



# **ANÁLISE COMPARATIVA DE REDES MULTI-LAYER PERCEPTRON (MLP) E RESERVOIR COMPUTING (RC) PARA PREVISÃO DE VAZÃO**

**Trabalho de Conclusão de Curso  
Engenharia da Computação**

**Renato Valença Novaes**

**Orientador: Profº. Dr. Mêuser Jorge Silva Valença**



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

**RENATO VALENÇA NOVAES**

**ANÁLISE COMPARATIVA DE REDES MULTI-  
LAYER PERCEPTRON (MLP) E RESERVOIR  
COMPUTING (RC) PARA PREVISÃO DE VAZÃO**

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

**Recife, Junho de 2017.**



### MONOGRAFIA DE FINAL DE CURSO

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

No dia 13 de julho de 2017, às 10:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente **RENATO VALENÇA NOVAES**, orientado pelo professor **Mêuser Jorge Silva Valença**, sob título **Análise Comparativa de Redes Multilayer Perceptron (MLP) e Reservoir Computing (RC) para Previsão de Vazão**, 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: 9,5 (note e meio)

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

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

SÉRGIO MARIO LINS GALDINO

MÊUSER JORGE SILVA VALENÇA

\* Este documento deverá ser encadernado juntamente com a monografia em versão final.

*Dedico este trabalho aos meus pais, Elizabete Valença e Antônio Novaes, verdadeiramente os maiores mestres que tive.*

# Agradecimentos

Primeiramente, agradeço em especial, aos meus pais Elizabete e Antônio, que sempre foram meus guias nessa estrada tortuosa da vida, me ajudando a superar diversas etapas de cabeça erguida.

Agradeço ao meu irmão Renan, por sempre estar ao meu lado quando preciso e por ser uma ótima pessoa e um grande amigo.

Agradeço imensamente a minha namorada Jessika, por estar ao meu lado desde o início, tanto nos momentos bons quanto nos momentos ruins. Você me ajudou a superar este desafio de maneira transcendental. Esta conquista também é sua.

Agradeço aos meus tios e primos por todo apoio e torcida pelo meu sucesso.

Agradeço a todos os meus colegas de faculdade, por serem sempre prestativos e unidos nas horas mais difíceis.

Agradeço aos bons professores da POLI, que contribuíram com a minha formação, especialmente ao professor Mêuser Valença pela orientação, ensinamentos, paciência e apoio.

Por fim, agradeço ao Google, por nunca me deixar na mão num momento de dúvidas e por possibilitar a busca de conhecimento de maneira fácil e rápida, contribuindo desta forma, com a minha graduação.

“Há uma força motriz mais poderosa que o vapor, a eletricidade  
e a energia atômica: a vontade”  
“Algo só é impossível até que alguém duvide e resolva provar ao contrário”  
**(Albert Einstein)**

# Resumo

O objetivo geral deste trabalho é fazer uma análise comparativa das redes Multi-Layer Perceptron (MLP) e Reservoir Computing (RC) para prevê a vazão de um mês a frente, considerando 12 meses de dados de vazão passados na Usina Hidrelétrica de Sobradinho, situada no estado da Bahia (BA). Para que essa comparação fosse possível, foi utilizado o teste estatístico de Wilcoxon. Os dados datam de janeiro de 1931 até dezembro de 2003. Como preparação, foi feita a normalização, defasagem e correlação dos dados para definir as variáveis de entrada. Para a rede MLP, foi usada uma arquitetura de seis neurônios na camada escondida, a função de ativação foi Sigmoid Logística e o algoritmo de treinamento o Backpropagation. Já para a RC, a arquitetura usada possui 25 neurônios no reservatório, sua função de ativação também foi a Sigmoid Logística e o critério de parada foi o Cross Validation. Os resultados mostraram que é melhor ter dois modelos, um especialista em períodos chuvosos e outro especialista em períodos secos, do que um único modelo genérico para prevê a vazão durante todo o ano. Além disso, as previsões considerando a sazonalidade foram, por unanimidade, melhores que os modelos que não a consideravam como entrada. Por fim, os resultados ainda mostraram que a rede RC é mais precisa que a rede MLP para este estudo de caso.

**Palavras-chave:** Previsão de vazão. Redes Neurais Artificiais. Multi-Layer Perceptron. Reservoir Computing.

# Abstract

The general objective of this work is to make a comparative analysis of the Multi-Layer Perceptron (MLP) and Reservoir Computing (RC) networks to predict the flow from one month to the next, considering 12 months of past flow data at the Sobradinho Hydroelectric Plant in the state of Bahia (BA). For this comparison to be possible, the Wilcoxon statistical test was used. The data date from January 1931 to December 2003. As preparation, the normalization, gap and correlation of the data were made to define the input variables. For the MLP network, a six-neuron architecture was used in the hidden layer, the activation function was Sigmoidal Logística and the Backpropagation training algorithm. For RC, the architecture used has 25 neurons in the reservoir, its activation function was also Sigmoidal Logística and the criteria of stop was the Cross Validation. The results showed that it is better to have two models, one expert in rainy periods and another specialist in dry periods, than a single generic model for predicting the flow throughout the year. In addition, seasonality forecasts were unanimously better than models that did not consider it as input. Finally, the results still showed that the RC network is more accurate than the MLP network for this case study.

**Keywords:** Forecast of flow. Artificial neural networks. Multi-Layer Perceptron. Reservoir Computing.

# Lista de Ilustrações

<b>Figura 1</b> - Geração de Energia Elétrica Mundial por fonte (%) (2012).....	4
<b>Figura 2</b> - Geração de Energia Elétrica no Brasil por fonte (%) (2015).....	4
<b>Figura 3</b> - Maiores países que utilizam a energia hidrelétrica (2012).....	4
<b>Figura 4</b> - Esquema de uma Usina Hidrelétrica.....	5
<b>Figura 5</b> - Esquema de um neurônio biológico.....	7
<b>Figura 6</b> - Esquema de uma ligação entre dois neurônios.....	8
<b>Figura 7</b> - Neurônio de McCulloch e Pitts.....	9
<b>Figura 8</b> - Exemplo de uma rede Multi-Layer Perceptron (MLP) com duas camadas escondidas.....	10
<b>Figura 9</b> - Esquema de uma rede neural recorrente Reservoir Computing (RC).....	13
<b>Figura 10</b> - Usina Hidrelétrica de Sobradinho, Bahia.....	14
<b>Figura 11</b> - Exemplo de transformação linear, tipo de normalização, utilizando a base de dados da Usina Hidrelétrica de Sobradinho, Bahia.....	15
<b>Figura 12</b> - Exemplo da sazonalidade, utilizando as funções seno e cosseno.....	17
<b>Figura 13</b> – <i>Box Plot</i> comparando melhores resultados de MLP.....	29
<b>Figura 14</b> - <i>Box Plot</i> comparando melhores resultados de RC.....	30
<b>Figura 15</b> – <i>Box Plot</i> comparando a rede MLP com a rede RC.....	31

# Lista de Tabelas

<b>Tabela 1</b> - Principais Usinas Hidrelétricas no Brasil.....	6
<b>Tabela 2</b> - Exemplo de base defasada.....	16
<b>Tabela 3</b> - Comparação entre o período seco com e sem sazonalidade para a rede MLP.....	22
<b>Tabela 4</b> - Comparação entre o período chuvoso com e sem sazonalidade para a rede MLP.....	22
<b>Tabela 5</b> - Comparação para o ano completo com e sem sazonalidade para a rede MLP.....	23
<b>Tabela 6</b> - Comparação entre o melhor modelo do ano inteiro com os melhores modelos parciais para a rede MLP.....	24
<b>Tabela 7</b> - Comparação entre o período seco com e sem sazonalidade para a rede RC.....	25
<b>Tabela 8</b> - Comparação entre o período chuvoso com e sem sazonalidade para a rede RC.....	266
<b>Tabela 9</b> - Comparação para o ano completo com e sem sazonalidade para a rede RC.....	26
<b>Tabela 10</b> - Comparação do melhor modelo do ano inteiro com os melhores modelos parciais.....	27
<b>Tabela 11</b> - Comparação do melhor modelo da rede MLP com o melhor modelo da rede RC.....	28

# Lista de Abreviaturas e Siglas

ANEEL – Agência Nacional de Energia Elétrica

BA - Bahia

EPMA – Erros percentuais médios absolutos

MLP – Multilayer Perceptron

MG – Minas Gerais

POLI – Escola Politécnica de Pernambuco

PNRH – Política Nacional de Recursos Hídricos

PSO – Otimização por Enxame de partículas

RC – Reservoir Computing

RNA – Redes Neurais Artificiais

SINGREH – Sistema Nacional de Gerenciamento de Recursos Hídricos

UPE – Universidade de Pernambuco

# Sumário

Capítulo 1 – Introdução.....	1
1.1 Objetivos.....	2
1.2 Estrutura da Monografia.....	2
Capítulo 2 – Fundamentação Teórica.....	3
2.1 Energia Hidrelétrica.....	3
2.2 Redes Neurais Artificiais (RNA).....	7
2.2.1 Multi-Layer Perceptron (MLP).....	10
2.2.2 Reservoir Computing (RC).....	12
Capítulo 3 – Metodologia.....	14
3.1 Base de Dados.....	14
3.2 Pré-processamento dos dados.....	14
3.3 Entrada das Redes Neurais Artificiais (RNAs).....	17
3.4 Arquitetura das redes.....	18
3.5 Testes estatísticos.....	20
Capítulo 4 – Resultados.....	21
4.1 Experimentos com Multi-Layer Perceptron (MLP).....	21
4.1.1 Modelo para o período seco.....	21
4.1.2 Modelo para o período chuvoso.....	22
4.1.3 Modelo para o ano completo.....	23
4.1.4 Comparação do melhor modelo do ano inteiro com os melhores modelos parciais.....	23
4.2 Experimentos com Reservoir Computing (RC).....	24
4.2.1 Modelo para o período seco.....	24
4.2.2 Modelo para o período chuvoso.....	25
4.2.3 Modelo para o ano completo.....	26
4.2.4 Comparação do melhor modelo do ano inteiro com os melhores modelos parciais.....	27
4.3 Comparativo dos resultados: Rede MLP X RC.....	28
4.4 Representação por Box Plot.....	29
4.4.1 Resultado para MLP.....	29
4.4.2 Resultado para RC.....	30
4.4.2 Melhor resultado MLPxRC.....	31

<b>Capítulo 5 – Considerações Finais.....</b>	<b>32</b>
<b>Referências.....</b>	<b>33</b>
<b>Apêndice.....</b>	<b>36</b>

# Capítulo 1 – Introdução

A água é um recurso finito e esse recurso é bastante utilizado em diversas atividades, como por exemplo, na agricultura e engenharia. Com as mudanças climáticas, essas atividades estão sendo diretamente afetadas. Isso torna sua gestão uma tarefa difícil de ser administrada. Nesse contexto, o gerenciamento de bacias hidrográficas, vem sendo um dos maiores focos para o controle dos recursos hídricos e energéticos em todos os países (ANEEL, 2008).

O desafio é achar maneiras de aproveitar adequadamente os recursos hídricos do planeta. Uma das principais utilizações desse recurso é na geração de energia elétrica. Segundo a Agência Nacional de Energia Elétrica (ANEEL), cerca de 60% da matriz energética brasileira é composta por hidroelétricas, porém, este percentual cai bastante quando analisado o aproveitamento do parque hidrelétrico como um todo (ANEEL, 2008).

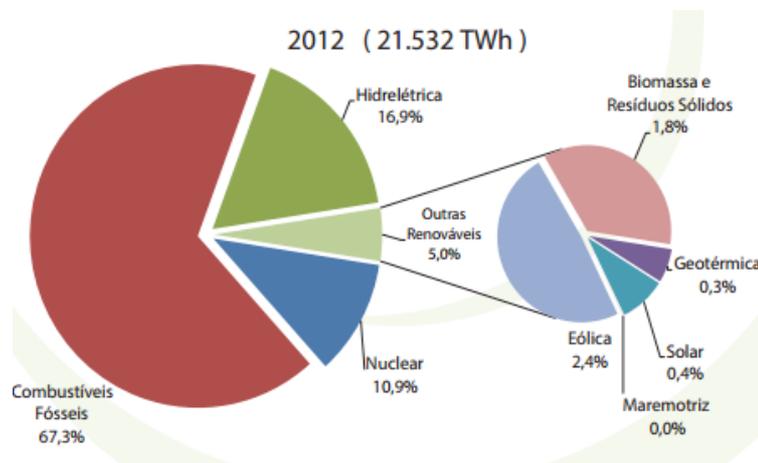
Tendo isso em vista, nota-se a importância de tomar medidas baseadas em dados confiáveis, como por exemplo, dados estatísticos e probabilísticos que possibilitem uma boa administração desse recurso. A previsão de vazão nas usinas hidrelétricas é de suma importância para esse gerenciamento. Ela possibilita antecipar problemas futuros e, assim, minimizar os possíveis impactos, agilizando uma tomada de decisão (CASTRO; CASTRO, 2011).

Diversas técnicas buscam diminuir o erro ao tentar prevê a vazão em uma usina hidrelétrica utilizando séries temporais, porém estudos recentes mostram que o uso das redes neurais artificiais (RNAs) para previsão de séries temporais vem aumentando (PAZ *et al.*, 2002; BATISTA, 2011). Uma RNA é um procedimento computacional que representa a estrutura de redes neurais biológicas, e são capazes de adquirir um conhecimento por meio da experiência (CARVALHO, 2009a).

As redes Multi-Layer Perceptron (MLP) e a Reservoir Computing (RC) são exemplos dessas redes. Ambas possuem vantagens e desvantagens, sendo uma mais adequada a certos problemas que outros. A MLP apresenta neurônios em camadas intermediárias ou escondidas, possibilitando solucionar problemas que não sejam linearmente separáveis (CARVALHO, 2009b). Já a RC apresenta um

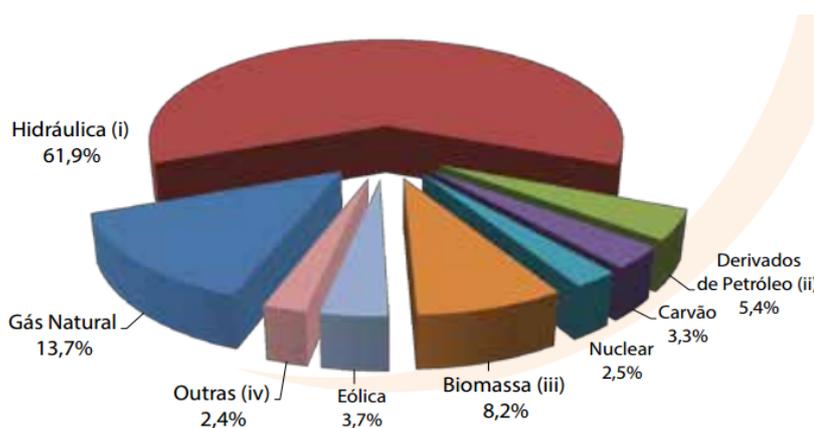


**Figura 1 - Geração de Energia Elétrica Mundial por fonte (%) (2012)**



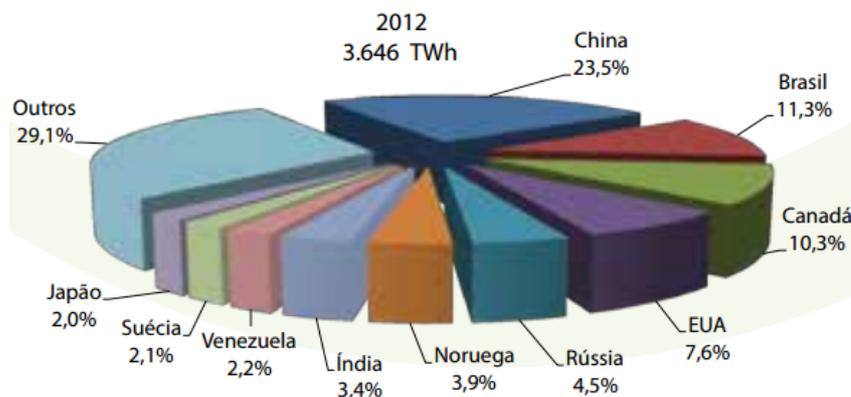
Fonte: Brasil (2016).

**Figura 2 - Geração de Energia Elétrica no Brasil por fonte (%) (2015)**



Fonte: Brasil (2016).

**Figura 3 - Maiores países que utilizam a energia hidrelétrica (2012)**



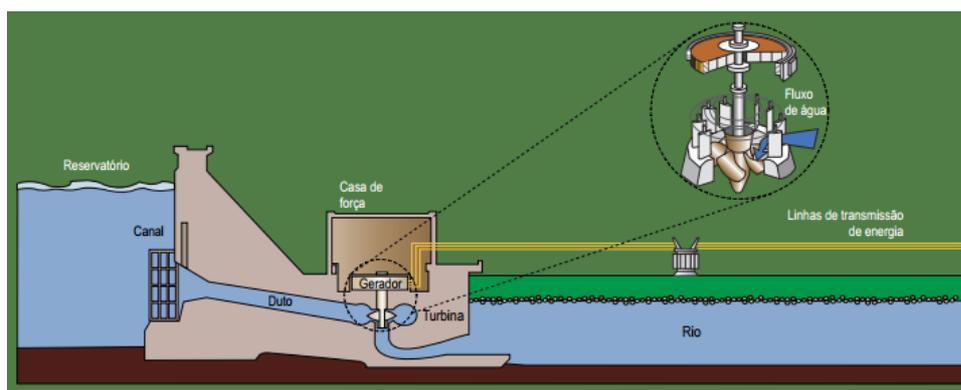
Fonte: Brasil (2016).

A energia hidrelétrica é gerada pelo aproveitamento do fluxo das águas de um rio, em uma usina, onde a energia cinética (do movimento da água) é convertida em energia mecânica através da rotação das turbinas que compõem esse sistema, para depois ser transformada em energia elétrica por um gerador (ECYCLE, 2013).

Para gerar este tipo de energia, é importante integrar a vazão do rio, a quantidade de água disponível em um período de tempo e os desníveis do relevo (que pode ser natural, como uma cachoeira, ou criados artificialmente, como uma barragem) (ANEEL, 2008).

Uma usina hidrelétrica, basicamente, é composta por uma barragem, um sistema de captação e adução de água, uma casa de força e um vertedouro (Figura 4). A barragem tem por finalidade interromper o curso normal do rio, permitindo a formação do reservatório. Os sistemas de captação e adução são constituídos por túneis ou canais com função de levar a água até a casa de força, local onde estão as turbinas. O movimento das turbinas transforma a energia cinética em energia elétrica por meio dos geradores que produzirão a eletricidade. Em seguida, a água é devolvida ao leito natural do rio pelo canal de fuga. Por fim, encontra-se o vertedouro, local que permite a saída da água sempre que os níveis do reservatório ultrapassam os limites estabelecidos, como por exemplo, no período chuvoso (ANEEL, 2008).

**Figura 4 - Esquema de uma Usina Hidrelétrica**



Fonte: ANEEL (2008).

Para a geração e transmissão de energia elétrica, o Brasil conta com um conjunto de mais de 150 usinas hidroelétricas, distribuídas nas 12 bacias hidrográficas. A tabela 1 mostra algumas das principais usinas hidrelétricas do Brasil.

**Tabela 1 - Principais Usinas Hidrelétricas no Brasil**

<b>Usinas</b>	<b>Rio</b>	<b>Estado</b>	<b>Capacidade aproximada</b>
Itaipu	Paraná	PR	14.000 MW
Belo Monte	Xingú	PA	11.233 MW
São Luíz do Tapajós	Tapajós	PA	8.381 MW
Tucuruí	Tocantins	PA	8.370 MW
Xingó	São Francisco	AL/SE	3.162 MW
Paulo Afonso	São Francisco	BA	2.462 MW
Sobradinho	São Francisco	BA	1.050 MW

Fonte: Adaptado de Tavares (2015).

Embora seja necessário um grande investimento inicial para a construção de uma usina hidrelétrica, além de impactos negativos tanto no âmbito social, como no ambiental, essa fonte de energia ainda é defendida por muitos pesquisadores. Uma das vantagens de se utilizar este tipo de fonte energética é a transformação limpa do recurso natural, em que praticamente não há liberação de poluentes, principalmente quando comparado com outras fontes de energia, como os combustíveis fósseis, por exemplo.

Uma discussão que merece destaque é a previsão de vazão das usinas hidrelétricas. A vazão é o escoamento superficial medido em determinados pontos do rio, sendo responsável pela potência de toda usina. Quanto mais vazão de água disponível para movimentar as turbinas, maior será a potência que esta usina gerará (GUILHERME, 2017).

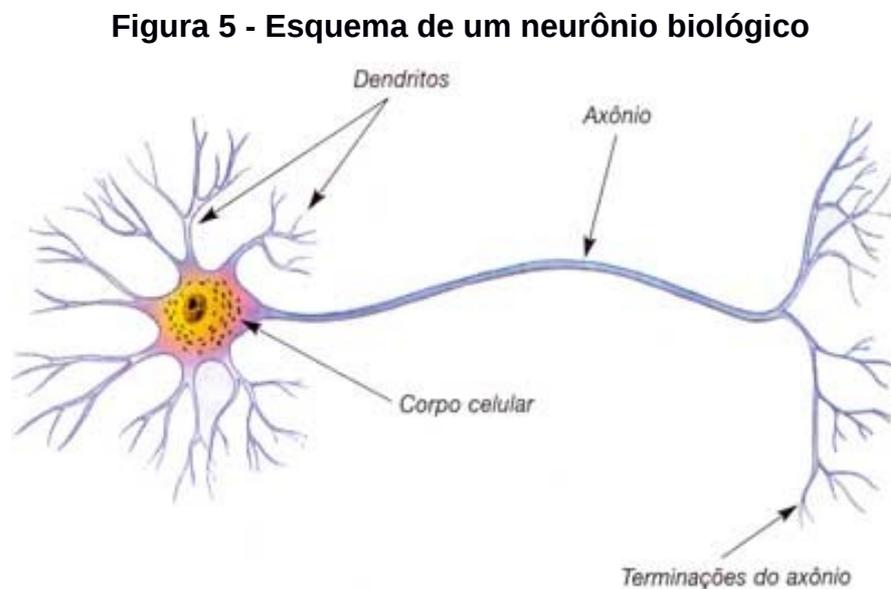
A previsão de vazão é extremamente importante. Com ela, é possível antecipar as baixas e as altas da vazão. Quando o valor previsto da vazão for muito alto, sabe-se que no futuro, terá grandes chances de haver uma enchente, caso contrário, se o valor da vazão previsto for muito baixo, é possível acionar outros tipos de geração de energia com antecedência, como termoelétricas, por exemplo, para suprir a baixa potencia que a usina gerará.

Diversas metodologias vêm sendo utilizadas para a previsão de vazões, como os modelos matemáticos convencionais, empíricos ou conceituais, porém, recentemente, algumas técnicas se mostraram mais eficientes, como as redes neurais artificiais (RNA).

## 2.2 Redes Neurais Artificiais (RNA)

Segundo Valença (2009) para poder entender como funciona uma rede neural artificial (RNA), primeiramente devemos conhecer o funcionamento de um neurônio biológico e como se comporta a transmissão de sinais entre essas células.

Os neurônios são células do sistema nervoso responsáveis por processar informações. São constituídos por três partes principais, os dendritos que é a parte que recebe informações, os axônios, que transportam o impulso nervoso de um neurônio para outro e o corpo celular, que é onde haverá a assimilação das informações (Figura 5) (LOPES, 2008).

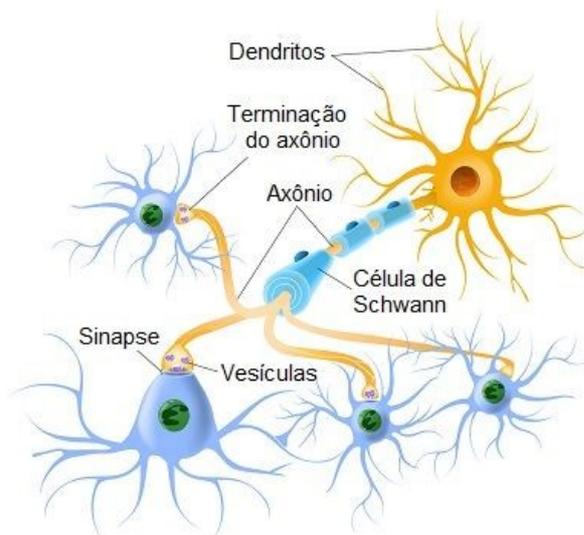


Fonte: SOGAB (2017).

No sistema nervoso, existe uma região nomeada de sinapse (Figura 6). Ela fica localizada entre neurônios, transmitindo sinais de um neurônio para o outro, que

ocorre graças aos neurotransmissores, estes, por sua vez, são biomoléculas produzidas pelos neurônios e armazenadas nas vesículas sinápticas (bolsas presentes nas extremidades dos axônios) (LOPES, 2008).

**Figura 6 - Esquema de uma ligação entre dois neurônios**

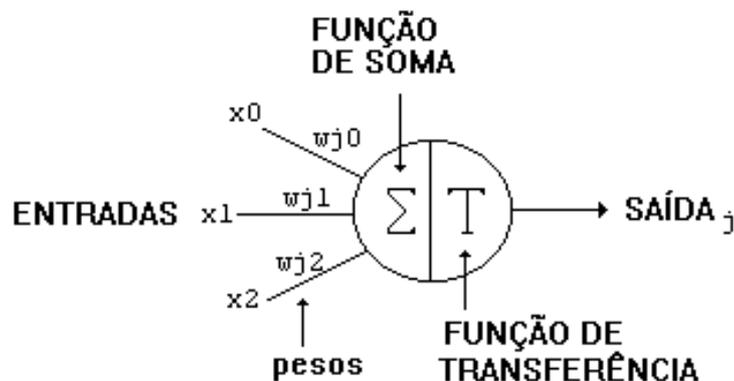


Fonte: Duarte (2016).

Desse modo, surge o conceito das redes neurais artificiais, que são técnicas computacionais que representam a estrutura de redes neurais biológicas, e são capazes de adquirir conhecimento por meio da experiência. Enquanto que no cérebro de mamíferos pode conter bilhões de neurônios, uma rede neural artificial pode conter centenas ou milhares (CARVALHO, 2009a).

O neurônio artificial é um “conjunto de elementos de processamento interconectados que, geralmente, encontram-se em camadas” (VALENÇA, 2009). O primeiro deles foi descrito pelos pesquisadores Warren McCulloch e Walter Pitts, em 1943. O modelo constitui-se de um vetor de entradas e as sinapses são representadas por pesos numéricos (Figura 7). A soma ponderada é sujeita a uma função de transferência ou de ativação, que indica se a soma é maior ou menor que o limiar do neurônio, se sim, ocorre a ativação do neurônio, caso contrário, ele é desativado (RNA.BLOGSPOT, 2010).

Figura 7 - Neurônio de McCulloch e Pitts



Fonte: RNA.Blogspot (2010).

A partir deste modelo, foi desenvolvida a lei do tudo ou nada. Essa lei afirma que o neurônio só liberará o impulso nervoso para outro neurônio, se este impulso for maior que o limiar excitatório (RNA.BLOGSPOT, 2010).

O neurônio de McCulloch e Pitts constitui-se de somar todas as entradas e multiplicá-las pelos seus respectivos pesos, isso é o que se chama “net” de um neurônio, como mostrado na equação abaixo.  $w_{ij}$  é um número real que representa a conexão sináptica da entrada  $j$ -ésimo neurônio. A conexão sináptica é conhecida como excitatória se  $w_{ij}$  for maior que zero ( $w_{ij} > 0$ ) ou inibitória se  $w_{ij}$  for menor que zero ( $w_{ij} < 0$ ) (ZAMBIASI, 2011).

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

Após a determinação do net, o valor da ativação do neurônio é atualizado através da função de ativação e o valor de saída é produzido através da função de saída (ZAMBIASI, 2011).

A função de ativação é uma função degrau dada por:

(2)

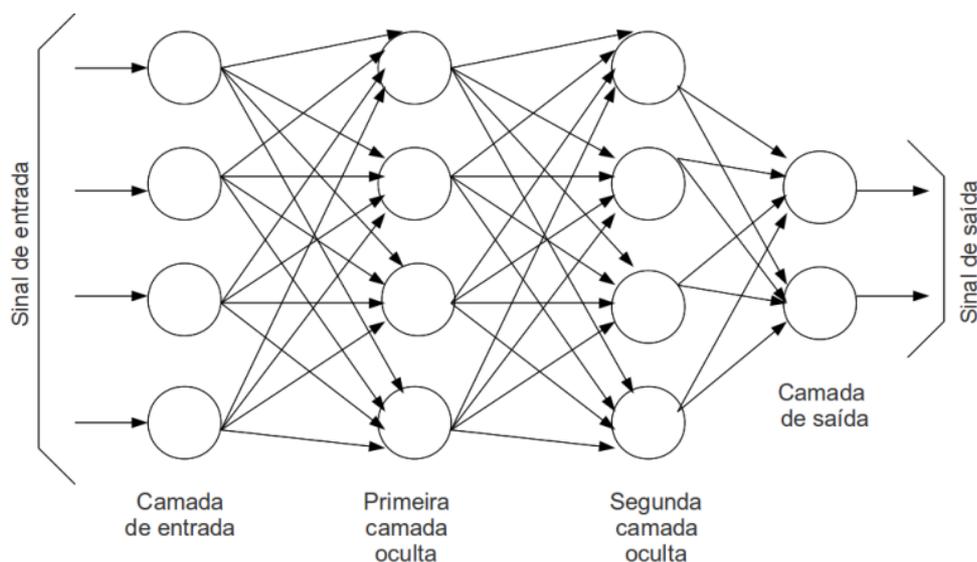
$$f(net_i) = 0, \forall net_i < 0$$

Existem vários tipos de redes neurais artificiais, onde cada uma delas é representada por uma arquitetura de processamento específica. Neste trabalho, utilizamos dois tipos de redes neurais: a Multi-Layer Perceptron (MLP) e a Reservoir Computing (RC).

### 2.2.1 Multi-Layer Perceptron (MLP)

A rede Multi-Layer Perceptron (MLP), é uma generalização da rede Perceptron (VALENÇA, 2009). A grande diferença entre elas, é que a MLP possui uma camada intermediária que possibilita solucionar problemas que não sejam linearmente separáveis. Em 1986, com o desenvolvimento do algoritmo de treinamento *backpropagation*, por Rumelhart, Hinton e Williams, mostrou-se a possibilidade de treinar de forma eficiente as redes com camadas intermediárias. Isso resultou no modelo de rede neurais artificiais mais utilizado na atualidade, as redes Multi-Layer Perceptron, treinadas com algoritmo *backpropagation* (Figura 8) (CARVALHO, 2009b).

**Figura 8 - Exemplo de uma rede Multi-Layer Perceptron (MLP) com duas camadas escondidas**



Fonte: Campos (2015).

Na MLP, as principais funções de ativação são a sigmoide logística e a tangente hiperbólica. Assim como na rede Perceptron, esta rede também possui treinamento supervisionado.

O funcionamento desta rede é bem simples, primeiro ela recebe as entradas e emitirá um sinal para cada camada através da função de ativação  $f(\text{net}_{ij})$ . Há uma propagação desse sinal por toda a rede até atingir a camada de saída onde é calculado o *feedforward*. Após esse procedimento, é possível fazer a comparação dos dados calculados com os dados gerados pela base de dados, encontrando, assim, o erro. Então esse erro é propagado no sentido inverso, para que haja o reajuste dos pesos e o treinamento da rede. Este procedimento de treinamento é um algoritmo chamado *backpropagation*.

As equações abaixo representam as entradas do sistema da rede neural e a função de ativação, respectivamente.

$$\text{net}_j = \sum_{i=1}^N w_{ij} \times x_j - \theta \quad (3)$$

$$f_{ij}(\text{net}_{ij}) = \frac{1}{1 + e^{-\text{net}_{ij}}} \quad (4)$$

Durante a etapa de treinamento, um grupo de padrões é apresentado à rede neural diversas vezes. Dessa forma, é possível determinar quantas épocas serão necessárias para concluir o treinamento. Esse número é variável e muito dependente do tipo do problema que a RNA está verificando. Determinar a quantidade de épocas e o momento da parada do treinamento é uma etapa importante, pois se ela for treinada demais (*overfitting*), irá acabar “decorando” os padrões e pode perder a capacidade de generalização. Outro problema, é se ela for treinada de menos. Neste caso, a RNA não será capaz de aprender nem de generalizar. Um dos critérios mais usados para saber quando parar o treinamento da RNA é a validação cruzada (LUCAS, 2009).

Na validação cruzada, a base de dados apresentada a rede é dividida em três partes: treinamento, validação e teste. O primeiro conjunto, treinamento, é utilizado

para ajustar os pesos conforme o algoritmo de treinamento (*backpropagation*). Após cada época, a rede é testada usando o conjunto de validação, quando há diferença entre o valor calculado e o desejado. Como o conjunto de validação não é utilizado para ajustar os pesos, ele sempre será algo novo para a rede neural, então, enquanto o erro de validação continuar diminuindo, a rede continua com o poder de generalização. O treinamento será parado, quando o erro de validação começar a aumentar, enquanto que o de treinamento continua a diminuir. Isso indica que a rede pode estar começando a decorar os padrões. Neste momento, o treinamento deve ser finalizado. Por fim, o conjunto de testes deve ser apresentado à rede já treinada para avaliar o seu desempenho (LUCAS, 2009).

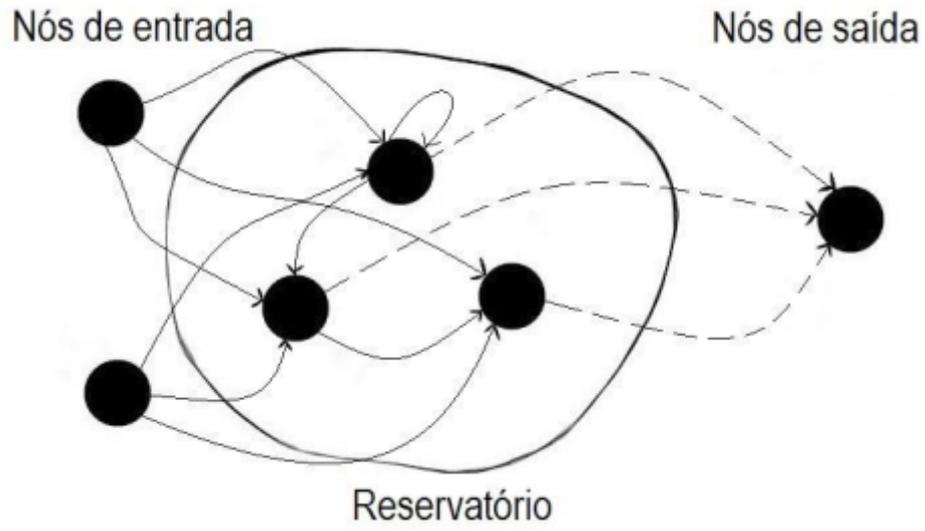
### 2.2.2 Reservoir Computing (RC)

Reservoir Computing (RC) é uma rede artificial que apresenta um reservatório dinâmico onde através de um mecanismo simples de leitura é treinado para ler o estado do reservatório e projetar a saída desejada. Sua principal vantagem é que sua formação acontece apenas na fase de leitura (SCHRAUWEN *et al.*, 2007).

A RC é uma rede neural recorrente (Figura 9) caracterizando-se possuir *feedback loop*, ou seja, uma retroalimentação. Devido a essa característica, elas são capazes de memorizar valores presentes e passados, por isso a dificuldade para treina-la é enorme (BEZERRA, 2016).

Essa rede neural é geralmente muito utilizada para resolver classificações temporais, previsões ou tarefas de regressão, onde um bom resultado pode ser alcançado, mesmo sem haver preocupação direta com os parâmetros do reservatório. No mundo real, é importante que a escala natural do tempo no reservatório seja ajustada para a mesma ordem de grandeza das aplicações temporais (MENEZES; VALENÇA, 2013).

Figura 9 - Esquema de uma rede neural recorrente Reservoir Computing (RC)



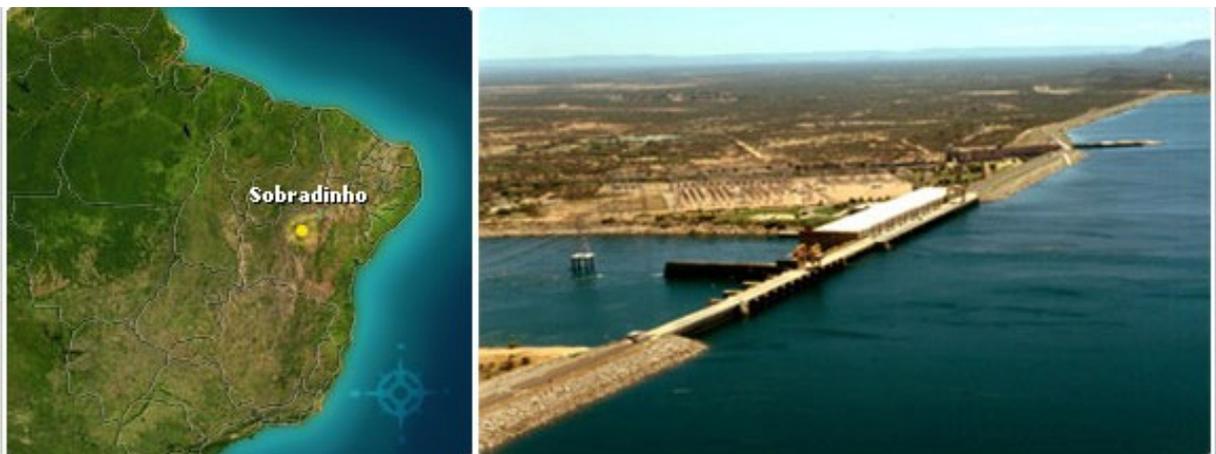
Fonte: Verstraeten (2009).

# Capítulo 3 – Metodologia

## 3.1 Base de Dados

A base de dados utilizada neste trabalho, com dados mensais de janeiro de 1931 a dezembro de 2003, foi referente à Usina Hidrelétrica de Sobradinho, que está localizada no estado da Bahia, a cerca de 40 km das cidades de Juazeiro (BA) e Petrolina (PE) (Figura 10). Ela está instalada no Rio São Francisco, principal rio da região nordestina, a cerca de 750 km de sua foz, possuindo, além da geração de energia elétrica, a função de regulador dos recursos hídricos da região. O reservatório de Sobradinho tem cerca de 320 km de extensão, com um espelho d'água de 4.214 km<sup>2</sup>, constituindo-se no maior lago artificial do mundo (CHESF, 2016).

**Figura 10 - Usina Hidrelétrica de Sobradinho, Bahia**



Fonte: CHESF (2016).

## 3.2 Pré-processamento dos dados

A primeira etapa do pré-processamento dos dados é a normalização. Todas as variáveis devem ser normalizadas, pois, geralmente, elas possuem grandes intervalos de variação. Neste caso, após a normalização, durante o processo de treinamento, os valores muito altos passam a receber a mesma importância dos

valores mais baixos. Além disso, as variáveis devem ser normalizadas de forma proporcional aos limites da função de ativação utilizada na camada de saída. Se a função de ativação for a sigmoide logística, os seus limites estarão entre [0 e 1], então os dados são normalizados entre [0,10 e 0,90] ou [0,15 e 0,85] para evitar os extremos onde a derivada da função se aproxima de zero (VALENÇA, 2005).

A transformação linear (Figura 11), descrita na equação abaixo, foi o tipo de normalização utilizado neste trabalho.

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

Onde:

- y = valor normalizado;
- Xi = valor original a ser normalizado;
- Xmin = menor valor do conjunto de dados;
- Xmax = maior valor do conjunto de dados;
- b = limite máximo desejado para a normalização (Para este trabalho utilizamos b = 0,85);
- a = limite mínimo desejado para a normalização (Para este trabalho, utilizamos a = 0,15).

**Figura 11 - Exemplo de transformação linear, tipo de normalização, utilizando a base de dados da Usina Hidrelétrica de Sobradinho, Bahia**

B2      fx = (0,85-0,15)*(A2-C2)/(D2-C2)+0,15			
A	B	C	D
Valores originais	Valores normalizados	Menor valor	Maior valor
4.676	0,342436003	506	15675,97
4.805	0,348388659	506	15675,97
6.630	0,432577164	506	15675,97
7.333	0,465045229	506	15675,97
4.467	0,332791949	506	15675,97
2.397	0,237276376	506	15675,97
1.870	0,212931207	506	15675,97
1.619	0,201344648	506	15675,97
1.448	0,193478223	506	15675,97
1.376	0,190136171	506	15675,97
1.935	0,215956404	506	15675,97
2.207	0,228493574	506	15675,97

Fonte: Elaboração do autor (2017).

Na segunda etapa, foi realizado um processo de defasagem (Tabela 2). A defasagem é uma técnica que se baseia em valores passados, a fim de determinar valores futuros (VALENÇA, 2005). Para este trabalho, os dados normalizados foram defasados em 12 entradas, ou seja, a rede neural artificial (RNA) se baseará em dados de 1 (um) ano do passado, para prever a vazão do mês seguinte.

**Tabela 2 - Exemplo de base defasada**

t-3	t-2	t-1	t
			0,342436
		0,342436	0,348389
	0,342436	0,348389	0,432577
0,342436	0,348389	0,432577	0,465045
0,348389	0,432577	0,465045	0,332792
0,432577	0,465045	0,332792	0,237276
0,465045	0,332792	0,237276	0,212931
0,332792	0,237276	0,212931	0,201345
0,237276	0,212931	0,201345	0,193478
0,212931	0,201345	0,193478	0,190136
0,201345	0,193478	0,190136	0,215956
0,193478	0,190136	0,215956	0,228494
0,190136	0,215956	0,228494	
0,215956	0,228494		
0,228494			

Legenda: Rede neural artificial (RNA) com três neurônios de entrada (t-3, t-2 e t-1) e um neurônio de saída (t).

Fonte: Elaboração do autor (2017).

Após o processo de defasagem, iniciou-se o processo de seleção das variáveis relevantes, pois nem todos os dados são fortemente relacionados, então é preciso selecionar aqueles que mais se relacionam com o que se espera na saída. Neste caso, foi feita uma correlação de cada uma das 12 colunas de entrada em relação à coluna de saída da RNA. Foram consideradas como boas entradas, as colunas que obtiveram uma correlação maior que 0,3, sendo assim, utilizadas para este modelo de previsão (Apêndice A).

### 3.3 Entrada das Redes Neurais Artificiais (RNAs)

Com as variáveis de entrada selecionadas, foram preparados três modelos para serem testados. O primeiro foi realizado utilizando a base de dados do ano inteiro (janeiro a dezembro), o segundo utilizou apenas os dados do período chuvoso (novembro a abril) e o terceiro, os dados do período seco (maio a outubro). Cada um dos modelos foi testado com e sem a presença da sazonalidade.

A sazonalidade foi representada utilizando as funções seno e cosseno, descritas nas equações abaixo, como duas novas entradas do sistema (Figura 12).

$$\sin\left(2\pi \times \frac{N}{T}\right) \quad (5)$$

$$\cos\left(2\pi \times \frac{N}{T}\right) \quad (6)$$

Em que:

- N = representa o mês e varia de 1 a 12;
- T = representa o período (Como trabalhamos com séries mensais, o valor desta variável sempre foi 12).

**Figura 12 - Exemplo da sazonalidade, utilizando as funções seno e cosseno**

ANO	SENO	COSENO	1	2	3	4	5	OUT
jan/1932	0.5	0.866	0.342436031	0.348388688	0.432577206	0.215956414	0.228493586	0.237276389
fev/1932	0.866	0.5	0.348388688	0.432577206	0.465045276	0.228493586	0.312895066	0.212931216
mar/1932	1	0	0.432577206	0.465045276	0.332791977	0.312895066	0.335741536	0.201344656
abr/1932	0.866	-0.5	0.465045276	0.332791977	0.237276389	0.335741536	0.274948487	0.193478229
mai/1932	0.5	-0.866	0.332791977	0.237276389	0.212931216	0.274948487	0.217834466	0.190136177
jun/1932	0	-1	0.237276389	0.212931216	0.201344656	0.217834466	0.192400201	0.215956414
jul/1932	-0.5	-0.866	0.212931216	0.201344656	0.193478229	0.192400201	0.186258262	0.228493586
ago/1932	-0.866	-0.5	0.201344656	0.193478229	0.190136177	0.186258262	0.18089402	0.312895066
set/1932	-1	0	0.193478229	0.190136177	0.215956414	0.18089402	0.172570274	0.335741536
out/1932	-0.866	0.5	0.190136177	0.215956414	0.228493586	0.172570274	0.168395996	0.274948487
nov/1932	-0.5	0.866	0.215956414	0.228493586	0.312895066	0.168395996	0.171971893	0.217834466
dez/1932	0	1	0.228493586	0.312895066	0.335741536	0.171971893	0.223857771	0.192400201

Fonte: Elaboração do autor (2017).

Dito isso, como resultados deste trabalho, haverá seis tabelas, representando os seguintes casos:

- Dados do ano inteiro considerando a sazonalidade;

- Dados do ano inteiro desconsiderando a sazonalidade;
- Dados do período chuvoso (nov - abr) considerando a sazonalidade;
- Dados do período chuvoso (nov – abr) desconsiderando a sazonalidade;
- Dados do período seco (mai – out) considerando a sazonalidade;
- Dados do período seco (mai – out) desconsiderando a sazonalidade.

Para cada tabela, considerou-se 50% dos dados para o treinamento da RNA, 25% para a validação cruzada e 25% destinados ao teste. Porém, antes desses dados serem utilizados como entrada da rede Reservoir Computing (RC), cada um deles foi dividido em seis arquivos, a saber: “inputs.csv” e “outputs.csv” para treino, “crossinputs.csv” e “crossoutputs.csv” para validação cruzada e “testinputs.csv” e “testoutputs.csv” destinados ao teste. Os nomes dos arquivos seguem um padrão requisitado pelo desenvolvimento da rede neural (FIGUEIREDO, 2014).

### 3.4 Arquitetura das redes

Após a preparação dos dados de entrada, é preciso definir a arquitetura que será utilizada pelas redes neurais artificiais Multi-layer Perception (MLP) e Reservoir Computing (RC). O número de entradas depende da base de dados e foi definido através do cálculo da correlação, como visto anteriormente. Já a saída representa o horizonte de previsão que queremos alcançar, como no nosso caso é um mês a frente, a saída da nossa rede, sempre será 1 (um).

A correlação aplicada na base de dados da Usina de Sobradinho selecionou cinco das 12 entradas possíveis. As sete restantes foram eliminadas devido aos valores de suas correlações (menor que 0.3).

Os principais parâmetros das redes neurais utilizadas neste trabalho, bem como os valores adotados são apresentados no quadro 1 e 2:

**Quadro 1 - Principais parâmetros utilizados e seus valores para a Rede Neural Artificial Multi-layer Perceptron (MLP)**

PARÂMETROS	REDE MLP
Número de neurônios na camada de entrada	5
Número de neurônios na camada escondida	6
Número de neurônios na camada de saída	1
Algoritmo de treinamento	<i>backpropagation</i>
Forma de inicialização dos pesos da rede	Aleatória
Função de ativação	Sigmoide Logística
Número máximo de ciclos	600
Número de experimentos	30
Taxa de aprendizado	0,8
Momentum	0,2

Fonte: Elaboração do autor (2017).

**Quadro 2 - Principais parâmetros utilizados e seus valores para a Rede Neural Artificial Reservoir Computing (RC)**

PARÂMETROS	REDE RC
Número de neurônios na camada de entrada	5
Número de neurônios na camada de saída	1
Quantidade de neurônios no reservatório	25
Forma de inicialização dos pesos da rede	Aleatória
Taxa de conectividade	0,3 – 0,4
Quantidade de ciclos no Warm up	10
Função de ativação no Reservatório	Sigmoide Logística
Função de ativação na camada de saída	Linear
Taxa de aprendizado	0,8
Critério de parada de treinamento	<i>cross validation</i>

Fonte: Elaboração do autor (2017).

### 3.5 Testes estatísticos

Cada grupo da base de dados foi treinado 30 vezes nas redes neurais MLP e RC. Para cada execução, foi obtido um total de 30 erros percentuais médios absolutos (EPMAs) , que foram utilizados no teste estatístico de Wilcoxon.

O teste de Wilcoxon é um teste não paramétrico, ou seja, não faz nenhuma hipótese em relação à distribuição das probabilidades dos dados. Este teste tem por objetivo verificar se as amostras apresentadas são estatisticamente iguais ou não.

Os testes foram realizados utilizando o Software R (R DEVELOPMENT CORE TEAM, 2007), considerando um nível de significância igual a 5% (*p-value*). Se o *p-value* obtiver um valor maior que 5%, significa que as duas amostras são estatisticamente iguais e que não há diferença usar uma ou outra, porém se o valor for menor que 5%, significa que as amostras são diferentes entre si. Nesse caso, aplica-se a mediana nas duas amostras e a que houver o menor valor será considerada a melhor rede entre as comparadas (VALENÇA, 2005).

Primeiramente, o teste de Wilcoxon foi aplicado aos pares 'nov – abr com sazonalidade' e 'nov - abr sem sazonalidade', e depois aplicado aos pares 'mai – out com sazonalidade' e 'mai - out sem sazonalidade'. Com os resultados em mãos, foi calculada a mediana para cada par, e aquele que obteve um melhor resultado foi testado com o melhor resultado do 'par de dados completos com e sem sazonalidade'. Este procedimento foi realizado tanto para a rede MLP, quanto para a rede RC. Posteriormente, utilizando o próprio teste de Wilcoxon, foi averiguado qual é a melhor rede neural, comparando os seus melhores resultados.

## Capítulo 4 – Resultados

O objetivo deste capítulo é mostrar os resultados alcançados aplicando os experimentos com as redes MLP e RC, utilizando dados de vazão da Usina Hidrelétrica de Sobradinho para prevê sua vazão mensal. Esses experimentos, que se dividem em três, tentam mostrar qual o melhor experimento para cada rede neural. O primeiro compara um experimento com apenas dados do período seco, com e sem sazonalidade. O segundo realiza esta mesma comparação para o período chuvoso. O terceiro verifica a melhor rede para a utilização dos dados do ano inteiro, com ou sem a sazonalidade. Por fim, tendo o melhor modelo para o ano completo e o melhor para o período seco e chuvoso, faz-se a comparação entre eles e define a melhor solução. Ainda, com a melhor solução para cada rede neural (MLP e RC), faz-se a comparação entre elas.

### 4.1 Experimentos com Multi-Layer Perceptron (MLP)

Para os experimentos utilizando o algoritmo de MLP, foi-se testado três casos, em que para cada um foi realizado um experimento com e sem sazonalidade. Desta forma, obtendo qual modelo tem melhor desempenho para esta rede.

Foi utilizada a configuração considerada ótima para esta rede, descrita por Valença (2009), onde há a utilização de seis neurônios na camada intermediária.

#### 4.1.1 Caso período seco

Para previsão de vazão em um horizonte de um mês a frente, considerando apenas dados do período seco, que vai de Maio a Outubro, o modelo que considera a sazonalidade obteve resultado superior ao sem sazonalidade, uma vez que o *p-value* foi inferior a 5%. Neste caso, observa-se a mediana de ambos os experimentos e aquele que obteve uma menor mediana é considerado o modelo mais eficiente (Tabela 3).

**Tabela 3 - Comparação entre o período seco com e sem sazonalidade para a rede MLP**

MODELO	WILCOXON (p-VALUE)	p-VALUE > 5%?	MEDIANA DOS EPMAS	MELHOR MODELO
Mai-Out com sazonalidade	1,55 x 10 <sup>-14</sup>	NÃO	23,61	<b>Melhor</b>
Mai-Out sem sazonalidade			39,25	

### 4.1.2 Modelo para o período chuvoso

Para previsão de vazão em um horizonte de um mês a frente, considerando apenas dados do período chuvoso, que vai de Novembro a Abril, o modelo que considera a sazonalidade obteve resultado superior ao sem sazonalidade, uma vez que o *p-value* foi inferior a 5%. Neste caso, observa-se a mediana de ambos os experimentos e aquele que obteve menor uma mediana é considerado o modelo mais eficiente (Tabela 4).

**Tabela 4 - Comparação entre o período chuvoso com e sem sazonalidade para a rede MLP**

MODELO	WILCOXON (p-VALUE)	p-VALUE > 5%?	MEDIANA DOS EPMAS	MELHOR MODELO
Nov-Abr com sazonalidade	5,98 x 10 <sup>-13</sup>	NÃO	13,23	<b>Melhor</b>
Nov-Abr sem sazonalidade			39,25	

### 4.1.3 Modelo para o ano completo

Para previsão de vazão em um horizonte de um mês a frente, considerando dados do ano inteiro, o modelo com e sem sazonalidade são considerados estatisticamente iguais, devido ao *p-value* ser maior que 5%. Então, neste caso, não

faz diferença considerar ou desconsiderar a sazonalidade. Como critério de escolha, foi-se definido que seria escolhido o que possuir um menor valor de mediana. Logo, o experimento com sazonalidade foi selecionado (Tabela 5).

**Tabela 5 - Comparação para o ano completo com e sem sazonalidade para a rede MLP**

MODELO	WILCOXON (p-VALUE)	p-VALUE > 5%?	MEDIANA DOS EPMAS	MELHOR MODELO
Jan-Dez com sazonalidade	0,224	SIM	32,20	<b>Escolhido</b>
Jan-Dez sem sazonalidade			37,75	

#### **4.1.4 Comparação do melhor modelo do ano inteiro com os melhores modelos parciais**

Os testes indicaram que, para o modelo do período seco e do período chuvoso, a melhor opção é levar em consideração a sazonalidade. Porém, é preciso comparar se é mais vantagoso ter um modelo genérico para toda e qualquer época do ano ou ter um modelo específico para períodos chuvosos e/ou secos. Para isso, foram analisados os 30 erros do período seco com sazonalidade e os 30 erros do período chuvoso também com sazonalidade e tirou-se a média aritmética, erro por erro, obtendo o erro médio anual. Logo após, comparou-se o desempenho desse modelo com o modelo genérico com sazonalidade para verificar o mais eficaz. Após a aplicação do teste de Wilcoxon, verificou-se um *p-value* menor que 5%, significando que os dois modelos são estatisticamente diferentes e como critério de avaliação a mediana foi utilizada. O modelo que apresentou uma menor mediana foi considerado mais eficiente. O experimento com dois modelos especialistas teve melhores resultados (Tabela 6).

**Tabela 6 - Comparação entre o melhor modelo do ano inteiro com os melhores modelos parciais para a rede MLP**

MODELO	WILCOXON (p-VALUE)	p-VALUE > 5%?	MEDIANA DOS EPMA <sub>s</sub>	MELHOR MODELO
Jan-Dez com sazonalidade	1,26 x 10 <sup>-07</sup>	NÃO	32,20	
Mai-Out com sazonalidade + Nov-Abr com sazonalidade (Erro médio)			18,12	<b>Melhor</b>

## 4.2 Experimentos com Reservoir Computing (RC)

Assim como na rede MLP, para esse trabalho, o algoritmo RC foi testado nos mesmos três modelos. Para cada modelo, foi realizado um experimento com a técnica da sazonalidade e sem essa técnica. Desta forma, obtendo um modelo com o melhor desempenho para algoritmo da RC.

### 4.2.1 Modelo para o período seco

Para previsão de vazão em um horizonte de um mês a frente, considerando apenas dados do período seco, que vai de Maio a Outubro, o modelo que considera a sazonalidade obteve resultado superior ao sem sazonalidade, uma vez que o *p-value* foi inferior a 5%. Neste caso, observa-se a mediana de ambos os experimentos e aquele que obteve uma menor mediana é considerado o modelo mais eficiente (Tabela 7).

**Tabela 7 - Comparação entre o período seco com e sem sazonalidade para a rede RC**

MODELO	WILCOXON (p-VALUE)	p-VALUE > 5%?	MEDIANA DOS EPMA <sub>s</sub>	MELHOR MODELO
Mai-Out com sazonalidade	2,20 x 10 <sup>-16</sup>	NÃO	17,09	<b>Melhor</b>
Mai-Out sem			23,75	

sazonalidade				
--------------	--	--	--	--

### 4.2.2 Modelo para o período chuvoso

Para previsão de vazão em um horizonte de um mês a frente, considerando apenas dados do período chuvoso, que vai de Novembro a Abril, o modelo que considera a sazonalidade obteve resultado superior ao sem sazonalidade, uma vez que o p-value foi inferior a 5%. Neste caso, observa-se a mediana de ambos os experimentos e aquele que obteve uma menor mediana é considerado o modelo mais eficiente (Tabela 8).

**Tabela 8 - Comparação entre o período chuvoso com e sem sazonalidade para a rede RC**

MODELO	WILCOXON (p-VALUE)	P-VALUE>5%?	MEDIANA DOS EPMAs	MELHOR MODELO
Nov-Abr com sazonalidade	5,98 x 10 <sup>-13</sup>	NÃO	8,47	<b>Melhor</b>
Nov-Abr sem sazonalidade			9,61	

### 4.2.3 Modelo para o ano completo

Para previsão de vazão em um horizonte de um mês a frente, considerando dados do ano inteiro, o modelo que considera a sazonalidade obteve resultado

superior ao sem sazonalidade, uma vez que o p-value foi inferior a 5%. Neste caso, observa-se a mediana de ambos os experimentos e aquele que obteve uma menor mediana é considerado o modelo mais eficiente (Tabela 9).

**Tabela 9 - Comparação para o ano completo com e sem sazonalidade para a rede RC**

MODELO	WILCOXON (p-VALUE)	p-VALUE > 5%?	MEDIANA DOS EPMAs	MELHOR MODELO
Jan-Dez com sazonalidade	2,20 x 10 <sup>-16</sup>	NÃO	16,45	<b>Melhor</b>
Jan-Dez sem sazonalidade			26,88	

#### 4.2.4 Comparação do melhor modelo do ano inteiro com os melhores modelos parciais

Os testes indicaram que, para o modelo do período seco e do período chuvoso, a melhor opção é levar em consideração a sazonalidade. Porém, é preciso comparar se é mais vantajoso ter um modelo genérico para toda e qualquer época do ano ou ter um modelo específico para períodos chuvosos e/ou secos.

Para isso, foram analisados os 30 erros do período seco com sazonalidade e os 30 erros do período chuvoso também com sazonalidade e tirou-se a média aritmética, erro por erro, obtendo o erro médio anual. Logo após, comparou-se o desempenho desse modelo com o modelo genérico com sazonalidade para verificar o mais eficaz. Após a aplicação do teste de Wilcoxon, verificou-se um p-value menor que 5%, significando que os dois modelos são estatisticamente diferentes e como critério de avaliação a mediana foi utilizada. O modelo que apresentou uma menor mediana foi considerado mais eficiente. O experimento com dois modelos especialistas teve melhores resultados (Tabela 10).

**Tabela 10 - Comparação do melhor modelo do ano inteiro com os melhores modelos parciais**

MODELO	WILCOXON	p-VALUE > 5%?	MEDIANA	MELHOR
--------	----------	---------------	---------	--------

	(p-VALUE)		DOS EPMA <sub>s</sub>	MODELO
Jan-Dez com sazonalidade	2,20 x 10 <sup>-16</sup>	NÃO	16,45	
Mai-Out com sazonalidade + Nov-Abr com sazonalidade (Erro médio)			12,73	<b>Melhor</b>

### 4.3 Comparativo dos resultados: Rede MLP X RC

Como último resultado, foi comparado o melhor modelo da rede MLP com o melhor modelo da rede RC. Ambas as redes obtiveram como melhor resultado a ideia de ter dois modelos, um para cada período considerado (chuvoso e seco), ambos com sazonalidade. Após o teste de Wilcoxon ter sido aplicado aos dois modelos, foi identificado o p-value menor que 5%, então através da mediana, chegamos ao resultado que o modelo da rede RC é mais eficiente que o da rede MLP para a previsão de vazão com um horizonte de um mês (Tabela 11).

**Tabela 11 - Comparação do melhor modelo da rede MLP com o melhor modelo da rede RC**

RED E	MODELO	WILCOXON (p-VALUE)	p-VALUE > 5%?	MEDIANA DOS EPMA <sub>s</sub>	MELHOR MODELO
<b>MLP</b>	Mai-Out com sazonalidade + Nov-Abr com sazonalidade (Erro médio)	2,20 x 10 <sup>-16</sup>	NÃO	18,12	
<b>RC</b>	Mai-Out com sazonalidade + Nov-Abr com sazonalidade (Erro médio)			12,73	<b>Melhor</b>

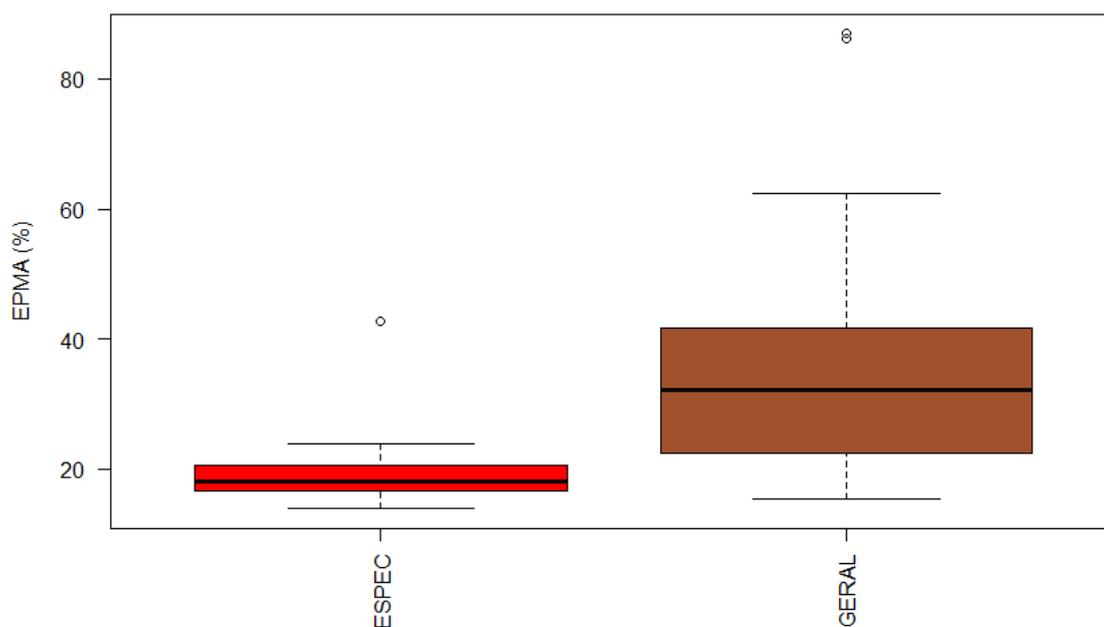
## 4.4 Representação por Box Plot

Para facilitar a compreensão dos resultados, foi feita a representação dos resultados em *Box Plots*.

### 4.4.1 Resultado para MLP

Para a MLP, observa-se na Figura 13 que o sistema especialista obteve um menor EPMA.

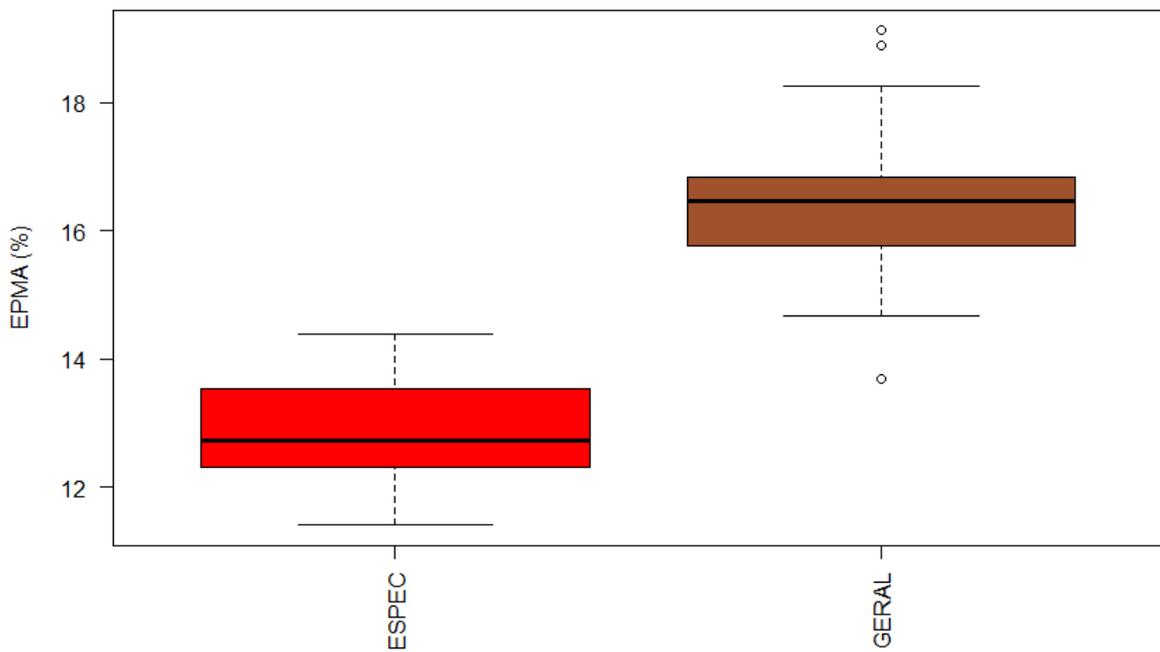
Figura 13 – *Box Plot* comparando melhores resultados de MLP



### 4.4.2 Resultado para RC

Para a RC, observa-se na Figura 14 que o sistema especialista também obteve um menor EPMA.

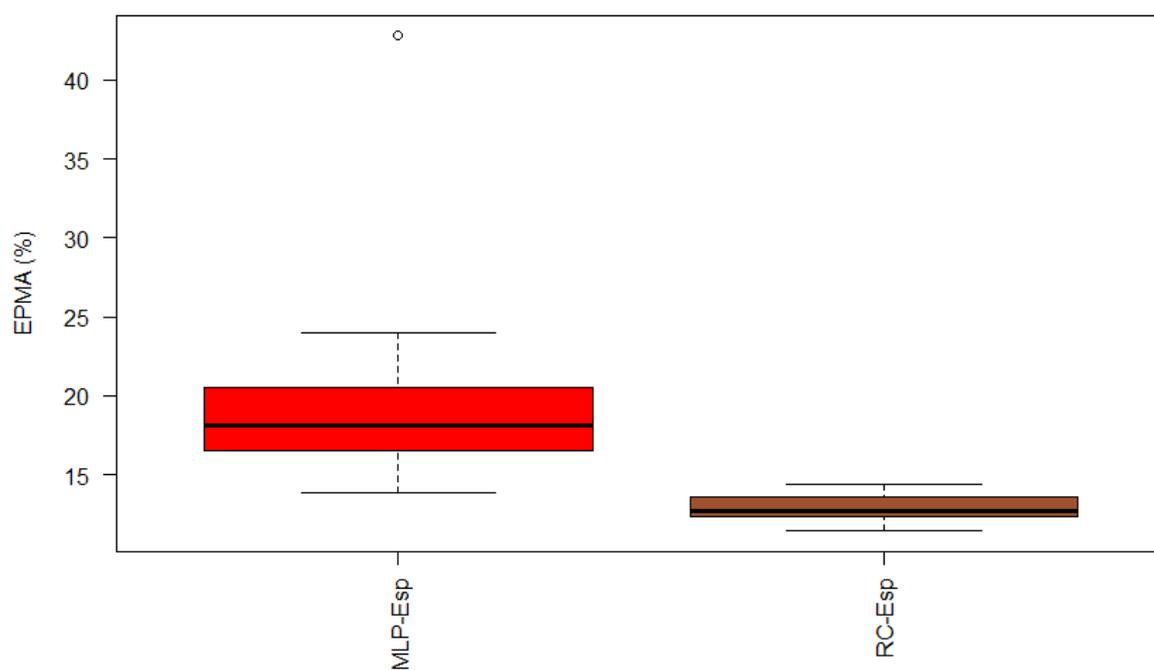
Figura 14 - *Box Plot* comparando melhores resultados de RC



### 4.4.2 Melhor resultado MLPxRC

Como foi visto na sessão anterior, para saber qual das redes obteve melhor resultado para esse cenário, foi comparado o melhor resultado da MLP com o melhor resultado da RC. Observa-se na Figura 15 que a rede RC obteve um EMPA mais baixo, comparado ao MLP.

Figura 15 – Box Plot comparando a rede MLP com a rede RC



## Capítulo 5 – Considerações Finais

A previsão de vazão mensal das bacias hidrográficas é realizada frequentemente para o planejamento energético do país, como também para alerta e prevenção de desastres, como por exemplo, as enchentes. Logo, ao longo dos anos, há uma crescente necessidade por um aumento na precisão dessa previsão. Este trabalho teve como objetivo principal, fazer uma análise comparativa das redes neurais artificiais MLP e RC para prevê a vazão de um mês a frente, considerando 12 meses de dados de vazão passados.

Os resultados mostraram que, nesse estudo de caso, é melhor ter dois modelos, um especialista em períodos chuvosos e outro especialista em períodos secos, do que um único modelo genérico para prevê a vazão durante todo o ano. Além disso, as previsões considerando a sazonalidade foram, por unanimidade, melhor que os modelos que não estavam a considerando como entrada. Por fim, os resultados ainda mostraram que a rede Reservoir Computing (RC) é mais precisa que a rede Multi-Layer Perceptron (MLP) para este estudo de caso.

Como sugestões para trabalhos futuros, pretende-se realizar outros testes estatísticos, como por exemplo, Shapiro-Wilk, Teste F, e T de Student, bem como testar a utilização de outro algoritmo de busca, para definir a correlação dos dados e determinar as variáveis de entrada das redes. Ainda, pretende-se utilizar outros processos, como a Otimização por Enxame de Partículas (PSO) (técnica bastante utilizada), testar outras funções de ativação, experimentar mudanças nos parâmetros das redes MLP e RC e testar se em outras bases de dados, como por exemplo, na Usina Hidrelétrica de Três Marias, a rede RC obtém bons resultados.

# Referências

ANEEL – Agência Nacional de Energia Elétrica. **Atlas de energia elétrica do Brasil**. 3 ed. Brasília: Aneel, 2008.

BATISTA, A. L. F. **Análises e Previsões de vazões do Rio Grande utilizando modelos de Box & Jenkins e redes neurais artificiais**. Computer on the Beach: Ituiutaba, Minas Gerais, 2011.

BEZERRA, Sabrina Guimarães Tavares de Andrade. **Reservoir computing com Hierarquia para Previsão de Vazão médias Diárias**. 2016. 73 f. Dissertação (Mestrado em Engenharia da Computação), Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, PE.

BRASIL – Ministério do Meio Ambiente. **Água**. 2017. Disponível em: <<http://www.mma.gov.br/agua>>. Acesso em: 13 jun. 2017.

BRASIL – Ministério de Minas e Energia. **Anuário Estatístico de Energia Elétrica 2016**: ano base 2015. Brasília: Epe, 2016.

BRASIL. Lei nº. 9.433, de 8 de janeiro de 1997. Institui a Política Nacional de Recursos Hídricos, cria o Sistema Nacional de Gerenciamento de Recursos Hídricos, regulamenta o inciso XIX do art. 21 da Constituição Federal, e altera o art. 1º da Lei nº. 8.001, de 13 de março de 1990, que modificou a Lei nº. 7.990, de 28 de dezembro de 1989. **Diário Oficial da República Federativa do Brasil**, Brasil, 09 jan. 1997.

CAMPOS, Paulemir G. **Redes Neurais Artificiais**. 2015. Disponível em: <<http://slideplayer.com.br/slide/8923411/>>. Acesso em: 24 jun. 2017.

CARVALHO, André Ponce de Leon F. de. **Redes Neurais Artificiais**. 2009a. Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural/>>. Acesso em: 20 jun. 2017.

CARVALHO, André Ponce de Leon F. de. **Perceptron Multi-Camadas**. 2009b. Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural/MLP.htm>>. Acesso em: 20 jun. 2017.

CASTRO, F. C. C. de; CASTRO, M. C. F. de. **Multilayer Perceptrons**. 2011. Disponível em: <[http://www.feng.pucrs.br/~decastro/pdf/RNA\\_C4.pdf](http://www.feng.pucrs.br/~decastro/pdf/RNA_C4.pdf)>. Acesso em: 20 jun. 2017.

CHESF - Companhia Hidrelétrica do São Francisco. **Descrição do aproveitamento de Sobradinho**. 2016. Disponível em:

<<https://www.chesf.gov.br/SistemaChesf/Pages/SistemaGeracao/Sobradinho.aspx>>. Acesso em: 13 jun. 2017.

DUARTE, Michelle. **Sinapses**. Disponível em: <<https://www.todamateria.com.br/sinapses/>>. Acesso em: 20 jun. 2017.

ECYCLE. **O que é energia hidráulica? Entenda como as hidrelétricas transformam a energia da água em eletricidade**. 2013. Disponível em: <<http://www.ecycle.com.br/component/content/article/69-energia/2906--o-que-e-energia-hidraulica-usina-hidreletricas-agua-eletrica-emissao-libera-metano-dioxido-de-carbono-barragem-reservatorio.html>>. Acesso em: 13 jun. 2017.

FIGUEIREDO, Bruno Monteiro. **Estudo comparativo entre técnicas de sazonalidade para a previsão de vazões utilizando redes neurais**. 2014. 68 f. Monografia (Bacharel em Engenharia de Computação), Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, PE.

GUILHERME, Antônio. **Vazão**. 2017. Disponível em: <<http://www.antonioguilherme.web.br.com/Arquivos/vazao.php>>. Acesso em: 13 jun. 2017.

LOPES, Sônia Godoy Bueno Carvalho. **Bio**: Volume Único. 2 ed. São Paulo: Saraiva, 2008.

LUCAS, Tarcísio Daniel Pontes. **Utilizando informações de tendência Fuzzy para previsão de vazões com Redes Neurais**. 2009. 64 f. Monografia (Bacharel em Engenharia de Computação), Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, PE.

MENEZES, Breno; VALENÇA, Mêuser. **Construindo intervalos de confiança na previsão da potência do vento utilizando Reservoir Computing**. In: XI Congresso Brasileiro de Inteligência Computacional, CBIC, 2013.

PAZ, A. R.; BUENO, E. O.; TUCCI, C. E. M. Análise de metodologias de previsão de vazões em tempo real. Estudo de casos: bacia do rio Doce (MG) e do rio Uruguai (RS). In: **II Simpósio de Recursos Hídricos do Centro-Oeste**, 2002, Campo Grande.

R DEVELOPMENT CORE TEAM. **R - A language and environment for statistical computing**. 2007. Vienna, Austria: R Foundation for Statistical Computing. Disponível em: <<https://www.r-project.org/>>. Acesso em: 13 jun. 2017.

RNA.BLOGSPOT. **O primeiro modelo de um neurônio criado por McCulloch e Pitts**. 2010. Disponível em: <<http://redesneuraisartificiais.blogspot.com.br/2010/10/o-primeiro-modelo-de-um-neuronio-criado.html>>. Acesso em: 20 jun. 2017.

SCHRAUWEN, B.; VERSTRAETEN, D.; CAMPENHOUT, J. V. An overview of reservoir computing: theory, applications, and implementations. In: **Proceedings of the European Symposium on Artificial Neural Networks**, ESANN, 2007.

SOGAB. **Neurônio**. 2017. Disponível em:  
<<http://www.sogab.com.br/anatomia/neuronio.jpg>>. Acesso em: 20 jun. 2017.

TAVAREZ, P. **Maiores usinas hidrelétricas do Brasil**. 2015. Disponível em:  
<<https://geografiacriticanaaveia.wordpress.com/2015/10/20/a-maiores-usinas-hidreletricas-do-brasil/>>. Acesso em: 13 jun. 2017.

VALENÇA, Mêuser Jorge Silva. **Fundamento das Redes Neurais**. Olinda: Livro Rápido, 2009.

VALENÇA, Mêuser Jorge Silva. **Aplicando Redes Neurais**. Olinda: Livro Rápido, 2005.

VERSTRAETEN, David. **Reservoir Computing**: rekenen met dynamische systemen. 2009. Disponível em:  
<[http://organic.elis.ugent.be/sites/organic.elis.ugent.be/files/dvrstrae\\_organic.pdf](http://organic.elis.ugent.be/sites/organic.elis.ugent.be/files/dvrstrae_organic.pdf)>. Acesso em: 24 jun. 2017.

ZAMBIASI, Saulo Popov. **O Neurônio Artificial**. 2011. 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: 20 jun. 2017.

# Apêndice

Apêndice A – Correlação das 12 colunas de entrada em relação à coluna de saída da Rede Neural Artificial. As correlações marcadas em azul correspondem aquelas que obtiveram um valor maior que 0,3.

jan/2003	0,33152972	0,346341881	0,288892846	0,229736491	0,17620968	0,167396214	0,165919612	0,156367845	0,15	0,157336865	0,169841835	0,212986291	0,316671416
fev/2003	0,346341881	0,288892846	0,229736491	0,17620968	0,167396214	0,165919612	0,156367845	0,15	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099
mar/2003	0,288892846	0,229736491	0,17620968	0,167396214	0,165919612	0,156367845	0,15	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824
abr/2003	0,229736491	0,17620968	0,167396214	0,165919612	0,156367845	0,15	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698
mai/2003	0,17620968	0,167396214	0,165919612	0,156367845	0,15	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698	0,190052821
jun/2003	0,167396214	0,165919612	0,156367845	0,15	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698	0,190052821	0,172010594
jul/2003	0,165919612	0,156367845	0,15	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698	0,190052821	0,172010594	0,16771922
ago/2003	0,156367845	0,15	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698	0,190052821	0,172010594	0,16771922	0,161120656
set/2003	0,15	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698	0,190052821	0,172010594	0,16771922	0,161120656	0,158029022
out/2003	0,157336865	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698	0,190052821	0,172010594	0,16771922	0,161120656	0,158029022	0,15
nov/2003	0,169841835	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698	0,190052821	0,172010594	0,16771922	0,161120656	0,158029022	0,15	0,165550462
dez/2003	0,212986291	0,316671416	0,329084099	0,252946824	0,246809698	0,190052821	0,172010594	0,16771922	0,161120656	0,158029022	0,15	0,165550462	0,200988902
<b>Correlação</b>	<b>0,655761942</b>	<b>0,56544918</b>	<b>0,322296858</b>	0,046475678	-0,207683174	-0,385552096	-0,443148768	-0,381837447	-0,202666572	0,076808452	<b>0,417358684</b>	<b>0,758487064</b>	1

Fonte: Elaboração do autor (2017).





