



# UTILIZAÇÃO DE REDES NEURAIS NO AUXÍLIO DA PREVISÃO DE GERAÇÃO SOLAR

**Trabalho de Conclusão de Curso**

**Engenharia da Computação**

**Caio Vinícius de Souza Silva**  
**Orientador: Prof. Dr. Mêuser Jorge Silva Valença**



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

**CAIO VINÍCIUS DE SOUZA SILVA**

**UTILIZAÇÃO DE REDES NEURAIS NO  
AUXÍLIO DA PREVISÃO DE GERAÇÃO  
SOLAR**

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

**Recife, dezembro de 2016.**

## MONOGRAFIA DE FINAL DE CURSO

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

No dia 22 de 12 de 2016, às 8:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente **CAIO VINICIUS DE SOUZA SILVA**, orientado pelo professor **Mêuser Jorge Silva Valença**, sob título **Utilização de Redes Neurais no Auxílio da Previsão de Geração Solar**, a banca composta pelos professores:

**Mêuser Jorge Silva Valença**

**Sérgio Mario Lins Galdino**

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: 10,0 ( DEZ )

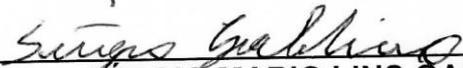
\*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

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

---

  
**MÊUSER JORGE SILVA VALENÇA**

---

  
**SÉRGIO MARIO LINS GALDINO**

*Dedico este trabalho à minha mãe Lúcia Souza, a minha avó Laura Souza e àqueles que me ajudaram nessa jornada de conhecimento.*

# Agradecimentos

Agradeço, primeiramente e antes de tudo, à Deus, que me concede todos os dias, uma nova oportunidade de viver, o ar pelo qual respiramos para realizar todas as nossas atividades e o conhecimento necessário para evoluir. Agradeço à Ele pela minha família, pelas oportunidades, pelas respostas positivas, pelas negativas, enfim, por tudo, pois o agradecimento total ultrapassaria as páginas desse trabalho. Bem, sem Ele, não estaria escrevendo este trabalho.

Agradeço, em segundo lugar, pela minha família, em especial, à minha mãe Lúcia Laurinda de Souza e à minha avó Laura Laurinda de Souza, pelo empenho em minha criação, pela motivação nas histórias de vida, pelo conhecimento e pelas crenças passadas, resumindo, por todo o suporte que elas me fornecem todos os dias, enfim, sem elas eu não seria ninguém.

Para mim, a persistência é o impossível saindo do corpo, e isso se dá de maneira constante na minha vida. Parabenizo a mim mesmo, por suportar longos horários sem descansar, para realizar projetos ou estudar.

Tenho muito a agradecer aos meus colegas da Universidade, sem os quais a vida acadêmica não seria tão bem aproveitada.

Por fim, agradeço a todos os professores da Universidade, sem os quais não existiria o conhecimento adquirido durante todos esses anos. Em particular, ao Prof. Dr. Mêuser Jorge Silva Valença, por me orientar nesse trabalho, pela motivação, amizade e inspiração.

# Resumo

O desenvolvimento industrial e tecnológico mundial está em constante crescimento, e é necessário uma maior produção de energia elétrica. Atualmente, a principal fonte de energia elétrica no Brasil são as usinas hidrelétricas, que corresponde a 90% da produção de energia no país. Com isso, a população paga um valor alto pela energia consumida, mas é o meio ambiente que sofre com os gases provenientes da combustão de combustíveis não renováveis, quando a água está escassa. Para contornar essa situação, o Brasil possui, como uma das fontes alternativas de energia, estações solares. E são nessas fontes alternativas que o Brasil precisa investir. Pesquisas para essas novas fontes precisam ser exploradas, pois para o melhor aproveitamento dessa energia limpa, é preciso dos dados fornecidos por estudos especializados. A energia solar foi a fonte que mais recebeu investimentos em 2012. Ela representa 26% da energia renovável no planeta. Por ano, as estações poupam 53 milhões de toneladas de gás carbônico (CO<sub>2</sub>). O uso de Redes Neurais (RNs), para prever variáveis meteorológicas, pode obter um melhor aproveitamento dessa fonte de energia. Sendo assim, este trabalho tem como objetivo utilizar uma RN para realizar a previsão de radiação solar, na estação meteorológica de superfície automática do Instituto Nacional de Meteorologia (INMET), em Petrolina, Pernambuco. Será utilizada a Rede Neural conhecida como *Reservoir Computing* (RC) para fazer a previsão da radiação futura a partir de valores anteriores de outras variáveis. Por fim, os resultados obtidos serão comparados para analisar qual configuração de rede apresentou o melhor desempenho.

**Palavras-Chave:** Previsão de radiação solar, RC, energia solar

# Abstract

World's industrial and technological development is constantly growing, and is needed a greater production of electricity. Currently, main source of electricity in Brazil are hydroelectric plants, which corresponds 90% of the energy production in the country. With this, population pays a high value for the energy consumed, but is environment that suffers with gases coming from the combustion of non-renewable fuels when water is scarce. To overcome this situation, Brazil has, as one of the alternative sources of energy, solar stations. And in these alternative sources that Brazil needs invest. Researchs for these new sources needs to be explored, because to make best use of this clean energy, one needs of data provided by specialized studies. Solar energy was source that received most investments in 2012. It represents 26% of renewable energy on the planet. Per year, stations save 53 million tons of carbon dioxide (CO<sub>2</sub>). Use of Neural Networks (NNs), to predict meteorological variables, can obtain better use of this energy source. Therefore, objective of this work is use an neural network to perform prediction of the solar radiation, in the automatic surface meteorological station of the National Institute of Meteorology (INMET), in Petrolina, Pernambuco. Neural network known as Reservoir Computing (RC) will be used to predict future radiation from previous values of other variables. Finally, results obtained will be compared to analyze which network configuration presented best performance.

**Keywords:** Solar radiation prediction, RC, solar energy

# Sumário

<b>Capítulo 1 Introdução</b>	<b>1</b>
1.1 Motivação	1
1.2 Objetivos	3
1.2.1 Objetivo Geral	3
1.2.2 Objetivos Específicos	3
1.3 Estrutura da Monografia	3
<b>Capítulo 2 Fundamentação Teórica</b>	<b>5</b>
2.1 Energia Solar	5
2.1.1 Radiação	7
2.1.2 Energia Solar no Brasil	8
2.1.3 INMET	10
2.2 Redes Neurais	11
2.2.1 <i>Reservoir Computing</i>	14
2.2.1.1 Construção do RC	15
2.2.1.2 Simulação do RC	16
2.2.1.3 Critério de Parada	18
<b>Capítulo 3 Metodologia</b>	<b>19</b>
3.1 Aquisição e Tratamento dos Dados	19
3.2 Implementação do RC	25

3.3	Simulação com o RC	27
3.4	Análise Estatística	30
3.4.1	Teste Shapiro-Wilk	30
3.4.2	Teste F	31
3.4.3	Teste t-Student	32
3.4.4	Teste da Soma dos Postos de Wilcoxon	33
<b>Capítulo 4 Resultados</b>		<b>34</b>
4.1	Cenário 1 – Caso 1 com 22 neurônios na camada de entrada	34
4.2	Cenário 1 – Caso 2 com 9 neurônios na camada de entrada	35
4.3	Cenário 1 – Caso 3 com 2 neurônios na camada de entrada	37
4.4	Melhor Cenário 1	38
4.5	Cenário 2 – Caso 1 com 15 neurônios na camada de entrada	39
4.6	Cenário 2 – Caso 2 com 5 neurônios na camada de entrada	40
4.7	Melhor Cenário 2	42
4.8	Cenário 3 – Caso 1 com 22 neurônios na camada de entrada	42
4.9	Cenário 3 – Caso 2 com 9 neurônios na camada de entrada	44
4.10	Cenário 3 – Caso 3 com 2 neurônios na camada de entrada	45
4.11	Melhor Cenário 3	46
4.12	Cenário 4 – Caso 1 com 15 neurônios na camada de entrada	47
4.13	Cenário 4 – Caso 2 com 5 neurônios na camada de entrada	49
4.14	Melhor Cenário 4	50

4.15	Cenário 5 – Caso 1 com 10 neurônios na camada de entrada	51
4.16	Melhor Cenário para Previsão da Radiação	52
<b>Capítulo 5 Conclusão e Trabalhos Futuros</b>		<b>54</b>
5.1	Conclusões	54
5.2	Trabalhos Futuros	55
<b>Bibliografia</b>		<b>56</b>
<b>Apêndice A Resultados da Análise Estatística no <i>Software R</i></b>		<b>58</b>
<b>Apêndice B <i>Script</i> utilizado para a execução da Análise Estatística no <i>Software R</i></b>		<b>64</b>

# Índice de Figuras

<b>Figura 1.</b>	Diagrama dos processos de interação da radiação solar com a atmosfera terrestre .....	6
<b>Figura 2.</b>	Comparação dos valores de radiação solar do Brasil e da Europa .....	8
<b>Figura 3.</b>	Usina Solar na Arena Pernambuco, em São Lourenço da Mata .....	9
<b>Figura 4.</b>	Localização das Estações Meteorológicas Automáticas do INMET no Brasil.....	11
<b>Figura 5.</b>	Modelo proposto por McCulloch e Pitts para representar o neurônio artificial .....	12
<b>Figura 6.</b>	Funções de ativação .....	13
<b>Figura 7.</b>	Arquitetura do <i>Reservoir Computing</i> . As linhas contínuas representam os pesos fixos e as linhas tracejadas, os pesos que serão ajustados durante o treinamento .....	15
<b>Figura 8.</b>	Gráfico com o ponto de parada da validação cruzada .....	18

# Índice de Tabelas

<b>Tabela 1.</b>	Variáveis medidas pelos sensores nas Estações Meteorológicas do INMET .....	11
<b>Tabela 2.</b>	Quantidade de colunas defasadas para cada variável .....	21
<b>Tabela 3.</b>	Casos para definir a quantidade de variáveis pela correlação .....	22
<b>Tabela 4.</b>	Variáveis e Função de Ativação presentes em cada cenário .....	22
<b>Tabela 5.</b>	Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 1 .....	23
<b>Tabela 6.</b>	Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 2 .....	23
<b>Tabela 7.</b>	Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 3 .....	24
<b>Tabela 8.</b>	Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 4 .....	24
<b>Tabela 9.</b>	Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 5 .....	24
<b>Tabela 10.</b>	Parâmetros utilizados para as simulações com o RC .....	27
<b>Tabela 11.</b>	Cenários com características utilizadas no treinamento do RC .....	28
<b>Tabela 12.</b>	Simulações realizadas com o RC .....	29
<b>Tabela 13.</b>	Pontos Positivos e Negativos dos Testes Paramétricos e Não Paramétricos .....	30
<b>Tabela 14.</b>	Hipóteses Nula e Alternativa do Teste Shapiro-Wilk .....	31
<b>Tabela 15.</b>	Hipóteses Nula e Alternativa do Teste F .....	31

<b>Tabela 16.</b>	Hipóteses Nula e Alternativa do Teste t-Student .....	32
<b>Tabela 17.</b>	Hipóteses Nula e Alternativa do Teste da Soma dos postos de Wilcoxon .....	33
<b>Tabela 18.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 1 - Caso 1 .....	34
<b>Tabela 19.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 1 - Caso 2 .....	36
<b>Tabela 20.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 1 - Caso 3 .....	37
<b>Tabela 21.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 1 .....	38
<b>Tabela 22.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 2 - Caso 1 .....	39
<b>Tabela 23.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 2 - Caso 2 .....	41
<b>Tabela 24.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 2 .....	42
<b>Tabela 25.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 3 - Caso 1 .....	43
<b>Tabela 26.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 3 - Caso 2 .....	44
<b>Tabela 27.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 3 - Caso 3 .....	45
<b>Tabela 28.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 3 .....	46

<b>Tabela 29.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 4 - Caso 1 .....	48
<b>Tabela 30.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 4 - Caso 2 .....	49
<b>Tabela 31.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 4 .....	50
<b>Tabela 32.</b>	Média das taxas de erro para quantidade de neurônios na camada do <i>reservoir</i> do Cenário 5 - Caso 1 .....	51
<b>Tabela 33.</b>	Média das taxas de erro para as melhores configurações de cada cenário .....	52
<b>Tabela 34.</b>	Resultado dos testes estatísticos do Cenário 1 .....	58
<b>Tabela 35.</b>	Resultado dos testes estatísticos do Melhor Cenário 1 .....	59
<b>Tabela 36.</b>	Resultado dos testes estatísticos do Cenário 2 .....	59
<b>Tabela 37.</b>	Resultado dos testes estatísticos do Melhor Cenário 2 .....	60
<b>Tabela 38.</b>	Resultado dos testes estatísticos do Cenário 3 .....	60
<b>Tabela 39.</b>	Resultado dos testes estatísticos do Melhor Cenário 3 .....	61
<b>Tabela 40.</b>	Resultado dos testes estatísticos do Cenário 4 .....	61
<b>Tabela 41.</b>	Resultado dos testes estatísticos do Melhor Cenário 4 .....	62
<b>Tabela 42.</b>	Resultado dos testes estatísticos do Cenário 5 .....	62
<b>Tabela 43.</b>	Resultado dos testes estatísticos do Melhor Cenário .....	63

# Tabela de Símbolos e Siglas

ANEEL – Agência Nacional de Energia Elétrica

EMA – Erro Médio Absoluto

EMQ – Erro Médio Quadrático

ESP – *Echo State Property*

INMET – Instituto Nacional de Meteorologia

MLP – *Multi-Layer Perceptron*

OMM – Organização Meteorológica Mundial

RC – *Reservoir Computing*

RN – Rede Neural

RNA – Rede Neural Artificial

RNR – Rede Neural Recorrente

# Capítulo 1

## Introdução

Este capítulo aborda a motivação e os objetivos gerais e específicos deste trabalho, e também a estrutura dos conteúdos que serão discutidos.

### 1.1 Motivação

O desenvolvimento industrial e tecnológico mundial está em constante crescimento, e por isso se faz necessário a produção, cada vez maior, de energia elétrica (MARTINS; PEREIRA; ECHER, 2004). Em outra perspectiva, o mundo enfrenta sérios problemas com o meio ambiente, e fontes de energia renováveis são essenciais para uma possível solução. E aqui no Brasil não podia ser diferente.

Atualmente, a principal fonte de energia elétrica no Brasil são as usinas hidrelétricas, que corresponde a 90% da produção de energia no país (PENA, 2016). Mas isso gera um agravante para a população, para empresas e para o meio ambiente, pois hidrelétrica funciona com água, e quando esta está escassa, a alternativa usada no Brasil são as usinas termelétricas, onde a obtenção de energia é por meio da queima de combustíveis fósseis.

Ou seja, a população e as empresas pagam um valor alto pela energia consumida, mas quem paga o maior e o pior preço é o meio ambiente, que sofre com os gases deixados no ar pela combustão de combustíveis não renováveis.

Em 2016, o Brasil vem sofrendo uma das maiores crises energéticas devido à falta de chuvas em muitos estados, fazendo com que a conta de energia dos brasileiros tenha um aumento.

Em 2015, entrou em vigor o sistema de bandeiras tarifárias, que indicam o custo da energia em função das condições de geração elétrica (SGT – ANEEL, 2015).

Quando os reservatórios atingem um nível crítico, há a implantação da chamada “bandeira vermelha”, que é um indicativo de que a produção energética do país está sendo gerada por termelétricas.

Para contornar essa situação, o Brasil atualmente possui, como fontes alternativas de energia: usinas eólicas, nucleares e solares. E são nessas fontes alternativas que o Brasil precisa investir.

Pesquisas para essas novas fontes precisam ser exploradas, pois para o melhor aproveitamento dessas fontes, é preciso dos dados fornecidos por estudos especializados na área de energia, além da importância sócio-econômica e ambiental que elas possuem (MARTINS; PEREIRA; ECHER, 2004). A partir disso, os resultados são inúmeros, como: Preservação do Meio Ambiente, Gestão Eficiente da Geração de Energia e Aumento da Produção Energética no País.

A energia solar foi a fonte que mais recebeu investimentos em 2012, com cerca de 1,5 bilhão de dólares. Ela representa 26% da energia renovável no planeta. Por ano, as estações poupam 53 milhões de toneladas de gás carbônico (CO<sub>2</sub>). Europa, Ásia e América do Norte são os continentes que mais apostaram neste setor (NICOLETTI, 2013).

Em 2018, o Brasil deverá estar entre os 20 países com maior geração de energia solar. A proporção de geração solar deve chegar a 1% do total. Estudos para o planejamento do setor elétrico em 2050 estimam que 18% dos domicílios no Brasil contarão com geração fotovoltaica (PORTAL BRASIL, 2016).

Uma vez que a geração solar está aumentando e se tornando essencial, e a literatura não apresenta técnicas sobre previsão de geração solar, neste trabalho vai ser utilizado uma arquitetura de rede neural chamada *Reservoir Computing* (RC) para realizar a previsão da radiação solar. O RC é uma rede neural recorrente que, além da camada de entrada e saída, possui 1 camada de neurônios intermediária. Esta camada intermediária tem por objetivo se aproximar do comportamento do cérebro. Os resultados do RC serão comparados entre si para definir a melhor configuração da rede para realizar a previsão da radiação solar.

## 1.2 Objetivos

Nessa Seção serão apresentados os objetivos gerais e os específicos.

### 1.2.1 Objetivo Geral

Realizar a previsão da radiação solar na estação meteorológica da cidade de Petrolina, no estado de Pernambuco (PE), no horizonte de 6 horas à frente, utilizando a arquitetura de Redes Neurais conhecida como *Reservoir Computing* (RC), além de configurar a Rede Neural (RN) para cada cenário a ser previsto. Cada cenário tem uma base de dados com variáveis distintas. Por fim, objetiva-se comparar os resultados obtidos pelo RC.

### 1.2.2 Objetivos Específicos

1. Tratamento dos dados de entrada;
2. Normalizar os dados para cada cenário;
3. Selecionar as variáveis mais importantes no processo de previsão;
4. Realizar configurações distintas nos parâmetros do RC;
5. Definir a melhor configuração de previsão;
6. Comparar os resultados obtidos pelo RC.

## 1.3 Estrutura da Monografia

Este trabalho está organizado em 5 capítulos: Introdução, Fundamentação Teórica, Metodologia, Análise dos Resultados e Conclusões. O capítulo da Fundamentação Teórica descreve os conceitos necessários para o entendimento deste trabalho, como a descrição de energia solar, radiação, redes neurais, e, mais especificamente, do RC.

O capítulo de Metodologia descreve todos os procedimentos utilizados para a realização desse trabalho, desde a aquisição e tratamento dos dados até a análise estatística realizada.

No capítulo de Análise dos Resultados, serão apresentados os resultados obtidos, após as simulações do RC, e os testes estatísticos utilizados para comparar as configurações utilizadas na previsão da radiação.

Por fim, no capítulo de Conclusões, são apresentados todos os resultados obtidos nesse trabalho. Além disso, será apresentado propostas para trabalhos futuros.

# Capítulo 2

## Fundamentação Teórica

Este capítulo apresenta uma breve explicação dos assuntos abordados nesse trabalho para a sua devida compreensão.

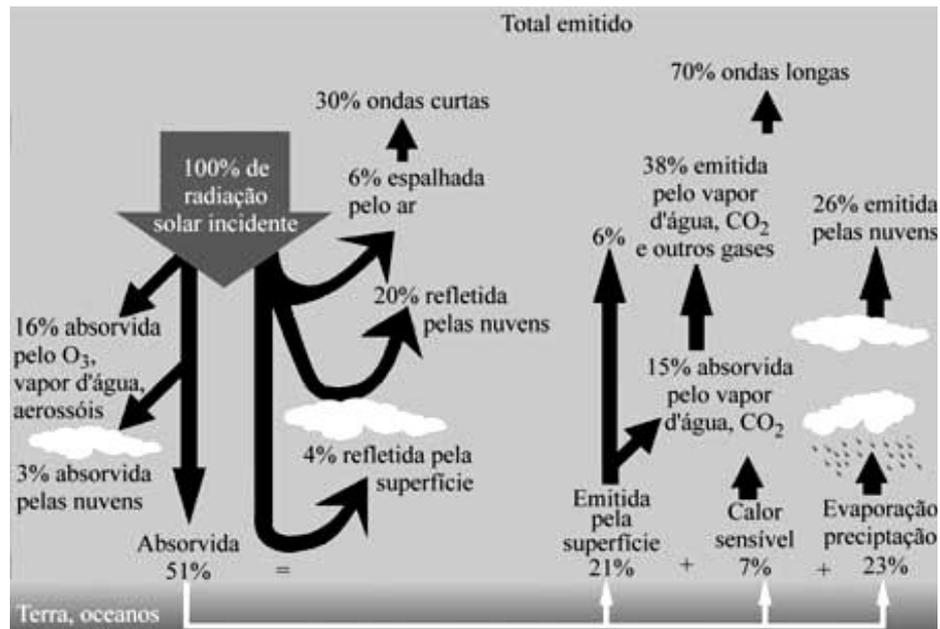
### 2.1 Energia Solar

Energia solar é aquela proveniente do Sol (energia térmica e luminosa). Esta energia é captada por painéis solares, formados por células fotovoltaicas, e transformada em energia elétrica ou mecânica. A energia solar é utilizada, principalmente, em residências para o aquecimento da água. Anualmente, o sol produz 4 milhões de vezes mais energia do que consumimos, para o seu potencial que é ilimitado.

A energia solar é considerada uma fonte de energia limpa e renovável, pois não polui o meio ambiente. Para se ter uma ideia do poder solar, em apenas um segundo, ele produz mais energia internamente que toda energia usada pela humanidade desde o começo dos tempos.

Em números, 15% da energia emitida pelo sol, que chega à terra, é refletida de volta para o espaço. Outros 30% são perdidos na evaporação da água, a qual sobe para a atmosfera, produzindo chuva. A energia solar é também absorvida pela terra, nuvens e oceanos. A energia restante, para manter o equilíbrio energético do planeta, deve então ser emitida sob a forma de radiação térmica (PORTAL ENERGIA, 2016), como pode ser visto na Figura 1.

Considerando a energia solar, ilimitada e gratuita, esta tem seu aproveitamento limitado. O problema é sua forma disseminada e a sua captação, que requer instalações complexas e dispendiosas.



**Figura 1.** Diagrama dos processos de interação da radiação solar com a atmosfera terrestre  
 [Fonte: MARTINS; PEREIRA; ECHER, 2004, p. 147]

Existem dois principais tipos de energia solar: Energia Solar Térmica e Energia Solar Fotovoltaica.

A Energia Solar Térmica é captada por coletores solares. Estes são os sistemas mais simples e econômicos, os quais são utilizados para captar o calor do sol e transferir o calor para um líquido, geralmente a água. Esses painéis são extremamente eficientes e reduzem em até 80% o consumo de energia relativo ao aquecimento da água. Estes painéis não geram eletricidade e geralmente aquecem a água e armazenam em um reservatório térmico.

A energia solar fotovoltaica é a energia elétrica produzida a partir da luz solar, captada por painéis solares. Quanto maior for a radiação solar, maior será a quantidade de eletricidade produzida. O processo de conversão da energia solar utiliza células fotovoltaicas, normalmente feitas de silício. Quando a luz solar incide sobre uma célula fotovoltaica, os elétrons do material semicondutor são postos em movimento, desta forma gerando eletricidade (PORTAL SOLAR).

Fazendo uma comparação, a energia solar térmica é mais eficiente e econômica, porém restrita à energia térmica. A energia fotovoltaica é a mais

utilizada, pois é mais confiável. No entanto, o custo de fabricação e instalação dos painéis solares é muito elevado. Outro problema é a dificuldade de armazenamento.

### 2.1.1 Radiação

A radiação solar que atinge o topo da atmosfera terrestre provém da região da fotosfera solar, que é uma camada tênue com aproximadamente 300 Km de espessura e temperatura superficial da ordem de 5800<sup>o</sup> K. Porém, esta radiação não se apresenta como um modelo de regularidade, pois há a influência das camadas externas do Sol (cromosfera e coroa) (CRESESB, 2008).

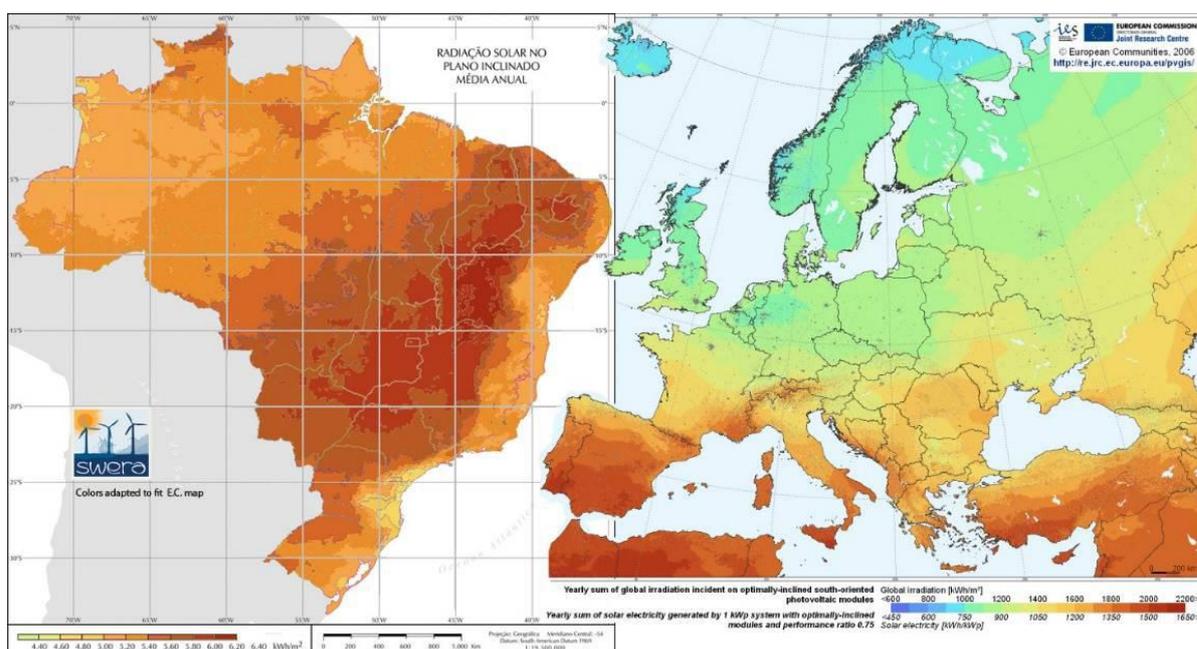
A radiação solar é radiação eletromagnética que se propaga a uma velocidade de 300.000 Km/s, podendo-se observar aspectos ondulatórios e corpusculares. De toda a radiação solar que chega às camadas superiores da atmosfera, apenas uma fração atinge a superfície terrestre, devido à reflexão e absorção dos raios solares pela atmosfera. Esta fração que atinge o solo é constituída por um componente direto e por um componente difuso (CRESESB, 2008).

A radiação representa a maior fonte de energia para a Terra, principal elemento meteorológico e um dos fatores determinantes do tempo e do clima, afeta processos físicos (aquecimento e evaporação) e biológicos (fotossíntese) que ocorrem na superfície terrestre. A radiação é a diferença entre os fluxos totais da radiação incidente e a emitida pela superfície, medida em plano horizontal. Durante o dia, o saldo de radiação em uma superfície tende a ser positivo, pois representa o período de brilho solar no qual os fluxos incidentes, global e atmosférico são superiores às frações emitidas. Da mesma forma, durante à noite, o saldo de radiação é negativo, já que o fluxo incidente passa a ser apenas atmosférico e a energia emitida pela superfície é superior a este (MONTEITH; UNSWORTH, 1990).

Apesar do território brasileiro possuir regiões com características climáticas distintas, a média anual da radiação é distribuída com uniformidade no país, apresentando médias anuais relativamente altas. Os valores de radiação solar incidente, em qualquer região do território brasileiro, são superiores aos da maioria

dos países da União Europeia, como Alemanha, França e Espanha, onde projetos de aproveitamento de recursos solares são amplamente disseminados.

O Brasil possui um potencial gigantesco para se aproveitar. O Mapa, de acordo com a Figura 2, faz uma comparação dos valores de radiação solar do Brasil (esquerda) e da Europa (direita). Fica fácil de observar que o potencial do Brasil é muito maior, no entanto, a Europa possui instalados 88GW de energia fotovoltaica, enquanto o Brasil ainda está em menos de 1GW (PORTAL SOLAR).



**Figura 2.** Comparação dos valores de radiação solar do Brasil e da Europa  
[Fonte: <http://www.portalsolar.com.br/energia-fotovoltaica.html>]

Os valores de radiação obtidos no site do Instituto Nacional de Meteorologia (INMET) tem periodicidade de 1 hora e representam a média da radiação medidas em Kilojoules por metro quadrado ( $\text{kJ}/\text{m}^2$ ). A Figura 2 apresenta, no lado esquerdo, a média anual do total diário de radiação solar incidente no território brasileiro.

### 2.1.2 Energia Solar no Brasil

Localizado na região intertropical, o Brasil possui grande potencial para geração de energia solar. A utilização da energia solar traz benefícios a longo prazo para o país, possibilitando o desenvolvimento de regiões isoladas, onde o custo para instalação da rede elétrica convencional é extremamente alto.

Nas regiões Sul e Sudeste do país, o principal uso da energia solar é para realizar o aquecimento de água em estabelecimentos. Nestas regiões, o consumo de energia elétrica é destinada ao aquecimento de água, o que tem contribuído para o crescimento do aproveitamento da energia solar. Já nas regiões Norte e Nordeste, o principal uso da energia solar é para geração fotovoltaica de energia elétrica, visando o atendimento de comunidades isoladas da rede de energia elétrica e ao desenvolvimento regional.

No Brasil, a maior usina de energia solar em operação comercial é a usina da Tractebel. Ela fica localizada em Tubarão – Santa Catarina, possui 19.424 painéis fotovoltaicos e foi construída para fins de pesquisa e desenvolvimento.

Em Pernambuco, a primeira usina solar está localizada na Arena Pernambuco, em São Lourenço da Mata, conforme a Figura 3. Ela possui 3.652 painéis e atende 30% da demanda de energia elétrica da Arena (SABOIA, 2015).



**Figura 3.** Usina Solar na Arena Pernambuco, em São Lourenço da Mata  
[Fonte: <http://www.blogdasppps.com/2015/05/usina-solar-abastece-30-do-consumo-de.html>]

### 2.1.3 INMET

O Instituto Nacional de Meteorologia (INMET) é um órgão do Ministério da Agricultura, Pecuária e Abastecimento, quem provém informações meteorológicas à sociedade brasileira e influi construtivamente no processo de tomada de decisão, contribuindo para o desenvolvimento sustentável do País. Esta missão é alcançada por meio de monitoramento, análise e previsão de tempo e de clima, que se fundamentam em pesquisa aplicada, trabalho em parceria e compartilhamento do conhecimento, com ênfase em resultados práticos e confiáveis.

O INMET representa o Brasil junto à Organização Meteorológica Mundial (OMM) e, por delegação desta Organização, é responsável pelo tráfego das mensagens coletadas pela rede de observação meteorológica da América do Sul e os demais centros meteorológicos que compõem o Sistema de Vigilância Meteorológica Mundial.

O Sistema de Coleta e Distribuição de Dados Meteorológicos do Instituto (temperatura, umidade relativa do ar, direção e velocidade do vento, pressão atmosférica, precipitação, entre outras variáveis) é dotado de estações de sondagem de ar superior (radiossonda); estações meteorológicas de superfície, operadas manualmente; e a maior rede de estações automáticas da América do Sul.

A rede de estações meteorológicas automáticas utiliza o que há de mais moderno internacionalmente. Os dados coletados por essa rede são disseminados, de forma democrática e gratuita, em tempo real, e têm aplicação em todos os setores da economia. As estações meteorológicas de superfície são compostas de uma unidade de memória central (“*data logger*”), ligada a vários sensores dos parâmetros meteorológicos, que integra os valores observados minuto a minuto e os disponibiliza automaticamente a cada hora. A Figura 4 apresenta um mapa do Brasil com a localização das estações meteorológicas do INMET.

Os dados coletados pelos sensores são dados brutos e sem validação, com o único objetivo de deixá-los disponíveis de forma imediata. Na Tabela 1 estão apresentadas as variáveis medidas pelos sensores nas estações meteorológicas do INMET.



**Figura 4.** Localização da Estações Meteorológicas Automáticas do INMET no Brasil [Fonte: INMET]

**Tabela 1.** Variáveis medidas pelos sensores nas Estações Meteorológicas do INMET [Fonte: INMET]

Temperatura (°C)			Umidade (%)			Pto. Orvalho (°C)			Pressão (hPa)		
Inst.	Máx.	Mín.	Inst.	Máx.	Mín.	Inst.	Máx.	Mín.	Inst.	Máx.	Mín.
Vento (m/s)			Radiação			Chuva					
Vel.	Dir. (°)	Raj.	(kJ/m <sup>2</sup> )			(mm)					

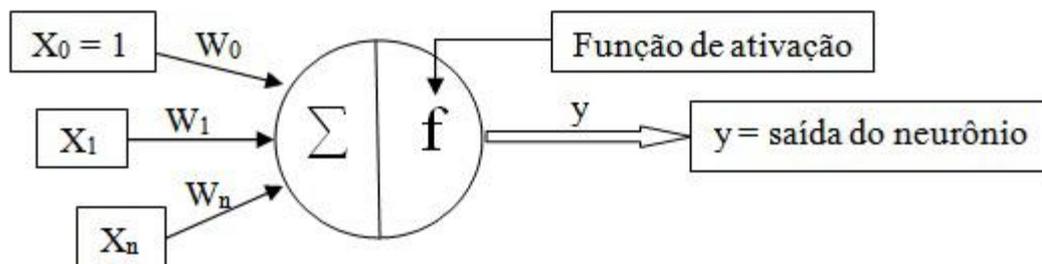
## 2.2 Redes Neurais

As redes neurais artificiais (RNAs) são técnicas computacionais que procuram simular o comportamento e funcionamento do cérebro humano. A RNA tem como base as redes neurais biológicas, que processa informações simultaneamente por uma rede de neurônios interconectados (VALENÇA, 2009).

Os neurônios biológicos são formados pelos dendritos, terminais que recebem sinais de outros neurônios, pelo corpo central, onde a informação é processada, e pelos axônios, que são os terminais de saída da informação processada.

Os neurônios possuem um limiar excitatório que define se a intensidade do sinal recebido é suficiente para disparar o impulso nervoso. Se o sinal tiver intensidade menor que o limiar, o impulso não é disparado. Caso o sinal tiver intensidade maior que o limiar, o impulso é disparado.

Os neurônios artificiais foram propostos em 1943 por McCulloch e Pitts. Seu modelo pode ser visualizado na Figura 5.



**Figura 5.** Modelo proposto por McCulloch e Pitts para representar o neurônio artificial

[Fonte: COUTINHO, 2012, p. 23]

O neurônio artificial é formado por um conjunto de entradas ( $x_j$ ), conectadas por ligações que possuem pesos ( $w_{ij}$ ). O peso representa a importância da entrada. Quanto maior a importância da entrada, maior será seu peso. Cada entrada é multiplicada pelo seu peso e o somatório desses produtos será a entrada do neurônio artificial, expressa na Equação 2.1.

$$net_i = \sum_{j=0}^n w_{ij} \cdot x_j \quad (2.1)$$

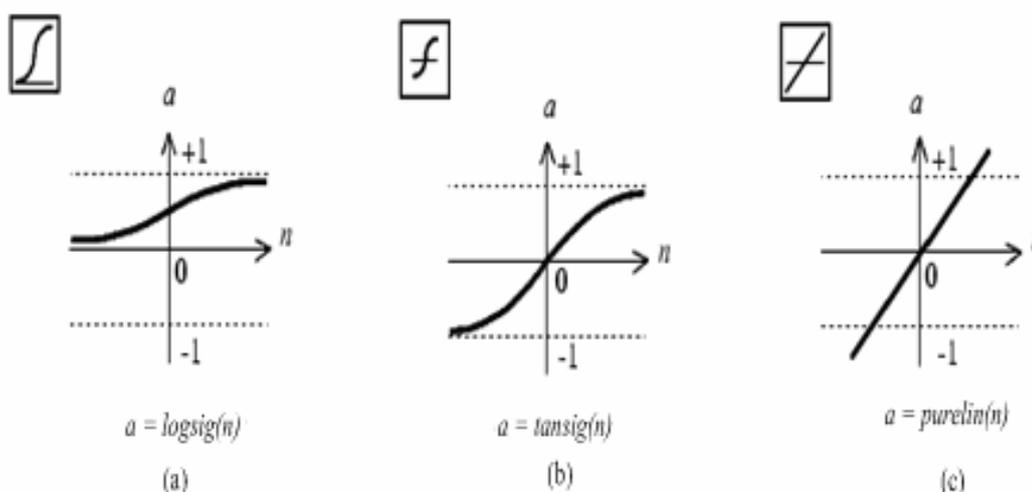
Sendo  $net_i$  utilizado para encontrar a saída do neurônio, este é calculado de acordo com a função de ativação utilizada. Há diversas funções de ativação propostas na literatura, porém as mais utilizadas são a função linear, sigmóide logística e a tangente hiperbólica (VALENÇA, 2009). As Equações 2.2, 2.3 e 2.4 representam essas funções, na mesma ordem. A Figura 6 apresenta graficamente

essas funções, da esquerda para a direita, tendo a função sigmóide logística como o primeiro gráfico, que varia de 0 até 1, em seguida, a função tangente hiperbólica, que varia de -1 até 1, e no terceiro gráfico, a função linear.

$$f(net_i) = net_i \quad (2.2)$$

$$f(net_i) = \frac{1}{1 + e^{-net_i}} \quad (2.3)$$

$$f(net_i) = \frac{e^{net_i} - e^{-net_i}}{e^{net_i} + e^{-net_i}} \quad (2.4)$$



**Figura 6.** Funções de ativação  
[Fonte: Neural Network Toolbox]

O treinamento para essas redes pode ser supervisionado (resposta conhecida pela rede) ou não supervisionado (resposta desconhecida pela rede), podendo ser executado de modo online (fim de cada iteração do treinamento da rede), ou de modo offline (fim do treinamento inteiro da rede) (VALENÇA, 2009).

As primeiras arquiteturas destas redes foram o *Perceptron* e a *Adaline*, sendo as duas arquiteturas capazes de solucionar apenas problemas linearmente separáveis. A diferença entre elas está na função de ativação, onde a função linear é para o *Perceptron* e a função sigmóide logística é para a *Adaline*. Posteriormente,

surgiu o *Multi-Layer Perceptron* (MLP), que possui, além da camada de entrada e saída, uma camada intermediária. A vantagem da camada intermediária é que a rede passa a resolver problemas que não são linearmente separáveis, possibilitando a aproximação de qualquer função contínua (HAYKIN, 2007).

Essas arquiteturas foram de grande importância para o estudo de novas Redes Neurais Artificiais (RNAs), como o *Reservoir Computing* (RC), que será melhor descrito na sequência.

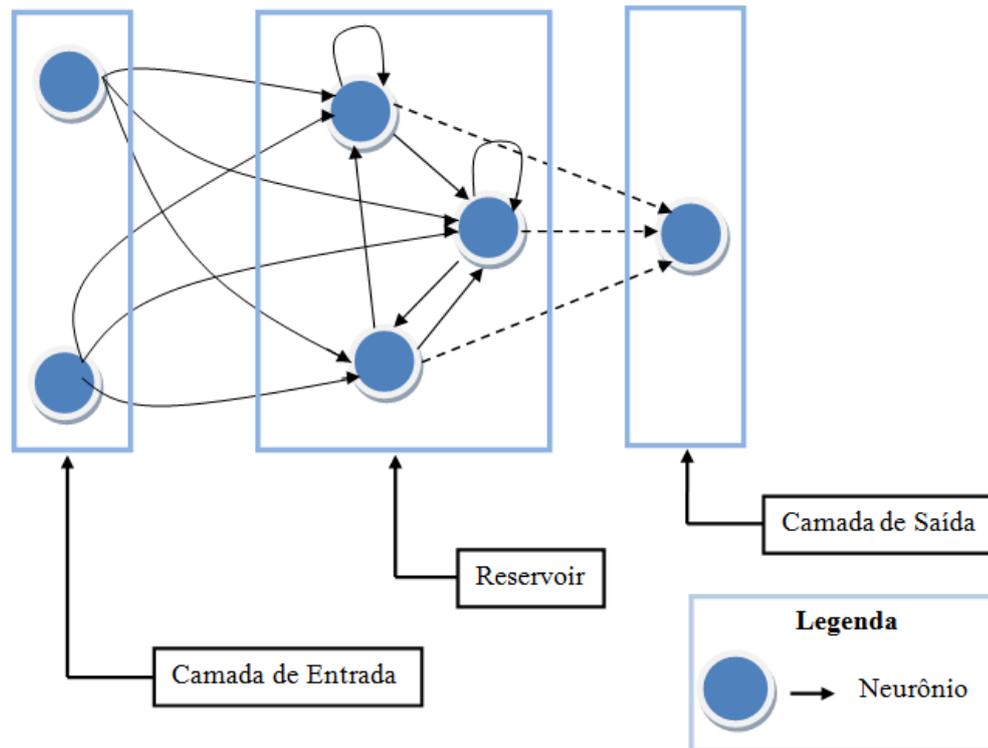
### 2.2.1 *Reservoir Computing*

O sinal, em redes neurais, é propagado da camada de entrada para a saída, sendo excelentes para problemas estáticos. As Redes Neurais Recorrentes (RNRs) foram feitas para problemas dinâmicos. Elas têm a capacidade de realimentar um neurônio de uma camada  $i$  para um neurônio de outra camada anterior  $i - j$  (COUTINHO, 2012).

Uma abordagem para a RNR é a Propriedade do Eco, do inglês *Echo State Property* (ESP), ou seja, devido às conexões recorrentes da rede, as informações anteriores ficam armazenadas. Porém, dados antigos são esquecidos depois de determinado tempo. Desse modo, a rede possui dados do presente e do passado, reforçando a aplicação em sistemas dinâmicos (COUTINHO, 2012).

Em 2007, Verstraeten criou o *Reservoir Computing* (RC), e a partir disso, o RC exemplifica sistemas de aprendizagem representados por uma rede neural recorrente dinâmica. O RC é constituído por três partes: uma camada de entrada, que representa as variáveis de entrada, um *reservoir*, que pode ser entendido como um reservatório de neurônios dinâmicos e com pesos fixos, e uma camada de saída com função linear (VERSTRAETEN, 2009).

A Figura 7 representa a arquitetura do RC com dois neurônios na camada de entrada, três na camada do *reservoir*, e um neurônio na camada de saída. Nota-se que na Figura 7, todos os neurônios da entrada devem estar conectados com o *reservoir*, os neurônios do *reservoir* devem estar conectados entre si e com a camada de saída.



**Figura 7.** Arquitetura do *Reservoir Computing*. As linhas contínuas representam os pesos fixos e as linhas tracejadas, os pesos que serão ajustados durante o treinamento

[Fonte: COUTINHO, 2012, p. 25]

### 2.2.1.1 Construção do RC

A camada de entrada utiliza uma quantidade de neurônios que representa as variáveis de entrada do problema acrescido do neurônio que representa o *bias*.

Após estabelecer as variáveis na camada de entrada, deve-se estabelecer a quantidade de neurônios utilizada no *reservoir*. Como essa abordagem de rede neural tem poucas pesquisas, esse valor é definido empiricamente, ou seja, ainda é indefinido o número de neurônios ideal no *reservoir*, isso vai depender de cada aplicação. Após a camada de entrada e *reservoir*, os neurônios na camada de saída também vai depender de cada aplicação.

Depois de configurar o RC, vai ser gerada a matriz de pesos que conecta a entrada com o *reservoir* ( $W_{in}$ ). Essa matriz terá como número de linhas a quantidade de neurônios na camada de entrada e como número de colunas a quantidade de

neurônios no *reservoir*. Esses pesos são gerados aleatoriamente, logo após são congelados, e estão entre -1 e 1.

Além da matriz  $W_{in}$ , deve ser gerada a matriz de pesos do *reservoir* ( $W_{res}$ ). Esses pesos são gerados aleatoriamente e entre -1 e 1. A partir disso, deve ser definida a taxa de conectividade do *reservoir*, ou seja, a porcentagem de neurônios que possuem pesos diferentes de 0. Esse também é um parâmetro da rede que precisa ser definido empiricamente, pois não há teorias que definam a melhor taxa de conectividade (COUTINHO, 2012).

A matriz  $W_{res}$  deve ter um raio espectral igual a 1, ou seja, a matriz deve ter seus valores alterados da seguinte forma:

- Inicialmente, a matriz deverá ser decomposta em valores singulares;
- Em seguida,  $W_{res}$  deverá ter os valores alterados até que o máximo valor da diagonal principal da matriz seja menor ou igual a 1.

A matriz que conecta o *reservoir* à camada de saída não precisa ser gerada nesse momento, já que ela será calculada no treinamento pelo método da Pseudo-Inversa de Moore-Penrose.

### 2.2.1.2 Simulação do RC

Para o treinamento do RC é necessário fazer o tratamento da base de dados e dividi-la em 3 subconjuntos: treinamento, validação cruzada e teste. O subconjunto de treinamento é utilizado para atualizar os estados do *reservoir* e ajustar os pesos que conectam o *reservoir* à camada de saída.

O subconjunto de validação cruzada é usado para parar o treinamento da rede neural. Essa é a melhor forma de parar o treinamento, evitando o superajustamento da rede ou que ela fique presa em mínimos locais (VALENÇA, 2009).

Por fim, o subconjunto de testes será utilizado para calcular a taxa de erro para a rede neural realizar a previsão. Nessa etapa, os estados dos neurônios permanecem inalterados e os pesos da matriz  $W_{res}$  não se alteram.

Os estados das recorrências dos neurônios do *reservoir* devem ser inicializados com o valor zero. Já que o RC é uma rede recorrente e armazena os estados em uma matriz ( $M_{est}$ ), é preciso que os valores finais não sejam influenciados por essa inicialização. Assim, antes de iniciar o treinamento, na inicialização dos estados, um conjunto de ciclos de *warm up* é executado, a fim de tirar a dependência do valor zero dos estados dos neurônios do *reservoir* (VERSTRAETEN, 2009).

Finalizado os ciclos de *warm up*, o treinamento do RC inicia. Primeiro, o RC carrega o subconjunto de treinamento e atualiza os estados do *reservoir*. As matrizes  $W_{in}$  e  $W_{res}$  são geradas aleatoriamente e não devem ser ajustadas. A matriz  $W_{out}$  é calculada através da pseudo-inversa de Moore-Penrose. A matriz  $W_{out}$ , em geral, não é quadrada e seu determinante pode se aproximar de zero, logo não existe solução analítica, por isso, se faz necessário o uso do cálculo da pseudo-inversa.

A Equação 2.5 demonstra que a matriz  $X$  pode ser decomposta em matrizes  $A$  e  $B$ , que são ortonormais, e a Equação 2.6 demonstra a definição da pseudo-inversa de Moore-Penrose.

$$A \cdot X = B \quad (2.5)$$

$$X = A^{-1} \cdot B \quad (2.6)$$

Ao fim de cada ciclo de treinamento, inicia-se um ciclo de validação cruzada. Esse processo se repete até o critério de parada ser atingido, e assim o treinamento é finalizado. Durante esse processo, a matriz  $W_{out}$  deve continuar sendo reajustada.

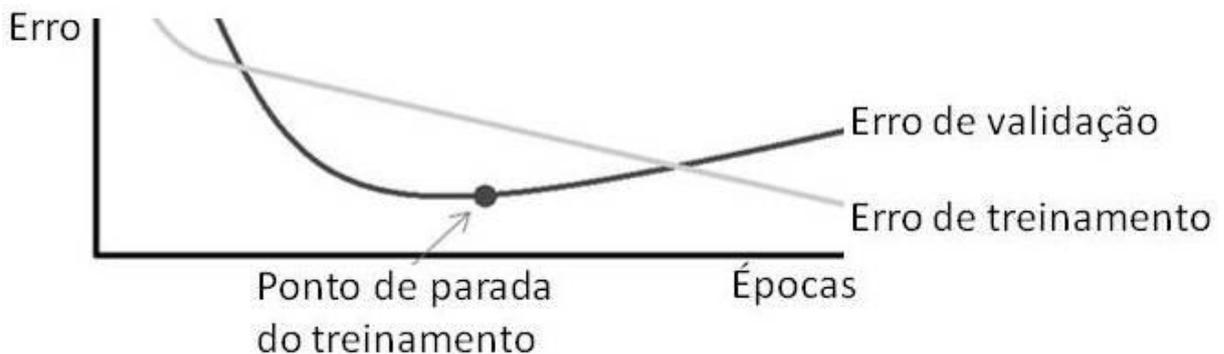
Terminado o treinamento, é iniciada a etapa de testes. O subconjunto de testes é apresentado ao RC, e as matrizes com os pesos,  $W_{in}$ ,  $W_{res}$  e  $W_{out}$ , assim como a matriz  $M_{est}$ , permanecem fixas. Nesse momento, é calculado o erro da previsão. Esses valores serão utilizados para realizar as comparações necessárias.

### 2.2.1.3 Critério de Parada

Durante o treinamento da rede neural pode ocorrer problemas de *overfitting* e *underfitting*. O *overfitting* é o treinamento excessivo, fazendo com que a rede memorize padrões e perca sua capacidade de generalização. O *underfitting* é o treinamento insuficiente, fazendo com que a rede não aprenda os padrões e assim não possa generalizar.

Sendo assim é necessário determinar um critério de parada, e um dos mais usados é a validação cruzada. Esta é a verificação da diferença entre a saída encontrada e a saída desejada, onde os pesos são inéditos a cada ciclo de validação. Enquanto o erro de validação estiver diminuindo, a rede continua treinando.

No momento em que o erro da validação começar a aumentar e o de treinamento continuar a diminuir, a rede está começando a memorizar padrões, sendo este o ponto de parada para o treinamento, conforme a Figura 8. Para realizar a avaliação do desempenho, é apresentado à rede um conjunto de teste.



**Figura 8.** Gráfico com o ponto de parada da validação cruzada  
[Fonte: elaboração própria]

# Capítulo 3

## Metodologia

Neste capítulo serão abordadas as etapas de desenvolvimento do trabalho, aquisição e tratamento dos dados, implementação e simulação da arquitetura do RC, e análise estatística, com o teste Shapiro-Wilk, teste F, teste t-Student e o teste da soma dos postos de Wilcoxon.

### 3.1 Aquisição e Tratamento dos Dados

A Tabela de Dados com as variáveis: Temperatura (°C), Umidade (%), Ponto de Orvalho (°C), Pressão (hPa), Vento (m/s), Radiação (kJ/m<sup>2</sup>) e Chuva (mm) foi retirada do site do Instituto Nacional de Meteorologia (INMET, 2016). A Base de Dados escolhida foi da estação Meteorológica da cidade de Petrolina/PE. O intervalo dos dados coletados foi do dia 15/09/2015 – 00:00 até o dia 14/09/2016 – 14:00, totalizando o período de um ano. A estação meteorológica é composta de uma unidade de memória central (“*data logger*”), ligada a vários sensores que integram os valores observados e os disponibiliza a cada hora, que totaliza 8.775 dados para cada variável.

O sistema de pesquisa do INMET disponibiliza os dados, no máximo, até 365 dias antes do dia atual e faz a observação de que os sensores capturam os dados e os deixam disponíveis de forma imediata. Esses dados foram coletados e colocados em uma planilha para serem tratados, representando uma série temporal para os dados escolhidos. O *software* utilizado para o tratamento de dados na planilha foi o *Microsoft Excel*.

A partir da tabela, foi realizado o tratamento dos dados, onde foram excluídas as 24 linhas do dia 15/09/2016 por falta de dados, devido aos sensores não capturarem os valores, sendo representados por “///”.

Foram excluídas as colunas de Temperatura Máxima e Mínima, Umidade Máxima e Mínima, Ponto de Orvalho Máximo e Mínimo, Pressão Máxima e Mínima, Direção e Rajada do Vento, por motivo de que para estas variáveis, os valores utilizados serão do Instante em que foram coletadas.

A linha do dia 22/08/2016 às 21:00, não possui dados. Para repor esses dados, foi aplicada a Média Aritmética dos valores do dia 22/08/2016 às 20:00 ( $y_{i-1}$ ) somados aos do dia 22/08/2016 às 22:00 ( $y_{i+1}$ ). Esta substituição é representada pela Equação 3.1.

$$v_i = \frac{y_{i-1} + y_{i+1}}{2} \quad (3.1)$$

Onde  $v$  representa o valor de cada variável do dia 22/08/2016 às 21:00 e  $i$  representa o índice na série temporal.

Para o cálculo da radiação do dia 22/08/2016 às 21:00, foi aplicada a Divisão do Valor da Radiação às 20:00 ( $y_{i-1}$ ) pelo valor 4. Este substituição é representada pela Equação 3.2.

$$r_i = \frac{y_{i-1}}{4} \quad (3.2)$$

Onde  $r$  representa o valor da radiação do dia 22/08/2016 às 21:00 e  $i$  representa o índice na série temporal.

A decisão pela utilização dessas duas aplicações de cálculo, para reposição dos dados, foi tomada observando o comportamento dos dados.

A base de dados possui altas variações de valores, onde, por exemplo, Temperatura varia de 18,4°C a 38,4°C, Pressão de 962,7hPa a 979,8hPa e Radiação de -3,54kJ/m<sup>2</sup> a 9310kJ/m<sup>2</sup>. No geral a superfície terrestre possui um balanço positivo de radiação, enquanto a atmosfera possui saldo negativo. Durante o dia, o balanço de radiação é positivo na Terra, pois o fluxo incidente é solar, e a

noite, é negativo, pois o fluxo incidente é apenas atmosférico, justificando os valores negativos da Radiação na Base.

Para converter esses valores altos em intervalos menores, é necessário utilizar uma função de normalização dos dados. Essa função vem para auxiliar a Rede Neural (RN), pois com valores no mesmo intervalo, a RN vai tratar as variáveis com a mesma importância. Sem essa função, variáveis com valores altos podem sugerir à RN que estas têm mais importância do que variáveis com valores menores e causar uma perda na capacidade de generalização (VALENÇA, 2009).

A técnica de normalização utilizada neste trabalho é a transformação linear. A Equação 3.3 representa a fórmula para normalizar os valores da base de dados.

$$y = \left( (b - a) \cdot \left( \frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) \right) + a \quad (3.3)$$

Onde  $a$  representa o limite mínimo dos dados,  $b$  representa o limite máximo que os dados podem obter após a normalização,  $x$  é o valor da variável atual,  $x_{\max}$  é o valor máximo da variável no conjunto original,  $x_{\min}$  é o valor mínimo da variável no conjunto original e  $y$  é o valor da variável normalizada.

Neste trabalho, foi utilizado o valor de 0,1 para  $a$  e 0,9 para  $b$ , para a função de ativação sigmóide logística, e -0,9 para  $a$  e 0,9 para  $b$ , para a função de ativação tangente hiperbólica. Ao fim do treinamento, o erro deve ser calculado após o valor ser desnormalizado, ou seja, voltar para o seu intervalo inicial. Após a normalização dos dados, foi realizada a defasagem dos dados em 95 colunas. A Tabela 2 exibe a quantidade de colunas defasadas para cada variável.

**Tabela 2.** Quantidade de colunas defasadas para cada variável  
[Fonte: elaboração própria]

Quantidade de Colunas	Variáveis
15	Temperatura, Umidade, Ponto de Orvalho, Pressão, Vento e Radiação
5	Chuva, apenas para verificar a relevância desta
6 (à frente)	Radiação

A defasagem e o deslocamento das colunas das variáveis foram feitas a partir da coluna original de cada variável. Foi utilizada uma técnica de seleção, chamada de correlação, onde esta é uma boa técnica para incluir variáveis e não para excluir variáveis. Assim, foi feita a correlação linear cruzada (utilizando o suplemento da ferramenta *Microsoft Excel: Análise de Dados*) dos valores das variáveis em relação à Radiação (variável que vai ser prevista). Uma correlação entre 0,40 e 0,69 é considerada moderada, entre 0,7 e 0,89, forte, e entre 0,9 e 1, muito forte. Com os valores obtidos pela correlação, será definida a quantidade de colunas de entrada para a RNA. Serão realizados 3 Casos, conforme a Tabela 3.

**Tabela 3.** Casos para definir a quantidade de variáveis pela correlação  
[Fonte: elaboração própria]

Casos	Correlação
Caso 1	Considerar como entrada todas as variáveis com correlação maior que $\pm 0,40$
Caso 2	Considerar como entrada todas as variáveis com correlação maior que $\pm 0,50$
Caso 3	Considerar como entrada todas as variáveis com correlação maior que $\pm 0,60$

Para este trabalho, foram utilizados 5 cenários (modificações da mesma base de dados), a fim de verificar o melhor cenário para realizar a previsão, conforme a Tabela 4.

**Tabela 4.** Variáveis e Função de Ativação presentes em cada cenário  
[Fonte: elaboração própria]

Cenários	Função de Ativação	Variáveis
Cenário 1	Sigmóide Logística	Temperatura, Umidade, Ponto de Orvalho, Pressão, Vento, Chuva e Radiação com valores negativos e positivos
Cenário 2	Sigmóide Logística	Temperatura, Umidade, Ponto de Orvalho, Pressão, Vento, Chuva e Radiação com valores positivos
Cenário 3	Tangente Hiperbólica	Temperatura, Umidade, Ponto de Orvalho, Pressão, Vento, Chuva e Radiação com valores negativos e positivos
Cenário 4	Tangente Hiperbólica	Temperatura, Umidade, Ponto de Orvalho, Pressão, Vento, Chuva e Radiação com valores positivos
Cenário 5	Tangente Hiperbólica	Radiação com valores negativos e positivos

De acordo com a correlação realizada no Cenário 1 (ver Tabela 4), 22 colunas se enquadram no Caso 1 (ver Tabela 3), 9 colunas se enquadram no Caso 2 (ver Tabela 3) e 2 colunas se enquadram no Caso 3 (ver Tabela 3), conforme a Tabela 5.

**Tabela 5.** Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 1  
[Fonte: elaboração própria]

Casos	Correlação	Colunas de Entrada na RNA
Caso 1	Maior que 0,4	Temperatura (t-10 / t-9 / t-8 / t-7 / t-6 / t-5), Umidade (t-10 / t-9 / t-8 / t-7 / t-6 / t-5) e Radiação (t-15 / t-14 / t-13 / t-12 / t-11 / t-10 / t-9 / t-3 / t-2 / t-1)
Caso 2	Maior que 0,5	Temperatura (t-9 / t-8 / t-7 / t-6), Umidade (t-8 / t-7) e Radiação (t-12 / t-2 / t-1)
Caso 3	Maior que 0,6	Radiação (t-2 / t-1)

De acordo com a correlação realizada no Cenário 2 (ver Tabela 4), 15 colunas se enquadram no Caso 1 (ver Tabela 3) e 5 colunas se enquadram no Caso 2 (ver Tabela 3), conforme a Tabela 6. No Cenário 2, o Caso 3 não ocorreu, pois não houve correlação maior que 0,6.

**Tabela 6.** Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 2  
[Fonte: elaboração própria]

Casos	Correlação	Colunas de Entrada na RNA
Caso 1	Maior que 0,4	Temperatura (t-11 / t-10 / t-9 / t-4), Umidade (t-11 / t-10 / t-9), Ponto de Orvalho (t-10), Pressão (t-10 / t-9) e Radiação (t-14 / t-13 / t-12 / t-6 / t-1)
Caso 2	Maior que 0,5	Temperatura (t-11 / t-10), Umidade (t-11 / t-10) e Radiação (t-13)

De acordo com a correlação realizada no Cenário 3 (ver Tabela 4), 22 colunas se enquadram no Caso 1 (ver Tabela 3), 9 colunas se enquadram no Caso 2 (ver Tabela 3) e 2 colunas se enquadram no Caso 3 (ver Tabela 3), conforme a Tabela 7.

De acordo com a correlação realizada no Cenário 4 (ver Tabela 4), 15 colunas se enquadram no Caso 1 (ver Tabela 3) e 5 colunas se enquadram no Caso 2 (ver Tabela 3), conforme a Tabela 8. No Cenário 4, o Caso 3 não ocorreu, pois não houve correlação maior que 0,6.

**Tabela 7.** Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 3  
[Fonte: elaboração própria]

Casos	Correlação	Colunas de Entrada na RNA
Caso 1	Maior que 0,4	Temperatura (t-10 / t-9 / t-8 / t-7 / t-6 / t-5), Umidade (t-10 / t-9 / t-8 / t-7 / t-6 / t-5) e Radiação (t-15 / t-14 / t-13 / t-12 / t-11 / t-10 / t-9 / t-3 / t-2 / t-1)
Caso 2	Maior que 0,5	Temperatura (t-9 / t-8 / t-7 / t-6), Umidade (t-8 / t-7) e Radiação (t-12 / t-2 / t-1)
Caso 3	Maior que 0,6	Radiação (t-2 / t-1)

**Tabela 8.** Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 4  
[Fonte: elaboração própria]

Casos	Correlação	Colunas de Entrada na RNA
Caso 1	Maior que 0,4	Temperatura (t-11 / t-10 / t-9 / t-4), Umidade (t-11 / t-10 / t-9), Ponto de Orvalho (t-10), Pressão (t-10 / t-9) e Radiação (t-14 / t-13 / t-12 / t-6 / t-1)
Caso 2	Maior que 0,5	Temperatura (t-11 / t-10), Umidade (t-11 / t-10) e Radiação (t-13)

De acordo com a correlação realizada no Cenário 5 (ver Tabela 4), 10 colunas se enquadram no Caso 1 (ver Tabela 3), conforme a Tabela 9. No cenário 5, os Casos 2 e 3 não ocorreram, pois não houve correlação maior que 0,5 e 0,6.

**Tabela 9.** Correlação linear das variáveis mais importantes para realizar a previsão da Radiação para o Cenário 5  
[Fonte: elaboração própria]

Casos	Correlação	Colunas de Entrada na RNA
Caso 1	Maior que 0,4	Radiação (t-15 / t-14 / t-13 / t-12 / t-11 / t-10 / t-9 / t-3 / t-2 / t-1)

As variáveis de Vento e Chuva, em todos os Cenários, não obtiveram correlação maior que 0,4, por isso, não possuem relevância, logo, não podem ser selecionadas como entrada da RNA.

## 3.2 Implementação do RC

Neste trabalho foi utilizado uma ferramenta, implementada na linguagem JAVA, pelos alunos de mestrado em Engenharia da Computação da Universidade de Pernambuco, que faz a simulação do RC. Essa ferramenta abrange problemas de previsão.

Para o treinamento, o RC precisa ter sua topologia definida, ou seja, definir os dados de entrada da rede neural, a quantidade de neurônios na camada de entrada, no *reservoir* e na camada de saída, definir a taxa de conectividade, o número de ciclos do *warm up*, a função de ativação na camada intermediária e a equação para o cálculo do erro. Os neurônios do *reservoir* utilizam como função de ativação a sigmóide logística, de acordo com a Equação 2.3, ou a tangente hiperbólica, de acordo com a Equação 2.4, e os da saída, a função linear, de acordo com a Equação 2.2. Os pesos foram gerados aleatoriamente e compreendidos no intervalo entre -1 e 1.

O RC inicia gerando aleatoriamente os pesos, e executa ciclos de *warm up* apenas para atualizar os estados dos neurônios do *reservoir*. Assim que o RC termina essa etapa, o treinamento com a validação é iniciado, os estados são atualizados e os pesos da matriz  $W_{out}$  é calculada através da pseudo-inversa de Moore-Penrose. Para calcular a pseudo-inversa, foi utilizada a biblioteca Jama para a linguagem JAVA.

Para a validação, foi utilizado o Erro Médio Quadrático (EMQ) para verificar se o treinamento podia ser finalizado. A Equação 3.4 define o Erro Médio Quadrático.

$$EMQ = \frac{1}{N} \sum_{i=1}^N (x_c - x_o)^2 \quad (3.4)$$

Onde  $x_c$  é o valor calculado pela rede, e  $x_o$  é o valor observado, ou seja, o valor previsto que foi apresentado à rede.

Terminado o treinamento, a rede neural recebe um subconjunto de testes, para ser calculado o Erro Médio Absoluto (EMA) para a previsão. A Equação 3.5 define o Erro Médio Absoluto.

$$EMA = \frac{1}{N} \sum_{i=1}^N |x_c - x_o| \quad (3.5)$$

O pseudocódigo do RC encontra-se em Pseudocódigo 1 (COUTINHO, 2012).

### Pseudocódigo 1

---

```

Definir a quantidade de neurônios na camada de entrada ;
Definir a quantidade de neurônios no reservoir ;
Definir a quantidade de neurônios na camada de saída ;
Gerar aleatoriamente os pesos da matriz  $W_{in}$  entre -1 e 1;
Gerar aleatoriamente os pesos da matriz  $W_{res}$  entre -1 e 1;
Normalizar os pesos de  $W_{res}$  para que o raio espectral da matriz fique menor ou
igual a 1;

while até o final da quantidade de ciclos de warm up do
    atualiza os estados dos neurônios do RC;
end

while até que o critério de parada seja atingido do
    for cada valor do conjunto de entrada do
        atualiza os estados dos neurônios do RC;
    end

    Calcula a pseudo-inversa de Moore-Penrose para encontrar a matriz de pesos
    que conecta o RC à camada de saída;

    for cada valor do conjunto de validação cruzada do
        atualiza os estados dos neurônios do RC;
    end

    Calcula os valores de saída do RC;
    Calcula o EMQ;
    Verifica se o critério de parada já foi atingido;
end

for cada valor do conjunto de testes do
    atualiza os estados dos neurônios do RC;
end

Calcula os valores de saída do RC;
Calcula o EMA // Erro Médio Absoluto para previsão;

```

### 3.3 Simulação com o RC

Para realizar as simulações com os 5 cenários, descritos na Seção 3.1, foram utilizadas as configurações do RC descritas na Tabela 10.

**Tabela 10.** Parâmetros utilizados para as simulações com o RC  
[Fonte: elaboração própria]

Parâmetro	Valor
Conectividade do RC	30%
Quantidade de neurônios na camada de entrada	22 ou 9 ou 2 (Cenário 1) (a depender da correlação utilizada)
	15 ou 5 (Cenário 2) (a depender da correlação utilizada)
	22 ou 9 ou 2 (Cenário 3) (a depender da correlação utilizada)
	15 ou 5 (Cenário 4) (a depender da correlação utilizada)
	10 (Cenário 5)
Quantidade de neurônios no <i>reservoir</i>	25 ou 50 ou 75 ou 100 (testes para verificar a melhor quantidade para cada cenário)
Quantidade de neurônios na camada de saída	6
Quantidade de ciclos de <i>warm up</i>	10
Função de ativação dos neurônios do <i>reservoir</i>	Sigmóide Logística ou Tangente Hiperbólica (a depender do cenário)
Função de ativação dos neurônios da camada de saída	Linear

A quantidade de neurônios na camada do *reservoir* foi baseada na análise do EMA obtido pelas simulações da rede, e foi escolhida a quantidade que apresentou o menor EMA. A quantidade de neurônios na camada de saída é definida pela previsão. Devido à periodicidade, para os dados de entrada, ser de 1 hora, para que se possa prever 6 horas à frente, é necessário utilizar 6 neurônios na camada de saída. Para que seja possível prever 6 horas à frente, são necessárias 6 colunas de dados como *output*.

Foram apresentados ao RC cenários com características diferentes entre si, para ser realizado o treinamento, pois uma das verificações, será do desempenho da rede alterando o número de neurônios na camada de entrada, conforme a Tabela

11. Cada caso de cada cenário apresenta o número de colunas de entrada da rede, como *input*, de acordo com o número de neurônios na camada de entrada. Para cada cenário foi realizado o embaralhamento dos dados, para que estes fiquem bem distribuídos. Se algum cenário possuir um padrão, a rede pode memorizar e perder sua capacidade de generalização, mas com esse embaralhamento, isto não ocorre.

**Tabela 11.** Cenários com características utilizadas no treinamento do RC

[Fonte: elaboração própria]

Cenários	Casos	Função de Ativação	Número de Neurônios na Camada de Entrada	Correlação
Cenário 1	Caso 1	Sigmóide Logística	22	Maior que 0,4
	Caso 2	Sigmóide Logística	9	Maior que 0,5
	Caso 3	Sigmóide Logística	2	Maior que 0,6
Cenário 2	Caso 1	Sigmóide Logística	15	Maior que 0,4
	Caso 2	Sigmóide Logística	5	Maior que 0,5
Cenário 3	Caso 1	Tangente Hiperbólica	22	Maior que 0,4
	Caso 2	Tangente Hiperbólica	9	Maior que 0,5
	Caso 3	Tangente Hiperbólica	2	Maior que 0,6
Cenário 4	Caso 1	Tangente Hiperbólica	15	Maior que 0,4
	Caso 2	Tangente Hiperbólica	5	Maior que 0,5
Cenário 5	Caso 1	Tangente Hiperbólica	10	Maior que 0,4

A partir dos dados de cada caso da Tabela 11, são gerados os dados de treinamento, validação e teste. Neste trabalho foram utilizados 50% dos dados para o subconjunto de treinamento (*input* e *output*), 25% para o subconjunto de validação (*crossinput* e *crossoutput*) e 25% para o subconjunto de teste (*testinput* e *testoutput*).

Após definir as configurações do RC, foram realizadas 30 simulações com cada um dos casos da Tabela 11. Esse número de simulações é ideal para realizar comparações estatísticas (JURISTO; MORENO, 2001). A Tabela 12 mostra a sequência das simulações.

**Tabela 12.** Simulações realizadas com o RC  
[Fonte: elaboração própria]

Casos por Cenários	Quantidade de neurônios no reservóir	Quantidade de simulações
Cenário 1 – Caso 1 / 2 / 3	25 / 50 / 75 / 100	30
Cenário 2 – Caso 1 / 2	25 / 50 / 75 / 100	30
Cenário 3 – Caso 1 / 2 / 3	25 / 50 / 75 / 100	30
Cenário 4 – Caso 1 / 2	25 / 50 / 75 / 100	30
Cenário 5 – Caso 1	25 / 50 / 75 / 100	30

Finalizadas as simulações, as taxas de erro encontradas pelo RC foram armazenadas para a comparação estatística entre as configurações de cada caso. Cada EMA foi dividido pela média dos valores da radiação de cada cenário e multiplicado por 100, fazendo cada EMA ser transformado em percentual, de acordo com a Equação 3.6.

$$EMA_p = \frac{EMA}{\frac{1}{N} \sum_{i=1}^N z_i} \times 100 \quad (3.6)$$

Onde  $EMA$  é o Erro Médio Absoluto para cada simulação,  $z_i$  é o valor de cada radiação e  $EMA_p$  é o EMA transformado em percentual.

Ressalta-se que, antes do EMA ser calculado, é preciso que a rede desnormalize os dados para que sejam comparados aos valores originais. A Equação 3.7 é utilizada para desnormalizar os dados.

$$x = \frac{(y - a)(x_{\max} - x_{\min})}{(b - a)} + x_{\min} \quad (3.7)$$

Onde  $a$  representa o limite mínimo dos dados, neste trabalho é usado 0,1 para sigmóide logística e -0,9 para tangente hiperbólica,  $b$  representa o limite máximo dos dados, neste trabalho é usado 0,9 para sigmóide logística e tangente hiperbólica,  $y$  é o valor da variável normalizada,  $x_{\max}$  é o valor máximo da variável no

conjunto original,  $x_{min}$  é o valor mínimo da variável no conjunto original e  $x$  é o valor da variável desnormalizada.

Assim, com todos os valores percentuais do EMA calculados para cada caso, o processo de análise estatística foi iniciado. Todos os testes utilizados estarão descritos na próxima seção.

### 3.4 Análise Estatística

Finalizadas todas as simulações, é necessário realizar testes estatísticos para validar os resultados encontrados, ou seja, para avaliar qual configuração do RC possui o melhor desempenho na previsão da radiação. Os testes utilizaram os 30 EMAs, em percentual, de cada configuração, como entrada para realizar a análise. Para realizar esta análise utilizou-se o *software* matemático R, já que este possui todas as implementações dos testes que foram utilizados. Este *software* utiliza como padrão um nível de significância ( $\alpha$ ) previamente definido no valor de 0,05.

As próximas seções descrevem cada teste realizado, seus objetivos e como cada um analisa os resultados encontrados.

#### 3.4.1 Teste Shapiro-Wilk

Antes de utilizar um teste paramétrico em um conjunto de dados é necessário verificar se as amostras são normalmente distribuídas e se elas possuem variâncias estatisticamente iguais. Caso isso seja validado, pode-se aplicar um teste paramétrico, caso contrário, deverá ser utilizado um teste não paramétrico. Os pontos positivos e negativos dos testes paramétricos e não paramétricos são descritos na Tabela 13.

**Tabela 13.** Pontos Positivos e Negativos dos Testes Paramétricos e Não Paramétricos

[Fonte: elaboração própria]

Teste	Ponto Positivo	Ponto Negativo
Paramétrico	Muito Significante (maior análise das amostras)	Faz Suposição
Não Paramétrico	Não Faz Suposição	Pouco Significante (menor análise das amostras)

O Teste de Shapiro-Wilk tem como objetivo verificar se as amostras são normalmente distribuídas. Para isso, é necessária a formulação das hipóteses nula e alternativa, conforme a Tabela 14.

**Tabela 14.** Hipóteses Nula e Alternativa do Teste Shapiro-Wilk  
[Fonte: elaboração própria]

Hipótese	Descrição
Hipótese Nula	A amostra provém de uma população normal
Hipótese Alternativa	A amostra não provém de uma população normal

Dessa forma, ao executar o teste para cada amostra, deve-se analisar o *p-value* encontrado e comparar com o nível de significância definido como 0,05. Caso o *p-value* seja menor que  $\alpha$ , a hipótese nula deve ser rejeitada e a amostra não deve ser considerada normalmente distribuída.

### 3.4.2 Teste F

O Teste F tem como objetivo verificar se as variâncias entre duas amostras são estatisticamente iguais, ou seja, provenientes de uma mesma população.

Da mesma forma que o teste anterior, é necessário a formulação das hipóteses para analisar o resultado encontrado, conforme a Tabela 15.

**Tabela 15.** Hipóteses Nula e Alternativa do Teste F  
[Fonte: elaboração própria]

Hipótese	Descrição
Hipótese Nula	As amostras possuem variâncias estatisticamente iguais
Hipótese Alternativa	As amostras possuem variâncias estatisticamente diferentes

Após a realização deste teste, deve-se verificar o *p-value*, caso este seja menor que o nível de significância  $\alpha$ , a hipótese nula deve ser rejeitada e as amostras possuem variâncias estatisticamente diferentes, assumindo a distribuição normal das amostras.

Com o resultado deste teste e com o da seção anterior, pode-se aplicar ou não um teste paramétrico. O teste paramétrico, para ser utilizado, é necessário ter suas amostras normalmente distribuídas e as variâncias das amostras estatisticamente iguais.

### 3.4.3 Teste t-Student

O teste t-Student realiza a análise das médias dos valores de duas amostras independentes.

Para analisar o resultado obtido, é necessário ter formulado as hipóteses nulas e alternativas, conforme a Tabela 16. O objetivo desse teste é verificar se as médias das amostras são estatisticamente iguais, ou se há alguma diferença entre elas, e neste último caso, a amostra que tiver a menor média de taxa de erro, pode ser considerada com um melhor desempenho.

**Tabela 16.** Hipóteses Nula e Alternativa do Teste t-Student  
[Fonte: elaboração própria]

Hipótese	Descrição
Hipótese Nula	As médias das amostras são estatisticamente iguais
Hipótese Alternativa	As médias das amostras são estatisticamente diferentes

A análise deve ser feita através do *p-value* encontrado após o teste. Caso ele seja menor que o nível de significância  $\alpha$ , a hipótese nula é rejeitada e as médias das amostras são consideradas estatisticamente diferentes.

Neste trabalho serão comparados as configurações, de cada caso (ver Tabela 12), no RC, e caso a hipótese nula seja rejeitada, a configuração que apresentar a menor média de taxa de erro, ou seja, a menor média da diferença entre os valores calculados e previstos, será considerada a que possui melhor desempenho para a previsão da radiação.

### 3.4.4 Teste da Soma dos Postos de Wilcoxon

O Teste da Soma dos Postos de Wilcoxon é útil quando precisa comprovar os resultados, e estes não são normais ou possuem variâncias estatisticamente diferentes. Este teste faz a sua análise baseado na mediana de duas amostras independentes. As hipóteses nulas e alternativas estão formuladas, conforme a Tabela 17.

**Tabela 17.** Hipóteses Nula e Alternativa do Teste da Soma dos postos de Wilcoxon  
[Fonte: elaboração própria]

Hipótese	Descrição
Hipótese Nula	As medianas das amostras são estatisticamente iguais
Hipótese Alternativa	As medianas das amostras são estatisticamente diferentes

Assim como nos testes anteriores, o *p-value* deve ser comparado com o nível de significância. Caso esse valor seja menor que 0,05, a hipótese nula deve ser rejeitada implicando que há diferença entre as duas amostras, ou seja, as medianas das amostras são consideradas estatisticamente diferentes. Nesse caso, a amostra com a menor média de taxa de erro, ou seja, a menor média da diferença entre os valores calculados e previstos, será considerada a que possui melhor desempenho para a previsão da radiação.

# Capítulo 4

## Resultados

Este capítulo irá apresentar todos os resultados obtidos nas simulações do RC para a variável de radiação como resposta para a previsão. Além disso, será feita uma análise estatística, com os valores do EMA de cada configuração utilizada pelo RC.

Como foi definido no capítulo anterior, 11 casos (modificações da base de dados original) (ver Tabela 11) foram definidos a fim de verificar qual a melhor configuração do RC para realizar a previsão da radiação.

### 4.1 Cenário 1 – Caso 1 com 22 neurônios na camada de entrada

Inicialmente foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do *reservoir* e a Tabela 18 exibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 1 – Caso 1 com 22 neurônios na camada de entrada.

**Tabela 18.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 1 – Caso 1  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	48,83%
50	44,09%
75	41,40%
100	39,75%

A partir desses resultados, a sequência de testes estatísticos foi realizada.

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 1 – Caso 1, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*.

## **4.2 Cenário 1 – Caso 2 com 9 neurônios na camada de entrada**

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do *reservoir* e a Tabela 19 exhibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 1 – Caso 2 com 9 neurônios na camada de entrada.

**Tabela 19.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 1 – Caso 2  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	54,34%
50	46,27%
75	43,44%
100	42,47%

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes, e com isso, o teste t-Student não pode ser realizado. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes, e com isso, o teste t-Student não foi realizado. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 1 – Caso 2, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*.

### 4.3 Cenário 1 – Caso 3 com 2 neurônios na camada de entrada

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do *reservoir* e a Tabela 20 exibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 1 – Caso 3 com 2 neurônios na camada de entrada.

**Tabela 20.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 1 – Caso 3

[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	69,19%
50	66,10%
75	63,88%
100	62,59%

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi menor que 0,05, logo as amostras não são normalmente distribuídas e será utilizado o teste não paramétrico. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi menor que 0,05, logo as amostras não são normalmente distribuídas. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 1 – Caso 3, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*.

## 4.4 Melhor Cenário 1

Para definir qual o melhor Cenário 1, serão analisadas as melhores configurações dos casos 1, 2 e 3 do Cenário 1 (ver Tabela 11), de acordo com a Tabela 21.

**Tabela 21.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 1  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
100 (Caso 1)	39,75%
100 (Caso 2)	42,47%
100 (Caso 3)	62,59%

O teste de Shapiro-Wilk foi realizado para 100 (Caso 1) e 100 (Caso 2) neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100 (Caso 1), pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 100 (Caso 1) e 100 (Caso 3) neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100 (Caso 1), pois possui a menor média da taxa de erro.

Para o Cenário 1, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*, 22 neurônios na camada de entrada, correlação maior que 0,4 e função de ativação sendo a sigmóide logística, ou seja, Caso 1.

## 4.5 Cenário 2 – Caso 1 com 15 neurônios na camada de entrada

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do *reservoir* e a Tabela 22 exhibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 2 – Caso 1 com 15 neurônios na camada de entrada.

**Tabela 22.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 2 – Caso 1  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	32,35%
50	30,70%
75	29,92%
100	29,65%

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi menor que 0,05, logo as amostras não são normalmente distribuídas. O teste de Wilcoxon foi realizado e o nível de significância foi menor

que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 2 – Caso 1, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*.

## **4.6 Cenário 2 – Caso 2 com 5 neurônios na camada de entrada**

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do *reservoir* e a Tabela 23 exhibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 2 – Caso 2 com 5 neurônios na camada de entrada.

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias

são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

**Tabela 23.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 2 – Caso 2  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	38,68%
50	37,74%
75	37,56%
100	37,58%

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi maior que 0,05, logo as médias são estatisticamente iguais. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois, para as médias estatisticamente iguais, o menor número de neurônios é melhor.

Para o Cenário 2 – Caso 2, de acordo com a análise estatística realizada, a melhor quantidade é 75 neurônios na camada do *reservoir*.

## 4.7 Melhor Cenário 2

Para definir qual o melhor Cenário 2, serão analisadas as melhores configurações dos casos 1 e 2 do Cenário 2 (ver Tabela 11), de acordo com a Tabela 24.

**Tabela 24.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 2

[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
100 (Caso 1)	29,65%
75 (Caso 2)	37,56%

O teste de Shapiro-Wilk foi realizado para 100 (Caso 1) e 75 (Caso 2) neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100 (Caso 1), pois possui a menor média da taxa de erro.

Para o Cenário 2, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*, 15 neurônios na camada de entrada, correlação maior que 0,4 e função de ativação sendo a sigmóide logística, ou seja, Caso 1.

## 4.8 Cenário 3 – Caso 1 com 22 neurônios na camada de entrada

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do *reservoir* e a Tabela 25 exhibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 3 – Caso 1 com 22 neurônios na camada de entrada.

**Tabela 25.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 3 – Caso 1  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	57,58%
50	48,98%
75	45,88%
100	43,81%

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi menor que 0,05, logo as amostras não são normalmente distribuídas. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 3 – Caso 1, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*.

## 4.9 Cenário 3 – Caso 2 com 9 neurônios na camada de entrada

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do reservoir e a Tabela 26 exhibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 3 – Caso 2 com 9 neurônios na camada de entrada.

**Tabela 26.** Média das taxas de erro para quantidade de neurônios na camada do reservoir do Cenário 3 – Caso 2

[Fonte: elaboração própria]

Quantidade de neurônios na camada do reservoir	Média da taxa de erro (30 simulações)
25	56,97%
50	49,09%
75	46,54%
100	44,93%

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 3 – Caso 2, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*.

## 4.10 Cenário 3 – Caso 3 com 2 neurônios na camada de entrada

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do *reservoir* e a Tabela 27 exibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 3 – Caso 3 com 2 neurônios na camada de entrada.

**Tabela 27.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 3 – Caso 3  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	71,22%
50	66,99%
75	65,08%
100	63,67%

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a

melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 3 – Caso 3, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*.

## 4.11 Melhor Cenário 3

Para definir qual o melhor Cenário 3, serão analisadas as melhores configurações dos casos 1, 2 e 3 do Cenário 3 (ver Tabela 11), de acordo com a Tabela 28.

**Tabela 28.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 3

[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
100 (Caso 1)	43,81%
100 (Caso 2)	44,93%
100 (Caso 3)	63,67%

O teste de Shapiro-Wilk foi realizado para 100 (Caso 1) e 100 (Caso 2) neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100 (Caso 1), pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 100 (Caso 1) e 100 (Caso 3) neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100 (Caso 1), pois possui a menor média da taxa de erro.

Para o Cenário 3, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*, 22 neurônios na camada de entrada, correlação maior que 0,4 e função de ativação sendo a tangente hiperbólica, ou seja, Caso 1.

## **4.12 Cenário 4 – Caso 1 com 15 neurônios na camada de entrada**

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do *reservoir* e a Tabela 29 exhibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 4 – Caso 1 com 15 neurônios na camada de entrada.

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a

melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

**Tabela 29.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 4 – Caso 1  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	34,17%
50	32,40%
75	31,48%
100	30,94%

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 4 – Caso 1, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*.

### 4.13 Cenário 4 – Caso 2 com 5 neurônios na camada de entrada

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do reservoir e a Tabela 30 exibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 4 – Caso 2 com 5 neurônios na camada de entrada.

**Tabela 30.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 4 – Caso 2  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	39,90%
50	38,52%
75	38,38%
100	38,42%

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi menor que 0,05, logo as amostras não são normalmente distribuídas. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi maior que 0,05, logo as medianas são estatisticamente iguais. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois, para as medianas estatisticamente iguais, o menor número de neurônios é melhor.

O teste de Shapiro-Wilk foi realizado para 50 e 100 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O

teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi maior que 0,05, logo as medianas são estatisticamente iguais. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois, para as medianas estatisticamente iguais, o menor número de neurônios é melhor.

Para o Cenário 4 – Caso 2, de acordo com a análise estatística realizada, a melhor quantidade é 50 neurônios na camada do *reservoir*.

## 4.14 Melhor Cenário 4

Para definir qual o melhor Cenário 4, serão analisadas as melhores configurações dos casos 1 e 2 do Cenário 4 (ver Tabela 11), de acordo com a Tabela 31.

**Tabela 31.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 4  
[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
100 (Caso 1)	30,94%
50 (Caso 2)	38,52%

O teste de Shapiro-Wilk foi realizado para 100 (Caso 1) e 50 (Caso 2) neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi maior que 0,05, logo as variâncias são estatisticamente iguais. O teste t-Student foi realizado e o nível de significância foi menor que 0,05, logo as médias são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100 (Caso 1), pois possui a menor média da taxa de erro.

Para o Cenário 4, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*, 15 neurônios na camada de entrada, correlação maior que 0,4 e função de ativação sendo a tangente hiperbólica, ou seja, Caso 1.

## 4.15 Cenário 5 – Caso 1 com 10 neurônios na camada de entrada

Foram realizadas as 30 simulações com o RC para 25, 50, 75 e 100 neurônios na camada do reservoir e a Tabela 32 exibe a média das taxas de erro encontradas por cada uma das configurações utilizando o Cenário 5 – Caso 1 com 10 neurônios na camada de entrada.

**Tabela 32.** Média das taxas de erro para quantidade de neurônios na camada do *reservoir* do Cenário 5 – Caso 1

[Fonte: elaboração própria]

Quantidade de neurônios na camada do <i>reservoir</i>	Média da taxa de erro (30 simulações)
25	61,27%
50	51,57%
75	48,13%
100	46,01%

O teste de Shapiro-Wilk foi realizado para 25 e 50 neurônios e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 50, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 50 e 75 neurônios e o nível de significância foi menor que 0,05, logo as amostras não são normalmente distribuídas. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 75, pois possui a menor média da taxa de erro.

O teste de Shapiro-Wilk foi realizado para 75 e 100 neurônios e o nível de significância foi menor que 0,05, logo as amostras não são normalmente

distribuídas. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, a melhor quantidade de neurônios na camada do *reservoir* vai ser 100, pois possui a menor média da taxa de erro.

Para o Cenário 5, de acordo com a análise estatística realizada, a melhor quantidade é 100 neurônios na camada do *reservoir*, 10 neurônios na camada de entrada, correlação maior que 0,4 e função de ativação sendo a tangente hiperbólica, ou seja, Caso 1.

## 4.16 Melhor Cenário para Previsão da Radiação

Feita a análise dos cenários 1, 2, 3, 4 e 5 (ver Tabela 11), foi definido a melhor quantidade de neurônios na camada do *reservoir* e na camada de entrada, a melhor correlação, a melhor função de ativação e a menor média da taxa de erro para cada cenário. A Tabela 33 resume os resultados encontrados pela rede neural utilizada nesse trabalho.

**Tabela 33.** Média das taxas de erro para as melhores configurações de cada cenário [Fonte: elaboração própria]

Cenários	Função de Ativação	Número de Neurônios na Camada de Entrada	Número de Neurônios na Camada do <i>reservoir</i>	Correlação	Média da taxa de erro (30 simulações)
Cenário 1	Sigmóide Logística	22	100	Maior que 0,4	39,75%
Cenário 2	Sigmóide Logística	15	100	Maior que 0,4	29,65%
Cenário 3	Tangente Hiperbólica	22	100	Maior que 0,4	43,81%
Cenário 4	Tangente Hiperbólica	15	100	Maior que 0,4	30,94%
Cenário 5	Tangente Hiperbólica	10	100	Maior que 0,4	46,01%

Feita a análise da Tabela 33, o Cenário 2 e o Cenário 4 foram os cenários que obtiveram a menor média da taxa de erro e para definir qual o melhor para a previsão da radiação, serão aplicados testes estatísticos nestes cenários.

O teste de Shapiro-Wilk foi realizado para o Cenário 2 e para o Cenário 4 e o nível de significância foi maior que 0,05, logo as amostras são normalmente distribuídas. O teste F foi realizado e o nível de significância foi menor que 0,05, logo as variâncias são estatisticamente diferentes. O teste de Wilcoxon foi realizado e o nível de significância foi menor que 0,05, logo as medianas são estatisticamente diferentes. Por isso, o melhor cenário para este trabalho será o Cenário 2, pois possui a menor média da taxa de erro.

Os resultados de todos os testes estatísticos podem ser encontrados no Apêndice A. O *script* que foi utilizado para a execução dos testes no *software* R pode ser encontrado no Apêndice B.

A partir da Tabela 33, pode-se concluir que o RC obteve resultados variados, devido as diferentes configurações de cada cenário. O próximo capítulo irá descrever as conclusões obtidas com este trabalho.

# Capítulo 5

## Conclusão e Trabalhos Futuros

### 5.1 Conclusões

A energia solar é uma fonte de energia renovável ainda pouco explorada, sendo necessário o desenvolvimento de pesquisas que auxiliem no crescimento do uso desse recurso natural. Essa fonte de energia pode ser transformada diretamente em energia elétrica pelo uso de painéis solares, auxiliando no consumo da energia elétrica, ou ser utilizada como fonte de calor para aquecimento da água.

Este trabalho de conclusão de curso teve como objetivo utilizar uma arquitetura de redes neurais, denominada *Reservoir Computing*, para realizar a previsão da radiação para 6 horas à frente, e comparar os resultados obtidos de cada cenário (modificações na base de dados), para determinar qual configuração obteve o melhor resultado. A radiação é uma variável que auxilia no desenvolvimento de projetos que utilizam a energia solar como fonte de energia. A base de dados utilizada foi obtida no site do Instituto Nacional de Meteorologia (INMET), e a estação meteorológica escolhida para a coleta de dados, está localizada na cidade de Petrolina, no estado de Pernambuco.

Neste trabalho foram utilizadas 11 configurações diferentes para a previsão da radiação no RC. Pelas simulações e testes estatísticos, foi possível determinar que a configuração do RC, para a variável de radiação, que apresentou o melhor desempenho foi o Cenário 2. Isso pode ser explicado pelo fato deste cenário possuir, apenas, valores positivos de radiação, possibilitando um melhor aprendizado da rede. Diferentemente de outros cenários, que além de valores positivos, possuíam também valores negativos para a variável de radiação.

A configuração deste cenário tem 15 neurônios na camada de entrada, 100 neurônios na camada do *reservoir*, 6 neurônios na camada de saída e função de ativação sigmóide logística.

Outra conclusão deste trabalho é que quando utiliza um cenário com a variável de radiação em conjunto com outras variáveis, o desempenho da rede é superior, ao contrário, de que quando utiliza um cenário apenas com a variável de radiação. Isso pode ser observado na Tabela 33, onde os cenários 1, 2, 3 e 4 utilizam a variável de radiação em conjunto com outras variáveis, e possuem as médias das taxas de erro menores em comparação ao cenário 5, que utiliza apenas a variável de radiação e possui a maior média da taxa de erro, ou seja, a maior média da diferença entre os valores calculados e previstos.

## 5.2 Trabalhos Futuros

Como trabalhos futuros, pretende-se a realização de um estudo mais aprofundado da previsão da radiação, como a definição de quais variáveis auxiliam na previsão, estudo da arquitetura *Deep Learning*, que são métodos que focam em aprender características e descobrir múltiplos níveis de abstração, a definição de outras configurações e um estudo comparativo entre o *Reservoir Computing* e o *Deep Learning*. Desta forma será possível determinar quais fatores e quais arquiteturas influenciam de forma positiva na previsão da radiação.

# Bibliografia

- [1] COUTINHO, L. D. Utilizando reservo r computing para realizar diagn stico precoce de mal de Alzheimer. Monografia (Gradua o em Engenharia da Computa o) – Universidade de Pernambuco – UPE, Recife, 2012.
- [2] CRESESB. Centro de Refer ncia para Energia Solar e E lica S rgio Brito. (2008) Radia o Solar. Dispon vel em: <[http://cresesb.cepel.br/index.php?section=com\\_content&cid=301](http://cresesb.cepel.br/index.php?section=com_content&cid=301)>. Acesso em 01 de novembro de 2016.
- [3] HAYKIN, S. Redes Neurais: Princ pios e Pr ticas. [S.I.]: Bookman, 2007.
- [4] INMET. (2016) SOBRE O INMET. Dispon vel em: <[http://www.inmet.gov.br/portal/index.php?r=home/page&page=sobre\\_inmet](http://www.inmet.gov.br/portal/index.php?r=home/page&page=sobre_inmet)>. Acesso em 02 de novembro de 2016.
- [5] JURISTO, N.; MORENO, A. M. *Basics of Software Engineering Experimentation*. [S.I.]: Kluwer Academic Publishers, 2001.
- [6] MARTINS, F. R.; PEREIRA, E. B.; ECHER, M. P. S. Levantamento dos recursos de energia solar no Brasil com o emprego de sat lite geoestacion rio – o Projeto Swera, Revista Brasileira de Ensino de F sica, vol. 26, No. 2, pp. 145–159, 2004.
- [7] MONTEITH, J. L.; UNSWORTH, M. H. *Principles of environmental physics*. 2.ed. London: Edward Arnd, 1990. 291p.
- [8] NICOLETTI, J. (2013) Energia solar: pa ses com maior capacidade instalada. Dispon vel em: <<http://www.dw.com/pt/energia-solar-pa%C3%ADses-com-maior-capacidade-instalada/a-16991069>>. Acesso em 08 de setembro de 2016.
- [9] PENA, R. F. A. (2016) Hidrel tricas no Brasil. Dispon vel em: <<http://mundoeducacao.bol.uol.com.br/geografia/hidreletricas-no-brasil.htm>>. Acesso em 05 de setembro de 2016.

- [10] PORTAL BRASIL. (2016) Brasil estará entre os 20 países com maior geração solar em 2018. Disponível em: <<http://www.brasil.gov.br/infraestrutura/2016/01/brasil-estara-entre-os-20-paises-com-maior-geracao-solar-em-2018>>. Acesso em 08 de setembro de 2016.
- [11] PORTAL ENERGIA. (2016) Vantagens e desvantagens da energia solar. Disponível em: <<http://www.portal-energia.com/vantagens-e-desvantagens-da-energia-solar/>>. Acesso em 01 de novembro de 2016.
- [12] PORTAL SOLAR. ENERGIA FOTOVOLTAICA. Disponível em: <<http://www.portalsolar.com.br/energia-fotovoltaica.html>>. Acesso em 01 de novembro de 2016.
- [13] PORTAL SOLAR. TIPOS DE ENERGIA SOLAR. Disponível em: <<http://www.portalsolar.com.br/tipos-de-energia-solar.html>>. Acesso em 01 de novembro de 2016.
- [14] SABOIA, A. (2015) Usina Solar abastece 30% do consumo de energia da Arena Pernambuco. Disponível em: <<http://www.blogdasppps.com/2015/05/usina-solar-abastece-30-do-consumo-de.html>>. Acesso em 01 de novembro de 2016.
- [15] SGT. Superintendência de Gestão Tarifária da Agência Nacional de Energia Elétrica (ANEEL). (2015) Bandeiras Tarifárias. Disponível em: <<http://www.aneel.gov.br/bandeiras-tarifarias>>. Acesso em 05 de setembro de 2016.
- [16] VALENÇA, M. J. S. Fundamentos das Redes Neurais: exemplos em JAVA. 2ªed.. ed. [S.I.]: Livro Rápido, 2009. 384p.
- [17] VERSTRAETEN, D. Reservoir Computing: computation with dynamical systems. XXII, 178 p. Tese (Doutorado) – Ghent University. Faculty of Engineering, Ghent, Belgium, 2009.

# Apêndice A

## Resultados da Análise Estatística no *Software R*

Neste Apêndice estão contidas as tabelas referentes aos resultados encontrados após a execução dos testes estatísticos, conforme está no Capítulo 4.

**Tabela 34.** Resultado dos testes estatísticos do Cenário 1  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	Caso 1	Caso 2	Caso 3
		<i>p-value</i>	<i>p-value</i>	<i>p-value</i>
25 – 50	Shapiro-Wilk 1	0,2499	0,07371	0,02229
	Shapiro-Wilk 2	0,4831	0,2509	0,02034
	Teste F	0,1425	0,01266	Não se aplica
	Teste t-Student	$2,2 * 10^{-16}$	Não se aplica	Não se aplica
	Teste de Wilcoxon	Não se aplica	$2,2 * 10^{-16}$	$2,2 * 10^{-16}$
50 – 75	Shapiro-Wilk 1	0,4831	0,2509	0,02034
	Shapiro-Wilk 2	0,8065	0,05545	0,9777
	Teste F	0,1519	$2,934 * 10^{-6}$	Não se aplica
	Teste t-Student	$5,365 * 10^{-15}$	Não se aplica	Não se aplica
	Teste de Wilcoxon	Não se aplica	$3,213 * 10^{-16}$	$7,61 * 10^{-16}$
75 – 100	Shapiro-Wilk 1	0,8065	0,05545	0,9777
	Shapiro-Wilk 2	0,8234	0,3117	0,3644
	Teste F	0,2877	0,7046	0,002374
	Teste t-Student	$1,908 * 10^{-11}$	$7,377 * 10^{-13}$	Não se aplica
	Teste de Wilcoxon	Não se aplica	Não se aplica	$1,157 * 10^{-14}$

**Tabela 35.** Resultado dos testes estatísticos do Melhor Cenário 1  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	<i>p-value</i>
100 (Caso 1) 100 (Caso 2)	Shapiro-Wilk 1	0,8234
	Shapiro-Wilk 2	0,3117
	Teste F	0,004598
	Teste t-Student	Não se aplica
	Teste de Wilcoxon	$2,2 * 10^{-16}$
100 (Caso 1) 100 (Caso 3)	Shapiro-Wilk 1	0,8234
	Shapiro-Wilk 2	0,3644
	Teste F	0,0002594
	Teste t-Student	Não se aplica
	Teste de Wilcoxon	$2,2 * 10^{-16}$

**Tabela 36.** Resultado dos testes estatísticos do Cenário 2  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	Caso 1	Caso 2
		<i>p-value</i>	<i>p-value</i>
25 – 50	Shapiro-Wilk 1	0,000696	0,4171
	Shapiro-Wilk 2	0,8477	0,5579
	Teste F	Não se aplica	$5,594 * 10^{-5}$
	Teste t-Student	Não se aplica	Não se aplica
	Teste de Wilcoxon	$1,64 * 10^{-15}$	$2,2 * 10^{-16}$
50 – 75	Shapiro-Wilk 1	0,8477	0,5579
	Shapiro-Wilk 2	0,5589	0,3349
	Teste F	0,02095	0,2582
	Teste t-Student	Não se aplica	0,0004575
	Teste de Wilcoxon	$4,6 * 10^{-15}$	Não se aplica
75 – 100	Shapiro-Wilk 1	0,5589	0,3349
	Shapiro-Wilk 2	0,2724	0,7505
	Teste F	0,8173	0,1672
	Teste t-Student	$6,851 * 10^{-6}$	0,6333
	Teste de Wilcoxon	Não se aplica	Não se aplica

**Tabela 37.** Resultado dos testes estatísticos do Melhor Cenário 2  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	<i>p</i> -value
100 (Caso 1) 75 (Caso 2)	Shapiro-Wilk 1	0,2724
	Shapiro-Wilk 2	0,3349
	Teste F	0,9173
	Teste t-Student	$2,2 * 10^{-16}$
	Teste de Wilcoxon	Não se aplica

**Tabela 38.** Resultado dos testes estatísticos do Cenário 3  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	Caso 1	Caso 2	Caso 3
		<i>p</i> -value	<i>p</i> -value	<i>p</i> -value
25 – 50	Shapiro-Wilk 1	0,0291	0,8173	0,05571
	Shapiro-Wilk 2	0,7644	0,23	0,4803
	Teste F	Não se aplica	0,1286	0,7043
	Teste t-Student	Não se aplica	$2,2 * 10^{-16}$	$2,2 * 10^{-16}$
	Teste de Wilcoxon	$6,308 * 10^{-15}$	Não se aplica	Não se aplica
50 – 75	Shapiro-Wilk 1	0,7644	0,23	0,4803
	Shapiro-Wilk 2	0,8109	0,8611	0,4002
	Teste F	0,09133	0,02975	0,1428
	Teste t-Student	$5,839 * 10^{-10}$	Não se aplica	$1,691 * 10^{-9}$
	Teste de Wilcoxon	Não se aplica	$3,093 * 10^{-10}$	Não se aplica
75 – 100	Shapiro-Wilk 1	0,8109	0,8611	0,4002
	Shapiro-Wilk 2	0,8479	0,5104	0,1751
	Teste F	0,09819	0,4557	0,04726
	Teste t-Student	$6,132 * 10^{-9}$	$1,273 * 10^{-8}$	Não se aplica
	Teste de Wilcoxon	Não se aplica	Não se aplica	$9,536 * 10^{-10}$

**Tabela 39.** Resultado dos testes estatísticos do Melhor Cenário 3  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	<i>p-value</i>
100 (Caso 1) 100 (Caso 2)	Shapiro-Wilk 1	0,8479
	Shapiro-Wilk 2	0,5104
	Teste F	0,5918
	Teste t-Student	$1,805 * 10^{-5}$
	Teste de Wilcoxon	Não se aplica
100 (Caso 1) 100 (Caso 3)	Shapiro-Wilk 1	0,8479
	Shapiro-Wilk 2	0,1751
	Teste F	0,0121
	Teste t-Student	Não se aplica
	Teste de Wilcoxon	$2,2 * 10^{-16}$

**Tabela 40.** Resultado dos testes estatísticos do Cenário 4  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	Caso 1	Caso 2
		<i>p-value</i>	<i>p-value</i>
25 – 50	Shapiro-Wilk 1	0,6146	0,02339
	Shapiro-Wilk 2	0,1412	0,5731
	Teste F	0,3863	Não se aplica
	Teste t-Student	$2,2 * 10^{-16}$	Não se aplica
	Teste de Wilcoxon	Não se aplica	$1,133 * 10^{-15}$
50 – 75	Shapiro-Wilk 1	0,1412	0,5731
	Shapiro-Wilk 2	0,2395	0,9922
	Teste F	0,004517	0,00508
	Teste t-Student	Não se aplica	Não se aplica
	Teste de Wilcoxon	$4,381 * 10^{-12}$	0,1342
75 – 100 (Caso 1) 50 – 100 (Caso 2)	Shapiro-Wilk 1	0,2395	0,5731
	Shapiro-Wilk 2	0,1485	0,5682
	Teste F	0,3314	$8,073 * 10^{-5}$
	Teste t-Student	$4,224 * 10^{-8}$	Não se aplica
	Teste de Wilcoxon	Não se aplica	0,328

**Tabela 41.** Resultado dos testes estatísticos do Melhor Cenário 4  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	<i>p-value</i>
100 (Caso 1) 50 (Caso 2)	Shapiro-Wilk 1	0,1485
	Shapiro-Wilk 2	0,5731
	Teste F	0,9515
	Teste t-Student	$2,2 * 10^{-16}$
	Teste de Wilcoxon	Não se aplica

**Tabela 42.** Resultado dos testes estatísticos do Cenário 5  
[Fonte: elaboração própria]

Neurônios na camada do reservóir	Teste	Caso 1
		<i>p-value</i>
25 – 50	Shapiro-Wilk 1	0,1575
	Shapiro-Wilk 2	0,4739
	Teste F	$9,747 * 10^{-8}$
	Teste t-Student	Não se aplica
	Teste de Wilcoxon	$2,2 * 10^{-16}$
50 – 75	Shapiro-Wilk 1	0,4739
	Shapiro-Wilk 2	0,001113
	Teste F	Não se aplica
	Teste t-Student	Não se aplica
	Teste de Wilcoxon	$4,939 * 10^{-11}$
75 – 100	Shapiro-Wilk 1	0,001113
	Shapiro-Wilk 2	0,9531
	Teste F	Não se aplica
	Teste t-Student	Não se aplica
	Teste de Wilcoxon	$2,56 * 10^{-11}$

**Tabela 43.** Resultado dos testes estatísticos do Melhor Cenário  
[Fonte: elaboração própria]

<b>Neurônios na camada do <i>reservoir</i></b>	<b>Teste</b>	<b><i>p-value</i></b>
100 (Cenário 2) 100 (Cenário 4)	Shapiro-Wilk 1	0,2724
	Shapiro-Wilk 2	0,1485
	Teste F	0,002512
	Teste t-Student	Não se aplica
	Teste de Wilcoxon	$2,2 * 10^{-16}$

# Apêndice B

## *Script* utilizado para a execução da Análise Estatística no *Software R*

```
dados <- read.csv(file.choose(), header = TRUE, sep = ";")
```

```
# LER DADOS  
#CENARIO 1 – CASOS 1 / 2 / 3  
#CENARIO 2 – CASOS 1 / 2  
#CENARIO 3 – CASOS 1 / 2 / 3  
#CENARIO 4 – CASO 1  
#CENARIO 5 – CASO 1  
caso25n <- c(dados[,1])  
caso50n <- c(dados[,2])  
caso75n <- c(dados[,3])  
caso100n <- c(dados[,4])
```

```
shapiro.test(caso25n)  
shapiro.test(caso50n)  
shapiro.test(caso75n)  
shapiro.test(caso100n)
```

```
var.test(caso25n, caso50n)  
t.test(caso25n, caso50n)  
wilcox.test(caso25n, caso50n)
```

```
var.test(caso50n, caso75n)  
t.test(caso50n, caso75n)  
wilcox.test(caso50n, caso75n)
```

```
var.test(caso75n, caso100n)  
t.test(caso75n, caso100n)  
wilcox.test(caso75n, caso100n)
```

```
# LER DADOS  
#CENARIO 4 – CASO 2  
caso25n <- c(dados[,1])  
caso50n <- c(dados[,2])  
caso75n <- c(dados[,3])  
caso100n <- c(dados[,4])
```

```
shapiro.test(caso25n)  
shapiro.test(caso50n)
```

shapiro.test(caso75n)  
shapiro.test(caso100n)

var.test(caso25n, caso50n)  
t.test(caso25n, caso50n)  
wilcox.test(caso25n, caso50n)

var.test(caso50n, caso75n)  
t.test(caso50n, caso75n)  
wilcox.test(caso50n, caso75n)

var.test(caso50n, caso100n)  
t.test(caso50n, caso100n)  
wilcox.test(caso50n, caso100n)