Futuros</b>		<b>31</b>
<b>Bibliografia</b>		<b>32</b>
<b>Apêndice A</b>		<b>36</b>

# Índice de Figuras

<b>Figura 1.</b>	Exemplo de Usina Hidroelétrica. ....	1
<b>Figura 2.</b>	Exemplo de previsão de vazão em tempo real: rio Pelotas. ....	2
<b>Figura 3.</b>	Matriz de oferta de energia elétrica no Brasil. ....	6
<b>Figura 4.</b>	Potencial tecnicamente aproveitável para geração de energia elétrica no mundo. ....	8
<b>Figura 5.</b>	O neurônio biológico.....	14
<b>Figura 6.</b>	Modelo de neurônio artificial proposto por McCulloch e Pitts. ....	15
<b>Figura 7.</b>	Representação gráfica de uma RNA-MLP com duas camadas intermediárias.....	16
<b>Figura 8.</b>	Representação gráfica da MLP 3 camadas.....	18
<b>Figura 9.</b>	Representação gráfica da rede <i>Reservoir Computing</i> .....	20
<b>Figura 10.</b>	Normalização da base de dados Três Marias. ....	22
<b>Figura 11.</b>	Script do software R para tratamento dos resultados da RC.....	28
<b>Figura 12.</b>	Resultados dos testes estatísticos. ....	29
<b>Figura 13.</b>	Saída – Software R. ....	36

# Índice de Tabelas

<b>Tabela 1.</b>	Potencial hidrelétrico brasileiro por bacia hidrográfica. ....	9
<b>Tabela 2.</b>	Principais características dos modelos de predição de vazão desenvolvidos pelo CEPEL.....	11
<b>Tabela 3.</b>	Quadro comparativo entre computadores e neurocomputadores. ....	13
<b>Tabela 4.</b>	Vetor $v$ defasado. ....	24
<b>Tabela 5.</b>	Entradas de vazão passadas. ....	25
<b>Tabela 6.</b>	Entradas de vazão futuras.....	25
<b>Tabela 7.</b>	Saídas das RC em 30 experimentos. ....	27

# Tabela de Símbolos e Siglas

ANEEL – Agência Nacional de Energia Elétrica

CEPEL - Centro de Pesquisas de Energia Elétrica

EP – Energia Potencial

EPMA – Erro Percentual Médio Absoluto

GEVAZP - Geração de Energia e Vazões Sintéticas

GW – Giga Watts

K+ - Potássio

MLP – *Multi-Layer Perceptron*

Na+ - Sódio

ONS – Operador Nacional do Sistema Elétrico

ONU – Organização das Nações Unidas

PMO - Programa Mensal de Operação Energética

PREVIVAZH – Modelo de Previsão de Vazões Diárias

PREVIVAZM - Modelo de Previsão de Vazões Mensais

R – The R Statistical Software

RC – *Reservoir Computing*

RNA – Redes Neurais Artificiais

SIN - Sistema Interligado Nacional

SIPOT – Sistema de Informações do Potencial Hidrelétrico Brasileiro

TWh – Terawatts-hora

# Capítulo 1

## Introdução

Este capítulo encontra-se dividido em três seções. Primeiramente caracteriza o problema e conseqüentemente a motivação para a evolução do trabalho; em seguida lista os objetivos gerais e específicos, e encerra com a estrutura da monografia, isto é, o que será mostrado nos próximos capítulos.

### 1.1 Caracterização do Problema

O Brasil é um país que apresenta um consumo crescente de energia elétrica [23], assim como outros países. Acontece que a diferença está nos seus recursos disponíveis e na diversidade deles para se produzir energia, um fator positivo. No entanto, os meios são escassos e a produção tem que ser feita proporcional e baseada na quantidade utilizável desses recursos. Embora há alguns anos atrás o Brasil já tenha produzido mais energia por outros meios, o de maior utilização atualmente é a água, e, conseqüentemente, o potencial hídrico faz com que a maior parte da energia seja produzida por esse recurso [15].

[fonte:<http://4.bp.blogspot.com/hmg5ztyJEg/Ta846GUCvsI/AAAAAAAAAETg/LgWmRNURHPA/s500/usina-itaipu-binacional.jpg>]

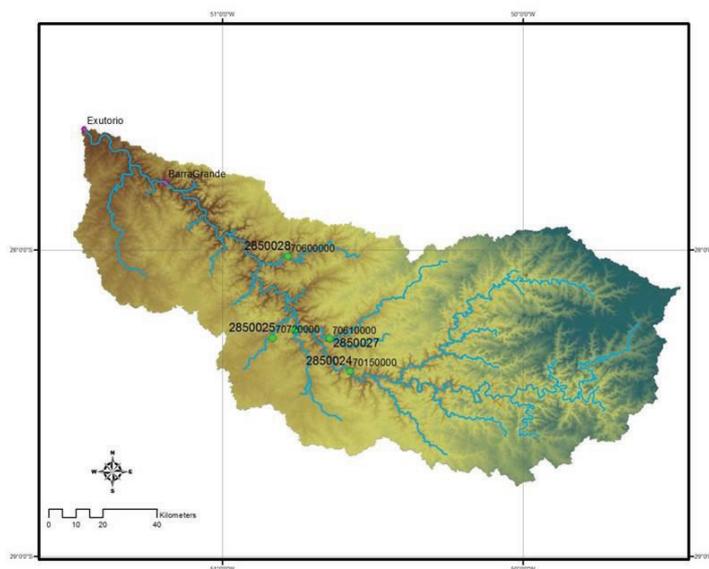


**Figura 1.** Exemplo de Usina Hidroelétrica.

Para uma padronização de como as empresas responsáveis pela geração de energia elétrica seguem suas diretrizes e metas, existe o Programa Mensal de Operação Energética (PMO) [22], que, de uma forma geral, objetiva reduzir custos e fazer com que haja um melhor aproveitamento hídrico por parte das usinas hidroelétricas, e então esse planejamento evitaria a produção de energia por outros recursos mais escassos e mais nocivos ao meio ambiente, como combustíveis fósseis.

Nesse contexto projetado existe a vazão, uma variável sem estado determinado, que por esse motivo se torna difícil de estimar. Assim, há a necessidade de se desenvolver sistemas que possam prever o seu comportamento de maneira efetiva.

[fonte: <https://www.ufrgs.br/hge/wp-content/uploads/2013/08/Pelotas.jpg>]



**Figura 2.** Exemplo de previsão de vazão em tempo real: rio Pelotas.

A previsão de vazão resulta num meio de tentar evitar tanto desastres ambientais causados pela água quando essa alcança um determinado pico inesperado, quanto de utilizar esse recurso para produzir o máximo com menores custos [24]. Porém, nos dias de hoje, a maioria das usinas usam técnicas para previsão compostas por modelos de regressão linear (ou físicos), e que internamente são desenvolvidos envolvendo a arquitetura *Multi-Layer Perceptron*

[21]. Já a *Reservoir Computing* tem comportamento dinâmico e pode ser configurado de tal forma que origine melhores resultados de previsão. Além disso, um detalhe importante é que as entradas da rede serão compostas não só por dados puros extraídos das usinas, mas também de uma seleção de variáveis de informação de tendência que já foram resultado de treinamentos anteriores. Dessa forma, o resultado final pode ser influenciado por esse diferencial.

As duas arquiteturas possuem vantagens e desvantagens, algumas sendo mais adequadas a determinados problemas que outros. Por fim, o objetivo deste trabalho é realizar uma comparação entre resultados de previsões de vazões compreendendo *Multi-Layer Perceptron* e *Reservoir Computing* através da escolha de variáveis de informação de tendência na busca de que a segunda rede proporcione o menor erro de defasagem do pico de vazão, e retratar qual a configuração das variáveis que permitiu esse resultado.

## 1.2 Objetivos

### 1.2.1 Objetivos Gerais

Este trabalho tem como objetivo geral melhorar a previsão de vazões em usinas hidrelétricas do país, com foco na redução do erro de defasagem do pico em seus gráficos, utilizando a arquitetura *Reservoir Computing* em comparação com os resultados gerados no uso da *Multi-Layer Perceptron*.

Ajustando sempre os parâmetros de treinamento da rede no levantamento de diversos cenários de entrada dos dados, a finalidade é descobrir uma configuração que resulte num erro mínimo satisfatório usando o RC.

### 1.2.2 Objetivos Específicos

- Implementação do *Reservoir Computing* na linguagem de programação JAVA;
- Treinar a rede *Multi-Layer Perceptron* e a *Reservoir Computing* com os dados da usina hidrelétrica nacional de Três Marias;
- Analisar estatisticamente os resultados obtidos e mensurar as diferenças relevantes entre as redes;

- Construir gráficos com os valores obtidos e verificar se realmente houve uma melhoria na previsão de vazão com o uso da RC e se o erro diminuiu.

## 1.3 Estrutura da Monografia

O capítulo 2 descreve a fundamentação teórica, conteúdo responsável por passar para o leitor todo o conhecimento de base para o entendimento do trabalho. Tal capítulo se divide em dois tópicos: energia hidrelétrica e redes neurais artificiais, mostrando a hierarquia existente entre as redes em termos de resolução dos problemas e um destaque para a tecnologias utilizadas na experimentação deste projeto. Em seguida, no capítulo 3, pode-se encontrar toda a metodologia conduzida para se atingir os objetivos da monografia, como a base de dados usada nos experimentos, a análise e tratamento desses dados, a integração da rede neural e todos os passos até os testes estatísticos. O capítulo 4 mostra os principais resultados obtidos a partir das simulações; os que de fato promoveram um impacto maior na redução da porcentagem de erro da previsão de vazão. Por fim, no capítulo 5, há as considerações finais; um resumo do trabalho explicitando as dificuldades encontradas e como os resultados podem ser ainda melhores sendo utilizados em sugestões de trabalhos futuros.

# Capítulo 2

## Fundamentação Teórica

Este capítulo apresenta os assuntos fundamentais para a tentativa de resolução do problema descrito no capítulo anterior. A seção 2.1 mostra conceitos de energia hidrelétrica, como é vista em nível de utilidade e através de quais recursos pode ser gerada mundialmente. Aprofundando, há um foco no potencial hidrelétrico nacional, direcionando o rumo para a previsão de vazões e as informações de tendência relacionadas. Por último, na seção 2.2, pode-se encontrar as definições de redes neurais artificiais e seus diversos tipos, além de como eles são usados para resolver casos complexos, cada um voltado para um determinado quadro a ser solucionado. Apesar das variedades, o tópico toma como eixo principal as inteligências utilizadas durante o desenvolvimento do trabalho.

### 2.1 Energia Hidrelétrica

#### 2.1.1 Introdução

A energia hidrolétrica, como o próprio nome diz, é gerada pelo forte movimento das águas, utilizando o potencial de um rio de níveis naturais, queda d'água ou artificiais. Essa energia é a segunda maior fonte de eletricidade do mundo. De acordo com o Renewables Global Status Report 2006, no ano de 2005 as usinas hidrelétricas produziram 19% da eletricidade consumida no mundo todo. A energia produzida pelas usinas hidrelétricas também é o equivalente a cerca de 5 bilhões de barris de petróleo [1]. Uma usina hidrelétrica pode ser definida como um conjunto de obras e equipamentos cuja finalidade é a geração da energia elétrica, através de aproveitamento do potencial hidráulico existente num rio [30].

Frequentemente constroem-se represas que retêm o curso da água, fazendo com que ela se acumule em um reservatório denominado barragem. Toda a energia elétrica promovida dessa maneira é levada por cabos, dos terminais do gerador até

o transformador de distribuição. A energia hidrelétrica apresenta certos problemas, entre eles conseqüências socioambientais de alagamentos e cheias em grandes áreas, inclusive urbanas [30].

Embora se exija grande investimento inicial na construção de barragens e de haver a possibilidade de prejuízos gerados pela falta de chuvas, as usinas que geram energia hidrelétrica, apesar de demorarem bastante para serem finalizadas, possuem uma vantagem principal que é ter como recurso uma fonte renovável, a água. Assim, consegue produzir eletricidade de forma limpa, não poluente e barata [30], representando mais de 70% da demanda energética nacional, como mostra na Figura 3.

Dentre os países que usam essa forma de se obter energia, o Brasil se encontra apenas atrás do Canadá e dos Estados Unidos, sendo, portanto, o terceiro maior do mundo em potencial hidrelétrico [8].

[fonte: Ministério das Minas e Energia (MME), 2010]

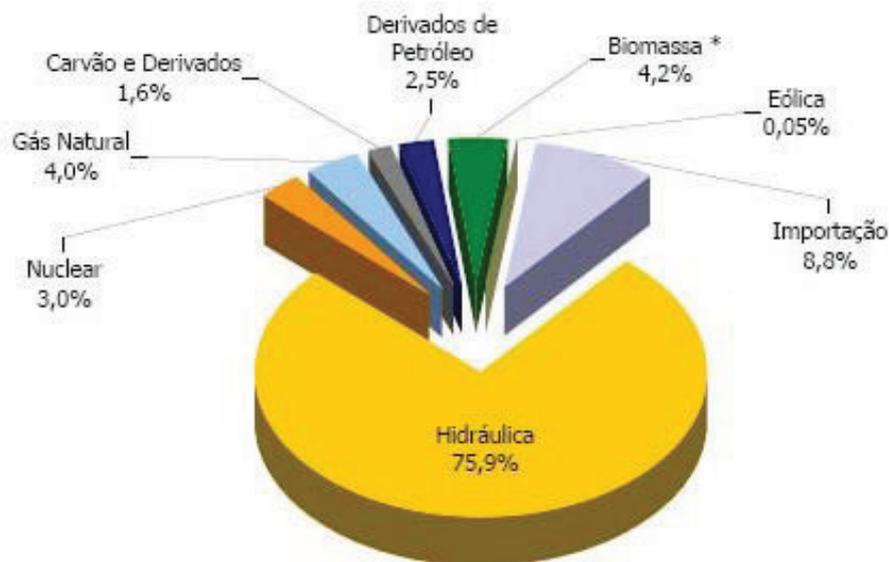


Figura 3. Matriz de oferta de energia elétrica no Brasil.

### 2.1.2 Potencial Hidrelétrico

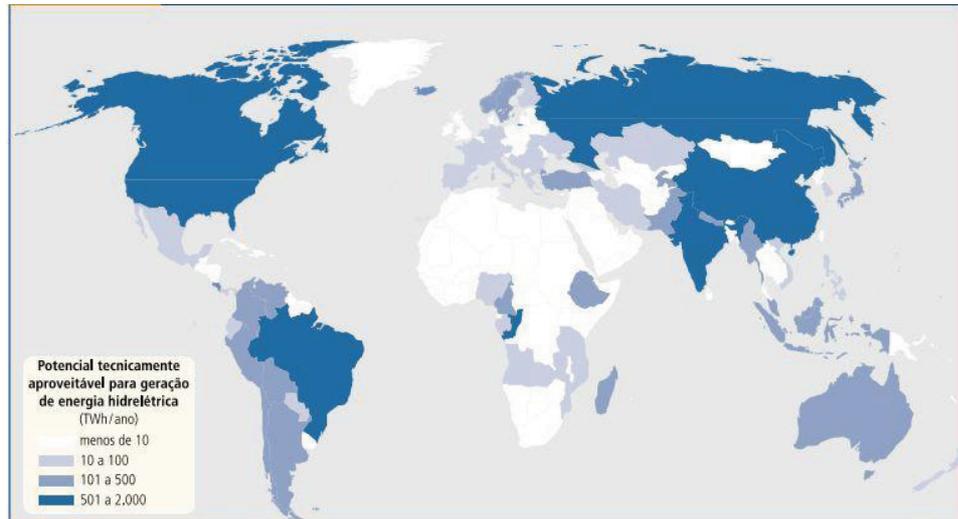
Uma primeira estimativa da quantidade de energia hidrelétrica disponível no mundo poder ser feita pela simples aplicação da fórmula de cálculo da energia potencial (EP):

$$EP = M \text{ (massa)} \times g \text{ (aceleração da gravidade)} \times h \text{ (altura)}$$

A quantia supostamente disponível de energia hidrelétrica, também denominada recurso total, é ainda irrealista do ponto de vista técnico. A quantidade efetivamente disponível depende das condições locais do aproveitamento (como a topografia e o tipo de chuva) e do tempo efetivo de operação do sistema. Teoricamente, uma usina hidrelétrica poderia operar continuamente (8.760 horas por ano), isto é, com um fator de capacidade de 100%. Na prática, porém, esse índice é da ordem de 40% apenas, em função de problemas operacionais e da necessidade de manutenção. Desse modo, estima-se que a energia hidrelétrica efetivamente disponível na Terra, isto é, o potencial tecnicamente aproveitável, varie de 10.000 TWh a 20.000 TWh por ano (ONU, 1992).

A Figura 4 ilustra o potencial tecnicamente aproveitável da energia hidráulica no mundo para geração de energia elétrica. Como se observa, os maiores potenciais estão localizados na América do Norte, antiga União Soviética, China, Índia e Brasil. O Continente Africano é o que apresenta os menores potenciais [5].

[fonte: [http://www2.aneel.gov.br/aplicacoes/atlas/pdf/04-Energia\\_Hidraulica\(2\).pdf](http://www2.aneel.gov.br/aplicacoes/atlas/pdf/04-Energia_Hidraulica(2).pdf)]



**Figura 4.** Potencial tecnicamente aproveitável para geração de energia elétrica no mundo.

### 2.1.3 Potencial Hidrelétrico Brasileiro

O potencial hidrelétrico brasileiro, tecnicamente explorável, é da ordem de 260 GW. De acordo com o SIPOT – Sistema de Informações do Potencial Hidrelétrico Brasileiro (sistema desenvolvido pela Eletrobras, com o objetivo de armazenar e processar informações sobre estudos e projetos de usinas hidrelétricas), o potencial passível de ser viabilizado era de 247 GW, ao final de 2014.

Desde 2007, com a conclusão do reinventário da bacia do Rio Xingu e de outras bacias, ficou definida a inviabilidade ambiental de alguns aproveitamentos, que totalizam perto de 13 GW [4].

O valor do potencial elétrico brasileiro é composto pela soma da parcela estimada com a inventariada. O potencial estimado é resultante da somatória dos estudos de potencial remanescente, que constitui uma estimativa realizada em escritório, a partir de dados existentes, sem qualquer levantamento complementar; e do potencial individualizado, resultado da estimativa realizada em escritório para um determinado local, a partir de levantamentos ágeis, sem qualquer levantamento

detalhado. Já a parcela inventariada inclui usinas em diferentes níveis de estudo, além de aproveitamentos em construção e operação (ELETROBRÁS, 2004). O potencial inventariado ainda é a soma dos rendimentos em inventário, com estudo de viabilidade, com projeto básico, em construção e em operação.

Os aproveitamentos somente são considerados para fins estatísticos nos estágios “inventário”, “viabilidade” ou “projeto básico”, se os respectivos estudos tiverem sido aprovados pelo poder concedente [6].

Apesar de o país possuir 260 GW de potencial elétrico – como foi explícito anteriormente – apenas 68% dessa capacidade foi inventariada (Tabela 1). Entre as bacias com maior potencial, destacam-se as do Rio Amazonas e do Rio Paraná.

Na Bacia do Amazonas, destaca-se a sub-bacia do Rio Xingu, com 12,7% do potencial inventariado do País. Outras sub-bacias do Amazonas, cujos potenciais estimados são consideráveis, são a do Rio Tapajós, a do Rio Madeira e a do Rio Negro. Já na Bacia do Paraná, existem várias sub-bacias com grandes potenciais somando 8,1% do potencial hidrelétrico inventariado no País.

**Tabela 1.** Potencial hidrelétrico brasileiro por bacia hidrográfica.

Bacia	Código	Estimado		Inventariado		Total (MW)	
		(MW)	% em relação ao total	(MW)	% em relação ao total	(MW)	% em relação ao total
Bacia do Rio Amazonas	1	64.164,49	78,8	40.883,07	23,0	105.047,56	40,6
Bacia do Rio Tocantins	2	2.018,80	2,5	24.620,65	13,9	26.639,45	10,3
Bacia do Atlântico Norte/Nordeste	3	1.070,50	1,3	2.127,85	1,2	3.198,35	1,2
Bacia do Rio São Francisco	4	1.917,28	2,4	24.299,84	13,7	26.217,12	10,1
Bacia do Atlântico Leste	5	1.779,20	2,2	12.759,81	7,2	14.539,01	5,6
Bacia do Rio Paraná	6	7.119,29	8,7	53.783,42	30,3	60.902,71	23,5
Bacia do Rio Uruguai	7	1.151,70	1,4	11.664,16	6,6	12.815,86	5,0
Bacia do Atlântico Sudeste	8	2.169,16	2,7	7.296,77	4,1	9.465,93	3,7
<b>Total</b>	-	<b>81.390,42</b>	<b>100</b>	<b>177.435,57</b>	<b>100</b>	<b>258.825,99</b>	<b>100</b>

[fonte:

[http://www2.aneel.gov.br/aplicacoes/atlas/energia\\_hidraulica/images/tab4\\_1.jpg](http://www2.aneel.gov.br/aplicacoes/atlas/energia_hidraulica/images/tab4_1.jpg)]

#### **2.1.4 A Previsão de Vazões**

A previsão de vazões tem-se apresentado como uma medida não estrutural de enorme valia na redução dos danos decorrentes das grandes cheias.

A variação do nível ou vazão de um rio depende das características físicas da bacia e de condições climatológicas, como as distribuições temporal e espacial da precipitação. Quando as chuvas são intensas, a quantidade de água que chega simultaneamente ao rio pode ser superior à capacidade de drenagem de sua calha normal, resultando na inundação das áreas ribeirinhas. As mesmas só podem ser previstas deterministicamente com antecedência de poucos dias ou horas. O tempo máximo possível de previsão de cheias, a partir da ocorrência da precipitação (modelos chuva-vazão), é limitado pelo tempo médio de deslocamento da água na bacia até a seção de interesse (Tucci, 1993).

Uma outra alternativa que tem sido utilizada é a realização da previsão de vazões com base nas informações de níveis ou vazões à montante da seção de interesse (modelos de propagação de vazões) e através da combinação das duas opções anteriores, ou seja, modelos chuva-vazão com propagação em rios.

Modelos matemáticos convencionais, empíricos ou conceituais, como modelos lineares, modelos de diferenças e modelos distribuídos não-lineares, já foram utilizados para prever vazões; porém algumas técnicas mais recentes e eficientes, como as redes neurais artificiais, também têm sido empregadas com o objetivo de previsão de vazões em tempo real [1].

#### **2.1.5 Modelos de Médio Prazo**

Em modelos de médio prazo, o horizonte de planejamento é maior. Normalmente se utiliza 12 meses à frente, porém este horizonte pode chegar até a 8 anos. A partir deste modelo é definida a quantidade de energia a ser utilizada pelo país. As vazões são consideradas estocásticas e o modelo mais comum é o GEVAZP (MACIEIRA; FALCÃO; PENNA, 2001).

### 2.1.6 Modelos de Curto Prazo

No modelo de previsão de curto prazo, a previsão é realizada para semanas a frente. Um dos modelos mensais utilizados é o modelo estocástico PREVIVAZM do Operador Nacional do Sistema Elétrico (ONS). Existe também o modelo Geração de Energia e Vazões Sintéticas, ou GEVAZP, que realiza previsões mensais para os dois primeiros meses mas pode chegar até 12 meses. Todos os modelos de curto prazo consideram as vazões como determinísticas (COSTA, 2003).

### 2.1.7 Modelo diário de operação

Na programação diária, a previsão é considerada determinística. Seu horizonte é normalmente de 7 dias, mas pode chegar a 14. O modelo utilizado hoje é o PREVIVAZH, fortemente utilizado na elaboração do Programa Mensal da Operação Energética (PMO). O PREVIVAZH usa métodos lineares que consideram fatores externos (precipitações, entre outros) e fatores internos, como vazões em dias anteriores.

Todos os modelos de predição mostrados até então realizam suas previsões a partir de métodos estatísticos e lineares. A Tabela 2 resume as principais características dos modelos desenvolvidos pelo CEPEL [32].

**Tabela 2.** Principais características dos modelos de predição de vazão desenvolvidos pelo CEPEL.

Etapa	Médio prazo	Curto prazo	Diário
<b>Modelo hidrológico</b>	GEVAZP	PREVIVAZM/ GEVAZP	PREVIVAZH
<b>Horizonte de planejamento</b>	Até 10 anos	Até 1 ano	Até 14 dias
<b>Discretização</b>	Mensal	Semanal/Mensal	Horária/Diária
<b>Afluências hidrológicas</b>	Estocástico	Determinístico/ Estocástico	Determinístico

[fonte: [http://tcc.ecomp.poli.br/20092/TCC\\_Tarcisio.pdf](http://tcc.ecomp.poli.br/20092/TCC_Tarcisio.pdf)]

## 2.2 Redes Neurais Artificiais

### 2.2.1 Introdução

As primeiras informações mencionadas sobre a neuro computação datam de 1943, em artigos de McCulloch e Pitts, em que sugeriam a construção de uma máquina baseada ou inspirada no cérebro humano.

Muitos históricos desconsideram a existência de pesquisa nessa área nos anos 60 e 70, pois foram marcados por um entusiasmo exagerado de muitos pesquisadores, que passaram a publicar mais e mais artigos e livros que faziam uma previsão pouco confiável para a época, sobre máquinas tão poderosas quanto o cérebro humano que surgiriam em um curto espaço de tempo. Isto tirou quase toda a credibilidade dos estudos desta área e causou grandes aborrecimentos aos técnicos de outras áreas [31]. Entretanto alguns pesquisadores ainda realizaram importantes trabalhos sobre modelos de redes neurais em visão, memória, controle e auto-organização, como Amari, Anderson, Cooper e Cowan [25]. Mais tarde, apontaram uma retomada das pesquisas com a publicação dos trabalhos do físico e biólogo Hopfield (1982) relatando a utilização de redes simétricas para otimização, através de um algoritmo de aprendizagem que estabilizava uma rede binária simétrica com realimentação.

O cérebro humano é considerado o mais fascinante processador baseado em carbono existente, sendo composto por aproximadamente 10 bilhões de neurônios. Todas as funções e movimentos do organismo estão relacionados ao funcionamento destas pequenas células. Os neurônios estão conectados uns aos outros através de sinapses, e juntos formam uma grande rede, chamada rede neural. As sinapses transmitem estímulos através de diferentes concentrações de  $\text{Na}^+$  (Sódio) e  $\text{K}^+$  (Potássio), e o resultado disto pode ser estendido por todo o corpo humano. Esta grande rede proporciona uma fabulosa capacidade de processamento e armazenamento de informação [31].

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que

adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento; já o cérebro de um mamífero pode ter muitos bilhões de neurônios [25].

A maior parte dos computadores disponíveis hoje segue o modelo de arquitetura de Von Neumann. Estes computadores apresentam um bom desempenho para tarefas comuns como processamento de números, transações, etc. No entanto, existe uma grande gama de aplicações que não são facilmente modeladas por computadores convencionais. Estas aplicações geralmente são aquelas facilmente resolvidas por seres humanos como, por exemplo, reconhecimento de faces, classificação de dados, filtragem de informações, etc. Neste contexto, as redes neurais artificiais surgem como uma alternativa às arquiteturas tradicionais. A ideia básica das redes neurais é imitar o funcionamento do cérebro humano e construir sistemas computacionais capazes de aprender, fazer generalizações e descobertas [17].

**Tabela 3.** Quadro comparativo entre computadores e neurocomputadores.

<b>Computadores</b>	<b>Neurocomputadores</b>
Executa programas	Aprende
Executa operações lógicas	Executa operações não lógicas, transformações, comparações
Depende do modelo ou do programador	Descobre as relações ou regras dos dados e exemplos
Testa uma hipótese por vez	Testa todas as possibilidades em paralelo

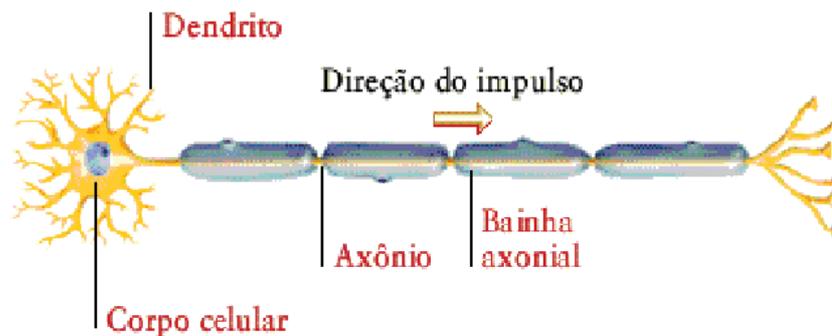
[fonte: <http://www.din.uem.br/ia/neurais/#neural>]

### **2.2.2 O neurônio biológico**

O sistema nervoso é formado por um conjunto extremamente complexo de células, os neurônios. Eles têm um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada; em seguida pelo corpo celular, e então pelo axônio, que são longos terminais de saída unidirecionais pelos quais passam o impulso nervoso [25]. A bainha de mielina ou axonal, como mostra da Figura 5, é apenas uma camada de gordura que atua como

um isolamento elétrico e aumenta a velocidade de propagação do impulso nervoso ao longo do axônio.

[fonte: <http://www.cerebromente.org.br/n05/tecnologia/image6.gif>]



**Figura 5.** O neurônio biológico.

Observando a simplicidade do funcionamento de um neurônio e o quão poderoso podem se tornar quando estão conectados, foi desenvolvido o primeiro modelo matemático que simula o seu comportamento energético, o chamado neurônio artificial.

### 2.2.3 O neurônio artificial

A história das Redes Neurais começou com o trabalho dos pesquisadores Warren McCulloch e Walter Pitts McCulloch. Os dois foram os primeiros a descreverem um modelo artificial para um neurônio biológico em 1943 [19].

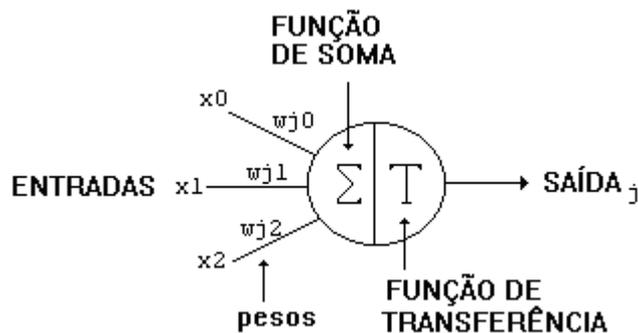
O neurônio artificial é um modelo simplificado e simulado do neurônio real e suas características básicas são a adaptação e a representação de conhecimentos baseada em conexões [18].

O modelo é formado por um vetor de entradas, que constitui o conhecimento adquirido a partir do ambiente – o que leva ao processo de aprendizagem - e os pesos sinápticos, que são representadas por valores numéricos, refletindo as forças entre os neurônios que serão utilizadas para armazenar o conhecimento adquirido. A soma ponderada das entradas é submetida à uma função de transferência, ou função de ativação, que determina se a soma é maior que um valor numérico - o

limiar do neurônio - se sim, o neurônio é ativado (valor 1); caso contrário, é desativado (valor 0). Tudo aquilo que o neurônio faz é responder se a soma recebida é maior que um valor numérico.

O neurônio obedece à lei do "tudo ou nada" [11], sempre estará em um de dois estados: ativado ou desativado (1 ou 0) e as entradas são recebidas de forma síncrona.

[fonte: <http://redesneuraisartificiais.blogspot.com.br/2010/10/o-primeiro-modelo-de-um-neuronio-criado.html>]



**Figura 6.** Modelo de neurônio artificial proposto por McCulloch e Pitts.

O somatório de todas as entradas, multiplicadas por suas respectivas forças de conexão sináptica (os pesos), dá origem ao chamado “net” de um neurônio [18].  $w_{ij}$  é um número real que representa a conexão sináptica da entrada do  $j$ -ésimo neurônio, conhecida como excitatória se  $w_{ij} > 0$ , ou inibitória caso  $w_{ij} < 0$ .

$$net_i(t) = \sum_{j=1}^n w_{ij}x_j(t)$$

Após a determinação do  $net$ , o valor de ativação do neurônio é atualizado através da função de ativação; e finalmente o valor de saída do neurônio é produzida através da função de saída.

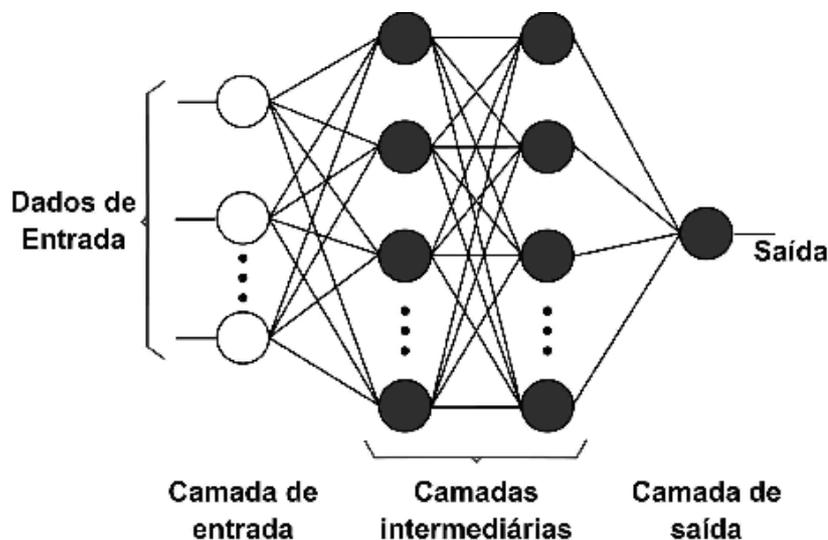
### 2.2.4 MLP

As redes *Multi-Layer Perceptron* (MLP) têm sido aplicadas com sucesso em uma variedade de áreas, desempenhando tarefas tais como: classificação de padrões (controle) e processamento de sinais.

Uma rede neural artificial do tipo MLP é constituída por um conjunto de nós fonte, os quais formam a camada de entrada da rede (*input layer*), uma ou mais camadas escondidas (*hidden layer*) e uma camada de saída (*output layer*). Com exceção da camada de entrada, todas as outras camadas são constituídas por neurônios e, portanto, apresentam capacidade computacional. O MLP é uma generalização do Perceptron [19].

A Figura 7 mostra a arquitetura de uma rede neural MLP com uma camada de entrada, duas camadas escondidas e uma camada e saída.

[fonte: [http://www.feng.pucrs.br/~decastro/pdf/RNA\\_C4.pdf](http://www.feng.pucrs.br/~decastro/pdf/RNA_C4.pdf)]



**Figura 7.** Representação gráfica de uma RNA-MLP com duas camadas intermediárias.

Estes neurônios, assim que receberem as entradas irão emitir um sinal para a camada seguinte através de uma função de ativação  $f(\text{net}_j)$ . Esses sinais se propagam pela rede até atingir a última camada (saída), calculando o sinal de saída da rede (*feedforward*). A partir deste cálculo, pode-se comparar os dados calculados

com os dados gerados pela base de dados, encontrando o erro. Esse último é propagado no sentido contrário para ajustar os pesos da rede.

$$net_j = \sum_{i=1}^N w_{ij} \times x_j - \theta$$

$$f_{ij}(net_{ij}) = \frac{1}{1 + e^{-net_{ij}}}$$

Para que este comportamento possa existir, faz-se necessário o uso de um algoritmo que auxilie as necessidades das redes de múltiplas camadas, o *backpropagation*.

### 2.2.5 Algoritmo Backpropagation

Em qualquer RNA temos os seguintes itens: neurônios e pesos. Os neurônios armazenam os valores que serão calculados para definição dos pesos, onde esses são uma espécie de chave para funcionamento de toda rede neural. É pelo peso que a RNA consegue identificar que aquele objeto é redondo e não quadrado [26]. O *backpropagation* é multicamada, pois tem no mínimo três camadas: entrada, intermediária e saída (Figura 8).

Temos 4 neurônios de entrada ( $x_1$ ,  $x_2$ ,  $x_3$  e  $x_4$ ), onde cada um destes se liga a todos os neurônios intermediários (camada oculta), e cada neurônio da camada oculta se liga a todos os neurônios da camada de saída.

[fonte: <http://www.devmedia.com.br/redesneuraisartificiaisalgoritmobackpropagation/28559>]

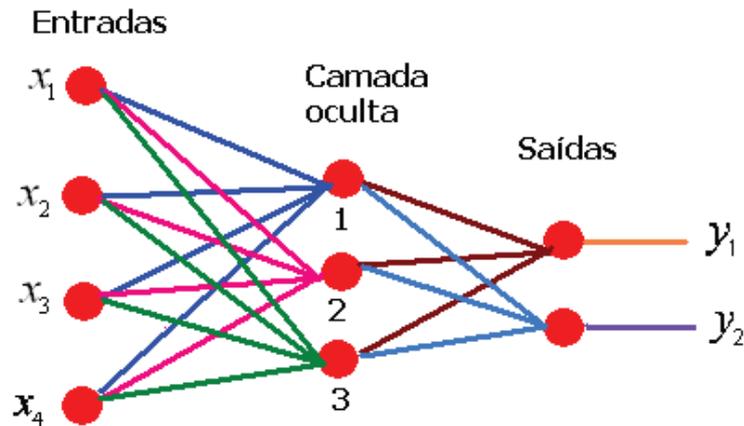


Figura 8. Representação gráfica da MLP 3 camadas.

Durante o treinamento, um conjunto de padrões é mostrado repetidas vezes a rede neural. Dessa forma, torna-se possível determinar o número de épocas do treinamento. Esse número é variável e depende muito do problema submetido a RNA. Determinar a quantidade de épocas e o momento de parada ideal não é simples, pois pode causar problemas como o *overfitting*; acontecimento associado ao treinamento demasiado da RNA, que irá decorar padrões e acarretará na perda da sua capacidade de generalização. Outro tipo de disfunção que pode ocorrer é se a RNA é treinada por menos tempo que o necessário. Nesse caso a RNA não será capaz de aprender ou de generalizar o suficiente. Um dos critérios de parada mais usados é a validação cruzada.

### 2.2.6 Critério de Parada: validação cruzada

Para utilizar desse critério se divide o conjunto em três diferentes partes: treinamento, validação e teste. O conjunto de treinamento é utilizado para o ajuste dos pesos de acordo com o algoritmo de treinamento. Após cada época, a rede previamente treinada é testada utilizando o conjunto de validação cruzada, quando se verifica a diferença entre o valor calculado e o desejado. Levando-se em conta que o conjunto de validação não é utilizado no ajuste dos pesos, ele será sempre

inédito para a rede neural, ou seja, enquanto o erro de validação cruzada continuar diminuindo, a rede continua sendo capaz de generalizar.

A partir do momento em que o erro de validação começa a aumentar enquanto o de treinamento continua a diminuir, é sinal de que a rede pode estar decorando os padrões de treinamento. É nesse momento que o treinamento deve ser parado. Posteriormente, o conjunto de testes é introduzido na rede para avaliar o seu desempenho [32].

### 2.2.7 RC

*Reservoir Computing* (RC) é um marco para a computação como uma rede neural. Tipicamente, um sinal de entrada é introduzido num sistema fixo (aleatório) chamado de reservatório dinâmico, e a dinâmica do reservatório é justificada por mapear a entrada para uma dimensão mais elevada. Em seguida, um mecanismo simples de leitura é treinado para ler o estado do reservatório e mapear para a saída desejada. O principal benefício é que sua formação é realizada somente na fase de leitura e o reservatório é fixo [28], como é mostrado na Figura 9.

O RC é geralmente muito adequada para a resolução de classificação temporal, tarefas de regressão ou previsões, onde um bom desempenho geralmente pode ser alcançado sem haver a preocupação direta com qualquer um dos parâmetros do reservatório. Em funcionalidades do mundo real, é crucial que a escala natural de tempo do reservatório seja ajustada para a mesma ordem de grandeza das aplicações temporais. Existem várias utilidades para o RC, as quais se destacam na engenharia e principalmente na robótica, onde têm sido usadas para controlar o braço de um robô, detectar obstáculos através de sua visão, rastrear objetos, ou até mesmo prever movimentos [2].

[fonte: [https://www.uni-ulm.de/fileadmin/\\_processed\\_/csm\\_ESN\\_03\\_280e23f4a3.jpg](https://www.uni-ulm.de/fileadmin/_processed_/csm_ESN_03_280e23f4a3.jpg)]

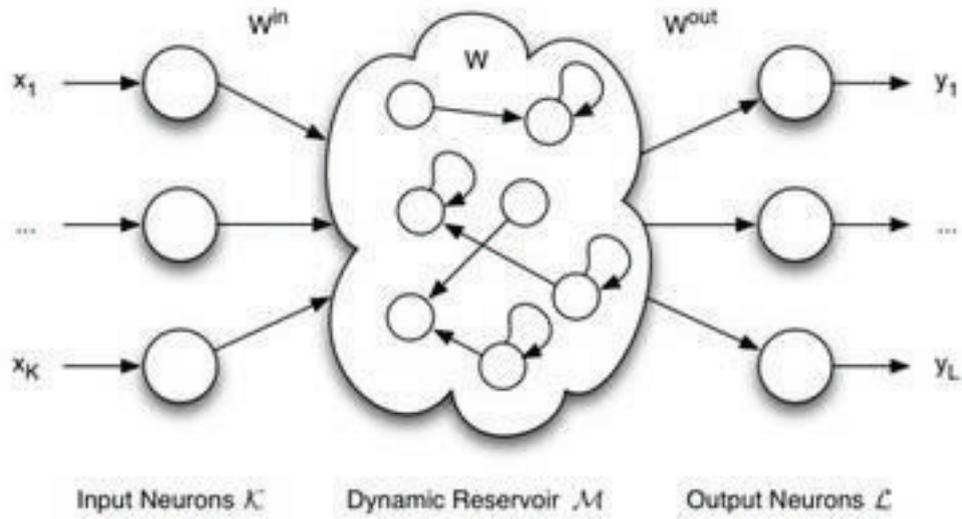


Figura 9. Representação gráfica da rede *Reservoir Computing*.

# Capítulo 3

## Metodologia

Este capítulo descreve toda a metodologia seguida para a resolução do problema proposto no trabalho.

### 3.1 Base de dados

As base de dados utilizadas neste trabalho foram cedidas pela Organização Nacional de Sistema Elétrico (ONS), que é o órgão responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN), sob a fiscalização da ANEEL.(ONS, 2014)

Foi utilizada neste trabalho a base de dados original de previsão de vazão diária da Usina Hidroelétrica de Três Marias. Através dessa base, foram geradas informações de tendência a partir dos dados de previsão de vazão média de 5 dias.

A base de dados apresenta falhas, visto que reflete na qualidade dos dados apresentados.

### 3.2 Normalização dos dados

A normalização dos vetores é o primeiro passo para o pré-processamento dos dados. Essa etapa tem como objetivo evitar que os valores altos influenciem de forma demasiada nos cálculos da RNA enquanto os valores baixos passam despercebidos. Ou seja, é feita para garantir que as variáveis em intervalos diferentes recebam a mesma atenção durante o treinamento. Além disso, as variáveis devem estar proporcionais aos limites da função de ativação usada na cama de saída. Se a função de ativação for sigmoide logística, seus valores estarão limitados entre [0 e 1], logo os dados são geralmente normalizados entre [0,10 e 0,90] ou [0,15 e 0,85].(Valença, 2005)

A normalização é descrita mediante a equação:

$$y = \frac{(b - a) \times (x_i - x_{min})}{(x_{max} - x_{min})} + a$$

Onde:

- $y$  = valor normalizado;
- $x_i$  = valor original;
- $x_{min}$  = valor mínimo de  $x$ ;
- $x_{max}$  = valor máximo de  $x$ ;
- $a$  e  $b$  = limites escolhidos. Neste trabalho,  $a = 0,15$  e  $b = 0,85$ .

Na Figura 10, o valor em destaque corresponde ao valor original, na coluna “Três Marias”. Em seguida, os valores normalizados através da aplicação da fórmula descrita.

(fonte: elaboração própria)

B6      fx      =(0,85-0,15)*(A6-C6)/(D6-C6)+0,15				
A	B	C	D	E
<b>Vazão - Três Marias</b>	<b>Normalizado</b>	<b>Min</b>	<b>Max</b>	
1293	0,271574344	42	7245	
1265	0,268853256	42	7245	
1139	0,256608358	42	7245	
1056	0,248542274	42	7245	
<b>989</b>	<b>0,242031098</b>	42	7245	
949	0,238143829	42	7245	

**Figura 10.** Normalização da base de dados Três Marias.

### 3.3 Seleção de variáveis

Após a normalização dos dados da base original, foi realizada a média móvel de 5 dias. Tal procedimento é definido como a média aritmética de um certo número (n) das observações mais recentes. No caso desse trabalho, consideramos  $n=5$ . Na medida em que se realizam novas observações, abandonam-se as observações mais antigas. O valor de n (número de períodos utilizados para se fazer a medida) reflete a capacidade de resposta frente à estabilidade da mesma forma que a definição constante de análise é feita em análise exponencial [7].

Em relação à previsão de vazão, a partir do valor relativo ao quinto dia da base original, para fazer a média foram considerados os quatro valores dos dias imediatamente anteriores, somado ao dia de referência. Toda essa soma dividida por “n”, no caso 5. Essa conta é feita para todos os valores da base, até que o último seja considerado como o quinto valor na soma; ou seja, só podemos somar 5 números consecutivos nesse cenário para obter o dividendo da média.

Em seguida, para gerar de fato informação de tendência, os valores de média móvel são derivados mais de uma vez. Na situação do trabalho, foram usadas as primeiras e as segundas derivadas, variando de 2 a 4 vezes para a primeira, e 1 a 3 vezes para a segunda.

As derivadas foram calculadas utilizando-se os dados da média móvel de 5 dias e, em cada vez que elas eram feitas, subtraía-se um valor do seu sucessor, a contar pelo valor de referência. Juntando-se todos os valores das primeiras e segundas derivadas, obtém-se as variáveis de informação de tendência do problema. Da mesma forma em que houve a normalização dos dados da base original, as derivadas também sofrem normalização para pré-processamento e defasagem dos dados.

### 3.4 Análise e tratamento dos dados

O processo de formatação dos vetores de dados é importante para que os dados possam servir corretamente como entrada na RC. Os valores servirão como

entrada na Rede Neural e, para isso, o modelo deve ligar-se corretamente com os neurônios de entrada, e, caso ocorra o treinamento supervisionado, deve-se ter bons resultados dos neurônios de saída.

Os vetores de dados estão divididos em intervalos de tempo. O grande vetor, onde contém sem formatação todos os valores da base de dados, será dividido em intervalos para que se possa deslocar no tempo, ocorrendo a defasagem dos dados, de forma que o conjunto possa representar o seu estado anterior.

O processo de defasagem constitui em deslocar o tempo  $t$  da posição  $i$  do vetor de dados para o instante  $t+1$  e  $i+1$ . A Tabela 4 abaixo demonstra como se comporta um vetor unidimensional  $v = \{1,2,3,4,5\}$  quando submetido a uma defasagem de um dia à frente de geração de energia.

**Tabela 4.** Vetor  $v$  defasado.

<b>t</b>	<b>t-1</b>	<b>t-2</b>	<b>t-3</b>
1			
2	1		
3	2	1	
4	3	2	1
5	4	3	2

(fonte: elaboração própria)

O processo de defasagem, para esse trabalho, será feito considerando-se 14 entradas de vazão passadas, que vêm antes do dia de saída, correspondentes aos dados da série original; e 12 entradas de vazão futuras, como mostra nas Tabelas 5 e 6, respectivamente.



Antes de passar esses dados da previsão de vazão pelo código implementado relativo ao *Reservoir Computing*, eles foram divididos em seis arquivos .csv: “inputs” e “outputs”, advindas do treino; “crossinputs” e “crossoutputs”, advindas da validação cruzada; e “testinputs” e “testoutputs”, advindas do teste. Essas foram as entradas da RC. Os nomes dos arquivos seguiam um padrão requisitado pelo desenvolvimento da rede neural.

### 3.5 Previsão de vazão utilizando o RC

Foram feitos 30 experimentos para análise comparativa e então foram obtidos 30 EPMA's representando as saídas da *Reservoir*. Como pode ser observado na Tabela 7, os erros percentuais variaram de 2 a 27, aproximadamente. A disparidade entre valores pode ser explicada pela normalização dos dados, que geram eventuais quebras de resultado, ou até mesmo pela quantidade de treinamentos que a rede sofreu, que pode ser maior que o necessário. É provável que ela tenha sido treinada demasiadamente e tenha perdido a sua capacidade de generalização, portanto sofrendo o *overfitting*.

Tabela 7. Saídas da RC em 30 experimentos.

	A
1	RC
2	26.288.125.080.983.900
3	26.104.457.581.404.800
4	2.634.108.530.793.510
5	2.581.150.928.395.470
6	26.100.372.038.458.700
7	25.802.765.130.041.400
8	26.030.320.090.997.900
9	2.595.707.213.400.920
10	26.139.414.231.831.300
11	2.615.997.498.957.520
12	2.647.788.615.716.290
13	26.432.228.931.736.500
14	2.610.528.107.759.410
15	2.626.080.196.213.430
16	25.935.225.409.739.000
17	26.161.235.844.643.200
18	25.973.109.468.792.500
19	2.593.480.996.379.270
20	25.985.780.951.894.500
21	2.592.706.164.164.080
22	25.864.680.016.655.700
23	25.952.857.301.512.400
24	2.622.480.147.474.190
25	26.086.018.136.165.700
26	26.159.969.449.275.100
27	2.602.904.690.500.200
28	26.282.682.615.680.600
29	25.922.107.064.917.700
30	26.222.841.321.149.800
31	26.136.229.012.634.400

(fonte: elaboração própria)

## 3.6 Testes estatísticos

Após os treinamentos com a RC, foram realizados testes estatísticos afim de avaliar qual o menor erro de defasagem obtido a partir de seus resultados, e se podem ser considerados mais eficazes que outros testes feitos com redes distintas.

Entre os diversos testes existentes, iremos destacar àquele que foi utilizado neste trabalho: o Teste de Shapiro-Wilk. Este tem o objetivo de identificar se os dados estão normalmente distribuídos e, caso sejam, precisa ser realizado outro teste, que não foi o caso.

### 3.6.1 Teste de Shapiro-Wilk

Foi utilizado o software R para os testes estatísticos Shapiro-Wilk. Os cálculos foram gerados no R conforme script na Figura 11:

(fonte: elaboração própria)

```
1 # Testes estatísticos
2 dados <- read.csv(file.choose(), header = TRUE, sep = ";")
3
4 firstModel <- c(dados[,1])
5 #secondModel <- c(dados[,2])
6 #thirdModel <- c(dados[,3])
7
8
9 # Desvio padrão dos modelos
10 sd(firstModel)
11 #sd(secondModel)
12 #sd(thirdModel)
13
14
15 # Médias dos modelos
16 mean(firstModel)
17 #mean(secondModel)
18 #mean(thirdModel)
19
20
21 # Medianas dos modelos
22 median(firstModel)
23 #median(secondModel)
24 #median(thirdModel)
25
26
27 # Shapiro - distribuição normal
28 shapiro.test(firstModel)
29
30
31 boxplot(dados)
```

Figura 11. Script do software R para tratamento dos resultados da RC.

# Capítulo 4

## Resultados

Este capítulo mostra os resultados alcançados mediante a aplicação da metodologia detalhada no capítulo 3.

Execução do script no software R: o código guarda os dados num array, calculando média, moda, variância, desvio padrão e os testes estatísticos geraram as respostas, conforme Figura 12:

(fonte: elaboração própria)

```
> # Testes estatísticos
> dados <- read.csv(file.choose(), header = TRUE, sep = ";")
> View(dados)
> firstModel <- c(dados[,1])
> #secondModel <- c(dados[,2])
> #thirdModel <- c(dados[,3])
> # Desvio padrao dos modelos
> sd(firstModel)
[1] 0.1735519
> #sd(secondModel)
> #sd(thirdModel)
> # Medias dos modelos
> mean(firstModel)
[1] 26.09366
> #mean(secondModel)
> #mean(thirdModel)
> # Medianas dos modelos
> median(firstModel)
[1] 26.10241
> #median(secondModel)
> #median(thirdModel)|
> # Shapiro - distribuicao normal
> shapiro.test(firstModel)

      Shapiro-Wilk normality test

data:  firstModel
W = 0.97301, p-value = 0.6242
```

Figura 12. Resultados dos testes estatísticos.

Usando o RC, foi observado um desvio padrão de 0,17, enquanto que utilizando o MLP na Usina Hidrelétrica de Furnas, por exemplo, esse valor pode chegar a 0,68; na Usina de Emborcação, o valor chega a 0,41; e na Usina de Sobradinho, o desvio padrão chega a 2,53 [22]. Dessa forma o resultado da *Reservoir* mostra um erro quase insignificante em relação a outras redes neurais utilizadas nos modelos de regressão linear na maioria das usinas hidroelétricas que se tem atualmente.

Dessa forma, os objetivos gerais e específicos deste trabalho não foram atendidos, no entanto mostraram que tal metodologia não é eficiente para outras tentativas de melhorar o erro da previsão de vazão, sendo, portanto, menos um obstáculo para as novas descobertas positivas a respeito.

## Capítulo 5

# Conclusão e Trabalhos Futuros

Através do resultados deste trabalho, pode-se concluir o experimento reduziu o erro de defasagem do pico de previsão de vazão utilizando uma rede neural não muito comum para estas técnicas padrão das usinas hidroelétricas, pois, embora não tendo superado às expectativas, o resultado comprovou que apresenta um desvio padrão menor que o gerado pelas redes *Multi-Layer Perceptron*, por exemplo [22].

Com isso, percebeu-se que a *Reservoir Computing* pode ser utilizada para a finalidade de previsão de vazões, por apresentar um erro menor do que aqueles que os modelos de regressão linear podem gerar, além de que as usinas hidroelétricas podem, a partir daí, passar a usar esse novo modelo como referência nas suas previsões, que serão mais próximas da realidade. Dessa forma, o risco de acontecer uma catástrofe ambiental resultante de previsões falhas será muito menor, e assim não expõe tanto a população a essa ameaça.

Como trabalhos futuros, há diversos outros tipos de redes neurais que podem ser utilizados para a previsão de vazões, embora a RC seja a mais avançada e capaz de resolver problemas mais complexos que temos no presente momento. Dessa maneira, os projetos poderão se estender para previsões especulando-se diferentes espaços de tempo, além de alterações nas entradas, aumentando ou reduzindo as primeiras e segundas derivadas a partir da média móvel.

Portanto há várias outras possibilidades de testes, que podem ou não ser favoráveis a uma grande descoberta, mas, caso não atendam às perspectivas, o que faz garantir a honra do projeto é exatamente a equipe poder chegar a uma conclusão de que aquela metodologia não precisa mais ganhar investimento; isto é, já elimina mais um obstáculo para outras descobertas importantes que possam vir no futuro.

---

# Bibliografia

- [1] **Análise de Metodologias de Previsão de Vazões em Tempo Real Estudo de Casos: Bacias do Rio Doce (MG) e do Rio Uruguai (RS).** Disponível em: <<http://rhama.net/download/artigos/artigo89.pdf>>, acesso em: 15 de maio de 2016.
- [2] **Análises e Previsões de Vazões do Rio Grande Utilizando Modelos de Box & Jenkins e Redes Neurais Artificiais.** Disponível em: <<http://siaiap32.univali.br/seer/index.php/acotb/article/viewFile/6405/3634>>, acesso em: 9 de junho de 2016.
- [3] **Capítulo 4: Multilayer Perceptrons.** Disponível em: <[http://www.feng.pucrs.br/~decastro/pdf/RNA\\_C4.pdf](http://www.feng.pucrs.br/~decastro/pdf/RNA_C4.pdf)>, acesso em: 12 de junho de 2016.
- [4] **Energia Hidráulica em 2014. Brasil e Mundo.** Disponível em: <<http://www.mme.gov.br/documents/1138769/2252804/Energia+Hidráulica+em+2014.pdf/a4f31f91-1737-4f3b-85fb-f960706d0c56>>, acesso em: 15 de maio de 2016.
- [5] **Energia Hidráulica.** Disponível em: <[http://www2.aneel.gov.br/aplicacoes/atlas/pdf/04-Energia\\_Hidraulica\(2\).pdf](http://www2.aneel.gov.br/aplicacoes/atlas/pdf/04-Energia_Hidraulica(2).pdf)>, acesso em: 15 de maio de 2016.
- [6] **Energia Hidráulica.** Disponível em: <[http://www2.aneel.gov.br/aplicacoes/atlas/energia\\_hidraulica/4\\_3.htm](http://www2.aneel.gov.br/aplicacoes/atlas/energia_hidraulica/4_3.htm)>, acesso em: 21 de maio de 2016.
- [7] **Glossário Logístico.** Disponível em: <<http://www.pinho.com.br/dicionario/M.htm>>, acesso em: 9 de junho de 2016.
- [8] **Gráfico energia gerada no mundo.** Disponível em: <<http://educenergiahidreletrica.blogspot.com.br>>, acesso em: 15 de maio de 2016.

- [9] **Histórico sobre usinas hidrelétricas e seus impactos ambientais no Brasil.**  
Disponível em: <<http://www.artigos.etc.br/historico-sobre-usinas-hidreletricas-e-seus-impactos-ambientais-no-brasil.html>>, acesso em: 10 de junho de 2016.
- [10] JURISTO, N.; MORENO, A. **Basics of software engineering experimentation.** [S.l.]: Springer Publishing Company, 2010.
- [11] **Lei do tudo ou nada.** Disponível em:  
<[http://men5185.ced.ufsc.br/trabalhos/05\\_eletrofisiologia/potencial\\_acao.htm](http://men5185.ced.ufsc.br/trabalhos/05_eletrofisiologia/potencial_acao.htm)>, acesso em: 01 de junho de 2016.
- [12] **Modelagem chuva-vazão mensal utilizando redes neurais artificiais.**  
Disponível em: <[http://www.ppgerha.ufpr.br/publicacoes/dissertacoes/files/093-Fernando\\_Weigert\\_Machado.pdf](http://www.ppgerha.ufpr.br/publicacoes/dissertacoes/files/093-Fernando_Weigert_Machado.pdf)>, acesso em: 28 de maio de 2016.
- [13] **Modelagem chuva-vazão utilizando redes neurais artificiais e algoritmos genéticos.** Disponível em:  
<<http://www.lbd.dcc.ufmg.br/colecoes/wcama/2011/001.pdf>>, acesso em: 28 de maio de 2016.
- [14] **Modelo de Previsão de Vazão com Informação de Precipitação Utilizando Redes Neurais.** Disponível em:  
<[http://www.ons.org.br/download/previsao\\_vazoes/artigos\\_sessao/AT\\_Sessão05.pdf](http://www.ons.org.br/download/previsao_vazoes/artigos_sessao/AT_Sessão05.pdf)>, acesso em: 31 de maio de 2016.
- [15] **Modelos de séries temporais e redes neurais artificiais na previsão de vazão.** Disponível em:  
<[http://repositorio.ufla.br/bitstream/1/1918/1/DISSERTAÇÃO\\_Modelos%20de%20séries%20temporais%20e%20redes%20neurais%20na%20previsão%20de%20vazão.pdf](http://repositorio.ufla.br/bitstream/1/1918/1/DISSERTAÇÃO_Modelos%20de%20séries%20temporais%20e%20redes%20neurais%20na%20previsão%20de%20vazão.pdf)>, acesso em: 10 de maio de 2016.
- [16] **Na overview of reservoir computing: theory, applications and implementations.** Disponível em:  
<<https://www.elen.ucl.ac.be/Proceedings/esann/esannpdf/es2007-8.pdf>>, acesso em: 31 de maio de 2016.

- [17] **Neurônio artificial.** Disponível em: <[https://pt.wikipedia.org/wiki/Neur%C3%B4nio\\_artificial](https://pt.wikipedia.org/wiki/Neur%C3%B4nio_artificial)>, acesso em: 21 de maio de 2016.
- [18] **O Neurônio Artificial.** Disponível em: <[http://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio\\_artificial/index.html](http://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio_artificial/index.html)>, acesso em: 01 de junho de 2016.
- [19] **O primeiro modelo de um neurônio criado por Mc Culloch e Pitts.** Disponível em: <<http://redesneuraisartificiais.blogspot.com.br/2010/10/o-primeiro-modelo-de-um-neuronio-criado.html>>, acesso em: 01 de junho de 2016.
- [20] **Perceptron.** Disponível em: <<https://pt.wikipedia.org/wiki/Perceptron>>, acesso em 11 de junho de 2016.
- [21] **Previsão de Vazões com a Metodologia DPFT e com Redes Neurais Artificiais.** Disponível em: <[https://www.researchgate.net/profile/Suzana\\_Montenegro2/publication/242759898\\_Modelo\\_Baseado\\_na\\_Tcnica\\_de\\_Redes\\_Neurais\\_para\\_Previso\\_de\\_Vazes\\_na\\_Bacia\\_do\\_Rio\\_So\\_Francisco/links/555b195708ae980ca611dd9e.pdf#page=7](https://www.researchgate.net/profile/Suzana_Montenegro2/publication/242759898_Modelo_Baseado_na_Tcnica_de_Redes_Neurais_para_Previso_de_Vazes_na_Bacia_do_Rio_So_Francisco/links/555b195708ae980ca611dd9e.pdf#page=7)>, acesso em: 10 de maio de 2016.
- [22] **Previsão de vazões médias mensais usando redes neurais nebulosas.** Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0103-17592003000300008](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592003000300008)>, acesso em: 10 de maio de 2016.
- [23] **Previsão de Vazões utilizando Redes Neurais Artificiais MLP e NSRBN.** Disponível em: <<http://www.sbpcnet.org.br/livro/63ra/conpeex/mestrado/trabalhos-mestrado/mestrado-alan-caio.pdf>>, acesso em: 10 de maio de 2016.
- [24] **Redes neurais artificiais aplicadas à previsão da vazão na bacia do Rio Acre.** Disponível em: <[http://www.academia.edu/8226806/\\_1\\_REDES\\_NEURAIAS\\_ARTIFICIAIS\\_APLICADAS\\_À\\_PREVISÃO\\_DA\\_VAZÃO\\_NA\\_BACIA\\_DO\\_RIO\\_ACRE](http://www.academia.edu/8226806/_1_REDES_NEURAIAS_ARTIFICIAIS_APLICADAS_À_PREVISÃO_DA_VAZÃO_NA_BACIA_DO_RIO_ACRE)>, acesso em: 10 de maio de 2016.

- [25] **Redes Neurais Artificiais.** Disponível em: <<http://www.icmc.usp.br/~andre/research/neural/>>, acesso em: 21 de maio de 2016.
- [26] **Redes Neurais Artificiais: Algoritmo Backpropagation.** Disponível em: <<http://www.devmedia.com.br/redes-neurais-artificiais-algoritmo-backpropagation/28559>>, acesso em: 01 de junho de 2016.
- [27] **Redes Neurais Artificial.** Disponível em: <[www.inf.ufpr.br/aurora/tutoriais/Redes%20Neurais%20Artificial.ppt](http://www.inf.ufpr.br/aurora/tutoriais/Redes%20Neurais%20Artificial.ppt)>, acesso em: 31 de maio de 2016.
- [28] **Reservoir computing.** Disponível em: <[https://en.wikipedia.org/wiki/Reservoir\\_computing](https://en.wikipedia.org/wiki/Reservoir_computing)>, acesso em: 9 de junho de 2016.
- [29] **The R Project for Statistical Computing.** Disponível em: <<http://www.r-project.org/>>, acesso em 2 de junho de 2016.
- [30] **Tudo sobre energia.** Disponível em: <<http://grupoperfeito.blogspot.com.br/2010/10/energia-hidreletrica.html>>, acesso em: 15 de maio de 2016.
- [31] **Uma Introdução às Redes Neurais.** Disponível em: <<http://www.din.uem.br/ia/neurais/#neural>>, acesso em: 21 de maio de 2016.
- [32] **Utilizando Informações de Tendência Fuzzy para Previsão de Vazões com Redes Neurais.** Disponível em: <[http://tcc.ecomp.poli.br/20092/TCC\\_Tarcisio.pdf](http://tcc.ecomp.poli.br/20092/TCC_Tarcisio.pdf)>, acesso em: 21 de maio de 2016.
- [33] VALENÇA, M. J. S. **Aplicando Redes Neurais: Um Guia Completo.** Olinda: Livro Rápido, 2005.
- [34] VALENÇA, M. J. S. **Fundamentos das redes neurais.** 2. ed. Olinda: Livro Rápido, 2010.

# Apêndice A

(fonte: elaboração própria)

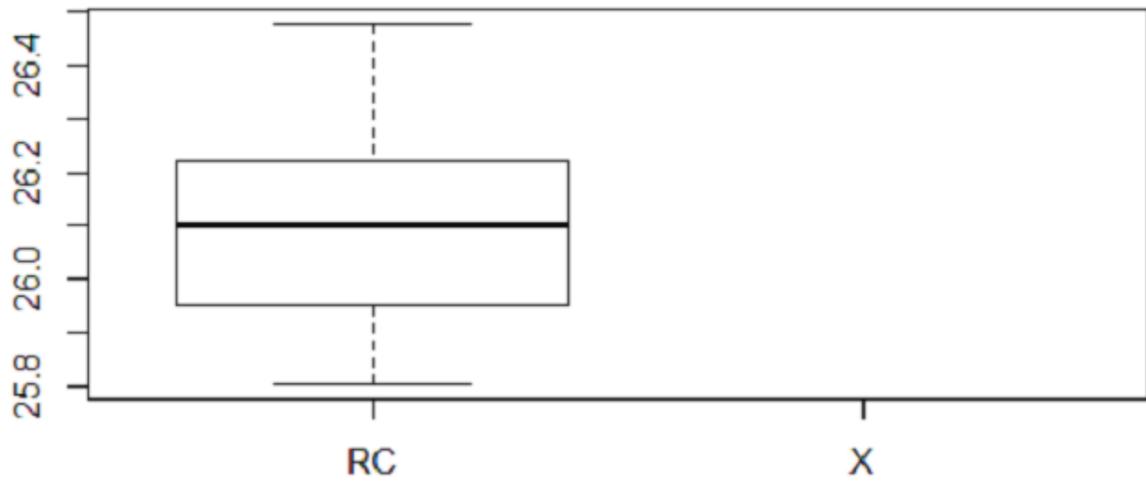


Figura 13. Saída – Software R.