



Sociedade Educacional Três de Maio - SETREM
Bacharelado em Sistemas de Informação

ANDRÉIA LUISA BARTH

CAMILA WOLFER

**APLICAÇÃO DE REDES NEURAIIS NA AVALIAÇÃO DA IRRADIAÇÃO SOLAR
COMO FONTE DE ENERGIA RENOVÁVEL**

Três de Maio

2016

**ANDRÉIA LUISA BARTH
CAMILA WOLFER**

**APLICAÇÃO DE REDES NEURAS NA AVALIAÇÃO DA IRRADIAÇÃO SOLAR
COMO FONTE DE ENERGIA RENOVÁVEL**

**Relatório de Conclusão de Curso Bacharelado
em Sistemas de Informação da Sociedade
Educativa Três de Maio – SETREM, para
obtenção de grau de Bacharel em Sistemas de
Informação.**

**Orientadores: M.Sc. Adalberto Lovato
Dr. Dalvan Jair Griebler**

Três de Maio

2016



A Comissão Examinadora, abaixo assinada, aprova o
Trabalho de Conclusão de Curso

**APLICAÇÃO DE REDES NEURAIS NA AVALIAÇÃO DA IRRADIAÇÃO SOLAR
COMO FONTE DE ENERGIA RENOVÁVEL**

Elaborado por:

ANDRÉIA LUÍSA BARTH

CAMILA WOLFER

apresentam à Faculdade Três de Maio como requisito parcial para obtenção do
grau de Bacharel em Sistemas de Informação.

Orientador: Prof. M.Sc. Adalberto Lovato
Bacharelado em Sistemas de Informação
Faculdade Três de Maio

Orientador: Prof. Dr. Dalvan Griebler
Bacharelado em Sistemas de Informação
Faculdade Três de Maio
Programa de Pós-Graduação em Ciência da Computação - PUCRS

Profa. Mestranda Denise Da Luz Siqueira
Bacharelado em Sistemas de Informação
Faculdade Três de Maio

Profa. M.Sc. Priscila Guarienti
Bacharelado em Sistemas de Informação
Faculdade Três de Maio

Profa. M.Sc. Vera Lúcia Lorenset Benedetti
Coordenação do Curso Bacharelado em Sistemas de Informação
Faculdade de Sistemas de Informação da SETREM

Três de Maio, 08 de agosto de 2016.

Dedicamos este trabalho especialmente aos nossos familiares, por todo apoio oferecido para que conseguíssemos chegar até aqui, e principalmente pela compreensão nos momentos em que estivemos ausentes.

AGRADECIMENTO

Agradecemos primeiramente a Deus, por ter iluminado o nosso caminho até aqui e por ter-nos dado força para superar todos os obstáculos enfrentados.

Agradecemos aos nossos orientadores, Adalberto Lovato e Dalvan Jair Griebler, por sempre se fazerem presentes para sanar dúvidas que surgiam durante a elaboração do trabalho, também pela paciência fornecida durante as explicações e por todo conhecimento que nos foi repassado.

Agradecemos a coordenadora do curso Vera Lúcia Lorenset Benedetti, por ter acreditado na proposta de trabalho e principalmente por sempre estar prontamente disposta a conversar conosco, bem como, realizar revisões de escrita.

Agradecemos aos nossos familiares e amigos, pelo incentivo a continuar buscando o conhecimento mesmo com todas as dificuldades enfrentadas e acreditando no mérito da titulação de Bacharel em Sistemas de Informação.

Gostaríamos também de destacar aqui, um colega em especial que infelizmente hoje não encontra-se mais entre nós, mas que foi muito importante durante o início da nossa caminhada, Dalvane Zanini, sempre nos apoiou para seguir acreditando no potencial do curso, auxiliou-nos na execução de trabalhos e que em nenhum momento apesar de dificuldades particulares deixou-nos abater pela tristeza, trazendo músicas, piadas e muitas risadas durante o pouco tempo que aproveitamos ao seu lado. Um grande abraço amigo.

RESUMO

Em consequência do avanço tecnológico e da interferência humana no cenário climático mundial, buscam-se cada vez mais alternativas que visam suprir a necessidade de gerar energia para bilhões de pessoas. A energia provinda do sol se renova naturalmente por meio do seu ciclo, e é utilizada como uma forma sustentável, visando o mínimo de impacto ao meio ambiente. No Brasil, a energia solar é uma das mais promissoras opções energéticas uma vez que a maior parte do seu território recebe elevada irradiação solar durante todo o ano. Nessa visão, surge o tema do presente estudo, que é focado na aplicação de redes neurais na avaliação da irradiação solar, como fonte de energia renovável. O trabalho, que visa avaliar a disponibilidade da energia provinda da irradiação solar, busca responder ao seguinte problema: A irradiação solar existente na região Noroeste do Rio Grande do Sul é adequada para uso, como fonte de energia renovável? Para auxílio na resolução desta problematização, fez-se uso de alguns métodos de abordagem, como o realismo crítico e a abordagem quantitativa foi utilizada na medição dos dados ambientes necessários para o estudo. Como métodos de procedimento fez-se uso da pesquisa bibliográfica com o objetivo de buscar conhecimento referente as áreas estudadas, e a coleta de dados, usada para coletar as informações providas da estação meteorológica da SETREM. A arquitetura da rede neural *Perceptron* projetada, e que trouxe resultados eficientes, possui uma camada de entrada contendo um vetor de 8 elementos, uma camada oculta de 20 neurônios, utilizou o algoritmo *Levenberg-Marquardt* para treinamento da rede, as funções *purelin* e *log-sigmóide* de transferência e uma camada de saída. A rede estruturada mostrou-se flexível quanto ao uso dos dados, podendo ser facilmente alterados sem grandes impactos em sua funcionalidade. Além disso, após análise dos resultados obtidos, conclui-se que a região Noroeste do Estado do Rio Grande do Sul teria sido capaz de gerar 1.211 kW/h de energia solar apenas na estação do Verão, ou seja, uma potência de 750 kW para uma usina que ocupasse uma área de um hectare, visto que possui boas previsões de irradiação solar, essencial para essa atividade.

Palavras-chave: Sistemas de Informação, Inteligência Artificial, Redes Neurais, Energia Solar, Matlab.

ABSTRACT

In consequence of technological advances and human interference with the global climate scenario, seek becoming more alternatives that meet the need of energy generated by billions of people. The stemmed energy from the sun renews itself naturally through its cycle, and is used as a sustainable way, aiming at minimal impact to the environment. In Brazil, the solar energy is one of the most promising energy options since most of its territory receives high solar radiation throughout the year. In this view, the subject of this study arises, which is focused on the application of neural networks in the evaluation of solar radiation, as a source of renewable energy. The work, which aims to assess the availability of stemmed energy of solar radiation, seeks to answer the following problem: The existing solar irradiation in the northwest of Rio Grande do Sul is suitable for use as a source of renewable energy? To aid in the resolution of this questioning, it was made use of some methods of approach, as critical realism and the quantitative approach was used the measurement of the environment data necessary for the study. As methods of procedure was done using literature in order to seek knowledge on the studied areas, and data collection, used to collect the information stemmed meteorological station SETREM. The architecture of the neural network Perceptron designed, and brought effective results, an input layer containing a vector of 8 elements, a hidden layer of 20 neurons, the algorithm used Levenberg-Marquardt for network training, purelin and transfer functions log-sigmoid and an output layer. The structured network proved to be flexible in the use of data, can be easily altered without substantial impact on its functionality. Besides that, after analysis of the results, it is concluded that the Rio Grande do Sul state Northwest region would have been able to generate 1,211 kW / h of solar energy only in the summer season, that is, an Power 750 kW for a plant that It occupies an area of one hectare, since it has good predictions of solar irradiation, essential for this activity.

Keywords: Information Systems, Artificial Intelligence, Neural Networks, Solar Energy, MATLAB.

LISTA DE SIGLAS

BPROP - *Backpropagation*

IA – Inteligência Artificial

MSE - *Mean Square Error*

RBPROP - *Resilient Propagation*

PMC - Perceptron de Múltiplas Camadas

R – Coeficiente de Correlação

RMSE - *Root Mean Square Error*

RNA – Rede Neural Artificial

RNAs – Redes Neurais Artificiais

SETREM – Sociedade Educacional Três de Maio

SIM – Módulo de interface dos sensores

USB – *Universal Serial Bus*

UV – Ultravioleta

LISTA DE QUADROS

Quadro 1 - Recursos Energéticos Renováveis e Uso	58
Quadro 2 - Exemplos de classificação de sistemas fotovoltaicos	61
Quadro 3 - Dados da estação meteorológica.....	77
Quadro 4 - Dados de Entrada utilizados na estruturação das redes	78
Quadro 5 - Parâmetros utilizados na configuração da rede	82
Quadro 6 - Entradas e <i>target</i> utilizados para testes da rede.....	83
Quadro 7 - Resultados verificados variando o número de neurônio na camada oculta	84
Quadro 8 - RMSE obtido a partir dos modelos de rede criados.....	88
Quadro 9 - Testes efetuados com rede neural de duas camadas ocultas.....	91
Quadro 10 - Comparativo entre trabalhos relacionados	103
Quadro 11 - Alcance dos objetivos.....	106
Quadro 12 - Cronograma de atividades.	113
Quadro 13 - Orçamento.....	114

LISTA DE FIGURAS

Figura 1 – Componentes do neurônio biológico.....	29
Figura 2 - Neurônio Artificial	30
Figura 3 - Mecanismo de aprendizado supervisionado.....	34
Figura 4 - Mecanismo de aprendizado não-supervisionado	35
Figura 5 - Rede com camada única	36
Figura 6 - Estrutura de rede neural com múltiplas camadas.....	37
Figura 7 - Neurônio Artificial com uma camada com estrutura recorrente.....	38
Figura 8 - Funcionamento de um neurônio computacional	41
Figura 9 - Tangente Hiperbólica	41
Figura 10 - Função Sigmoidal	42
Figura 11 - Cálculo da função linear.....	42
Figura 12 - Representação gráfica da função linear	43
Figura 13 - Ciclo de ajuste dos pesos	44
Figura 14 - Ilustração de rede Perceptron multicamadas	45
Figura 15 - Algoritmo de aprendizado Backpropagation	46
Figura 16 - Representação das duas fases de treinamento da rede PMC	47
Figura 17 - Perceptron contendo 3 neurônios	49
Figura 18 - Calculo da saída y.....	50
Figura 19 - Fluxograma do Algoritmo <i>Backpropagation</i>	52

Figura 20 - Descida do Gradiente	53
Figura 21 - Radiação solar á nível do solo	63
Figura 25 - Modelo da estrutura da Rede Neural Artificial com uma camada oculta.	79
Figura 26 - Função Purelin	80
Figura 27 - Metodologia utilizada no presente estudo.	81
Figura 28 - Erro quadrático (MSE).	85
Figura 29 - Desempenho do treinamento.....	86
Figura 30 - Regression.	87
Figura 31 - Modelo da estrutura da Rede Neural Artificial com duas camadas oculta.	89
Figura 32 - <i>Regression</i> rede neural de duas camadas ocultas.....	92
Figura 33 - Nível de radiação por m ²	93
Figura 34 - Modelo utilizado para treinamento das estações do ano.....	94
Figura 35 - Regression da estação verão	95
Figura 36 - Desempenho do treinamento da rede para os dados do verão.....	96
Figura 37 - Regression da estação outono	97
Figura 38 - Desempenho do treinamento da rede para os dados do outono	98
Figura 39 - Regression da estação inverno.....	99
Figura 40 - Desempenho do treinamento da rede para os dados do inverno.....	100
Figura 41 - Regression da estação primavera	101
Figura 42 - Desempenho do treinamento da rede para os dados da primavera	102
Figura 43 - Disposição de componentes no <i>software</i> MATLAB.....	115
Figura 44 - Funções de coleta de dados da Estação Meteorológica da SETREM. .	118

SUMÁRIO

INTRODUÇÃO	15
1 CAMINHO METODOLÓGICO	17
1.1 TEMA	17
1.1.1 Delimitação do tema	17
1.2 OBJETIVOS	19
1.2.1 Objetivo geral	19
1.2.2 Objetivos específicos	19
1.3 JUSTIFICATIVA	20
1.4 PROBLEMA	23
1.5 HIPÓTESES	23
1.6 METODOLOGIA	23
1.6.1 Método de abordagem	23
1.6.2 Métodos de procedimentos	24
1.6.3 Técnicas	25
1.7 CRONOGRAMA	25
1.8 ORÇAMENTO	25
2 FUNDAMENTAÇÃO TEÓRICA	26
2.1 INTELIGÊNCIA ARTIFICIAL	26
2.1.1 Redes Neurais	27
2.1.2 Neurônios Biológicos	28
2.1.3 Neurônio artificial	29
2.1.4 Principais arquiteturas de redes neurais artificiais (RNAs)	32
2.1.5 Multiplicação de Matrizes	38
2.1.6 Derivadas	39
2.1.7 Funcionamento de uma rede Perceptron	40

2.1.8	Princípio de funcionamento do <i>Perceptron</i> multicamadas	44
2.1.9	Processo de treinamento do <i>Perceptron</i> multicamadas	47
2.1.10	Funcionamento Rede <i>Perceptron</i> contendo 3 neurônios	48
2.1.11	Método BPROP	50
2.1.12	Método RBPROP	55
2.1.13	<i>Levenberg-Marquardt</i>	56
2.2	ENERGIAS RENOVÁVEIS	58
2.2.1	Norma ABNT NBR 11704	60
2.2.2	Tecnologias de células fotovoltaicas	61
2.2.3	Radiação solar	62
2.3	TRABALHOS RELACIONADOS	65
2.3.1	Redes neurais artificiais para predição de radiação solar com base em estações indianas	65
2.3.2	Utilizando redes neurais artificiais para prever a irradiação solar direta	66
2.3.3	Previsão da radiação solar usando redes neurais artificiais	66
2.3.4	Aplicação de redes neurais na previsão de radiação solar para sistemas híbridos de energias renováveis	67
2.3.5	Rede neural artificial e <i>wavelet</i> de decomposição na previsão de radiação solar global horizontal	67
2.3.6	Utilizando redes neurais artificiais para previsão da radiação solar global em Teerã considerando partículas de poluição do ar	68
2.3.7	Estimativa da radiação solar global usando rede neural artificial em Qena, no Alto Egito	68
2.3.8	Utilização de redes neurais multicamadas para determinar a radiação solar global sobre superfícies inclinadas em Fianarantsoa Madagascar	69
2.3.9	Previsão de irradiação solar previsão baseado em redes neurais artificiais usando parâmetros estatísticos	69
2.3.10	Modelo de rede neural artificial de Previsão de Radiação Solar: Pedido de Dimensionamento Stand-Alone para sistema de energia fotovoltaica	70
2.3.11	Previsão de energia solar para a Malásia utilizando redes neurais artificiais	70
2.3.12	Previsão de radiação solar diária usando ANNS para Províncias da Turquia	71
2.3.13	Previsão de radiação solar usando redes neurais artificiais	72
2.3.14	Uma abordagem de pós-processamento rede neural para a melhoria das previsões NWP de Radiação Solar	72
3	ANÁLISE E DISCUSSÃO DE RESULTADOS	74
3.1	ANÁLISE DA SITUAÇÃO ATUAL	74

3.2	ESTRUTURAÇÃO DA REDE NEURAL COM UMA CAMADA OCULTA.....	77
3.2.1	Processo de treinamento da Rede	82
3.3	REDE NEURAL DE DUAS CAMADAS OCULTAS	89
3.4	COMPARATIVO DE IRRADIAÇÃO SOLAR ENTRE AS ESTAÇÕES DO ANO 92	
3.4.1	Verão	94
3.4.2	Outono	96
3.4.3	Inverno	98
3.4.4	Primavera.....	100
3.4.5	Análise dos trabalhos relacionados	102
3.5	PROPOSTAS FUTURAS.....	104
	REFERÊNCIAS BIBLIOGRÁFICAS	108

INTRODUÇÃO

Durante milênios, a energia foi para o homem apenas uma fonte de calor. Sua aplicação se restringia à defesa dos rigores do frio, à preparação dos alimentos e a instrumento de ritos religiosos. O sol era o astro que caracterizava o período diurno e se não era tratado como astro rei, era tido como um dos deuses a comandar o mundo.

A partir da revolução industrial, quando se descobriu que calor se transforma em trabalho, as fontes de calor, inicialmente lenha e carvão, se tornaram materiais estratégicos de desenvolvimento e poder. Indústrias se multiplicaram, meios de transporte se modificaram e alguns, como o automóvel, mudaram o mundo.

A transformação de energia em trabalho transformou o mundo para melhor. Populações inteiras passaram a ter acesso a melhores condições de vida. Mas o uso intensivo dos recursos geradores de energia trouxe duas consequências adversas: a exaustão dos combustíveis fósseis e a degradação do meio ambiente.

Nesse contexto, as fontes renováveis de energia se tornam centrais na atenção e no interesse das pesquisas científicas. Entre elas, a luz solar volta a elevar o sol como astro-rei (DIENSTMANN, 2009).

O avanço tecnológico traz ao homem a oportunidade de estudar, viabilizar e explorar novas fontes de energia para atender as necessidades produzidas por bilhões de pessoas.

As energias renováveis são conhecidas por se renovarem naturalmente por meio do seu ciclo e se originam, em última análise, da energia provinda do sol. Essas energias são utilizadas como uma forma sustentável e resultam no mínimo impacto ao meio ambiente, substituindo aos poucos a energia provinda de fontes fósseis.

O interesse na utilização da energia solar como uma fonte alternativa aumentou muito nos últimos tempos, principalmente devido a questões econômicas e ambientais (PACHECO, 2006). Com isso, muitos investidores vêm mostrando interesse quanto ao uso da energia solar, porém, para que projetos sejam realizados, é necessário que se faça um estudo sobre a região em que o empreendimento será implantado.

As tecnologias a serem usadas também são consideradas um fator de alta importância no processo decisório, pois de acordo com as condições climáticas encontradas em cada região, é possível otimizar a coleta de energia provinda do sol por meio de uma tecnologia mais adequada para o local. Baseados nos estudos dos índices climáticos da região e as tecnologias que hoje mais são aplicadas nas placas solares é possível que se faça um projeto adequado que resulte em um bom desempenho energético.

Como grande aliado da tecnologia, a Inteligência Artificial vem trazendo inovações para as pesquisas, onde é possível que se desenvolva estudos em diferentes áreas de aplicação (RUSSEL, et al., 2004), inclusive sobre os dados climáticos coletados, através do uso de Redes Neurais Artificiais.

Visando este cenário, deu-se início a pesquisa que visa identificar o melhor modelo de rede neural artificial que identifica a irradiação solar da região em pauta, onde são considerados conhecimentos referentes as áreas de Inteligência Artificial, Energia Solar e Tecnologias Fotovoltaicas. A proposta de estudo busca auxiliar na identificação da melhor tecnologia de placas solares a ser utilizada na região de Três de Maio – RS.

O presente relatório se encontra disposto em três capítulos, onde no primeiro estão descritas as definições do projeto de pesquisa, a definição do tema, a problematização, os objetivos específicos, a justificativa para a execução do trabalho e o processo de metodologia utilizado. No segundo capítulo encontra-se o referencial teórico da pesquisa, utilizado como base para o desenvolvimento do trabalho.

No terceiro e último capítulo, são apresentadas todas as etapas efetuadas para a realização do trabalho, assim como os resultados que foram obtidos por meio da estruturação das redes neurais artificiais, também a identificação do melhor modelo de rede neural o qual melhor prevê a irradiação solar na região.

1 CAMINHO METODOLÓGICO

A presente pesquisa visa estabelecer os conceitos para a aplicação de redes neurais no estudo da quantidade de energia que pode ser gerada a partir da irradiação solar, e desta forma, atender a demanda do trabalho de conclusão de curso. Estão dispostos nesse capítulo os aspectos metodológicos da pesquisa.

1.1 TEMA

Aplicação de redes neurais na avaliação da irradiação solar, como fonte de energia renovável.

1.1.1 Delimitação do tema

O estudo proposto, aborda o desenvolvimento da aplicação de redes neurais para avaliação da quantidade de energia que pode ser gerada a partir da irradiação solar na região Noroeste do Rio Grande do Sul. O mesmo foi realizado em Três de Maio – RS, latitude $27^{\circ} 46' e 24''$ S, longitude $54^{\circ} 14' e 24''$ W, altitude 343m, envolvendo as áreas de Inteligência Artificial e Estatística e Probabilidade. Se constituiu na aplicação do método *Levenberg-Marquardt* utilizando dados do ano de 2015 extraídos da estação meteorológica da SETREM.

A estação meteorológica transmite informações em tempo real de diversas variáveis do tempo, contém as seguintes funções de coleta de dados:

- pluviômetro (mede a precipitação pluviométrica);
- sensor de temperatura do ar (barômetro);
- sensor de umidade;
- anemômetro (mede a velocidade do vento e sua direção);

- sensor de radiação solar;
- sensor de radiação ultravioleta (UV);
- módulo de interface dos sensores (SIM).

O SIM é composto de uma placa eletrônica de tratamento dos sinais recebidos dos sensores e de um radiotransmissor. O alcance do sinal de rádio é de 300 metros em linha reta e sem obstáculo até o receptor. Havendo obstruções, como paredes, cercas ou árvores, o alcance varia de 60 a 120 metros.

O SIM envia dados para uma estação de controle chamada Console, que contém um *display* capaz de apresentar os seguintes dados e informações:

- velocidade do vento;
- direção do vento;
- umidade do ar externo;
- umidade do ar interno;
- temperatura externa;
- temperatura interna;
- sensação térmica externa;
- índice temperatura/umidade/insolação/vento;
- ponto de orvalho;
- pressão atmosférica atual;
- tendência da pressão atmosférica nas últimas três horas;
- precipitação pluviométrica acumulada do mês e do ano;
- precipitação pluviométrica acumulada no dia atual (desde zero hora);
- precipitação pluviométrica acumulada nas últimas 24 horas);
- taxa de precipitação pluviométrica (na últimos 15 minutos);
- precipitação pluviométrica (do último evento ocorrido depois de um período de 24 horas sem chuva);
- Evapotranspiração atual;
- Evapotranspiração acumulada no mês e no ano.

O console, por sua vez, é capaz de comunicar-se com o *software* proprietário *WeatherLink* instalado em um computador com sistema operacional *Windows* (diversas versões). Essa comunicação se faz por meio de uma conexão USB ou por comunicação serial.

Na estação meteorológica as medições dos sensores são analógicas e a apresentação das mesmas no console é contínua. No entanto, o registro no banco de dados é determinado por parâmetros do software *WeatherLink*.

A pesquisa foi desenvolvida pelas acadêmicas Andréia Luisa Barth e Camila Wolfer, do curso de Bacharelado em Sistemas de Informação da Sociedade Educacional Três de Maio – SETREM, na cidade de Três de Maio – RS, no período de novembro de 2015 a agosto de 2016.

Foram abordados conceitos de redes neurais, energias renováveis, estatística, que envolveram cálculos que utilizaram informações como a temperatura ambiente, irradiação solar, umidade do solo, sensação térmica, umidade do ar, orvalho, precipitação, entre outras informações que serão relevantes para o estudo.

Para desenvolvimento da rede neural artificial, utilizou-se o *software Matlab*, que auxilia na resolução de problemas numéricos e complexos. Para preparação dos dados meteorológicos provindos da estação SETREM antes da importação dos mesmos no MATLAB, foi utilizado o *Microsoft Office Excel*.

1.2 OBJETIVOS

Na sequência estão apresentados o objetivo geral e os objetivos específicos do trabalho.

1.2.1 Objetivo geral

O objetivo geral deste estudo consiste em avaliar a disponibilidade de energia provinda da irradiação solar.

1.2.2 Objetivos específicos

Os objetivos específicos deste estudo consistem em:

- Identificar o problema da pesquisa e realizar o levantamento das hipóteses.
- Verificar por meio de pesquisas bibliográficas, a utilização e aplicação de redes neurais artificiais.

- Estudar conceitos de fontes de energias renováveis, em particular a solar.
- Pesquisar os métodos BPROP, PBPROP e *Levenberg-Marquardt*.
- Analisar a situação atual de coleta de dados da Estação Meteorológica da SETREM.
- Analisar os tipos de dados coletados pela Estação Meteorológica da SETREM.
- Montar modelos de rede neural para analisar a viabilidade da rede na avaliação da irradiação solar por meio dos dados provindos da Estação Meteorológica SETREM.
- Analisar os resultados obtidos da aplicação da rede neural nas quatro estações do ano.
- Pesquisar e estudar trabalhos relacionados ao assunto.
- Apresentar os resultados aos interessados, através de banca avaliadora.

1.3 JUSTIFICATIVA

Com o avanço tecnológico e o uso excessivo dos recursos naturais, o mundo vem sofrendo um impacto grandioso na produção de energia. Atualmente, os recursos utilizados para esse fim ainda são, na sua maioria, derivados do petróleo e outros combustíveis fósseis. Porém, é necessário ter cautela quanto a esses recursos e usá-los com moderação, pois os mesmos são finitos. Visando a utilização de um novo recurso para a geração de energia, muitas pessoas e empresas estão investindo nas energias renováveis, como por exemplo o sol, que é um elemento universal e com disponibilidade em toda a Terra.

Fazendo uso de novos recursos energéticos renováveis, não se está beneficiando somente a economia local e mundial, mas também as gerações futuras, que poderão usufruir de um planeta mais limpo e com recursos disponíveis.

Neste contexto, muitos investidores vêm estudando a viabilidade de inserir essa fonte de energia em determinados locais, realizando análises referente ao nível de

irradiação disponível, para assim determinar qual a melhor tecnologia a ser utilizada. A partir do estudo referente à viabilidade, os investidores buscam saber se os investimentos sobre a implementação de recursos de energia solar trarão retorno ou serão investimentos sem lucratividade.

Quando realizados estudos referentes a disponibilidade de irradiação solar em determinado local e região, é possível selecionar a melhor tecnologia a ser usada em painéis solares para a coleta da energia solar. Novos estudos podem ser realizados utilizando como base uma região estudada, visando identificar a melhor tecnologia que pode ser utilizada em outras regiões, levando em conta sempre o melhor desempenho.

Atualmente, a maior parte dos painéis solares é composta pelo componente Silício (Si), que traz mais eficiência aos painéis de acordo com a sua pureza. Dentre essas tecnologias existem as células fotovoltaicas de Silício Monocristalino, Policristalino, Microcristalino e Silício Amorfo, que possuem suas particularidades em relação a eficiência (DIENSTMANN, 2009).

Para tornar-se possível a definição de qual tecnologia utilizar, é necessário que seja avaliado o nível de energia solar que atinge o painel solar, por meio da irradiação solar, que posteriormente é transformado em energia elétrica. Para isso, é necessário que se faça uso de algumas tecnologias de auxílio, como a Inteligência Artificial e pontos de coletas de dados relacionados aos fatores ambientais influentes.

A Inteligência Artificial pode ser considerada um grande aliado nas pesquisas referente ao uso das energias renováveis, principalmente as Redes Neurais Artificiais (RNAs), pois por meio delas é possível dar mais precisão ao estudo e aos dados disponíveis, usando cálculos que indiquem a abundância dos recursos necessários para se fazer uso de determinado tipo de energia renovável. No caso da energia solar, por meio das RNAs é possível calcular os níveis de irradiação solar disponíveis em determinada região por exemplo.

Alguns estudiosos apresentam novos conceitos relacionados ao uso dos recursos renováveis e também ao uso das RNAs, dentre eles é possível citar (HINRICHS, et al., 2008) que demonstra princípios físicos que fazem parte do uso energético e os efeitos que os mesmos trazem ao meio ambiente. Já (GOLDSCHMIDT, et al., 2015) abordam os principais conceitos referente a RNAs,

toda a sua estrutura e aplicação, importantes para o estudo a ser realizado neste trabalho.

Visando a implementação do uso da energia solar como fonte principal de consumo na região de Três de Maio - RS, é necessário que se conheça os níveis de irradiação disponíveis no ambiente para cada estação do ano, por meio da análise dos dados disponíveis e coletados na estação de testes. Com isso, é possível identificar qual a tecnologia necessária para essa região é mais adequada.

Atualmente, a SETREM possui uma estação meteorológica que coleta algumas informações ambientes da região, porém, as mesmas ficam apenas armazenadas para consulta, sem serem utilizadas para algum fim específico. Com esses dados é possível realizar a criação da RNA para cálculo da irradiação atual presente na região, facilitando assim algumas definições quanto à implementação dos painéis solares.

Estudos meteorológicos são uma tarefa que exigem esforços para considerar todas as variáveis que possam permitir a previsão do clima. Este, na região Noroeste do Rio Grande do Sul, é de muita instabilidade, é uma região difícil de se fazer previsões. No campo da Agricultura, desenvolver sementes adequadas apresenta dificuldades. No campo da Energia Solar, a possibilidade de obter informações para decisões sobre o investimento passa pela previsão do clima. Desenvolver programas ou métodos para auxiliar na simulação do clima serão muito importantes para ambos os casos.

Esta pesquisa tem como objetivo estruturar uma RNA capaz de avaliar a irradiação solar disponível na região Noroeste do Estado do Rio Grande do Sul, utilizando dados de temperatura, índice UV, umidade, velocidade do vento, barômetro, orvalho, precipitação de chuva e hora, coletados na estação meteorológica da Sociedade Educacional Três de Maio (SETREM), localizada na cidade de Três de Maio, RS.

Portanto, a principal contribuição deste trabalho será o desenvolvimento de um método de avaliação de clima, utilizando o algoritmo *Levenberg-Marquardt* o qual é considerado o método mais rápido para realizar o treinamento de redes neurais do tipo *feedforward backpropagation*. Paralelamente, como corolário, abre a oportunidade de se conhecer melhor o que hoje se classifica como “instabilidade climática”.

1.4 PROBLEMA

Diante deste contexto, chega-se ao seguinte problema: A irradiação solar existente na região Noroeste do estado do Rio Grande do Sul é adequada para uso, como fonte de energia renovável?

1.5 HIPÓTESES

A partir do problema, tem-se as seguintes hipóteses:

- a) Os dados meteorológicos da estação permitem avaliar a irradiação solar existente.
- b) Os dados meteorológicos permitem avaliar a variação da irradiação solar nas quatro estações do ano.
- c) A rede neural com duas camadas ocultas permite fazer avaliação da irradiação a partir dos dados meteorológicos.

Variáveis:

- Dados meteorológicos da estação SETREM;
- Irradiação solar;
- Irradiação solar no inverno, verão, primavera e outono;
- Camadas ocultas da rede neural.

1.6 METODOLOGIA

Com base na teoria de Gerhardt, utiliza-se uma metodologia para obter um caminho organizado na realização de algo.

A metodologia utilizada no presente estudo se subdivide em métodos quanto à abordagem, os procedimentos e as técnicas utilizadas.

1.6.1 Método de abordagem

A abordagem utilizada foi o realismo crítico. Por meio da construção da rede neural e os resultados obtidos por ela será possível corroborar ou falsear as hipóteses.

Abordagem quantitativa para avaliar os resultados apresentados por meio do melhor modelo de rede neural, utilizando as entradas de dados relacionadas a temperatura ambiente, umidade do ar e do solo, velocidade e direção do vento, precipitação de chuvas, pressão atmosférica, índices UV e de radiação solar, entre outros.

1.6.2 Métodos de procedimentos

Neste trabalho, aplicou-se o procedimento de pesquisa bibliográfica com o intuito de buscar conhecimento referente aos assuntos tratados ao longo do estudo, assim como os conceitos de Inteligência Artificial, Estatística e Energias Renováveis.

Coletar os dados da estação de todo ano de 2015, em um período de 5 em 5 minutos, construir a rede neural com duas camadas internas, analisar a consistência dos dados, inserir os dados no programa *Matlab*, rodar o programa e analisar os resultados.

Na busca da resolução para o problema levantado, a validação das hipóteses é tratada conforme segue:

- Os dados meteorológicos da estação permitem avaliar a irradiação solar existente.

Validação: Atualmente a SETREM possui uma estação meteorológica para captação dos dados referente a: temperatura ambiente, umidade do ar e do solo, velocidade e direção do vento, precipitação pluviométrica, pressão atmosférica e índices UV. Estes dados serão utilizados como base de entrada para a rede neural de duas camadas, que terá como saída a irradiação solar.

- Os dados meteorológicos permitem avaliar a variação da irradiação solar nas quatro estações do ano.

Validação: Para validação desta hipótese, foram utilizados os dados captados pela estação meteorológica da SETREM para análise do nível de irradiação solar em cada estação do ano.

- A rede neural com duas camadas internas permite fazer avaliação da irradiação a partir dos dados meteorológicos.

Validação: Para validação desta hipótese foi utilizado o nível de irradiação solar coletado pela Estação e também aquela obtida como resultado da RNA. Entre elas será feita a correlação.

1.6.3 Técnicas

Como técnica de pesquisa para desenvolvimento do estudo proposto, foi utilizado o método *Levenberg-Marquardt*, o qual é considerado o mais rápido para realizar o treinamento de redes neurais do tipo *feedforward backpropagation* (Liu, 2010), utilizado no processo de estruturação da rede neural para realizar o treinamento da mesma.

1.7 CRONOGRAMA

O cronograma deste estudo está disponível para consulta no Apêndice A deste documento.

1.8 ORÇAMENTO

O orçamento deste trabalho encontra-se disponível para consulta no Apêndice B deste documento.

2 FUNDAMENTAÇÃO TEÓRICA

O presente estudo buscou conhecimentos na área de Inteligência Artificial, Energias Renováveis, Estatística e Matemática aplicada, abordando mais fortemente a área de Redes Neurais Artificiais. Os tópicos citados serão apresentados nas próximas seções.

2.1 INTELIGÊNCIA ARTIFICIAL

Considerada um dos estudos mais recentes da ciência e da área de engenharia, a IA (Inteligência Artificial) iniciou-se logo após a Segunda Guerra, utilizada para implementação de tarefas específicas como jogos de xadrez, teoremas matemáticos, criação de poesias e até a direção de um carro (RUSSEL, et al., 2004).

Durante milhares de anos os seres humanos procuraram entender de que forma pensamos, como é gerado o pensamento e o raciocínio. A IA além de compreender, busca também construir ou simular uma entidade inteligente. As definições de inteligência artificial falam basicamente em quatro categorias: sistemas que pensam como seres humanos, sistemas que pensam racionalmente, sistemas que atuam como seres humanos e sistemas que atuam racionalmente (RUSSEL, et al., 2004).

Para os autores (RUSSEL, et al., 2004), historicamente todas as quatro estratégias para o estudo da IA têm sido seguidas. Existe um conflito entre abordagens centradas em torno do estudo dos seres humanos e abordagens centradas em torno da racionalidade.

A IA vem sendo muito estudada devido ao seu grande leque de abrangência em diferentes campos quanto ao auxílio na realização de determinados processos, áreas como automotiva, eletrônica, financeira, segurança, medicina, robótica,

telecomunicações, transporte, dentre outras. Estas áreas podem e vem sendo beneficiadas com o uso desse tipo de inteligência.

Com base nos estudos já realizados, sabe-se que buscar a perfeição quanto a imitação do pensamento humano é o principal foco da IA. Por meio da construção de Redes Neurais Artificiais, é possível não somente imitar o comportamento humano, mas também o pensamento, tanto racional como emocional (BRAGA, et al., 2007).

Diante deste cenário, uma das áreas que se deu ênfase neste estudo foram as Redes Neurais que serão apresentadas com melhor detalhamento nas próximas seções.

2.1.1 Redes Neurais

As redes neurais biológicas formam-se a partir de um conjunto de neurônios, que possuem como função principal, a de coletar, realizar o processamento e disseminação de impulsos elétricos. O processamento das informações do cérebro surge principalmente das redes e conexões entre os neurônios (RUSSEL, et al., 2004).

De acordo com a teoria de (AQUILANO, et al., 2001), as redes neurais representam hoje uma área relativamente nova em suas aplicações e de crescente de previsão. Diferentemente das técnicas de previsão estatísticas mais comuns que conhecemos, como por exemplo, a análise de séries temporais, aplicação de fórmulas e a análise de regressão, as redes neurais simulam o aprendizado humano aplicando o raciocínio lógico.

Desta forma, com o passar do tempo e com o uso contínuo, as redes neurais podem desenvolver um melhor entendimento dos relacionamentos complexos que existem entre as entradas e as saídas de um processamento. Em um exemplo prático, como uma operação de prestação de serviço, estas entradas devem incluir fatores tais como histórico de vendas, condições mercadológicas, horário do dia, dia da semana e o mês. As saídas seriam o número de *prospects* clientes esperados em um determinado dia e em determinado período. Além disso, as redes neurais realizam cálculos muito mais rapidamente do que as técnicas de previsão tradicionais (AQUILANO, et al., 2001).

As redes neurais podem ser divididas em duas categorias gerais: as supervisionadas e as não-supervisionadas. Nos modelos supervisionados, dados históricos são utilizados para “treinar” o *software*, modelo o qual, foi aplicado no presente estudo. Nos modelos não-supervisionados, nenhum treinamento ocorre, no entanto, o *software* em execução pesquisa e identifica padrões que existem em um determinado conjunto de dados (BRAGA, et al., 2007).


Para que exista uma melhor compreensão da origem das redes neurais, na seção seguinte é apresentada a estrutura dos Neurônios Biológicos, os quais serviram como um espelhamento para a constituição dos Neurônios Artificiais.

2.1.2 Neurônios Biológicos

Os neurônios são considerados um conjunto complexo do corpo humano, e possuem a função de determinar o funcionamento e o comportamento das pessoas e seu raciocínio (RUSSEL, et al., 2004).

Estes neurônios biológicos são divididos de maneira simplificada, em três componentes: o corpo celular, os dendritos e o axônio, cada um destes com suas partes específicas, no entanto, complementares. O corpo celular possui dimensão de apenas alguns milésimos de milímetros, e os dendritos apresentam poucos milímetros de comprimento. O axônio, no entanto, pode ser mais longo e, em média, tem calibre uniforme. Os dendritos têm por função receber as informações ou impulsos nervosos, oriundas de outros neurônios e os conduzem até o corpo celular. Neste componente a informação é processada, e novos impulsos são gerados. Esses impulsos são transmitidos a outros neurônios, passando através do axônio até os dendritos dos neurônios seguintes. O ponto de contato entre a terminação axônica de um neurônio e um dendrito de outro é chamado de sinapse. É através das sinapses que os neurônios se unem funcionalmente, formando as redes neurais biológicas (BRAGA, et al., 2007).

Na Figura 1, é possível observar os componentes de um neurônio biológico:



Fonte: BRAGA; CARVALHO; LUDERMIR (2007)
 Figura 1 – Componentes do neurônio biológico

De acordo com (BRAGA, et al., 2014), o cérebro humano contém em torno de 100 milhões de neurônios, sua célula fundamental. No entanto, não há um número exato sobre a quantidade de neurônios que o cérebro contém, existem várias pesquisas recentes na área, porém, nenhuma conclusiva.

Ainda seguindo a linha de pensamento de (BRAGA, et al., 2007), cada um desses neurônios processa e se comunica com milhares de outros continuamente e em paralelo. A estrutura individual desses neurônios, a topologia de suas conexões e o comportamento conjunto desses elementos de processamento naturais formam a base para o estudo das RNAs.

Algumas estruturas neurais são definidas no nascimento, enquanto outras vão se desenvolvendo de acordo com a aprendizagem e as novas ligações que são criadas. As estruturas neurais podem se alterar durante toda a vida, podendo ser de enfraquecimento ou fortalecimento das sinapses dos neurônios.

2.1.3 Neurônio artificial


As estruturas das redes neurais artificiais foram desenvolvidas a partir de modelos conhecidos de sistemas nervosos biológicos e do cérebro humano, os neurônios biológicos. Os neurônios artificiais denominados elementos computacionais ou unidades de processamento, são considerados modelos bem simplificados dos neurônios biológicos (SILVA, et al., 2010).

Com base na teoria de (GOLDSCHMIDT, et al., 2015), “numa RNA os neurônios são arrumados em camadas, com conexões entre elas. Uma RNA pode conter uma ou várias camadas ocultas, de acordo com a complexidade do problema”. De acordo com a teoria, em uma RNA simples, a camada que recebe os dados é chamada camada de entrada e a camada que mostra o resultado é chamada camada de saída e os neurônios são a parte da estrutura responsáveis por processar as informações com base nos dados de entrada. A camada interna, onde ocorre o processamento interno da rede é tradicionalmente chamada de camada oculta, esta pode conter uma única camada ou diversas.

Os neurônios artificiais, usados nos modelos de redes neurais artificiais, são não-lineares, ou seja, fornecem saídas tipicamente contínuas e realizam funções simples, como coletar os sinais existentes de suas entradas, acrescentá-los de acordo com sua função operacional e produzir uma resposta, levando em consideração sua função de ativação.

Segundo estudos do autor (SILVA, et al., 2010), o modelo mais simples de neurônio artificial, e que engloba as principais características de uma rede neural biológica, foi proposto por McCulloch & Pitts (1943), sendo ainda o modelo mais utilizado nos dias atuais considerando as diferentes arquiteturas de redes neurais artificiais existentes.

Cada neurônio da rede pode ser implementado conforme pode ser observado na Figura 2, onde existem diversos sinais de entrada, provindos do meio externo (aplicação) representados pelo conjunto $\{x_1, x_2, x_3, \dots, x_n\}$, que são análogos aos impulsos elétricos externos captados pelos dendritos no neurônio biológico.



Fonte: SILVA; SPATTI; FAUZINO (2010)
Figura 2 - Neurônio Artificial

As análises realizadas pelas junções sinápticas do modelo biológico são representadas no neurônio artificial pelo conjunto de pesos $\{w_1, w_2, \dots, w_n\}$. De forma analógica, a relevância de cada uma das entradas $\{x_i\}$ do neurônio é executada por meio de suas multiplicações pelos respectivos pesos sinápticos $\{w_i\}$, portanto, são essas as informações externas que chegam ao neurônio. Desta forma, torna-se possível verificar que a saída do corpo celular artificial, representado por u , é a soma ponderada de suas entradas.

Considerando a Figura 2, verifica-se que o neurônio artificial é constituído de sete elementos básicos, sendo eles:

- a) Sinais de Entrada $\{x_1, x_2, x_3, \dots, x_n\}$ - são os sinais vindos do meio externo e que representam os valores assumidos pelas variáveis de uma aplicação específica. Os sinais de entrada são usualmente normalizados, visando incrementar a eficiência computacional dos algoritmos de aprendizagem.
- b) Pesos sinápticos $\{w_1, w_2, \dots, w_n\}$ – são os valores que servirão para ponderar cada uma das variáveis de entrada da rede, permitindo-se quantificar as suas relevâncias em relação à funcionalidade do respectivo neurônio.
- c) Combinador Limiar $\{\varepsilon\}$ – sua função é agregar todos os sinais de entrada que foram apresentados pelos respectivos pesos sinápticos, a fim de produzir um valor de potencial de ativação.
- d) Limiar de Ativação $\{\emptyset\}$ – é uma variável que especifica qual será o patamar apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção a saída dos neurônios.
- e) Potencial de Ativação $\{u\}$ – é o resultado produzido pela diferença do valor produzido entre o combinador e o linear de ativação. Se tal valor é positivo, ou seja, se $u \geq \emptyset$, então o neurônio produz um potencial excitatório, caso contrário, o potencial será inibitório.
- f) Função de ativação $\{g\}$ – seu objetivo é limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional.
- g) Sinal de saída $\{y\}$ – consiste no valor final produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada, podendo ser também utilizado por outros neurônios que são sequencialmente interligados.

2.1.4 Principais arquiteturas de redes neurais artificiais (RNAs)

As RNAs são consideradas modelos matemáticos fundamentados a partir do funcionamento das redes neurais biológicas e na estrutura cerebral. Modelos de RNAs possuem uma capacidade de adquirir, armazenar e utilizar o conhecimento através de experimentos, simulando através da computação as habilidades humanas de aprendizado, associação, abstração, entre outras (GOLDSCHMIDT, et al., 2015).

O funcionamento das RNAs ocorre de forma parecida com os neurônios humanos. As mesmas são compostas por nodos, ou unidades vinculadas, onde cada vínculo possui um peso numérico associado e que determina a frequência e intensidade do sinal da conexão. Além disso, as RNAs são compostas também por unidades de processamento, que geralmente conectam-se por canais comunicativos que são associados aos pesos. Essas unidades realizam operações somente sobre os dados locais que foram recebidos pelas entradas em suas conexões (RUSSEL, et al., 2004).

A arquitetura de uma rede neural pode ser dividida basicamente em três partes, denominadas de camadas, as quais são nomeadas da seguinte forma (SILVA, et al., 2010):

- a) Camada de Entrada – é responsável pelo recebimento de informações (dados), sinais características ou medições advindas de meio externo, sendo que, tais entradas (amostras) são geralmente normalizadas em relação as faixas de variações dinâmicas produzidas pelas funções de ativação.
- b) Camadas ocultas, intermediárias, ocultas ou invisíveis – são aquelas compostas de neurônios que possuem a responsabilidade de extrair as características associadas ao processo ou sistema a ser deduzido. Quase todo o processamento interno da rede é realizado nessas camadas.
- c) Camada de saída – é também constituída de neurônios, sendo responsável pela produção e apresentação dos resultados finais da rede, os quais são provindos dos processamentos realizados pelos neurônios das camadas anteriores.

De acordo com a teoria de (HEATON, 2015), a maioria das estruturas das RNAs usam algum tipo de neurônio. Existem diversos tipos de redes neurais atualmente,

programadores e outros profissionais introduzem as suas pesquisas as estruturas de rede neural experimentais o tempo todo.

Uma grande característica, e possivelmente a mais importante das RNAs, é a capacidade de aprender por meio de exemplos repassados. O conhecimento não é adquirido exatamente por meio de regras impostas, mas sim através de ajustes nas conexões entre os neurônios.

O aprendizado ocorre quando são feitos ajustes nos parâmetros (pesos) da rede, que ao final de cada processo guardam as informações e conhecimento adquirido do meio externo.

Aprendizado é o processo pelo qual os parâmetros livres de uma rede neural são ajustados por meio de uma forma continuada de estímulos pelo ambiente externo, sendo o tipo específico de aprendizado definido pela maneira particular como ocorre os ajustes dos parâmetros livres (BRAGRA, et al., 2014).

O aprendizado é utilizado como uma melhoria no desempenho e eficiência da rede neural, de acordo com os critérios estabelecidos anteriormente. O erro resultante da resposta da rede, relacionado aos dados fornecidos pelo meio externo, são utilizados como medidas de desempenho para a correção de erros. Com isso, espera-se que os erros diminuam à medida que é adquirido o aprendizado.

Nas seções seguintes, encontra-se alguns tipos de treinamento utilizados no presente estudo.

2.1.4.1 Tipos de Aprendizado da RNA

O aprendizado pode ocorrer de diferentes formas, uma delas é o aprendizado supervisionado, que exige necessariamente que haja um supervisor externo responsável por estimular as entradas da rede por meio de padrões, e então fazendo comparações com as saídas esperadas (BRAGRA, et al., 2014).

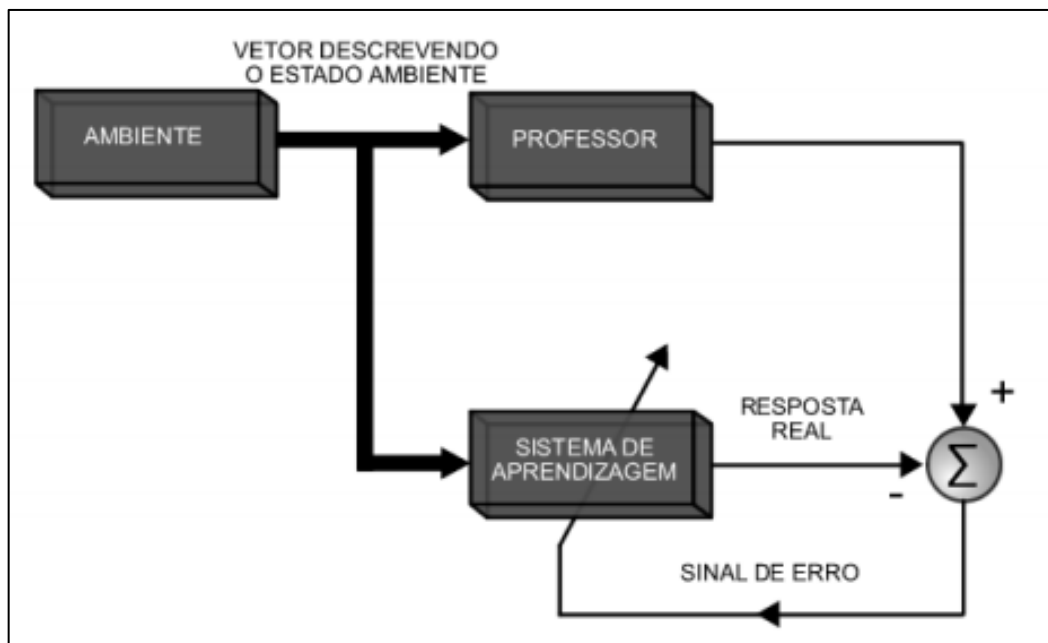
Na mesma linha de pensamento, a estratégia do treinamento supervisionado consiste em se ter disponível, considerando cada amostra dos sinais de entrada, as respectivas saídas desejadas, ou seja, cada amostra de treinamento é constituída pelos sinais de entradas e suas correspondentes saídas. Desta forma, não há então a necessidade de disponibilizar uma tabela de dados (contendo saídas e entradas) representativa do processo, também conhecida por tabela atributos/valores, e que

contemple inclusive, o seu comportamento, pois, é a partir de tais informações que as estruturas das redes neurais formularão as “hipóteses” sobre o que deve ser aprendido.

Neste caso, a aplicação do treinamento supervisionado, depende apenas da disponibilidade desta tabela atributos/valores, sendo que tudo se comporta como se houvesse um “professor” ensinando para a rede neural qual a resposta correta para cada amostra apresentada em suas entradas.

O treinamento supervisionado é um caso típico de inferência indutiva pura, em que os parâmetros livres da rede são ajustados em função de se conhecer *a priori* quais são as saídas desejadas ao sistema investigado.

Na Figura 3, apresenta-se um modelo de aprendizado supervisionado onde a partir de um determinado ambiente, a rede recebe ajustes de pesos de um professor externo e a partir destes ajustes o treinamento da rede é realizado novamente a fim de obter a saída desejada.



Fonte: SOARES, 2011.

Figura 3 - Mecanismo de aprendizado supervisionado

Outra forma de treinamento é o aprendizado não-supervisionado, que diferentemente do supervisionado, durante a aplicação de um algoritmo de aprendizado não existem as saídas desejadas (alvo).

Não há um supervisor externo responsável pelo acompanhamento do processo. Nesse caso, há somente um padrão de entradas disponíveis para a rede, onde durante o processo de aprendizado os mesmos são apresentados de forma contínua a rede, fazendo com que haja aprendizado por meio da regularidade dos dados apresentados. Esse tipo de aprendizado está representado na Figura 4.



Fonte: SOARES, 2011.

Figura 4 - Mecanismo de aprendizado não-supervisionado

Nesse tipo de treinamento a própria rede deve se auto organizar em relação às particularidades existentes entre os elementos componentes do conjunto total de amostras, identificando subconjuntos que contenham dados semelhantes. Os pesos sinápticos e limiares dos neurônios da rede são ajustados pelo algoritmo de aprendizado de forma a exibir a sua representação internamente dentro da própria rede.


Além dos dois tipos de treinamento já apresentados, temos o treinamento por reforço. Os algoritmos de aprendizado utilizados no treinamento com reforço ajustam os parâmetros internos dos neurônios baseando-se em qualquer informação provinda da interação do sistema que está sendo mapeado.

Com base nessa situação, o processo de treinamento da rede é realizado tipicamente por tentativa e erro, pois a única resposta disponível para uma determinada entrada é se esta é satisfatória ou não. Se for considerada satisfatória, incrementos e modificações nos pesos são gradualmente efetuados visando reforçar a condição comportamental envolvida no sistema.

Diversos algoritmos de aprendizado utilizados no treinamento com reforço são baseados em métodos que selecionam probabilisticamente as ações de ajuste.

2.1.4.2 Arquitetura de camada simples

Uma arquitetura de camada simples possui apenas uma camada de entrada e uma camada oculta de neurônios, a qual é responsável pela saída dos dados. Na Figura 5 pode-se observar a estrutura de uma rede de camada simples.



Fonte: SILVA, 2010.

Figura 5 - Rede com camada única


É chamada de rede neural de uma única camada ou *perceptron*, pois, possui todas as entradas conectadas diretamente às saídas de informações. Tendo em vista que cada unidade de saída é independente das outras – cada peso afeta apenas uma das saídas (RUSSEL, et al., 2004).

O fluxo de informações em uma rede de camada única segue sempre em uma única direção, ou seja, iniciando na camada de entrada e indo em direção a camada de saída. É válido observar que a quantidade de saídas nas redes pertencentes a arquitetura sempre coincidirá com o número de neurônios (SILVA, et al., 2010)

2.1.4.3 Arquitetura de camadas múltiplas

Diferentemente das redes pertencentes à arquitetura anterior, as redes de camadas múltiplas são constituídas pela presença de uma ou mais camadas ocultas de neurônios. São empregadas na solução de diversos problemas, relacionados à

aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, controle de processos, entre outros. A Figura 6 ilustra uma estrutura de rede de camadas múltiplas.



Fonte: SILVA, 2010.


Figura 6 - Estrutura de rede neural com múltiplas camadas

Na imagem é possível observar os detalhes da RNA, onde na camada de entrada são fornecidos os dados e pesos a serem usados, as camadas intermediárias onde são realizados os cálculos sobre os pesos e suas variáveis, e por fim, a camada de saída, obtendo-se o resultado buscado.

2.1.4.3.1 Arquiteturas de alimentação direta e recorrentes.

Existe basicamente duas principais categorias de estruturas de redes neurais: redes acíclicas ou redes de alimentação direta e redes cíclicas ou redes recorrentes. Uma rede acíclica representa uma função de sua estrutura atual, ou seja, ela não possui nenhum estado interno dos pesos.

No entanto, uma rede recorrente utiliza saídas para alimentar de volta suas próprias entradas. Nessa estrutura, não existe um sentido único para o fluxo dos dados entre os neurônios e camadas internas. Cada camada da rede pode conter conexões entre os elementos de processamento da mesma camada, das camadas anteriores ou das camadas posteriores ocultas. Por isso são denominadas redes de retroalimentação, onde, um determinado neurônio pode ser alimentado ou retroalimentado pelas saídas. A Figura 7 ilustra uma rede de realimentação recorrente.



Fonte: SILVA, 2010.

Figura 7 - Neurônio Artificial com uma camada com estrutura recorrente

Para dar sequência nas explicações do funcionamento de cada tipo de rede, se faz necessário apresentar uma breve explicação do funcionamento de alguns cálculos matemáticos.

2.1.5 Multiplicação de Matrizes

A representação das matrizes é dada pelo seu número de linha e colunas, identificando as linhas como m e colunas como n , representando assim $A_{m \times n}$. Se o número de linhas for 2 e o número de colunas 3, então a matriz será $A_{2 \times 3}$.

Considerando que as linhas são dadas como i e as colunas como j , e cada elemento da matriz como a , podemos representar a seguinte matriz:

$$\begin{bmatrix} a_{11} & a_{12} & \dots & a_{1j} \\ a_{21} & a_{22} & \dots & a_{2j} \\ \vdots & \vdots & \dots & \vdots \\ a_{i1} & a_{i2} & \dots & a_{ij} \end{bmatrix}$$

Para efetuar a multiplicação de matrizes, é necessário que o número de colunas da primeira matriz seja igual ao número de linhas da segunda matriz, tendo-se como resultado uma matriz com o número de linhas da primeira matriz e o número de colunas da segunda matriz:

$$A_{m \times n} \cdot B_{n \times p} = C_{m \times p}$$

Ao multiplicarmos duas matrizes, é necessário obter o produto da multiplicação dos elementos da primeira linha da matriz A, pelos elementos da primeira coluna da matriz B, e após soma-los:

$$\begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} \cdot \begin{bmatrix} 5 & 6 \\ 7 & 8 \end{bmatrix} = \begin{bmatrix} 1.5 + 2.7 & 1.6 + 2.8 \\ 3.5 + 4.7 & 3.6 + 4.8 \end{bmatrix} = \begin{bmatrix} 19 & 22 \\ 43 & 50 \end{bmatrix}$$

2.1.6 Derivadas

De acordo com a teoria de (CARNEIRO, et al., 2011), o cálculo das derivadas foi inventado por Leibnitz e Newton. Embora possuindo uma notação um tanto complexa, Newton desenvolveu o conceito de derivada e percebeu a sua importante utilidade na formulação matemática. Em termos técnicos, a derivada de uma função não passa de um caso especial de limite. Para que o assunto se torne mais claro, vamos a um exemplo de derivada:

A velocidade momentânea (igual a derivada da posição em relação ao tempo) corresponde ao limite da velocidade média para um intervalo de tempo imperceptível (muito pequeno que tende a se anular) (CARNEIRO, et al., 2011). Para calcular a derivada de uma função $f(x)$ num certo ponto x_0 , inicialmente é dado um acréscimo Δx em x_0 e calcula-se a diferença:

$$\Delta f = f(x_0 + \Delta x) - f(x_0),$$

e a razão

$$\frac{\Delta f}{\Delta x} = \frac{f(x_0 + \Delta x) - f(x_0)}{\Delta x}$$

Desta forma, a derivada no ponto x_0 , designada por $(df / dx)_{x=x_0}$, é dada pelo limite:

$$\left(\frac{df}{dx}\right)_{x=x_0} = \lim_{\Delta x \rightarrow 0} \frac{\Delta f}{\Delta x} = \lim_{\Delta x \rightarrow 0} \frac{f(x_0 + \Delta x) - f(x_0)}{\Delta x}.$$

A derivada é o grau de inclinação do gráfico de uma determinada função, para um dado valor de x . Pode ser interpretada também o quanto o valor de y varia em função de x .

No caso da reta, a derivada é constante e corresponde ao valor do coeficiente angular, pois é constante por todo o gráfico. Em funções que não são retas, a derivada

depende do valor de x . Assim como por exemplo, numa função como uma parábola, a inclinação do gráfico dessa função não é a mesma para todos os valores de x .

2.1.7 Funcionamento de uma rede Perceptron

O *Perceptron* foi inventado por Rosenblatt (1958, 1962). Redes *Perceptrons* foram usadas por muitos trabalhos, principalmente durante a década de 60. Caíram em desuso por muito tempo após uma publicação de que eles poderiam ser utilizados apenas para problemas linearmente separáveis (NETO, et al., 2010). No entanto, por volta do ano de 1986, Rumelhart e outros (RUMELHART et al., 1986; MCCLELLAND & RUMELHART, 1986) impulsionaram novamente o seu uso, por meio da proposta de *Perceptrons* multicamadas com a utilização de um algoritmo de treinamento para esse tipo de arquitetura, denominado *backpropagation*, o qual está apresentado na seção seguinte.

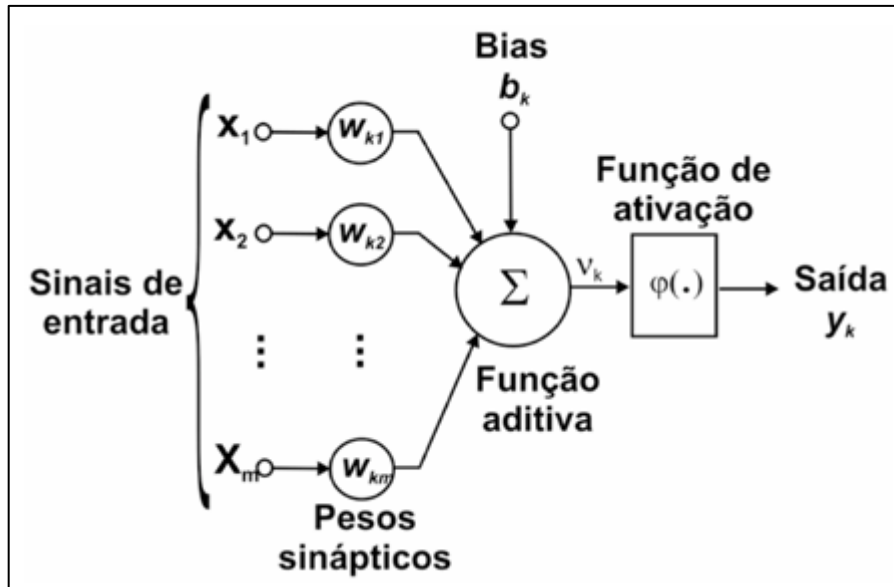
Uma rede neural *Perceptron* possui em seu processamento uma função linear de ativação que traz um resultado específico, mas que, também pode ser modificada de acordo com a programação que é dada a rede neural.

Na Figura 8, é possível observar as entradas das redes neurais representadas pelo X (x_1, x_2, \dots, x_n). Os pesos sinápticos são representados pelo W (w_1, w_2, \dots, w_n). A função responsável pela soma da multiplicação de X por W ($x_1 w_{11} + x_2 w_{12}, \dots, + x_n w_{1n}$), é representada pelo \sum .

O limiar de ativação é representado pelo viés B no caso B_1 e saída por y .

Dado um conjunto de valores de entrada, para eles, existe um valor de saída que será chamado de saída ideal ou *target*, representada por y_t .

Existem vários tipos de redes neurais, e a principal objetivada neste estudo, é a rede neural supervisionada, onde sempre há um supervisor que indica à rede neural qual o resultado esperado, assim aprimorando a mesma até que chegue a este resultado. Esse aprimoramento da rede neural indica o ajuste dos valores dados aos pesos para que quando processada a entrada, possa-se obter o resultado esperado.



Fonte: SILVA, 2010.

Figura 8 - Funcionamento de um neurônio computacional

Logo após a função de adição, a rede neural possui uma função de ativação, também conhecida como função limiar. A função limiar é aquela cuja entrada é a somatória e cuja saída sempre está entre valores -1 e +1. A Figura 9 ilustra a função tangente hiperbólica.

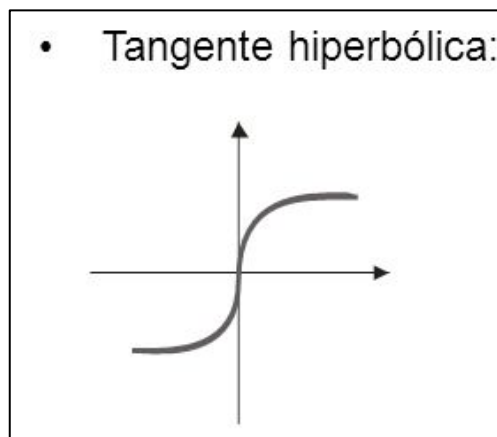


Figura 9 - Tangente Hiperbólica

Essa função se chama tangente hiperbólica. Uma outra função muito usada é a da Figura 10.

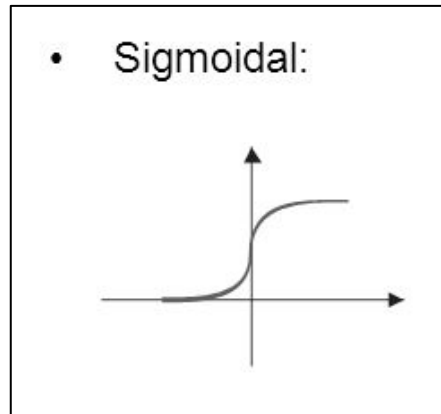


Figura 10 - Função Sigmoidal

Essa figura representa a estrutura da função Sigmoidal, cuja fórmula é:

$$f(x) = \frac{1}{1 + e^{-n}}$$

Onde o valor de e , número de Neper, é fixo e vale 2,718.

O n é o resultado da soma da função aditiva. Para o cálculo da soma entre x e w , é utilizada uma matriz simples responsável pela multiplicação dos valores, que são depois adicionados ao b :

$$[x_1 \ x_2 \ x_n] \cdot \begin{bmatrix} w_1 \\ w_2 \\ w_n \end{bmatrix} + b = [(x_1 \cdot w_1) + (x_2 \cdot w_2) + (x_n \cdot w_n)] + b = n$$

Após calculado o valor de n , se obtêm o valor da função de ativação. No caso da rede *perceptron* é o valor da saída.

Na Figura 11, traz-se a representação do cálculo de uma função log-simóide:

n	e^{-n}	$1 + e^{-n}$	$1 / 1 + e^{-n}$
0	1	2	0,5
1	0,367917586	1,367918	0,731038
2	0,13536335	1,135363	0,880775
3	0,049802557	1,049803	0,95256
4	0,018323237	1,018323	0,982006
5	0,006741441	1,006741	0,993304
6	0,002480295	1,00248	0,997526
7	0,000912544	1,000913	0,999088
8	0,000335741	1,000336	0,999664
9	0,000123525	1,000124	0,999876
10	4,5447E-05	1,000045	0,999955

Figura 11 - Cálculo da função linear

Primeiramente, busca-se o resultado de n , o qual é obtido através do resultado da função de soma. Após, realiza-se o cálculo da potência entre e e $-n$, que em seguida é adicionado a 1. Por fim, é realizada a divisão de 1 pelo valor obtido anteriormente, que mostrará o valor final da função $f(x)$.

Esses valores, localizados entre 1 e 0, trazem um gráfico mostrado na Figura 12.

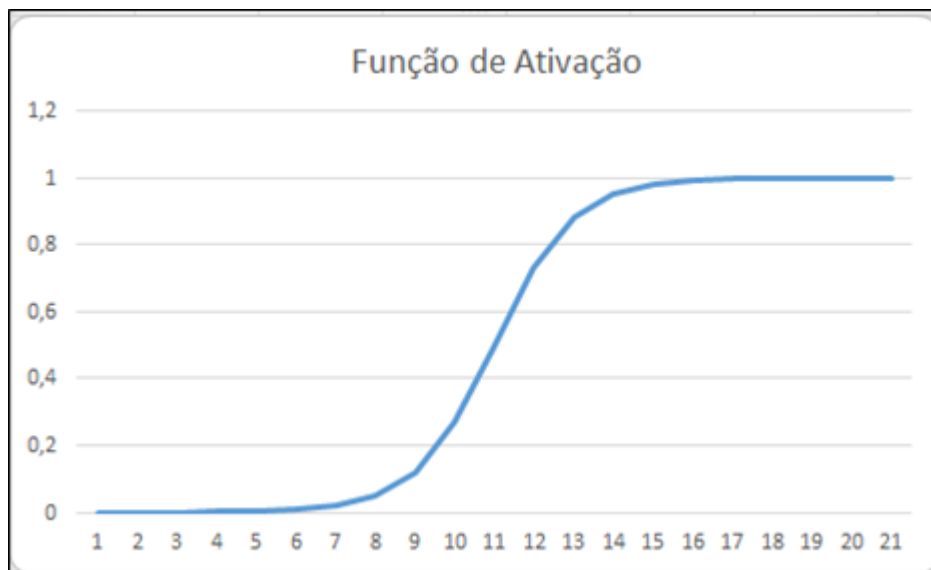


Figura 12 - Representação gráfica da função linear

A partir dos resultados da função e da saída do *perceptron*, é possível determinar se há necessidade ou não de modificar os pesos para que se possa chegar ao resultado desejado, ou seja, para aproximar o y calculado do y_t .

A diferença entre y e y_t ($y - y_t$) é chamada de erro e_r .

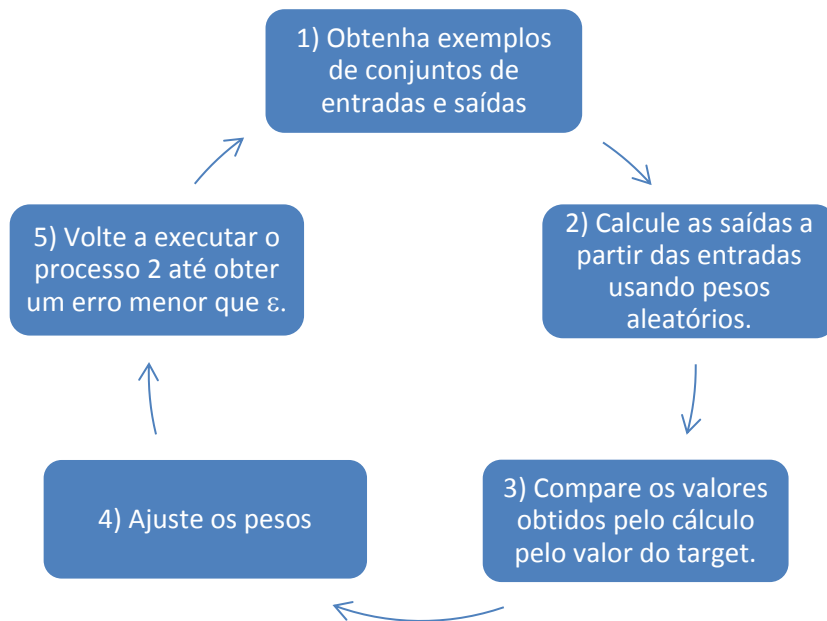
Se e_r for positivo no caso da *perceptron* apresentada, então os valores de w devem ser diminuídos. Se o valor do erro for negativo, os valores dos pesos devem ser aumentados.

O processo é repetido com os mesmos valores de entrada e o mesmo target até que uma das duas opções seguintes aconteça:

- a) $y = y_t$
- b) $|y - y_t| < \varepsilon$, sendo esse ε um valor muito pequeno, arbitrado antes de começar o processo.

Surge nesse momento a dúvida de quanto aumentar ou de quanto diminuir o valor dos pesos (w). No caso do *perceptron*, é praxe, utilizar 0,8 para diminuir e 1,2 para aumentar os pesos (SCHAFFER, 2015).


Sempre que o peso é alterado, é necessário que se repita todo o cálculo novamente, desde a multiplicação das entradas e pesos até a função de ativação, obtendo assim uma nova saída que possibilitará uma nova análise da rede. Na Figura 13 é possível observar o ciclo de funcionamento de ajuste dos pesos.



Fonte: Adaptado. SCHAFFER, 2015.
Figura 13 - Ciclo de ajuste dos pesos

2.1.8 Princípio de funcionamento do *Perceptron* multicamadas

De acordo com a teoria de (SILVA, et al., 2010), observa-se que cada uma das entradas da rede, representando os sinais advindos de determinada aplicação, será propagada uma a uma em direção à camada neural de saída do PMC (Perceptron de Múltiplas Camadas). Neste caso, as saídas dos neurônios da primeira camada neural oculta, representam as entradas dos neurônios pertencentes à segunda camada oculta. Na Figura 14 pode-se observar uma rede Perceptron multicamadas.



Fonte: SILVA, 2010.

Figura 14 - Ilustração de rede Perceptron multicamadas

Em uma rede PMC, independentemente da quantidade de camadas intermediárias é sempre realizada num único sentido, ou seja, partindo da camada de entrada em direção à camada de saída.


Ainda de acordo com a teoria de (SILVA, et al., 2010), a especificação de uma rede PMC, assim como a quantidade de camadas intermediárias e seus respectivos número de neurônios, dependem de diversos fatores. Em resumo, a classe de problema, a disposição das amostras de treinamento e os valores iniciais atribuídos tanto aos parâmetros de treinamento como às matrizes de pesos são elementos que auxiliam na definição de sua topologia.

Conforme mencionado anteriormente, o ajuste dos pesos e do limiar de ativação de cada um dos neurônios utilizados em uma rede PMC, é efetuado utilizando-se o processo de treinamento supervisionado, ou seja, para cada amostra de dados de entrada se obtém a resposta desejada (saída).

O algoritmo de aprendizado aplicado no decorrer do processo de treinamento das redes PMC é denominado *backpropagation* ou algoritmo de retro propagação do erro.

No entendimento de (HEATON, 2015), *backpropagation* é um algoritmo de aprendizado baseado na correção do erro através do método do gradiente. O gradiente descendente refere-se ao cálculo de cada gradiente em peso na rede neural para cada elemento de formação.

Como a rede neural não são inseridas as saídas mas sim o valor esperado para um elemento de formação, o gradiente de cada peso vai lhe dar uma indicação sobre como modificar cada peso para atingir o resultado esperado. Se a saída da rede neural fez exatamente o que era esperado, o gradiente para cada peso seria de 0, indicando que nenhuma mudança para o peso é necessário (HEATON, 2015). Ele é composto de duas fases: cálculo do erro (*forward*) e correção dos pesos sinápticos (*backward*). A Figura 15 ilustra o processo de aprendizado *backpropagation*.



Fonte: HEATON, 2015.

Figura 15 - Algoritmo de aprendizado Backpropagation


Durante o processo de treinamento da rede com o algoritmo *backpropagation*, a rede opera da seguinte maneira: na fase inicial, um padrão é apresentado a camada de entrada da rede. A atividade resultante propaga pela rede, camada por camada, até a camada de saída. No passo seguinte, a saída obtida é comparada a saída desejada para o padrão apresentado na entrada da rede. Se esta não estiver correta, o erro é calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é propagado pela rede.

No t3pico a seguir, consta a explica33o de como funciona o treinamento de um processo de aprendizado supervisionado.

2.1.9 Processo de treinamento do *Perceptron* multicamadas

Para as redes PMC, o processo de treinamento ocorre com a utiliza33o do algoritmo *backpropagation*, conhecido tamb3m por regra Delta generalizada.

A Figura 16, 3 considerada uma configura33o de PMC constitu3da de duas camadas ocultas, sendo composta por n sinais de entrada em sua camada de entrada, n_1 neur3nios na primeira camada neural oculta, n_2 neur3nios na segunda camada e ainda n_3 sinais associados a camada neural de sa3da.



Fonte: HEATON, 2015.

Figura 16 - Representa33o das duas fases de treinamento da rede PMC

A primeira fase a ser aplicada denomina-se “propaga33o adiante” ou *forward*, na qual os sinais $\{x_1, x_2, \dots, x_n\}$ de uma amostra do conjunto de treinamento s3o inseridos nas esferas de entrada da rede e s3o alastrados camada a camada at3 a produ33o das respectivas sa3das. A aplica33o dessa fase, visa obter principalmente as respostas da rede, levando em considera33o apenas os valores atuais dos pesos sin3pticos e dos neur3nios, os quais permanecer3o inalterados at3 o final da execu33o desta fase (HEATON, 2015).

Em seguida, as respostas reproduzidas pelas saídas da rede, são comparadas com as respostas desejadas, pois, conforme já mencionado anteriormente, trata-se de um processo de aprendizado supervisionado.


Considerando que uma rede PMC é constituída de n_3 neurônios em sua camada de saída, os desvios (erros) entre as respostas desejadas e aqueles produzidos pelos neurônios de saída, são então calculados em conjunto, e utilizados para ajustar os pesos e limiares de todos os neurônios constituintes da rede.

Desta forma, devido aos valores de erros encontrados, aplica-se em seguida a segunda fase do método *backpropagation*, denominada de “propagação reversa” ou *backward*. Diferentemente da fase anterior, os ajustes e variações dos pesos sinápticos e limiares de todos os neurônios da rede são efetuados no decorrer desta fase.

Em resumo, a aplicação sucessiva das fases *forward* e *backward* fazem com que os pesos sinápticos se ajustem automaticamente em cada nova interação. Desta forma, atua na diminuição gradativa da soma dos erros produzidos pelas respostas da rede em comparação frente àquelas desejadas.

2.1.10 Funcionamento Rede *Perceptron* contendo 3 neurônios

Na Figura 17 é apresentada uma RNA de camada única ou *perceptron* contendo três neurônios. Assim como, a rede neural que contém um neurônio apenas, a RNA *perceptron* também possui em sua arquitetura as entradas, os pesos, funções e as saídas.



Fonte: HAGAN; DEMUTH; BEALE; JESÚS, 2007.
 Figura 17 - Perceptron contendo 3 neurônios

As entradas são representadas pelo p ($p_1, p_2, p_3, \dots, p_r$), os pesos sinápticos pelo w ($w_{1,1}, w_{1,2}, \dots, w_{s,r}$). O limiar de ativação é representado pelo viés b ($b_1, b_2, b_3, \dots, b_s$).

Assim como para o neurônio único, nesse caso também ocorrerá a soma dos resultados entre a multiplicação de p por w , da seguinte forma:

$$\begin{bmatrix} w_{1,1} & w_{1,2} & w_{1,3} & w_{1,4} \\ w_{2,1} & w_{2,2} & w_{2,3} & w_{2,4} \\ w_{3,1} & w_{3,2} & w_{3,3} & w_{3,4} \end{bmatrix} \times \begin{bmatrix} p_1 \\ p_2 \\ p_3 \\ p_4 \end{bmatrix} = \begin{bmatrix} w_{1,1} \cdot p_1 + w_{1,2} \cdot p_2 + w_{1,3} \cdot p_3 + w_{1,4} \cdot p_4 \\ w_{2,1} \cdot p_1 + w_{2,2} \cdot p_2 + w_{2,3} \cdot p_3 + w_{2,4} \cdot p_4 \\ w_{3,1} \cdot p_1 + w_{3,2} \cdot p_2 + w_{3,3} \cdot p_3 + w_{3,4} \cdot p_4 \end{bmatrix}$$


O resultado dessa multiplicação será somado a $[b_1 \ b_2 \ b_3]$, o que trará o valor de n (n_1, n_2, n_3).

Os valores de n serão submetidos à função de ativação, neste caso a função log-simóide, conhecida pela fórmula:

$$f(x) = \frac{1}{1 + e^{-n}}$$

Depois de realizados os cálculos pela função log-simóide, obtêm-se os valores relativos a a (a_1, a_2, a_3).

Os valores de a serão submetidos a um novo cálculo de soma e função de ativação, conforme demonstra a Figura 18.



Fonte: BARTH; GRIEBLER; LOVATO; WOLFER, 2016.
 Figura 18 - Cálculo da saída y .

Ou seja, os valores de a são somados e após é aplicada a função log-sigmóide para que se obtenha então o valor de saída y .

O processo é repetido quantas vezes necessário, alterando-se os valores dos pesos (w) até que se obtenha a saída ideal y_t (*target*).

2.1.11 Método BPROP

O método *backpropagation* (BPROP) foi complementado em 1986, por Rumelhart, Hinton e Willian e consiste em um procedimento de aprendizagem de redes neurais *Feedforward* (onde os neurônios estão dispostos em camadas, conectadas por pesos unidirecionais na direção entrada à saída) de múltiplas camadas. Basicamente, esse procedimento faz uso de vetores capazes de mapear um conjunto de entradas para um conjunto específico de saídas (TISSOT, CAMARGO, & POZO, 2009).

Esse tipo de aprendizado é utilizado para ajustar iterativamente os pesos da rede neural para assim minimizar a diferença dos valores da saída atual e da saída desejada. Inicialmente a rede possui pesos aleatórios. No processo de aprendizagem, é apresentado um vetor de entrada para a rede e então o mesmo é propagado para obter-se o valor da saída. Assim, o vetor de saída resultante é comparado ao vetor de saída desejado, o que resulta em um erro, que é retropropagado pela rede, permitindo assim o ajuste dos pesos. O processo é repetido até que se obtenha o valor do vetor de saída desejado.

Com isso, é possível dividir o algoritmo *backpropagation* em três fases (BOUSFIELD, 2008):

(1) Inicialmente é alimentado um padrão de entrada (vetor), que é propagado entre todas as camadas da rede, sempre para frente, até que o sinal consiga atingir a

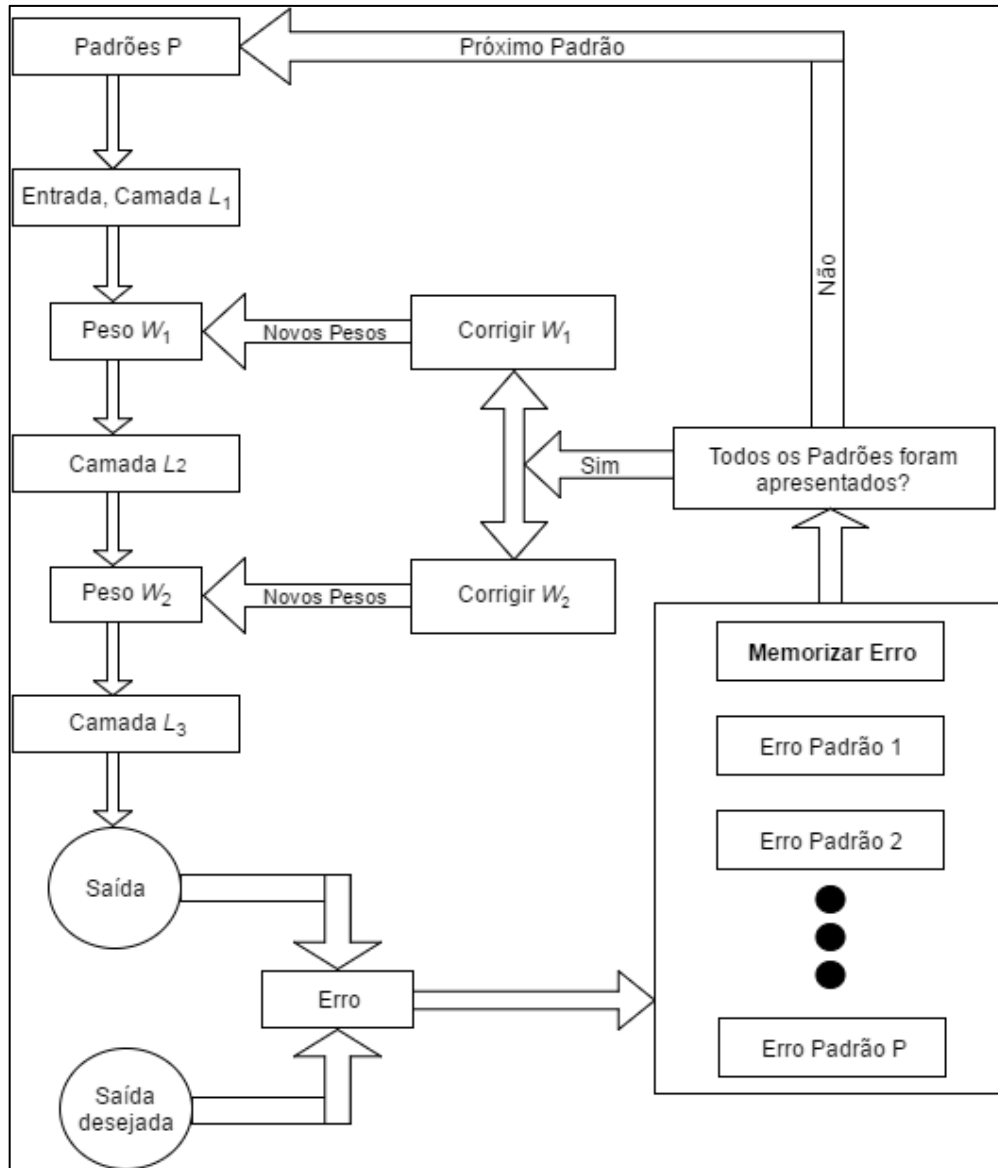
camada de saída, onde então é gerada uma resposta. Nesta fase, é ponderado um peso w para a entrada de cada neurônio.

(2) Posteriormente, aplicando uma regra de correção, os pesos são ajustados por meio da retropropagação (*backpropagation*) do erro, fazendo uso da saída gerada e a saída desejada. Esse é um tipo de aprendizagem supervisionado. Nesta etapa, o erro é propagado em direção a camada de entrada, e distribuído entre os neurônios.

(3) Enquanto o erro, encontrado entre a saída da rede e a saída desejada, for maior que um valor considerado tolerado, o ciclo é reiniciado e mantido até alcançar seu objetivo. Os neurônios frequentemente utilizados atuam com uma função

sigmoidal $y = \frac{1}{1+e^{-x}}$

A Figura 19 ilustra o fluxograma de um algoritmo *backpropagation*.



Fonte: BOUSFIELD, 2008.

Figura 19 - Fluxograma do Algoritmo *Backpropagation*

Primeiramente, apresenta-se o padrão de entrada. Depois é propagado o peso para cada camada. Para os neurônios de cada camada calcula-se o valor da entrada multiplicado pelo peso. Então é propagado o sinal para a camada de saída, onde o mesmo é comparado a saída desejada para obter-se o erro. Para cada neurônio na camada de saída deve-se calcular o erro médio quadrático. Após o processo, deve-se ajustar os pesos entre as camadas e para cada camada deve-se calcular o ajuste dos pesos.


As redes neurais que utilizam o método *backpropagation*, especialmente as redes multicamadas, trabalham com uma regra delta variada, chamada de regra delta generalizada. A funcionalidade da regra delta generalizada ocorre quando é utilizada

na rede uma função de ativação semi-linear, diferenciável e não decrescente, que em sua maioria é a função sigmoide já vista anteriormente.

Segundo conceituação de (CARVALHO, 2009), o percentual de aprendizado adquirido é uma proporção constante no intervalo $[0,1]$, pois este método de aprendizado demanda apenas que a mudança incisiva no peso seja proporcional à saída desejada.

Porém, o gradiente descendente requer passos extremamente pequenos, assim quanto maior a constante utilizada, maior será o resultado da mudança nos pesos, podendo assim aumentar a velocidade do aprendizado. Com isso é possível levar à uma oscilação na superfície de erro. (CARVALHO, 2009) ainda explica que nesse caso o ideal seria empregar a maior taxa possível de aprendizado e que essa taxa não induzisse à uma oscilação no processo de treinamento da rede, trazendo como resultando um aprendizado mais acelerado.

A descida do gradiente irá determinar um vetor de pesos, responsável por minimizar o erro E . Isso ocorre iniciando com um vetor de pesos arbitrário que deverá ser modificado repetidamente (sempre no intervalo $[0,1]$), em pequenos passos. Em cada passo, o vetor de pesos utilizado anteriormente é alterado com o objetivo de produzir uma maior queda na superfície de erro. O processo é repetido até que se atinja o erro global mínimo. A Figura 20 ilustra a descida do gradiente.



Fonte: KOERICH, 2005
Figura 20 - Descida do Gradiente

O algoritmo de aprendizagem *backpropagation* utiliza a descida do gradiente a fim de minimizar o erro quadrático médio encontrado entre a saída da rede e a saída desejada.

O erro quadrático médio é dado pela expressão: $E_M = \frac{1}{p} \sum_{k=1}^p E(k)$.

Calcula-se a influência de cada peso sobre a rede neural utilizando a derivada da função do erro E em relação a cada peso:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial s_i} \frac{\partial s_i}{\partial net_i} \frac{\partial net_i}{\partial w_{ij}}$$

Onde w_{ij} é o peso do neurônio j para o neurônio i, s_i é a saída e net é a soma ponderada das entradas do neurônio i. Uma vez identificada a derivada parcial de cada peso, é aplicada uma função a fim de minimizar o erro:

$$w_{ij}(t + 1) = w_{ij}(t) - \epsilon \frac{\partial E}{\partial w_{ij}}(t)$$

Após calculado o erro, o algoritmo faz a correção dos pesos, partindo da saída até a entrada, em todas as camadas da rede.

A taxa de aprendizado a ser utilizado é um parâmetro de grande importância no aprendizado da rede neural. A mesma não deve ser muito pequena, pois causa um treinamento muito lento da rede, e nem muito grande, pois gera muita oscilação.

Segundo o conceito de (CARNEIRO, et al., 2011), quando utilizada uma taxa de aprendizado muito pequena, e dependendo dos pesos iniciais (aleatórios), a Rede Neural pode ficar retida em um mínimo local. Quando essa taxa de aprendizado é muito grande, a Rede Neural pode não conseguir alcançar o mínimo global, pois os valores determinados aos pesos são muito grandes.

Schaffer (2015) recomenda que os valores a serem utilizados sejam 0,8 e 1,2 para ajuste dos pesos, onde caso o valor da saída for positivo, será realizada a multiplicação do valor por 0,8. Bem como, se o valor for negativo, será realizada a multiplicação pelo valor 1,2.

O principal objetivo desse aprendizado *backpropagation* é a obtenção de um mapeamento entre as entradas e saídas. Quando uma rede é considerada bem treinada, isso significa que a mesma aprendeu um modelo suficientemente bem para que posteriormente tenha boas estimativas.

No estudo do conceito *backpropagation*, encontram-se alguns pontos positivos e negativos quanto ao uso desse método, sendo eles:

-Negativos: é considerado um método bastante caro computacionalmente, pois é mais lento; não resolve bem os problemas considerados de grande porte; por vezes, a solução encontrada pelo método é um mínimo local para a função erro.

-Positivos: possuir um poder de aproximação considerado universal: considerando uma função contínua, há uma rede que possui duas camadas – sendo uma oculta - que pode ser treinada pelo método *backpropagation* a fim de aproximar o quanto desejar essa função; e ainda, é algoritmo mais usado.

2.1.12 Método RBPROP

O método '*Resilient Propagation*' ou RBPROP é um esquema de aprendizado adaptado para um melhor desempenho no processamento de perceptron multicamadas, uma vez que a adaptação ocorre diretamente no peso de acordo com o gradiente local. O RPROP leva em consideração somente o sinal da derivada parcial, atuando de forma independente sobre cada peso da rede neural.

Para que isso seja possível é necessário analisar cada valor separadamente através do cálculo de $\Delta_{ij}^{(t)}$ que determina o valor a ser alterado. Esse valor, baseia-se na visão sobre o erro E, de acordo com a seguinte regra:

$$\Delta_{ij}^{(t)} = \begin{cases} n^+ * \Delta_{ij}^{(t-1)} & , \text{ if } \frac{\partial E^{(t-1)}}{\partial w_{ij}} * \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ n^- * \Delta_{ij}^{(t-1)} & , \text{ if } \frac{\partial E^{(t-1)}}{\partial w_{ij}} * \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)} & , \text{ else} \end{cases}$$

$$\text{where } 0 < n^- < 1 < n^+$$

Por meio dessa regra é possível observar que cada vez que a derivada parcial, de w_{ij} , correspondente ao peso muda de sinal, indica que a última atualização foi muito grande e devido a isso o salto foi maior que o mínimo local, e então, é necessário que se faça um novo ajuste do valor $\Delta_{ij}^{(t)}$ de acordo com o fator η^- . Se o sinal da derivada for mantido, o valor a ser atualizado deve ser levemente aumentado na intenção de acelerar o processo.

Uma vez adaptados os valores para cada peso, a rede deve seguir a regra: se a derivada for positiva (aumento do erro), deve-se reduzir o valor do peso na próxima adaptação; se a derivada for negativa, é necessário aumentar o valor para treinamento.

$$\Delta w_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)} & , \quad \text{if } \frac{\partial E^{(1)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}^{(t)} & , \quad \text{if } \frac{\partial E^{(1)}}{\partial w_{ij}} < 0 \\ 0 & , \quad \text{else} \end{cases}$$

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

Porém, para as regras de ajuste, se aplica uma exceção, se a derivada mudar seu sinal a alteração anterior foi muito grande e o valor mínimo foi ultrapassado, devendo-se então reverter a alteração do peso anterior.

Para se alcançar o erro mínimo, diversos estudos consideram alguns valores como adequados para o ajuste dos pesos, podendo-se assim chegar mais rápido ao valor desejado. Quando o valor de η for negativo (η^-) o ajuste do peso deverá ser a multiplicação do ajuste anterior por 0,5. Se o valor de η for positivo (η^+), a regra a ser aplicada é a multiplicação da última alteração pelo valor de 1,2.

Seguindo essa regra, é possível se chegar a um resultado esperado de forma mais rápida e eficiente, evitando assim um grande retrabalho na busca do valor ideal dos pesos incididos sobre a rede neural.

2.1.13 Levenberg-Marquardt

Assim como o Método de *Gauss Newton*, o algoritmo *Levenberg-Marquardt* é eficiente quando não se trabalha com mais do que centenas de conexões na rede neural (HAGAN, 1994). Isso ocorre por este algoritmo precisar armazenar uma matriz quadrada, onde sua dimensão é definida pelo número de conexões efetuadas pela rede.

Em algumas pesquisas ou aplicações computacionais, faz-se necessário, a utilização de um método de medição para auxiliar na avaliação de dados experimentais, nesses casos, pode-se utilizar um algoritmo de minimização, que dentre os existentes, o mais conhecido e aplicado é o *Levenberg-Marquardt*.

De acordo com (Liu, 2010), é considerado o método mais rápido para realizar o treinamento de redes neurais do tipo *feedforward backpropagation*.

No processo de desenvolvimento do cálculo este método aplica dois diferentes tipos de matrizes, sendo elas, a matriz Jacobiana e Hessiana. Nos tópicos a seguir, o grupo demonstra a explicação da aplicação e cálculo de cada uma destas matrizes.

2.1.13.1 Matriz Jacobiana

É formada pelas derivadas (ver tópico 2.1.6) parciais de uma função vetorial de primeira ordem. Quando uma função é diferenciável em um determinado ponto, a sua derivada é dada em coordenadas para a Matriz Jacobiana, no entanto, uma função não precisa ser diferenciável para a existência da Jacobiana. Basta que as derivadas parciais existam. Fórmula:

$$JF(x, y) = \begin{bmatrix} x^2y \\ x \\ y \\ x - y \end{bmatrix}' = \begin{bmatrix} 2xy & x^2 \\ 1 & -x \\ y & y^2 \\ 1 & -1 \end{bmatrix}.$$

2.1.13.2 Matriz Hessiana

Essa matriz sempre será uma matriz quadrada. Seu determinante é denominado da função hessiana, o qual não possui os mesmos resultados da função Jacobiana, pois um trata-se da constante das primeiras derivadas parciais e a outra das segundas derivadas parciais.

Esta matriz é utilizada para identificar pontos críticos. Ou seja, realizando uma comparação com a aplicação desta no uso de redes neurais sua utilização auxilia na identificação dos pontos de correlação apresentados no desempenho da rede.

Fórmula:

$$H[f(x_1, x_2, x_3, \dots, x_n)] = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \dots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$$

2.2 ENERGIAS RENOVÁVEIS

Atualmente as fontes renováveis de energia fornecem aproximadamente 9% da energia mundial e de 8% a 10% das necessidades dos Estados Unidos. No entanto, em muitas partes do mundo esses percentuais vêm aumentando de maneira significativa. A energia eólica é o recurso energético cuja utilização aumenta mais rapidamente no mundo hoje, com índice de crescimento de 37% ao ano na Europa. Em seguida vem a energia fotovoltaica, com 24% de crescimento por ano no mundo. Entretanto, a energia hidrelétrica fornece 19% da energia consumida no planeta atualmente. Alguns estudos recentes apontam que as fontes renováveis de energia devem aumentar sua participação para 30% a 40% do total em 2050, especialmente as relacionadas com a mudança climática (HINRICHS, et al., 2008).

Os recursos energéticos renováveis podem ser categorizados nas formas: solar, eólica, hídrica, biomassa e geotérmica. Cada um desses recursos tem muitos usos, apresentados no Quadro 01.

RECURSOS ENERGÉTICOS RENOVÁVEIS E USO	
Radiante (Solar)	Aquecimento e refrigeração de ambientes (ativos ou passivos) Aquecimento doméstico de água, piscinas Eletricidade (fotovoltaica) Fornalhas solares, eletricidade térmica
Eólica	Eletricidade (turbinas de vento) Mecânica (bombeamento de água, moção)
Hídrica	Eletricidade, mecânica (rodas d'água)
Biomassa	Calor (combustão direta), eletricidade Combustíveis (gás, líquidos)
Geotérmica	Eletricidade, aquecimento coletivo

Fonte: HINRICHS; KLEINBACH, 2008.

Quadro 1 - Recursos Energéticos Renováveis e Uso

As fontes renováveis oferecem muitas vantagens para um mundo carente de energia. Podem ser utilizadas de muitas maneiras, gerando problemas ambientais mínimos ou nem causar estes e podem ser controladas com o uso de tecnologias apropriadas. Esses recursos renováveis oferecem esperança principalmente aos países em desenvolvimento, cujo os índices de desenvolvimento econômico são

seriamente comprometidos pelos altos custos da energia. Principalmente pelo fato da Terra receber muitas vezes mais energia do sol do que a consumida sob todas as outras formas.

Considerando alguns aspectos importantes, pode-se afirmar que as energias renováveis são subutilizadas. A primeira razão disso é em função da economia, especialmente quando o custo da geração de energia renovável é comparada com o custo de combustíveis comerciais de baixo custo. Os preços das fontes de energia diminuíram consideravelmente nos últimos anos 20 anos, mesmo assim, existem outros fatores que limitam a aplicação de sua utilização. Continuam existindo incertezas técnicas e financeiras, inadequações na documentação e da avaliação de diversos projetos solares que tem sido desenvolvidos globalmente, falta de estratégias governamentais coerentes e descrença pura por parte de muitos tomadores de decisão relacionadas a energia.

Também existem dificuldades quanto ao armazenamento de energia, pelo fato desses recursos serem difusos e dependentes do tempo e clima. Entretanto, as fontes de energia continuarão disponíveis por muito tempo mesmo depois que os combustíveis fósseis se esgotarem (HINRICHS, et al., 2008).

Devido à grande escassez de energias não renováveis como o petróleo e as alterações climáticas que vem sendo constantes, muitas pesquisas vêm sendo realizadas a cerca, da questão energética, onde se buscam alternativas renováveis que possam substituir a escassez. Essa energia renovável pode ser de origem animal, vegetal, força do vento, captação de luz, dentre outros.

Tratando-se de fontes alternativas, o Brasil possui um grande diferencial quanto a esse quesito, pois sua biodiversidade permite que essa energia seja gerada por diversos meios, tanto a hidroelétrica já muito utilizada, como a utilização da velocidade dos ventos, a captação de luz solar, entre outros (PACHECO, 2006).

A energia solar possui utilidades como aquecimento de ambientes e água, produção de energia elétrica, e possui um grande índice de acerto no Brasil, considerando que a radiação solar é alta, principalmente na região do Nordeste, onde o clima é quente e a insolação é alta durante todo o ano.

A energia solar térmica é captada através de painéis térmicos ou coletores solares. Os mesmos são muito utilizados em casas e hotéis para o aquecimento de

água e também de ambientes. Os painéis solares têm a função de captar e transferir o calor provindo da radiação solar para a água que passa dentro delas para assim ser utilizado como uma fonte de calor.

Quando ocorre geração de eletricidade por meio da irradiação solar, o processo é chamado de energia solar fotovoltaica que consiste basicamente na transformação da energia do sol em eletricidade. Esse tipo de energia já é conhecido a bastante tempo, desde 1839 quando foi descoberto por Edmond Becquerel, porém, o seu uso e aproveitamento iniciou-se apenas após 100 anos (FILHO, 2003).

2.2.1 Norma ABNT NBR 11704

Para a construção e uso de painéis solares, faz-se necessário seria algumas técnicas e normas que propõem o uso correto do material. A norma ABNT NBR 11704 define a classificação dos sistemas fotovoltaicos de energia solar em energia elétrica.

De acordo com a Norma ABNT NBR 11704 (2008), o sistema fotovoltaico necessita de alguns componentes fundamentais para seu funcionamento, sendo eles: um controlador de carga, componente eletrônico destinado ao controle e monitoramento da carga e descarga da bateria receptora da energia fotovoltaica; um inversor, responsável pela conversão da tensão contínua, que provém do gerador fotovoltaico ou da bateria, em uma tensão alternada; um seguidor de potência máxima, dispositivo controlador que permite um funcionamento do sistema próximo à potência máxima da geração fotovoltaica, sob variadas condições de irradiação, temperatura do ambiente e carga disponível.

Quanto à classificação dos sistemas que possuem interligação ao sistema público de energia elétrica, a Norma dita que os sistemas se classificam em:

- a) Sistemas isolados: que não possuem nenhuma conexão ao sistema de energia elétrica público;
- b) Sistemas com conexão à rede elétrica: que possuem efetivamente uma conexão ao fornecimento público de energia elétrica.

Além disso, a Norma também dita a classificação quanto a configuração dos sistemas, sendo eles:

- a) Sistemas puros: aqueles que fazem uso exclusivo de um gerador fotovoltaico como gerador de energia;

- b) Sistemas híbridos: que resultam de uma associação entre o gerador fotovoltaico com outro gerados de energia elétrica.

A Norma disponibiliza também alguns exemplos de sistemas fotovoltaicos, conforme pode ser observado no Quadro 2:

Tipo de sistema		Alimentação dos consumidores	Acumulação de energia elétrica	Componentes básicos	Aplicações típicas
Sistemas isolados	Puros	Tensão contínua	Não	Seguidor de potência máxima (desejável)	Bombeamento, produção de hidrogênio etc.
			Sim	Controlador de carga e acumulador	Iluminação, telecomunicações, sinalização náutica, cerca elétrica, proteção catódica etc.
		Tensão alternada	Não	Inversor	Bombeamento, uso industrial etc.
			Sim	Controlador de carga, acumulador e inversor	Eletrificação rural, bombeamento, telecomunicações, uso industrial, iluminação etc.
	Híbridos	Tensão contínua	Sim	Controlador de carga, acumulador e gerador complementar	Telecomunicações, iluminação, sinalização rodoviária e ferroviária etc.
		Tensão alternada	Opcional	Controlador de carga, acumulador opcional e gerador complementar	Iluminação, uso industrial etc.
Sistemas conectados à rede elétrica	Puros	Tensão alternada	Não	Inversor	Aplicações residenciais, comerciais e industriais, produção de energia para a rede pública etc.
	Híbridos	Tensão alternada	Não	Inversor e gerador complementar	Aplicações residenciais, comerciais e industriais, produção de energia para a rede pública etc.
			Sim	Inversor, gerador complementar e acumulador	Eletrificação rural, uso industrial, suprimento ininterrupto de energia etc.
NOTA Todos os tipos de sistemas possuem gerador fotovoltaico entre os componentes básicos.					

Fonte: ABNT NBR 11704, 2008.

Quadro 2 - Exemplos de classificação de sistemas fotovoltaicos

2.2.2 Tecnologias de células fotovoltaicas

Em sua grande maioria, as células fotovoltaicas encontradas nos painéis solares são produzidas a partir do uso do Silício (Si), componente responsável pela captação de elétrons geradores de energia. Essas células podem ser constituídas de diferentes formas, usando cristais monocristalinos, cristais policristalinos e ainda o silício amorfo. Essas células solares são as responsáveis pela conversão da energia luminosa em energia elétrica.

As células monocristalinas possuem um rendimento elétrico alto, mas em contrapartida, o uso de um material puro e de estrutura perfeita de cristal, faz com que seja necessária uma grande quantidade de energia para sua fabricação, tornando suas técnicas de produção caras e complexas.

Células poli-cristalinas possuem um custo considerado menor, considerando que necessitam de menos energia em sua fabricação, porém com isso apresentam inferioridade no seu rendimento elétrico, causada pelo cristal imperfeito que é utilizado na fabricação.


As células de Silício amorfo possuem o menor custo e também o menor rendimento elétrico. Essas células são películas finíssimas que podem ser utilizadas na construção, o que faz diminuir mais o seu proveito de energia.

Historicamente, as células de silício monocristalino são as células mais utilizadas como conversor de energia solar em eletricidade, considerando que sua fabricação é uma metodologia básica e bem formada.

2.2.3 Radiação solar

O Sol é considerado o maior transmissor de energia natural, sendo responsável pela sobrevivência dos seres terrestres e uma fonte inesgotável de energia, podendo ser utilizada, por meio de captadores e conversores, como energia elétrica. Uma forma de conversão dessa energia solar é através das células fotovoltaicas, convertendo a radiação solar em energia elétrica.

A quantidade de radiação que chega a Terra é alta, porém, apenas uma fração desta chega até a superfície terrestre, devido a fatores de influência como a reflexão e absorção dos raios solares pela atmosfera terrestre. Essa fração que atinge o solo também provém de forma distinta, podendo ser de irradiação direta, quando não há obstáculos entre o solo e a atmosfera, e a irradiação difusa, que ocorre através das nuvens dispostas depois da atmosfera. A Figura 21 ilustra a radiação a nível de solo.



Fonte: FOCUSOLAR, 2015.

Figura 21 - Radiação solar á nível do solo

Alguns fatores possuem grande influência na intensidade da irradiação solar no solo terrestre. A alternância dos dias e noites, as estações do ano períodos nublados e chuvosos, trazem muita variabilidade para o recurso energético solar a ser utilizado, podendo induzir muitas vezes na aquisição de um sistema capaz de estocar a energia adquirida da conversão.

Na sequência estão dispostos alguns tipos de irradiância encontrados durante o estudo realizado:


- **Irradiância direta:** representa a irradiância incidente numa superfície horizontal do solo que não sofreu nenhum processo radioativo na atmosfera;
- **Irradiância difusa:** consiste na irradiância incidente em uma superfície horizontal provinda do espalhamento por componentes atmosféricos, exemplo: moléculas, nuvens. É responsável pela iluminação de locais que não recebem luminosidade direta do sol;
- **Irradiância global:** consiste na totalidade da irradiância, ou seja, é o somatório da irradiância direta e difusa;
- **Irradiância direta normal:** consiste em uma parte da irradiância solar vinda diretamente do sol com incidência normal à superfície e está associada ao ângulo solar direto, em relação ao ângulo horizontal;

A medida de radiação solar, tanto direta como difusa incidente em determinado local, é o maior fator de influência no estudo das condições adequadas para implantação do recurso fotovoltaico. Através de um histórico de medidas de radiação

em determinada região, é possível determinar a viabilidade da instalação de sistemas térmicos e principalmente fotovoltaicos.

2.2.3.1 Componentes de um sistema fotovoltaico

Os sistemas fotovoltaicos podem ser classificados basicamente em três categorias, sendo os sistemas isolados, sistemas híbridos e sistemas conectados a rede. Apesar de suas características distintas, os sistemas fotovoltaicos possuem uma configuração básica comum entre si, demonstrada pela Figura 22.



Fonte: CRESESB, 2008.

Figura 22 - Componentes básicos de um sistema fotovoltaico

Nos sistemas isolados é comum que seja utilizada alguma forma de armazenamento da energia produzida através da radiação solar. Podendo ser através de baterias, onde as mesmas podem ser utilizadas posteriormente para a geração de energia, caso exista a necessidade. Alguns sistemas isolados não necessitam de um sistema de armazenamento, quando utilizada a energia na medida em que a mesma é produzida.

Os sistemas híbridos possuem variadas fontes de geração de energia, como a fonte eólica, diesel, fotovoltaica, entre outros, quando não possuem conexão com a rede de energia convencional. Essa variedade de possibilidades exige um maior controle e uma maior complexidade na otimização de seu uso para que se possa garantir a máxima eficiência da energia produzida.

Sistemas interligados a rede utilizam um grande número de painéis fotovoltaicos, transmitindo toda a geração de energia diretamente à rede, não sendo assim necessário um meio de armazenamento da energia. Esses sistemas vêm como um complemento à fonte de energia convencional, conectando-se a conversores que levam toda a energia para a rede.

2.3 TRABALHOS RELACIONADOS

Durante o desenvolvimento do trabalho de conclusão de curso, foi realizado um estudo em artigos relacionados ao tema da pesquisa, focando principalmente naqueles que utilizaram o mesmo método de treinamento da rede neural, o algoritmo *Levenberg-Marquardt* e que mensuram o nível de irradiação solar, com o objetivo de atualizar-se sobre as pesquisas recentemente desenvolvidas, contextualizar e diferenciar as contribuições científicas.

A estrutura da pesquisa aplicada nos trabalhos relacionados deu-se da seguinte forma:

TÍTULO	Título do trabalho.
OBJETIVO	Objetivo dos autores com a aplicação do trabalho.
MOTIVAÇÃO	Motivação a qual levou-os a realizar o estudo.
DESENVOLVIMENTO	Estruturação da rede neural, dados utilizados, número de camadas e neurônios.
RESULTADOS OBTIDOS	Resultados obtidos com a aplicação do estudo.
CONCLUSÕES	Conclusão dos autores.

2.3.1 Redes neurais artificiais para predição de radiação solar com base em estações indianas

Amit Kumar Yadav e S.S. Chandel - Centre for Energy and Environment National Institute of Technology Hamirpur H.P. *India-International Journal of Computer Applications* (0975 – 8887) Volume 50 – No.9, July 2012.

O trabalho de (Yadav et al. 2012) buscou, através do uso do método Levenberg-Maquart, mensurar a previsão de radiação solar utilizando como base 12 estações Indianas com diferentes condições climáticas. Para estruturação da rede, utilizou dados de latitude, longitude e insolação (luz do sol) como parâmetros de entrada, contendo apenas uma camada oculta com a função de ativação tan-sigmóide, uma camada de saída com a função de ativação Purelin.

A estruturação da rede neural ocorreu no *software* MATLAB. A proposta de rede neural desenvolvida obteve resultados satisfatórios após sua aplicação, tornando-se adequada para utilização em aplicações de energia solar.

2.3.2 Utilizando redes neurais artificiais para prever a irradiação solar direta

James Mubiru - Department of Physics, Makerere University, P.O. Box 7062, Kampala, Uganda - *Hindawi Publishing Advances in Artificial Neural Systems*. Volume 2011.

O trabalho de (Mubiru 2011) buscou desenvolver um modelo de previsão capaz de estimar a média diária mensal da radiação solar direta na Uganda, através de dados coletados de 4 diferentes estações meteorológicas, utilizando redes neurais artificiais (RNAs).

Através do uso do método *Levenberg-Maquardt*, estruturou uma rede de 6 neurônios capaz de prever a irradiação solar utilizando dados de horas de sol e irradiação (de 2003 a 2005) e temperatura máxima (de 1993 a 2005). Três funções de transferência foram investigadas, o que incluiu a tangente sigmóide, ingresse sigmóide e função linear. Para a montagem da rede, foi usado o *software* MATLAB. Quando comparada a um modelo empírico, a rede proposta no trabalho mostrou-se superior, trazendo dados mais confiáveis sobre a previsão de irradiação.

2.3.3 Previsão da radiação solar usando redes neurais artificiais

João Faceira, Paulo Afonso e Paulo Salgado - *Springer International Publishing Switzerland*, 2015.

O trabalho de (Faceira et al. 2015) propôs um algoritmo capaz de prever a radiação solar horária a curto e médio prazo, transformando os dados de radiação solar medidos em dados de radiação úteis para aplicações de energia. Fazendo uso do método de aprendizagem *Levenberg-Marquardt* e da função Sigmóide de ativação, foram propostos três modelos de RNAs, capazes de predizer a radiação solar. Os dados utilizados no estudo foram coletados diariamente de janeiro de 2010 á Dezembro de 2011 em Ponte da Barca - Portugal.

Os três modelos propostos foram dispostos da seguinte forma: os modelos I e II continham duas entradas e o modelo III cinco entradas com uma estrutura de *feedback*, todas utilizando 20 neurônios na camada oculta. Entre todos os dados disponíveis, utilizou-se 75% dos dados, por uma escolha aleatória, para a formação e o restante foi utilizado na fase de teste. Quando comparados, o modelo III trouxe um melhor resultado uma vez que possui um erro menor que 10%, considerado um bom índice de acordo com o estudo.

2.3.4 Aplicação de redes neurais na previsão de radiação solar para sistemas híbridos de energias renováveis

P. Chatziagorakis, N. Georgoulas, S. Papadopoulou, C. Elmasides, D. Giaouris, P. Seferlis, G.Ch. Sirakoulis, I. Karafyllidis, A. I. Papadopoulos, F. Stergiopoulos, I. Andreadis, C. Ziogou, D. Ipsakis e S. Voutetakis - *Springer International Publishing Switzerland*, 2014.

O trabalho de (Chatziagorakis et al. 2014) estruturou uma rede neural capaz de melhorar a gestão de energias renováveis através da irradiação solar presente. Os dados utilizados na rede foram coletados em um período de dois anos (não especificados) em uma estação próxima a Xanthi, na Grécia. A rede possui uma camada oculta contendo 10 neurônios, onde utilizou-se o algoritmo *Levenberg-Maquardt* para seu aprendizado.

O modelo proposto recebe como entrada a medição da irradiação dos três últimos dias, para assim estimar o valor futuro de irradiação. Os testes foram realizados com 96, 24 e 4 amostras/dia, onde foi provado que 24 amostras/dia proporcionou os melhores resultados em termos de precisão e velocidade computacional. Para reduzir o valor de erro, foram retirados os valores de irradiação coletados à noite, que eram sempre iguais a zero. Como resultado, o modelo proposto pode ser utilizado para prever a saída dos sistemas fotovoltaicos híbridos e fornecer um *feedback* valioso para sistemas de Gestão de Energia Estratégica.

2.3.5 Rede neural artificial e *wavelet* de decomposição na previsão de radiação solar global horizontal

Luiz Albino Teixeira Júnior, Rafael Morais de Souza, Moisés Lima de Menezes, Keila Mara Cassiano, José Francisco Moreira Pessanha e Reinaldo Castro Souza - *Brazilian Operations Research Society Printed version ISSN 0101-7438*, 2015.

O trabalho de (Teixeira Júnior et al. 2014) propôs um método que combina uma RNA com uma função de decomposição (*Wavelet*) para gerar a curto prazo uma previsão da irradiação solar.

Para estruturação da rede, foi utilizado o *software* MATLAB, contendo 10 dados de entrada, uma camada oculta composta por 19 neurônios artificiais, contendo a função de ativação: tangente hiperbólica e um neurônio na camada de saída com a função de ativação linear. Utilizou 7008 amostras desde janeiro a dezembro para

utilizar como entrada. A aplicação do trabalho ocorreu na cidade de Cuiabá. Com palavras próprias, os autores afirmam que a utilização de um método de decomposição junto a RNA, lhes trouxe melhores resultados, quando comparado a um modelo empírico de RNA.

2.3.6 Utilizando redes neurais artificiais para previsão da radiação solar global em Teerã considerando partículas de poluição do ar

Masoud Vakili, Saeed-Reza Sabbagh-Yazdi, Koosha Kalhor e Soheila Khosrojerdi - Department of Mechanical Engineering - International Conference on Technologies and Materials for Renewable Energy, Environment and Sustainability, 2015.

O trabalho de (Vakili et al. 2015) estruturou uma rede neural contendo quatro dados de entrada, sendo eles: velocidade do vento, umidade relativa do ar, temperatura máxima e mínima. Para aprendizado da rede foram utilizados dados de 2012 e 2013 e para testes foram utilizados dados de 2013 e 2014, totalizando em 226 dias utilizados para análise e aplicação do estudo.

O autor não especifica a quantidade de neurônios utilizados nas camadas ocultas, nem mesmo o número total de dados de entrada, citando apenas as variáveis utilizadas, no entanto, aplica o método *Levenberg-Marquardt* para treinamento da rede. Os resultados obtidos com essa rede foram ótimos, pois atingiram um coeficiente de correlação de 0,992, o que representa um valor muito próximo a 1, indicando que a rede atinge quase 100% de confiabilidade.

2.3.7 Estimativa da radiação solar global usando rede neural artificial em Qena, no Alto Egito

Emad A. Ahmed e M. El-Nouby Adam - *Journal of Clean Energy Technologies*, Vol. 1, No. 2, April 2013.

O trabalho de (Ahmed et al. 2013) buscou, através do uso da Equação de Regressão: *Angstrom-type*, realizar uma estimativa média diária de radiação solar em Qena, no Alto Egito. Os dados de entrada para estruturação da rede foram adquiridos a partir da estação meteorológica da Universidade do Sul Vale e foram utilizados dados de todo o ano de 2007.

Os resultados indicam um bom encaixe entre o valor estimado e a média da irradiação diária. Mas os resultados calculados pelo modelo de RNA são melhores do que o calculado pelo modelo empírico (ANN).

2.3.8 Utilização de redes neurais multicamadas para determinar a radiação solar global sobre superfícies inclinadas em Fianarantsoa Madagascar

I.A.J. Razafiarison, L.F.G Andriazafimahazo, B.O.A. Ramamonjisoa e B. Zeghmati -
Laboratoire de Physique Appliquée de l'Université de Fianarantsoa - Revue des Energies
Renouvelables, 2011.

O trabalho de (Razafiarison et al. 2011) buscou realizar uma avaliação da irradiação solar que atinge superfícies inclinadas em Fianarantsoa Madagascar. A motivação para realização deste estudo foi auxiliar os moradores da região que utilizam a energia em seu trabalho diário.

Para estruturação da rede o autor utilizou 4 neurônios contendo a função log-sigmóide na primeira camada e um linear na camada de saída. Como entrada, foram utilizados os dados de latitude, longitude e índice de claridade diária de 1 ano. A rede foi estruturada no software MATLAB. Após a estruturação da rede os autores concluíram que os resultados dependem muito da arquitetura da rede, ou seja, número de neurônios, entradas, etc.

2.3.9 Previsão de irradiação solar previsão baseado em redes neurais artificiais usando parâmetros estatísticos

Fei Wang, Zengqiang Mi, Shi Su 3 e Hongshan Zhao - School of Electrical and Electronic
Engineering, North China Electric Power University, 2012.

O trabalho de (Wang et al. 2012) buscou estruturar uma Rede Neural Artificial (RNA) baseando-se em dados estatísticos, visando uma maior eficácia e precisão na previsão de irradiação solar em dias instáveis. Para o estudo, fez-se uso do *software* Matlab para estruturar uma rede de quatro camadas, sendo a camada de entrada, 2 camadas ocultas e a camada de saída, sendo que na primeira camada oculta utilizou-se 11 neurônios e 15 neurônios na segunda camada oculta.

Como algoritmo de treinamento, foi utilizado o método de *Levenberg-Marquart* para analisar os dados referentes ao período de março de 2011 a dezembro de 2011,

retirados da estação do Parque Indiano de Ciência e Tecnologia, coletados sempre no intervalo de 1 hora. Além disso, o estudo fez uso de três diferentes indicadores para analisar os resultados obtidos, sendo eles o Erro Percentual Absoluto Médio (MAPE), Erro Médio Quadrático (RMSE) e Erro Médio Absoluto Viés (MABE). A RNA utilizando dados estatísticos mostrou, através da comparação entre os dados medidos e os valores previstos, que é uma rede eficaz e confiável, uma vez que mostrou resultados satisfatórios.

2.3.10 Modelo de rede neural artificial de Previsão de Radiação Solar: Pedido de Dimensionamento Stand-Alone para sistema de energia fotovoltaica.

A., Benghanem M., Bendekhis M. Mellit - Institute of engineering sciences (CUYFM), faculty of electrical engineering (USTHB), 2005.

O trabalho de (Mellit et al. 2005) teve como objetivo estruturar uma RNA de previsão de irradiação solar utilizando uma rede de Função de Base Radial (RBF). Para certificar-se da melhor rede a ser utilizada, o autor do estudo realizou alguns testes com diferentes redeu neurais de diferentes estruturas. Como dados de entrada, o estudo utilizou apenas a temperatura e a insolação, instituindo um ano típico para referência, como uma média á longo prazo, objetivando uma saída única.

Para validar o modelo a ser escolhido, foram realizadas comparações entre os resultados obtidos pela rede e os dados globais da irradiação solar já medidos, onde então chegou-se a conclusão de que o melhor desempenho foi atingido pela rede de uma camada oculta de 9 neurônios. Os dados utilizados nesse teste nunca haviam sido vistos pela rede, ou seja, eram totalmente desconhecidos, onde foram obtidas previsões com erro médio relativo de 1,34%.

A grande vantagem do modelo, é a capacidade de previsão de irradiação utilizando apenas dados de temperatura e quantidade de sol.

2.3.11 Previsão de energia solar para a Malásia utilizando redes neurais artificiais

Tamer Khatib, Azah Mohamed, K. Sopian, M. Mahmoud - Department of Electrical, Electronic & System Engineering, Faculty of Engineering & Built Environment, National University of Malaysia, Selangor, Malaysia, 2012.

O trabalho de (Khatib et al. 2012) buscou estruturar uma RNA para prever a claridade utilizada para calcular a irradiação solar, onde essa rede deveria prever os índices de claridade com base na quantidade de horas de sol, o dia e as coordenadas de localização para posteriormente calcular a irradiação solar global e difusa.

Para isso, o estudo fez uso de fórmulas e dados coletados na Malásia nos anos de 1984 á 2004 em 28 diferentes estações meteorológicas, onde dessas 23 foram utilizadas para treinar a rede e 5 para testar a rede que se constituiu em 3 camadas, sendo a camada de entrada, uma camada oculta e uma camada de saída.

As funções de transferência utilizadas foram a função log-sigmóide e o backpropagation. Com base nos resultados foi possível observar que a Malásia possui um clima estável ao longo do ano, onde a rede atingiu um erro quadrático médio de 5,86%.

2.3.12 Previsão de radiação solar diária usando ANNS para Províncias da Turquia.

SOLMAZ, Özgür, KAHRAMANLI, Humar, KAHRAMAN Ali, ÖZGÖREN Muammer. Prediction of daily solar radiation using ANNS for selected provinces in Turkey - Selcuk University, Department of Mechanical Education, Konya, Turkey, 2010.

O trabalho de (Solmaz et al. 2010) buscou realizar a avaliação do nível de irradiação solar em 6 diferentes cidades da Turquia visto que esta região está investindo bastante na questão de energia solar, sendo elas Antalya, Konya, Mersin, Mugla, Sanliurfa e Sivas. Para isso, fez uso de dois modelos diferentes de rede neural, sendo que um deles contém a função log-sigmóide. Os parâmetros de entrada utilizados na rede foram latitude, longitude e a temperatura média, coletados no período de 1998 a 2008.

No estudo, observou-se que os dias com a maior duração de luz solar aparecem em julho, enquanto os de menor índice de sol ocorrem em dezembro. Os resultados indicam que a rede de maior sucesso e eficiência possuía 10 neurônios e que a RNA sugerida possui a capacidade de prever valores precisos de irradiação solar, visto que o erro entre os valores medidos e os valores previstos de irradiação foram calculados como 8,96% e 10,12%, ou seja, ainda que uma seja mais eficiente, as duas redes apresentaram bons resultados.

2.3.13 Previsão de radiação solar usando redes neurais artificiais

Fernando Ramos Martins, Enio Bueno Pereira, Ricardo André Guarnieri - Center for Earth System Science, 2012.

O trabalho de (Martins et al. 2012) objetivou trazer informações mais precisas e confiáveis sobre a disponibilidade de energia solar futuramente, a fim de otimizar a geração de eletricidade e sistemas de distribuição energéticos. O modelo neural Modelo Eta / CPTEC utilizado no estudo é um modelo já estruturado em 1996, utilizado em pesquisas de condições climáticas e posteriormente adequado para a América do Sul. Para o treinamento da rede foram utilizados os dados meteorológicos coletados pela estação SONDA no período de 2001 a 2005, que possui localização em Florianópolis e São Martinho da Serra.

Das 58 variáveis coletadas foram utilizadas 36 para a primeira RNA e 8 para a segunda. Para avaliar os resultados, foram realizadas várias análises estatísticas e simulações utilizando diferentes subconjuntos, a fim de encontrar um conjunto que representasse os melhores resultados. Concluiu-se que as duas redes apresentaram desempenhos muito semelhantes, mas que ao final não trouxeram resultados eficientes.

2.3.14 Uma abordagem de pós-processamento rede neural para a melhoria das previsões NWP de Radiação Solar

Philippe Lauret, Maïmouna Diagnea, Mathieu Davida - University of La Réunion, 15 Avenue Cassin, 97715 Saint-Denis, Réunion, France, 2014.

O trabalho de (Lauret et al. 2013) buscou, através do uso de uma RNA, investigar se é possível que redes neurais artificiais sejam utilizadas como uma técnica de pós-processamento, visando melhorar as saídas de irradiação solar de mesoescala WRF. Através da análise dos erros é possível determinar as entradas da rede relevantes e necessária para a correção dos valores.

O modelo atmosférico WRF (Weather Research and Forecasting - Tempo de pesquisa e previsão) é um modelo de previsão numérico de tempo, desenvolvido tanto para fins de pesquisa quanto operacionais. Para testar as precisões das previsões WRF, foi escolhida a estação de ST Pierre. Para treinamento da rede, foram utilizados

dados obtidos a partir de um terreno mensurado pela estação, e são utilizados para construir o modelo de RNA de modo a reduzir a tendência das previsões WRF. Os resultados de avaliação de previsões dependem não somente do método de previsão, mas também das condições climáticas do local selecionado. Os dois métodos conduziram a resultados semelhantes, enquanto o método de correção MOS levou a uma redução significativa de polarização. Com isso, verifica-se que mais trabalhos devem ser feito no sentido de melhorar os resultados.

Os tópicos apresentados no capítulo 2 foram essenciais para o embasamento do estudo. Desde os principais conceitos sobre a inteligência artificial, neurônios artificiais e funções de ativação. Na capítulo seguinte estão apresentados os resultados obtidos com a aplicação da pesquisa.

3 ANÁLISE E DISCUSSÃO DE RESULTADOS

Neste capítulo são apresentados os resultados obtidos com o desenvolvimento do trabalho. Inicialmente está mostrada a situação que se encontra a estação meteorológica da SETREM, bem como, os dados que a mesma está coletando atualmente. Também é exposto neste capítulo como ocorreu o desenvolvimento do trabalho, e logo, os resultados obtidos com o treinamento e interações da rede neural.

3.1 ANÁLISE DA SITUAÇÃO ATUAL

O Campus da SETREM dispõe hoje de uma estação meteorológica que transmite informações em tempo real sobre diversas variáveis climáticas, tais como, temperatura, umidade, precipitação, pressão atmosférica, velocidade e direção do vento, índices UV e de radiação solar. Todas essas informações são coletadas de minuto em minuto por meio de sensores que estão disponíveis para consulta no site da Instituição.

O equipamento da estação meteorológica foi viabilizado por meio de uma parceria com o Governo Municipal de Três de Maio, que a disponibilizou à SETREM através de um termo de cessão de uso. O equipamento é da marca Davis, fabricada nos Estados Unidos, local de onde foi importado. Seu material de fabricação apresenta robustez e durabilidade elevada, especialmente porque parte do seu equipamento fica exposto às intempéries do tempo.

Na Figura 23, podem ser observados os componentes da estação meteorológica da SETREM.



Fonte: DAVIS, 2016.
 Figura 23 - Estação Meteorológica – Davis

Algumas especificações técnicas sobre a estação: o equipamento disponível no campus é do tipo sem fio e possui um conjunto de sensores multi-funções, como um coletor de chuva, sensores de temperatura e umidade, anemômetro, painel solar e adaptador de energia. Ela é composta pela tecnologia de rádio *spread spectrum* (técnica de codificação e transmissão digital) para transmitir os dados meteorológicos sem fio a até 1.000 pés (300 m).

A estação meteorológica contém as seguintes funções de coleta de dados:

- Pluviômetro (mede a precipitação pluviométrica).
- Sensor de temperatura do ar (barômetro).
- Sensor de umidade.
- Anemômetro (mede a velocidade do vento e sua direção).
- Sensor de radiação solar.
- Sensor de radiação ultravioleta (UV).
- Módulo de interface dos sensores (SIM).

O SIM é composto de uma placa eletrônica de tratamento dos sinais recebidos dos sensores e de um radiotransmissor. O alcance do sinal de rádio é de 300 metros em linha reta e sem obstáculo até o receptor. Havendo obstruções, como paredes, cercas ou árvores, o alcance varia de 60 a 120 metros.

O SIM envia dados para uma estação de controle chamada Console, que contém um display capaz de apresentar os seguintes dados e informações:

- Velocidade do vento.
- Direção do vento.
- Umidade do ar externo.
- Umidade do ar interno.
- Temperatura externa.
- Temperatura interna;
- Sensação térmica externa;
- Índice temperatura/umidade/insolação/vento;
- Ponto de orvalho;
- Pressão atmosférica atual;
- Tendência da pressão atmosférica nas últimas três horas;
- Precipitação pluviométrica acumulada do mês e do ano;
- Precipitação pluviométrica acumulada no dia atual (desde zero hora);
- Precipitação pluviométrica acumulada nas últimas 24 horas);
- Taxa de precipitação pluviométrica (nos últimos 15 minutos);
- Precipitação pluviométrica do último evento ocorrido depois de um período de 24 horas sem chuva);
- Evapotranspiração atual;
- Evapotranspiração acumulada no mês e no ano.

O console, por sua vez, é capaz de comunicar-se com o *software* proprietário *WeatherLink* instalado num computador com sistema operacional *Windows* (diversas versões). Essa comunicação se faz por meio de uma conexão USB ou por comunicação serial.

Na estação meteorológica as medições dos sensores são analógicas e a apresentação das mesmas no console é contínua. No entanto, o registro no banco de dados é determinado por parâmetros do *software* proprietário *WeatherLink*.

De todos estes dados de coleta que a Estação realiza, para desenvolvimento do trabalho, foram utilizados apenas os seguintes componentes:

- Umidade do ar externo.

- Velocidade do Vento.
- Temperatura externa.
- Ponto de orvalho;
- Pressão atmosférica atual;
- Precipitação pluviométrica acumulada no dia atual (desde zero hora);

Os componentes eletrônicos da estação, estão instalados em um local resistente às condições climáticas mais intensas.

O Quadro 3, mostra os dados obtidos da estação meteorológica. Estes são apresentados em forma de colunas de acordo com o período filtrado pelo usuário no momento do *download* dos dados através do *site* da Instituição SETREM.

dia	temperatura	umidade	velocidadevento	direcaovento	barometro	orvalho	precipitacao	rajada	taxachuva	direcao	indicecalor	hora
03/03/2016	18,9	92	0	171	1007,4	17,6	0,4	16,1	0	S	19,7	19:14:00
03/03/2016	18,9	92	0	191	1007,3	17,6	0,4	16,1	0	S	19,7	19:15:00
03/03/2016	18,9	92	0	189	1007,4	17,6	0,4	16,1	0	S	19,6	19:16:00
03/03/2016	18,9	93	0	185	1007,4	17,7	0,4	16,1	0	S	19,7	19:17:00
03/03/2016	18,9	93	0	199	1007,4	17,7	0,4	16,1	0	SSW	19,7	19:18:00
03/03/2016	18,8	93	0	180	1007,4	17,7	0,4	16,1	0	S	19,6	19:19:00
03/03/2016	18,8	93	0	169	1007,4	17,7	0,4	16,1	0	S	19,6	19:20:00
03/03/2016	18,8	93	0	194	1007,4	17,7	0,4	16,1	0	SSW	19,6	19:21:00
03/03/2016	18,8	93	0	185	1007,5	17,7	0,4	16,1	0	S	19,6	19:22:00
03/03/2016	18,8	93	0	180	1007,5	17,6	0,4	16,1	0	S	19,5	19:23:00
03/03/2016	18,8	93	0	207	1007,5	17,6	0,4	16,1	0	SSW	19,5	19:24:00
03/03/2016	18,8	94	0	202	1007,5	17,8	0,4	16,1	0	SSW	19,5	19:25:00
03/03/2016	18,8	94	0	202	1007,5	17,8	0,4	16,1	0	SSW	19,5	19:26:00
03/03/2016	18,8	93	0	171	1007,5	17,6	0,4	16,1	0	S	19,5	19:27:00
03/03/2016	18,8	94	0	185	1007,6	17,8	0,4	16,1	0	S	19,5	19:28:00
03/03/2016	18,8	94	0	185	1007,6	17,8	0,4	16,1	0	S	19,5	19:29:00
03/03/2016	18,8	94	0	185	1007,6	17,8	0,4	16,1	0	S	19,5	19:30:00
03/03/2016	18,8	94	0	185	1007,6	17,8	0,4	16,1	0	S	19,5	19:31:00
03/03/2016	18,8	94	0	185	1007,6	17,8	0,4	16,1	0	S	19,5	19:32:00
03/03/2016	18,8	94	0	189	1007,6	17,8	0,4	16,1	0	S	19,5	19:33:00
03/03/2016	18,8	94	0	185	1007,6	17,8	0,4	16,1	0	S	19,5	19:34:00
03/03/2016	18,8	94	0	202	1007,6	17,8	0,4	16,1	0	SSW	19,5	19:35:00
03/03/2016	18,8	94	0	197	1007,6	17,8	0,4	16,1	0	SSW	19,5	19:36:00
03/03/2016	18,8	94	0	200	1007,7	17,8	0,4	16,1	0	SSW	19,5	19:37:00
03/03/2016	18,8	94	0	197	1007,7	17,8	0,4	16,1	0	SSW	19,5	19:38:00

Fonte: BARTH; GRIEBLER; LOVATO; WOLFER, 2016.

Quadro 3 - Dados da estação meteorológica

A partir dos dados obtidos da estação meteorológica iniciou-se a realização das pesquisas para identificar como estes dados seriam tratados e posteriormente utilizados para estruturação das redes neurais.

3.2 ESTRUTURAÇÃO DA REDE NEURAL COM UMA CAMADA OCULTA

Para dar início à etapa de desenvolvimento e estruturação das redes neurais no software MATLAB, primeiramente foram extraídos da Estação Meteorológica da

SETREM, os dados referentes aos meses de janeiro a abril do ano de 2015, para serem utilizados como teste inicial de viabilidade da rede neural com uma camada oculta.

Dentre todos os dados que são coletados pela estação, foram selecionados para teste os dados de Temperatura, UV, Umidade, Velocidade do vento, Pressão atmosférica, Orvalho, Precipitação de chuva e o Horário da coleta. Para processar as informações coletadas, foram estruturados 15 modelos de rede neural, onde na camada oculta variou-se de 6 a 20 neurônios, afim de identificar quais seriam os melhores resultados.

O Quadro 4 apresenta uma amostra dos valores de entradas que foram utilizadas para estruturação das redes neurais, apresentados em forma de colunas. Além destes, mostra-se os resultados mínimos e máximos de cada entrada.

	Temperatura	UV	Umidade	Vel do vento	Barômetro	Orvalho	Precipitação	Hora
Amostra	22.2	0	93	1.34	1010	21	0.99	0
Máximo	32.1	10.8	99	6.71	1022	25	36.4	0.997
Mínimo	0	0	0	0	1002	0	0	0

Fonte: BARTH; GRIEBLER; LOVATO; WOLFER (2016)

Quadro 4 - Dados de Entrada utilizados na estruturação das redes

Após a coleta realizada pela estação meteorológica, houve a necessidade de realizar ajustes nos dados de entrada, uma verificação e validação, para então posteriormente serem importados no *software* MATLAB.

Quanto aos ajustes realizados, é possível afirmar que houve um árduo trabalho de tratamento dos dados de entrada. Sem a depuração de todos os dados, não era possível realizar a importação dos mesmos no *software* MATLAB, pois não eram reconhecidos. Frequentemente, mesmo após conseguir realizar a importação destes, eles não eram reconhecidos pelo programa como dados aceitáveis para utilização, assim impossibilitando o uso para treinamento da rede neural. Por isso, foi necessário revisar e tratar cada um dos dados de entrada.

A Figura 25 apresenta o modelo de rede neural utilizado no presente estudo, contendo oito variáveis de entrada, conforme especificados acima, uma camada oculta com os neurônios e funções de ativação.




Figura 22 - Modelo da estrutura da Rede Neural Artificial com uma camada oculta.

Optou-se por utilizar a função log sigmóide na camada oculta, e na camada de saída a função *Purelin*, que são funções de transferência neural responsáveis por realizar cálculos a partir das entradas disponibilizadas.

Para a camada oculta foram consideradas apenas funções em que a saída seria limitada, isso porque os valores de entrada possuem uma amplitude muito grande. Os valores da pressão atmosférica giram em torno de 1000 decaPascal e a velocidade do vento apresentava valores entre 0 e 6,75 m/s. Essas grandezas são contínuas por isso foi necessário a utilização de uma função contínua em todo o domínio, foi considerado ainda que todos os valores de entrada e de saída eram positivos. Para essas condições a função adequada é a Log-sigmóide.

Como as saídas da camada oculta tem valores limitados e a radiação solar pode variar de 0 a mais de 1000, na camada de saída é preciso utilizar uma função que amplie esses valores, por isso da utilização da função *Purelin*.




Figura 23 - Função Purelin

Uma única camada oculta foi utilizada na rede, testando-a com um número de 6 a 20 neurônios. Quanto maior o número de neurônios, mais flexível a rede se torna, havendo assim mais parâmetros para serem otimizados.

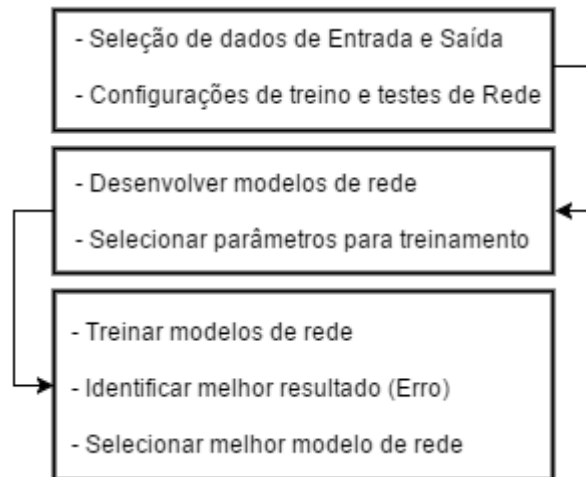
A seguir os passos para formação da rede no *software* MATLAB:

- 1- Tratar os dados de entrada (depuração).
- 2 - Definir o tamanho da matriz de acordo com o conjunto de dados a serem utilizados.
- 3 - Definir o tipo de treinamento e as validações da rede.
- 4 - Criar e Treinar a rede neural.
- 5 - Gerar os valores de saída
- 6 - Analisar os dados de saída.
- 7 - Comparar os dados de saída com o valor desejado, verificando assim o desempenho da rede.

Na Figura 27, apresenta-se de forma resumida o método utilizado no presente estudo, desde a seleção dos dados de entrada até a determinação do melhor modelo de rede neural.

Sendo assim, na primeira fase foi feita uma seleção de dados e configuração do treinamento e testes de rede. Na segunda fase, foram desenvolvidos os modelos e selecionados os parâmetros para o treinamento (ver Quadro 5).

Por fim, na terceira fase foram treinados vários modelos de rede e identificados os melhores resultados de erro, conseqüentemente apresentando o mais adequado modelo de rede neural.



Fonte: BARTH; GRIEBLER; LOVATO; WOLFER (2016)

Figura 24 - Metodologia utilizada no presente estudo.

Para dar início ao processo de modelagem da rede neural no *software* MATLAB, foram utilizados alguns comandos de programação na linguagem do próprio *software* para conseguir criar uma rede neural customizada, com a possibilidade de alterar manualmente o número de entradas, neurônios utilizados, funções de ativação e saídas.

Os comandos que foram utilizados para sua estruturação, foram os seguintes:

COMANDO	SIGNIFICADO
<code>net=network;</code>	Criar rede
<code>net.numInputs=1;</code>	Camada de Entrada
<code>net.numLayers=2;</code>	Número total de camadas da rede
<code>net.inputs{1}.size=8;</code>	Número de entradas
<code>net.layers{1}.size=10;</code>	Número de neurônios da Camada oculta
<code>net.layers{2}.size=1;</code>	Número de saídas
<code>net.biasConnect(1)=1;</code>	Conexão da Camada de entrada com oculta.
<code>net.biasConnect(2)=1;</code>	Número de conexão da Camada oculta com a Camada de saída.
<code>net.inputConnect(1,1)=1;</code>	Define qual camada conecta com a camada de entrada.
<code>net.layerConnect(2,1)=1;</code>	Define qual a conexão da Camada 1 com a camada 2.
<code>net.outputConnect=[0 1];</code>	Considera o valor da última camada
<code>net.layers{1}.transferFcn='tansig';</code>	Função utilizada na Camada oculta.
<code>net.layers{2}.transferFcn='purelin';</code>	Função utilizada na Camada de saída.
<code>net.trainFcn='trainlm';</code>	Algoritmo de treinamento: <i>Levenberg-Marquardt</i>
<code>net.divideFcn='dividerand';</code>	Divide os dados aleatoriamente

<code>net.initFcn='initlay';</code>	Inicializar a rede
<code>net.layers{1}.initFcn='initnw';</code>	Algoritmo que distribui os pesos e entradas entre um intervalo aleatório de valores, porém, sem muitas variações – Primeira Camada.
<code>net.layers{2}.initFcn='initnw';</code>	Algoritmo que distribui os pesos e entradas entre um intervalo aleatório de valores, porém, sem muitas variações – Segunda Camada.
<code>net.plotFcns={'plotperform','plottrainstate','plotregression';</code>	Define quais são os gráficos que o <i>software</i> deve apresentar.
<code>net.performFcn='mse';</code>	Define que a função de desempenho é o quadrado médio dos erros.
<code>p1=[29;5.5;53;2.2;1010;18;0;0.69];</code>	Definição dos valores do peso 1.
<code>net=init(net);</code>	Comando para inicializar a rede.
<code>net=train(net,entrada,target);</code>	Comando para treinar a rede neural.
<code>r=sim(net,p1);</code>	Comando para testar a funcionalidade da rede utilizando determinado peso.
<code>B=A'</code>	Comando para transposição da Matriz A de coluna para linha ou vice-versa.

Quadro 5 - Parâmetros utilizados na configuração da rede

Por meio destes comandos são definidos o número de entradas da rede, o número de camadas utilizadas, definição de neurônios em cada camada, funções de ativação, bem como, o algoritmo de treinamento da rede.

3.2.1 Processo de treinamento da Rede

Pode-se afirmar com base na teoria estudada que a propriedade mais importante das redes neurais é a habilidade de aprender e se adaptar ao seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento.

Nesta fase, seguindo o algoritmo de treinamento escolhido, neste caso o *Levenberg-Marquardt*, serão ajustados os pesos das conexões. É importante considerar, nesta fase, alguns aspectos tais como a inicialização da rede, o modo de treinamento e o tempo de treinamento. A definição dos pesos a se utilizar é um ponto crucial neste processo, pois é através deles que se possibilita a melhora no tempo de processamento da rede e conseqüentemente o seu desempenho.

O treinamento da rede é interrompido quando a rede apresentar uma taxa de erro suficientemente pequena. Assim, deve-se encontrar um ponto ótimo de parada apresentando o erro mínimo encontrado e o ponto de melhor desempenho da rede.

No Quadro 6, estão dispostos os dados de pesos utilizados como entrada, bem como o valor medido de saída (*target*), onde P representam dados aleatórios provindos da estação meteorológica e *target* é a irradiação esperada, a qual será calculada após o processo de treinamento da rede. Todos estes foram essenciais para realização dos testes de treinamento das redes neurais:

	Temperatura	UV	Umidade	Veloc do vento	Barômetro	Orvalho	Precipitação	Hora	Target
P1	29	5,5	53	2,24	1010	18	0	0,698	265
P2	29,1	4,2	56	2,68	1010	19	0	0,719	283
P3	28,6	2,2	57	2,68	1010	19	0	0,736	292
P4	27,4	1	64	3,13	1009	20	0	0,788	213
P5	21,6	3,1	95	1,34	1005	21	7,19	0,608	158
P6	23,4	5,5	92	1,34	1004	22	7,19	0,632	169
P7	25,2	1,9	79	1,34	1003	21	7,19	0,747	214
P8	29,7	7,6	73	1,79	1010	24	3	0,556	313
P9	29,3	5,3	75	1,79	1009	24	3	0,594	336
P10	29,2	8,6	67	3,13	1013	22	0	0,618	362

Quadro 6 - Entradas e *target* utilizados para testes da rede

No processo de testes de simulações da rede, foram realizados diversos treinamentos para cada rede estruturada, utilizando as entradas que foram apresentados no desenvolvimento. Para cada estrutura de rede, foram realizadas 10 diferentes combinações.

No Quadro 7 estão apresentados os resultados obtidos com os treinamentos realizados dos 15 modelos de rede neural estruturados para avaliação da eficiência da rede na identificação da irradiação solar.

É possível observar que houveram variações de 6 a 20 neurônios na camada oculta e utilizando conjuntos de 10 pesos. Os melhores resultados foram encontrados no processo de treinamento com 20 neurônios na camada oculta. Esse resultado afirmou a teoria dos pesquisadores deste trabalho, onde diziam que quanto maior o número de neurônios utilizados na camada oculta, melhores seriam os resultados obtidos.

Os resultados citados acima podem ser observados no Quadro 7.

	6 Neurônios	7 Neurônios	8 Neurônios	9 Neurônios	10 Neurônios
P1	294	294	293	294	293
P2	241	241	241	241	241
P3	151	150	150	149	149
P4	70	70	70	69	71
P5	169	171	169	168	169
P6	269	271	269	270	270
P7	107	109	107	105	108
P8	355	355	353	355	355
P9	272	272	272	272	273
P10	386	385	383	386	386
	11 Neurônios	12 Neurônios	13 Neurônios	14 Neurônios	15 Neurônios
P1	281	300	299	285	294
P2	224	246	245	230	242
P3	145	151	149	142	149
P4	79	71	70	90	68
P5	132	166	153	170	167
P6	214	273	259	255	269
P7	93	104	103	116	104
P8	328	348	348	351	352
P9	232	266	265	263	273
P10	384	377	377	385	379
	16 Neurônios	17 Neurônios	18 Neurônios	19 Neurônios	20 Neurônios
P1	299	300	298	281	288
P2	246	246	245	229	238
P3	151	150	149	147	142
P4	72	71	70	72	83
P5	168	168	169	127	139
P6	265	274	255	214	240
P7	97	105	105	83	114
P8	349	347	341	325	326
P9	270	266	260	237	245
P10	377	374	369	394	389

Quadro 7 - Resultados verificados variando o número de neurônio na camada oculta

Na Figura 28, apresenta-se o resultado do Erro Quadrático Médio - *Mean Square Error* - MSE), da rede neural com 20 neurônios na camada oculta.

Como se pode ver o erro quadrático médio partiu com uma grandeza inicial de 10^4 e terminou com um valor de 10^3 . Esse valor foi alcançado com a utilização de 65 épocas.

Épocas, por definição significa usar todos os dados disponíveis para treinamento. Na rede que possui 15 mil dados, ele considera somente dez mil e quinhentos (10500), então, desses valores ele percorre grupos de 20 dados e atualiza os parâmetros da rede. Posteriormente, considera outros 20 vetores e assim repetidamente. Desta forma, avaliando o resultado do gráfico apresentado abaixo (Figura 31), ele considerou 71 vezes esses 10500 vetores de 8 elementos (70% dos 15 mil dados). O restante 30% dos dados são utilizados para validação e treinamento.

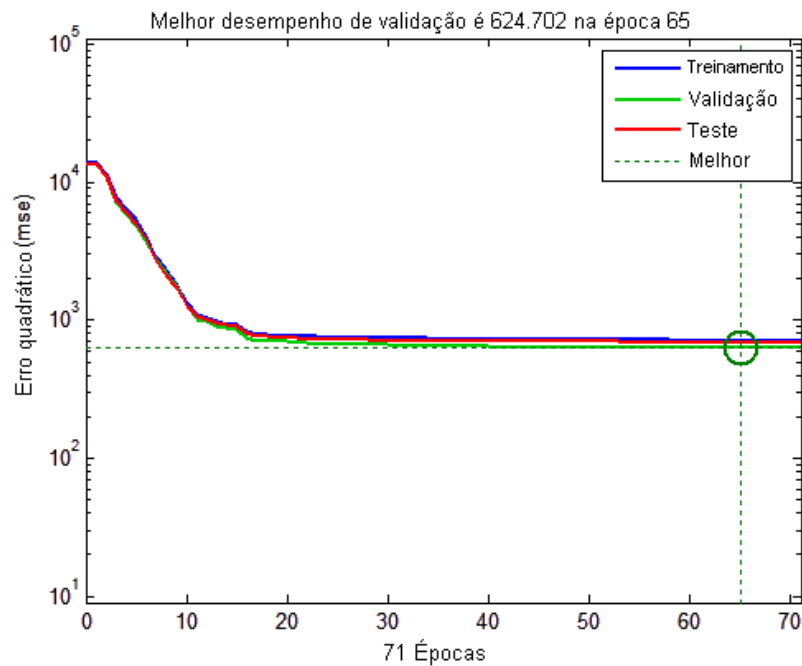


Figura 25 - Erro quadrático (MSE).

O gradiente representa o grau de inclinação na superfície de erro, e tem como objetivo alcançar o erro mínimo global. Para isso, em cada passo do treinamento, o vetor de pesos utilizado anteriormente é alterado com o objetivo de produzir uma maior queda na superfície de erro. Quando a inclinação do gradiente diminui, significa que se está chegando próximo do valor mínimo.

Enquanto o gradiente busca a maior queda de erro, o μ é um incremento colocado para chegar no resultado final. Como o MSE é uma equação de segundo grau, ele vai se aproximando do valor mínimo, e o μ é o incremento que ocorre para chegar no valor mínimo. À medida que o Gradiente diminui, aumenta o μ .

Pode-se observar na Figura 29 que o resultado esperado foi atingido com 65 épocas, mas que o total de épocas realizados pelo treinamento foi 71 épocas. Isso porque o *software* MATLAB já tem esse parâmetro definido onde mesmo após o atingimento do resultado ele realiza mais 6 interações de épocas.

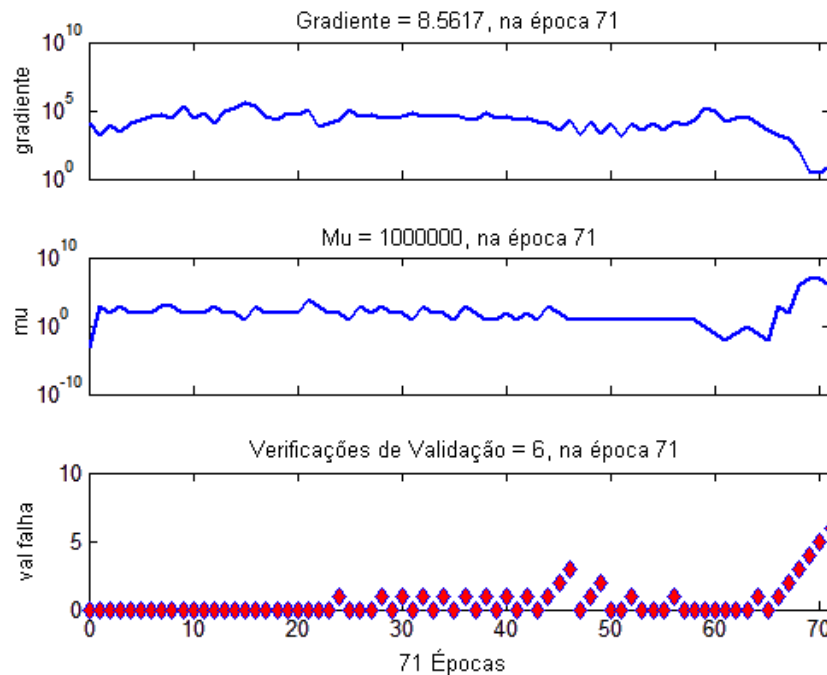


Figura 26 - Desempenho do treinamento.

As verificações de validação, indicam que foram realizadas 6 interações consecutivas e o resultado não se alterou, com isso o teste é cessado.

Ao treinar a rede, o primeiro processo realizado pelo *Matlab* é dividir os dados em três diferentes conjuntos. O primeiro subconjunto de dados é de treinamento, onde do total de dados absorvidos pela rede, ele utiliza 70% destes (selecionados aleatoriamente) para calcular o gradiente e realizar o ajuste dos pesos da rede. O subconjunto de validação toma 15% dos dados, também selecionados aleatoriamente, mostrando os erros da rede, podendo ser reduzido durante o treinamento e aumentando na medida que o treinamento ocorre. O conjunto de dados do teste não é utilizado durante o treinamento da rede, é útil para conferir a efetividade da rede e também para verificar se no teste é atingido o erro encontrado na validação.

A rede neural é baseada em uma regressão. Existem os resultados esperados e existem os resultados estimados pela rede neural. A representação ideal dessa relação é uma rede de ângulo de 45° . Mas os resultados obtidos não são exatamente aqueles esperados e cada resultado é um ponto plotado, que quanto mais próximo da reta de regressão melhor. O R diz o quanto ela está próxima dos valores reais.

Nos gráficos da Figura 30, a linha pontilhada na diagonal que parte da origem significa a saída desejada a ser atingida. A linha colorida e contínua, representa a melhor linha de regressão obtida no ajuste linear entre as saídas reais e as saídas

desejadas. O valor do Coeficiente de Correlação (R) significa a relação entre a saída real e a saída desejada. Se R for igual a 1, há uma relação linear exata entre a saída real e saída desejada. Caso R for próximo a zero, então a relação linear não existe.

A Figura 30(a) apresenta os resultados de saídas reais de treinamento. A linha é a reta de regressão obtida. Na Figura 30(b), se observa o processo de validação da rede, que apresentou um coeficiente de correlação de 0.97. A Figura 30(c) apresenta os resultados do teste.

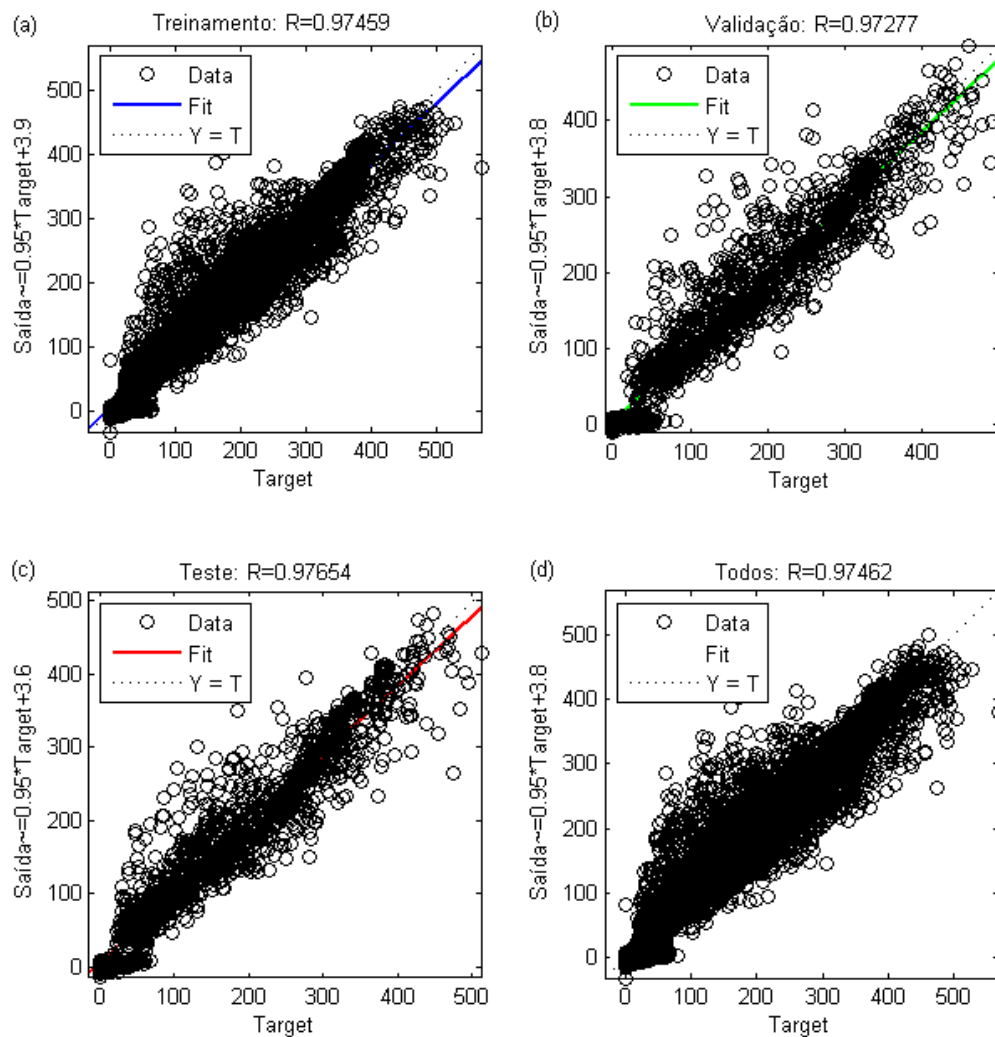


Figura 27 - Regression.

No Quadro 8 encontram-se os resultados obtidos para o *Root Mean Square Error* (RMSE), responsável por medir o desempenho da Rede Neural (que representa a soma dos quadrados dos erros). A coluna 'Modelo Rede' representa todos os modelos utilizados para testar o desempenho da Rede Neural que, por exemplo, na

rede NET6 utilizou-se 6 neurônios na camada oculta e na rede NET20, 20 neurônios. Os parâmetros de entrada são representados por:

- TP (temperatura);
- UV (índice UV);
- UM (umidade);
- VV (velocidade do vento);
- B (barômetro);
- OR (orvalho);
- PR (precipitação de chuva);
- HR (hora).

Modelo Rede	Parâmetros de Entrada	Nº Camadas	Nº Neurônios	Desempenho	RMSE (%)
NET6	TP, UV, UM, VV, B, OR, PR, HR	1	6	855,94	5,16%
NET7	TP, UV, UM, VV, B, OR, PR, HR	1	7	885	5,25%
NET8	TP, UV, UM, VV, B, OR, PR, HR	1	8	870	5,20%
NET9	TP, UV, UM, VV, B, OR, PR, HR	1	9	787	4,95%
NET10	TP, UV, UM, VV, B, OR, PR, HR	1	10	837	5,10%
NET11	TP, UV, UM, VV, B, OR, PR, HR	1	11	707	4,69%
NET12	TP, UV, UM, VV, B, OR, PR, HR	1	12	842	5,12%
NET13	TP, UV, UM, VV, B, OR, PR, HR	1	13	804	5,00%
NET14	TP, UV, UM, VV, B, OR, PR, HR	1	14	768	4,89%
NET15	TP, UV, UM, VV, B, OR, PR, HR	1	15	788	4,95%
NET16	TP, UV, UM, VV, B, OR, PR, HR	1	16	786	4,95%
NET17	TP, UV, UM, VV, B, OR, PR, HR	1	17	769	4,89%
NET18	TP, UV, UM, VV, B, OR, PR, HR	1	18	768	4,89%
NET19	TP, UV, UM, VV, B, OR, PR, HR	1	19	652	4,50%
NET20	TP, UV, UM, VV, B, OR, PR, HR	1	20	619	4,39%

Quadro 8 - RMSE obtido a partir dos modelos de rede criados.

A partir de todos os testes realizados, observou-se que a rede neural com 20 (NET20) neurônios na camada oculta trouxe os melhores resultados, visto que obteve um melhor desempenho (erro quadrático médio) e o erro menor encontrado (RMSE %). Há uma pequena diferença entre o resultado previsto e o resultado esperado, conforme visto no Quadro 8. Observou-se também que alguns números de neurônios trouxeram resultados semelhantes, o que demonstra que quanto mais diferenciado o número de neurônios, mais distantes serão seus resultados, podendo trazer uma melhor visão da importância em utilizar o número correto de neurônios para otimizar o funcionamento da rede.

É importante ressaltar que este processo de treinamento da rede neural de uma camada oculta, utilizando os dados coletados pela estação meteorológica de Janeiro a Abril de 2015, foi necessário para identificar o número de neurônios que melhor

atende as necessidades da rede para avaliação da irradiação solar na região Noroeste do estado do Rio Grande do Sul.

3.3 REDE NEURAL DE DUAS CAMADAS OCULTAS

A etapa de estruturação da rede neural com duas camadas ocultas no software MATLAB seguiu o mesmo método que o processo de estruturação e treinamento da rede com apenas uma camada oculta.

No processo de treinamento da rede, foram empregados os dados referentes aos meses de janeiro a abril do ano de 2015 a fim de analisar a eficiência da rede neural com duas camadas ocultas.

A Figura 31 apresenta o modelo de rede neural de duas camadas ocultas, onde na primeira delas utilizou-se 14 neurônios e na segunda camada oculta 20 neurônios, contendo 8 dados meteorológicos de entrada. O algoritmo para treinamento *Levenberg-Marquardt* e função de ativação log-sigmóide, na segunda camada oculta também a função log-sigmóide e *Purelin* na camada de saída.

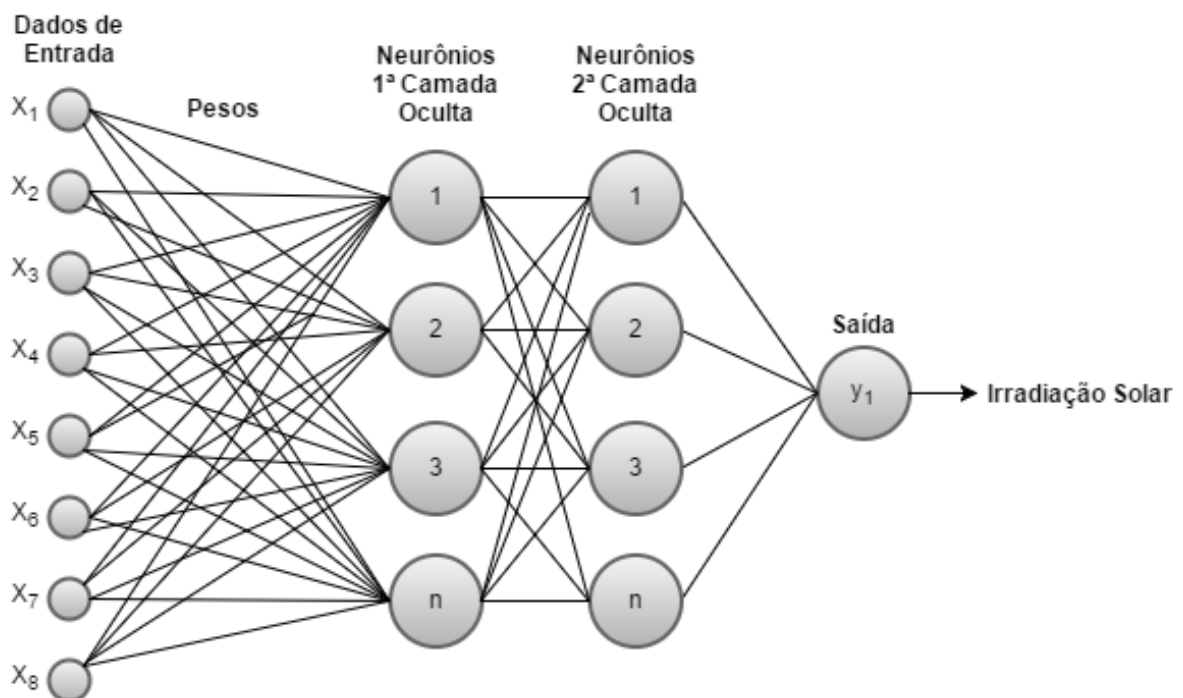


Figura 28 - Modelo da estrutura da Rede Neural Artificial com duas camadas oculta.

Para a estruturação da rede neural com duas camadas ocultas a formação da rede neural no *software* MATLAB ocorreu da seguinte forma:

COMANDO	SIGNIFICADO
<code>net=network;</code>	Criar rede
<code>net.numInputs=1;</code>	Camada de Entrada
<code>net.numLayers=3;</code>	Número total de camadas da rede
<code>net.inputs{1}.size=8;</code>	Número de entradas
<code>net.layers{1}.size=14;</code>	Número de neurônios da primeira camada oculta
<code>net.layers{2}.size=20;</code>	Número de neurônios da segunda camada oculta
<code>net.layers{3}.size=1;</code>	Número de neurônios na saída
<code>net.trainFcn='trainlm';</code>	Algoritmo de treinamento: Levenberg-Marquardt.
<code>net.biasConnect(1)=1;</code>	Número de conexão da Camada de entrada com a Camada oculta.
<code>net.biasConnect(2)=1;</code>	Número de conexão da Camada oculta com a Camada de saída.
<code>net.biasConnect(3)=1;</code>	Número de conexão da Camada de saída.
<code>net.inputConnect(1,1)=1;</code>	Define qual camada conecta com a camada de entrada.
<code>net.layerConnect(2,1)=1;</code>	Define qual camada conecta com a camada oculta.
<code>net.layerConnect(3,2)=1;</code>	Define qual camada conecta com a camada de saída.
<code>net.outputConnect=[0 0 1];</code>	Considera como saída o valor da última camada.
<code>net.layers{1}.transferFcn='logsig';</code>	Função utilizada na primeira camada oculta.
<code>net.layers{2}.transferFcn='logsig';</code>	Função utilizada na segunda camada oculta.
<code>net.layers{3}.transferFcn='purelin';</code>	Função utilizada na Camada de saída.
<code>net.divideFcn='dividerand';</code>	Divide os dados aleatoriamente
<code>net.initFcn='initlay';</code>	Inicializar a rede
<code>net.layers{1}.initFcn='initnw';</code>	Algoritmo que distribui os pesos e entradas entre um intervalo aleatório de valores, porém, sem muitas variações – Primeira Camada.
<code>net.layers{2}.initFcn='initnw';</code>	Algoritmo que distribui os pesos e entradas entre um intervalo aleatório de valores, porém, sem muitas variações – Segunda Camada.
<code>net.layers{3}.initFcn='initnw';</code>	Algoritmo que distribui os pesos e entradas entre um intervalo aleatório de valores, porém, sem muitas variações – Camada de saída.
<code>net.plotFcns={'plotperform','plottrainstate','plotregression';</code>	Define quais são os gráficos que o <i>software</i> deve apresentar.
<code>net.performFcn='mse';</code>	Define que a função de desempenho é o quadrado médio dos erros.
<code>net=init(net);</code>	Comando para inicializar a rede
<code>net=train(net,entrada,target);</code>	Comando para treinar a rede neural

$r = \text{sim}(\text{net}, p1);$	Comando para testar a funcionalidade da rede utilizando determinado peso.
$B = A'$	Comando para transposição da Matriz A de coluna para linha ou vice-versa.

O processo de treino da rede neural com duas camadas ocultas seguiu o mesmo padrão utilizado na rede que possuía somente uma camada oculta. No entanto, algumas características foram diferenciadas nessa estruturação.

A rede assumiu 14 neurônios para a primeira camada oculta, 20 neurônios para a segunda camada oculta e seguiu com apenas 1 saída, pois, o alvo a ser atingido (*target*) segue o mesmo.

No Quadro 9 demonstra os resultados obtidos nos testes da rede com duas camadas ocultas. O alvo esperado nesses testes são os resultados apresentados na coluna *Target*.

	Temperatura	UV	Umidade	Vel. Do Vento	Barômetro	Orvalho	Precipitação	Hora	Target	14 e 20 Neurônios
P1	29	5.5	53	2.24	1010	18	0	0.698	265	79.27
P2	29.1	4.2	56	2.68	1010	19	0	0.719	283	79.49
P3	28.6	2.2	57	2.68	1010	19	0	0.736	292	63.12
P4	27.4	1	64	3.13	1009	20	0	0.788	213	42.19
P5	21.6	3.1	95	1.34	1005	21	7.19	0.606	158	26.31
P6	23.4	5.5	92	1.34	1004	22	7.19	0.632	169	28.45
P7	25.2	1.9	79	1.34	1003	21	7.19	0.747	214	42.65
P8	29.7	7.6	73	1.79	1010	24	3	0.556	313	94.51
P9	29.3	5.3	75	1.79	1009	24	3	0.594	336	98.17
P10	29.2	8.6	67	3.13	1013	22	0	0.618	362	104.9

Quadro 9 - Testes efetuados com rede neural de duas camadas ocultas

Ao se observar os resultados, nota-se que a rede com duas camadas ocultas não se mostrou tão eficiente, pois, os resultados atingidos foram muito distantes da *target* esperada. É possível observar por exemplo, que nos resultados obtidos com o P1 esperava-se atingir um valor próximo a 265 (*target*) e o resultado obtido com a rede neural chegou apenas a 79.27, o que pode ser considerado um resultado ruim tornando a rede ineficiente.

Além disso, os resultados do treino da rede também não foram satisfatórios, visto que o MSE sempre assumiu valores muito elevados.

Na Figura 32, é possível observar os resultados obtidos para o *Regression* da rede com duas camadas ocultas, onde, comparando com a rede de uma camada oculta, distanciaram-se muito de 1, que seria o melhor valor a ser alcançado.

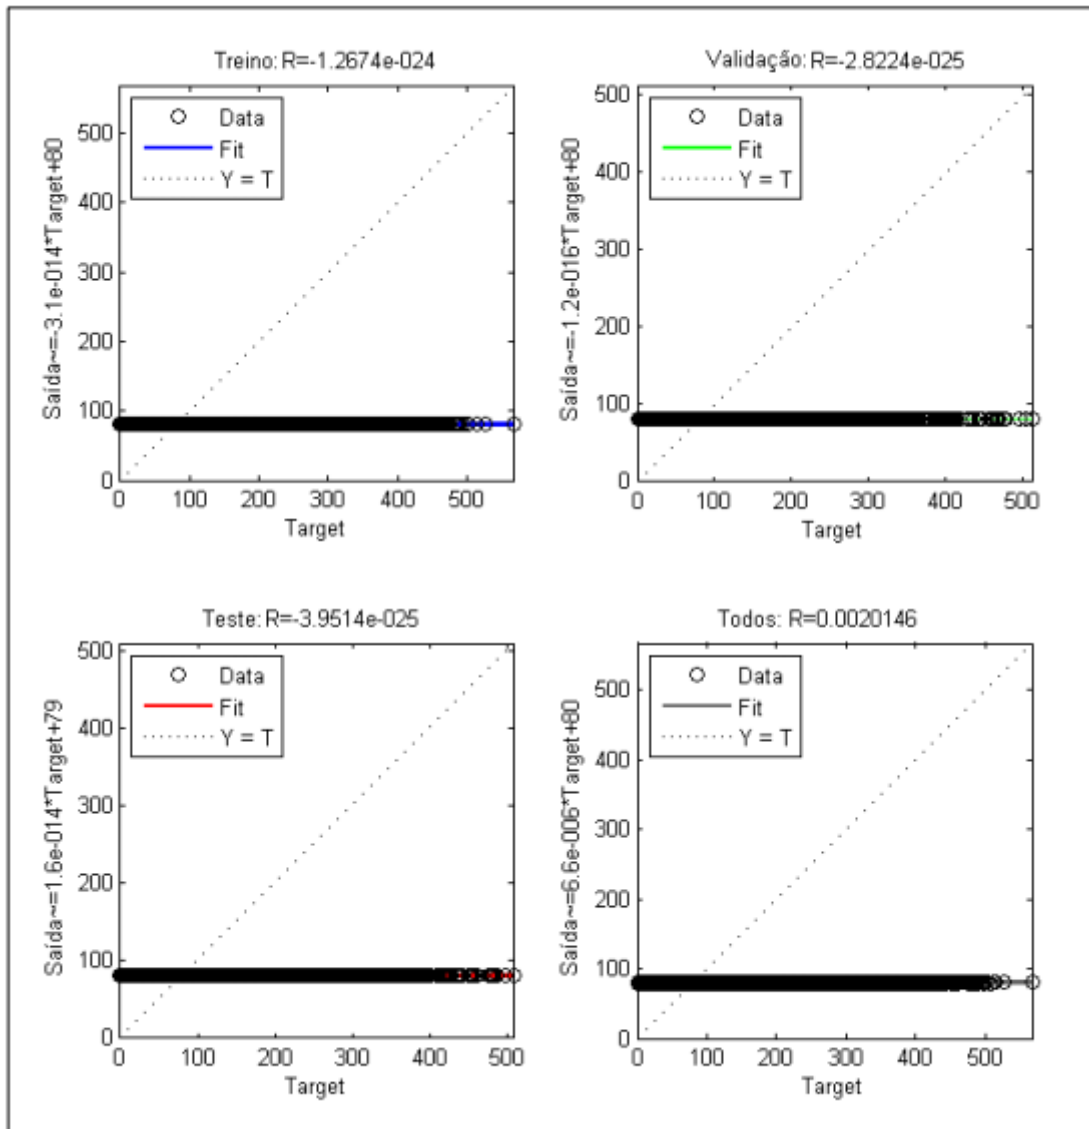


Figura 29 - *Regression* rede neural de duas camadas ocultas

O *Root Mean Square Error* (RMSE) encontrado para a rede com duas camadas ocultas foi de 20,56%, que pode ser considerado um erro alto quando comparado ao resultado obtido na rede neural com apenas uma camada oculta onde obtivemos um resultado de 4,39%.

3.4 COMPARATIVO DE IRRADIAÇÃO SOLAR ENTRE AS ESTAÇÕES DO ANO

O Sul do Brasil é caracterizado pelo seu clima subtropical, onde suas estações do ano são bem definidas, sendo os verões quentes e os invernos conhecidos por suas temperaturas baixas, que frequentemente são negativas. Com isso, este estudo também buscou analisar a irradiação solar presente nas 4 estações do ano.

Na Figura 33 está apresentada uma comparação do nível de radiação solar coletado pela estação meteorológica, entre as quatro estações do ano de 2015:

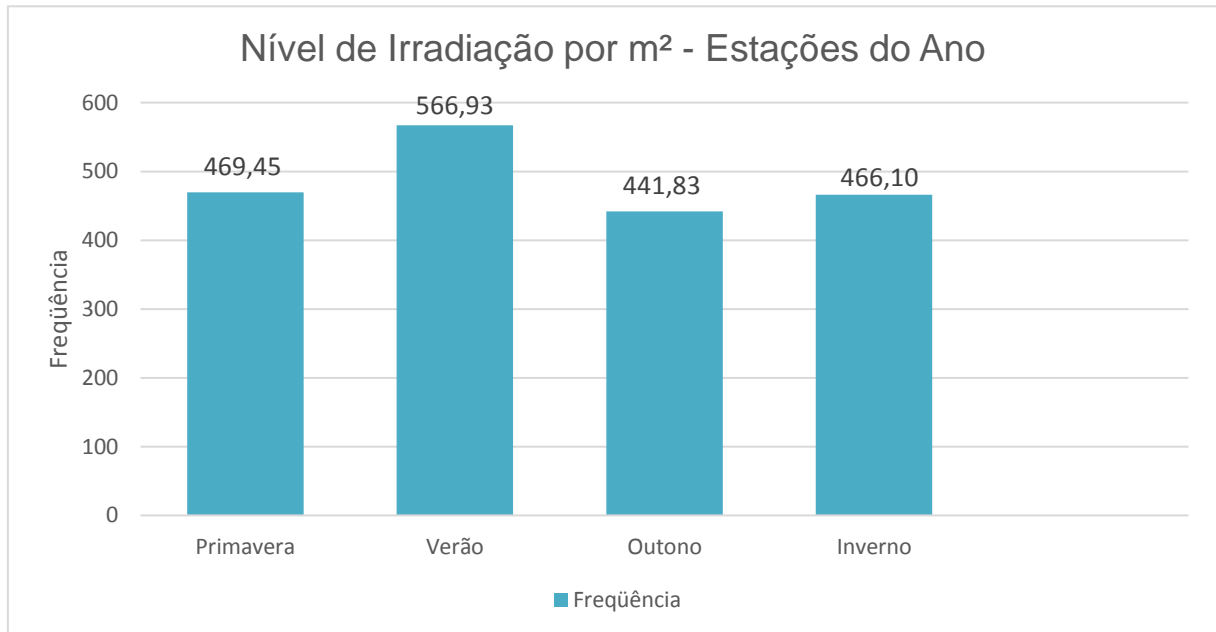


Figura 30 - Nível de radiação por m²

É possível observar que na estação do verão se tem o maior índice de radiação solar provinda do sol, conseqüentemente por ser considerada a estação mais quente de todo o ano. O menor índice é apresentado no outono, possivelmente devido as diferentes condições climáticas na região, pois, não encontrou-se erros nos dados originais coletados para essa estação.

Com base nas informações citadas acima, aplicou-se uma rede neural a fim de identificar qual o mês do ano com maior nível de irradiação solar.

Para dar início aos testes da rede, houve a necessidade de definir determinados meses para cada estação do ano:

Estação do Ano	Meses
VERÃO	Janeiro, Fevereiro e Março
OUTONO	Abril, Maio e Junho
INVERNO	Julho, Agosto e Setembro
PRIMAVERA	Outubro, Novembro e Dezembro

A Figura 34 apresenta o modelo de rede neural utilizado para treinamento de cada estação do ano. A rede foi constituída contendo 5 dados de entrada, sendo eles:

temperatura, umidade, pressão atmosférica, orvalho e hora. Possuindo uma camada oculta com 20 neurônios e função *tan-sigmóide* de ativação.

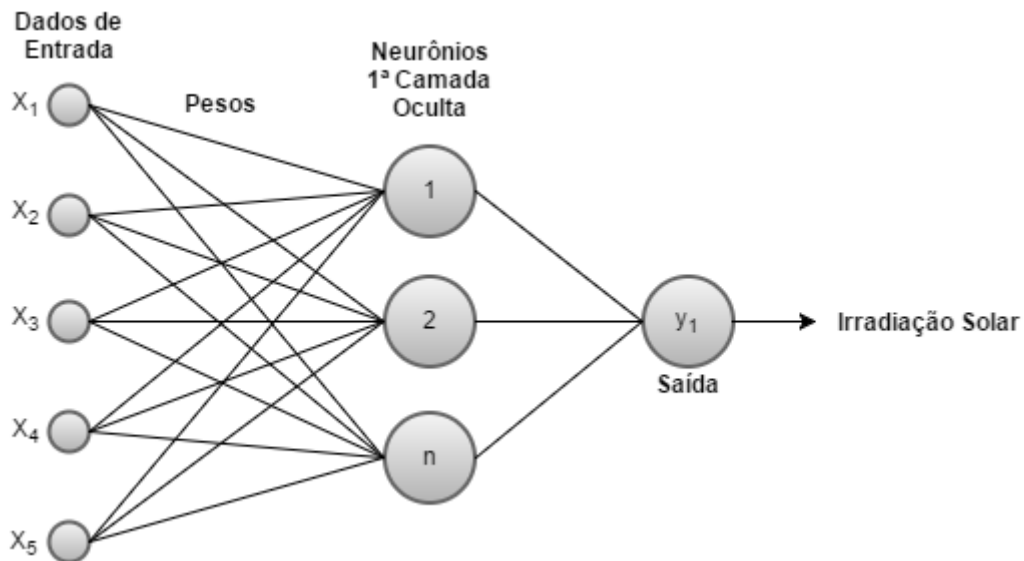


Figura 31 - Modelo utilizado para treinamento das estações do ano

Inicialmente foram realizados testes de rede utilizando oito variáveis de entrada, no entanto, mesmo após depuração desses dados, os mesmos não eram importados no *software* MATLAB. Devido a essa baixa integridade dos dados coletados pela estação meteorológica, optou-se por utilizar somente cinco variáveis de entrada. No entanto, é válido ressaltar que a quantidade de dados utilizados como entrada, não influencia no resultado esperado, pois, as variáveis utilizadas são específicas para identificação da irradiação solar.

As cinco variáveis utilizadas para essa etapa do trabalho foram Temperatura, Umidade, Pressão Atmosférica, Orvalho e Hora. Na sequência encontram-se os resultados obtidos com cada estação do ano.

3.4.1 Verão

Os dados coletados da Estação referentes ao verão totalizaram-se em 6.161 dados, referentes aos meses de Janeiro, Fevereiro e Março. Para esses meses, a Estação teve problemas na coleta de dados, sendo que no mês de Janeiro foram coletados apenas dados do primeiro dia do mês. Em Fevereiro, a coleta iniciou no dia 10 e seguiu até o último dia do mês. Já em Março, a coleta ocorreu apenas nos três primeiros dias do mês.

O verão no Sul do Brasil costuma ser de temperaturas altas e grande presença de luz solar, com isso, os níveis de irradiação solar podem ser altos, visto a pouca presença de nuvens e umidade, que interferem diretamente na quantidade de irradiação que atinge a superfície terrestre.

Analisando os dados da estação do verão, é possível verificar que o coeficiente de correlação alcançou o valor de 0.90, conforme pode ser visto na Figura 35, podendo ser considerado um bom resultado, visto que aproxima-se de 1.

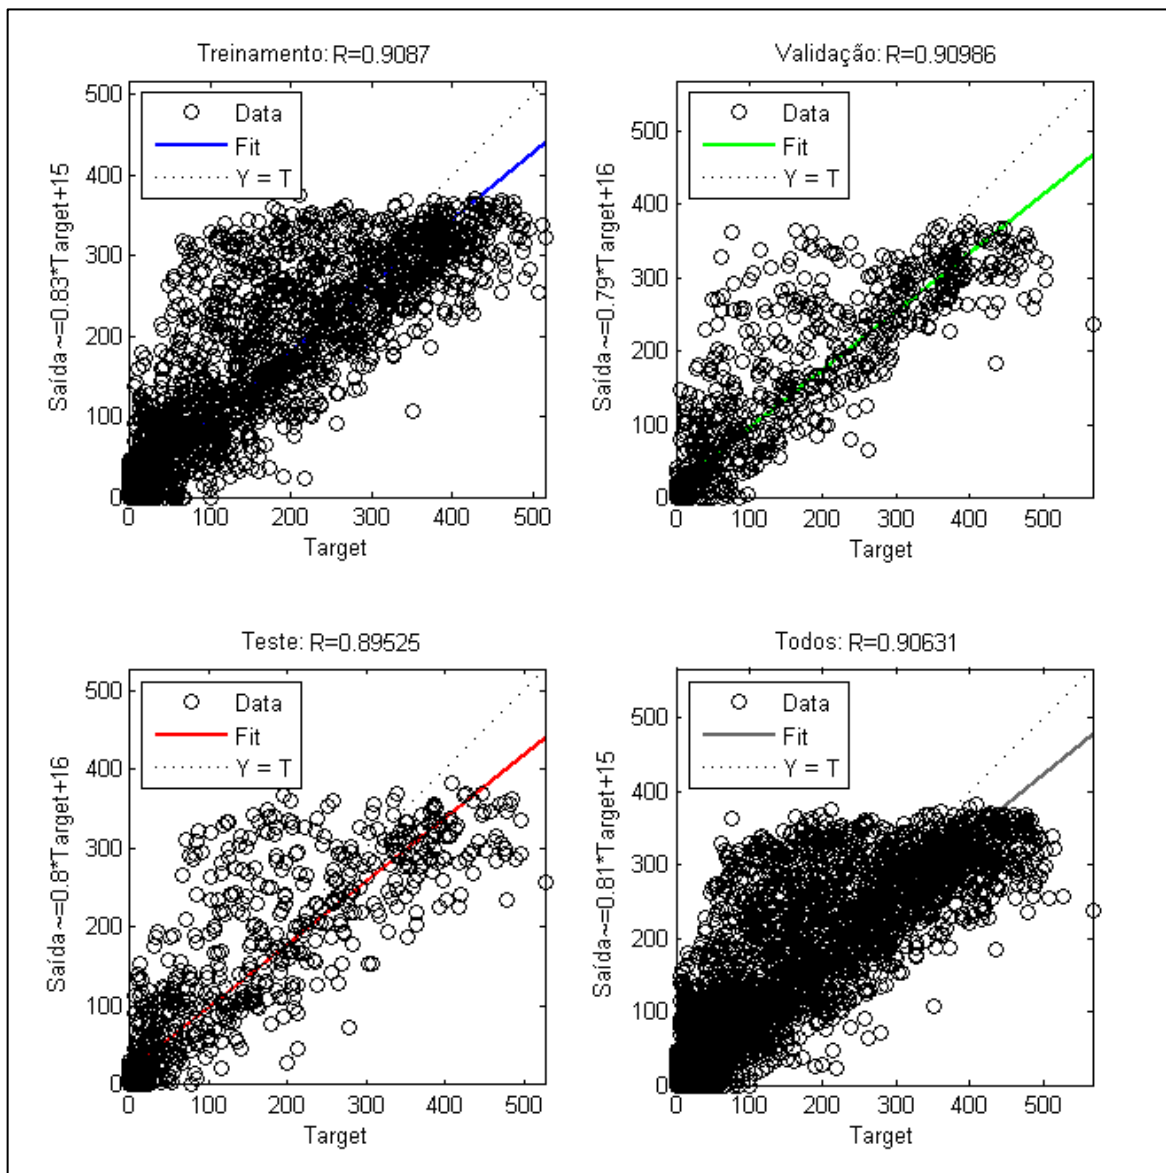


Figura 32 - Regression da estação verão

A Figura 36 mostra o desempenho obtido pela rede no treinamento dos dados do verão, onde o melhor resultado foi encontrado na época 5, de um total de 11 épocas processadas pela rede neste treinamento.

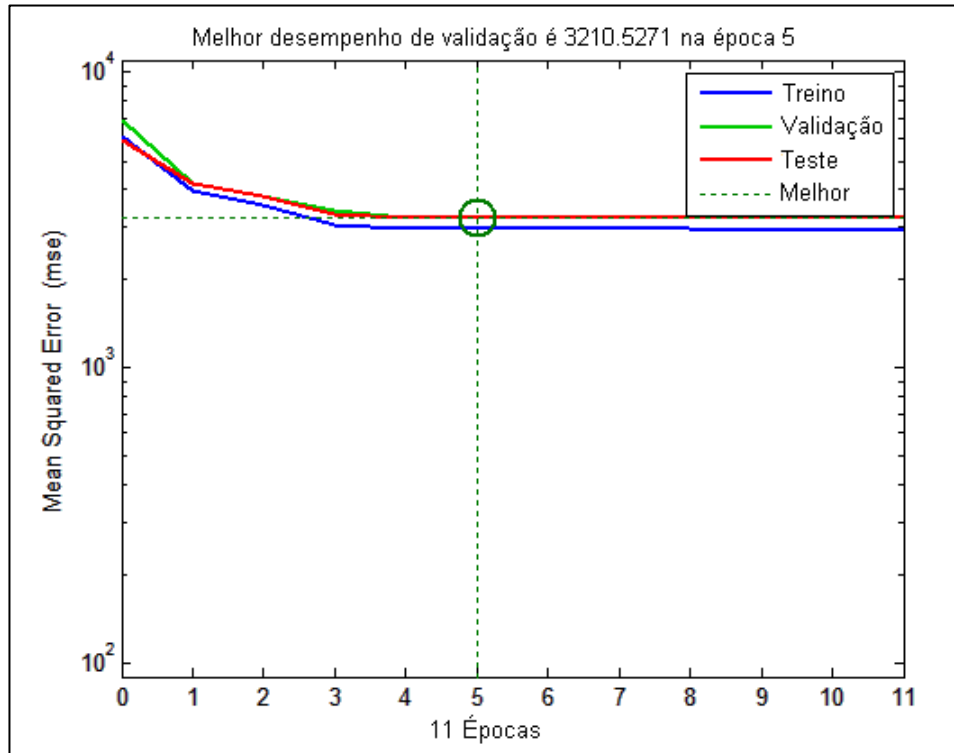


Figura 33 - Desempenho do treinamento da rede para os dados do verão

A partir dessa informação, é possível calcular o *Root Mean Square Error* (RMSE), que para os dados de verão foi de 9,99%. Esse pode ser considerado um bom erro visto o déficit de dados que ocorreram neste período.

3.4.2 Outono

Ao treinar a rede utilizando os dados da estação do Outono, notou-se uma melhora significativa nos resultados finais, visto que a Estação Meteorológica não teve problemas na coleta dos dados desse período, que faz referência aos meses de Abril, Maio e Junho. Neste período, totalizou-se em 25.059 dados à serem treinados.

O *Regression* encontrado para esse período foi de 0.93, conforme mostra a Figura 37, um resultado mais satisfatório quando comparado ao período anterior.

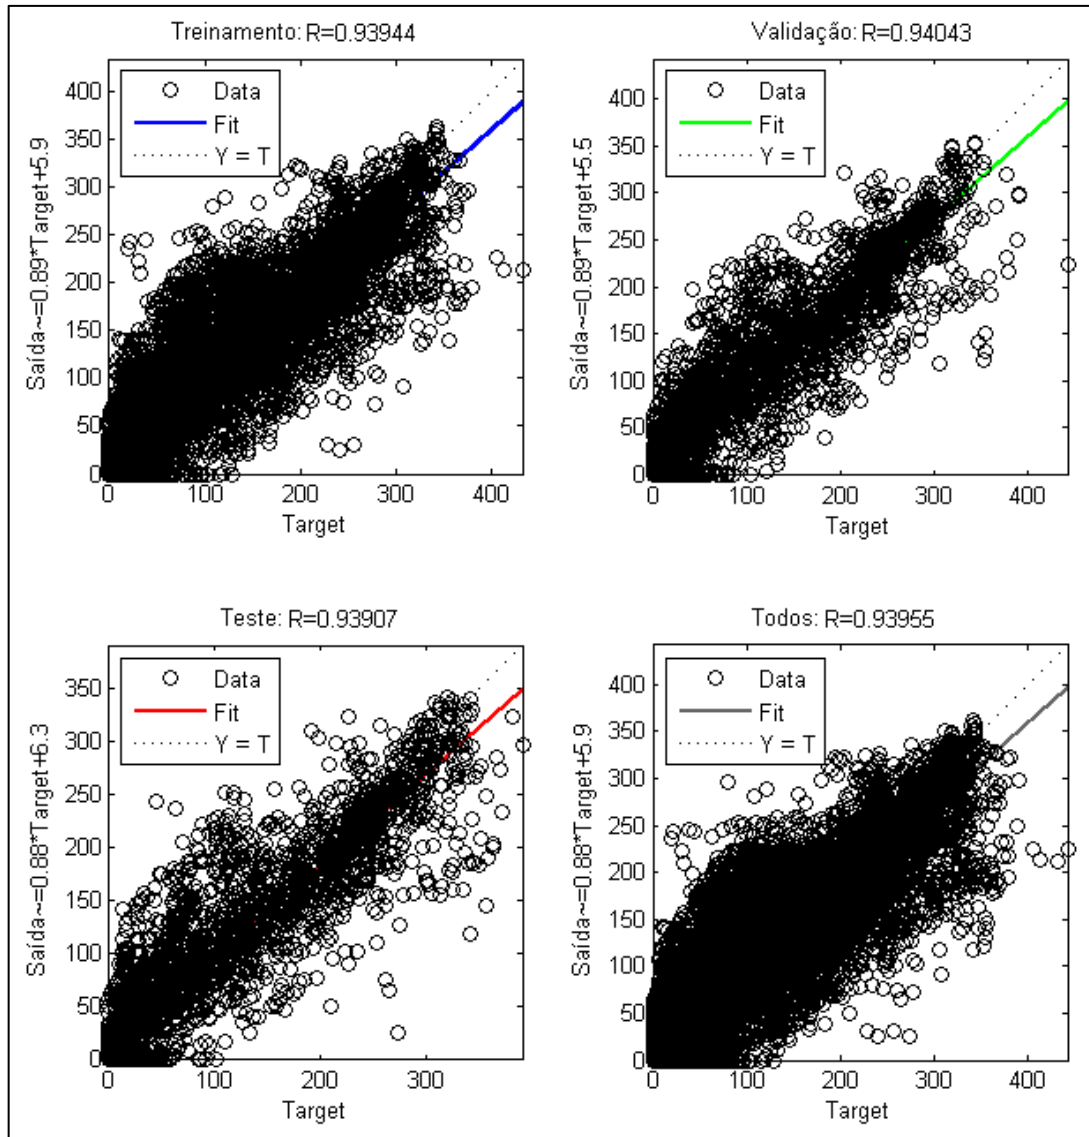


Figura 34 - Regression da estação outono

O desempenho obtido na validação do treinamento pode ser visto na Figura 38, onde o melhor resultado alcançado foi de 927.78, o que gera um RMSE de 6,48%.

Além disso, é possível observar que o melhor desempenho foi encontrado na época 15 de um total de 21 épocas calculadas pelo treinamento.




Figura 35 - Desempenho do treinamento da rede para os dados do outono

Os resultados apresentados pela estação do Outono se mostram mais eficientes e otimistas quando comparados com os resultados da estação do verão. Levando em consideração que os dados do verão poderiam ser melhores devido à inclinação do sol nessa estação do ano. No entanto, não foi o que a rede apresentou devido à incoerência na coleta desses dados pela estação meteorológica.

3.4.3 Inverno

Os dados da estação Inverno foram coletados referentes aos meses de Julho, Agosto e Setembro, totalizando 25.059 dados. Para estes dados não notou-se nenhuma inconformidade na coleta, porém nessa estação do ano, é possível observar algumas diferenças na questão climática, como:

- No inverno a presença de luz solar e calor é reduzida nas regiões mais próximas ao Sul do Brasil, devido a declinação do sol que nessa estação do ano está mais presente no hemisfério norte.

- Além disso, conforme estudado na teoria, alguns fatores podem influenciar na perda de irradiação solar que atinge a superfície terrestre, como a presença de nuvens, que são frequentes nessa época do ano por ser uma estação chuvosa.

Com isso, o resultado do desempenho da rede para a estação do Inverno pode ser visto na Figura 39. Nessa estação atinge-se um coeficiente de correlação de 0.90 o que pode ser considerado um bom resultado, pois ainda com pouca disponibilidade de irradiação e levando em conta o ângulo do sol para a atmosfera terrestre, foi possível aproximar-se do melhor resultado, que seria 1. Ou seja, mesmo na estação do Inverno, que na região Noroeste é bastante rigorosa, há probabilidade de boas previsões de irradiação solar.

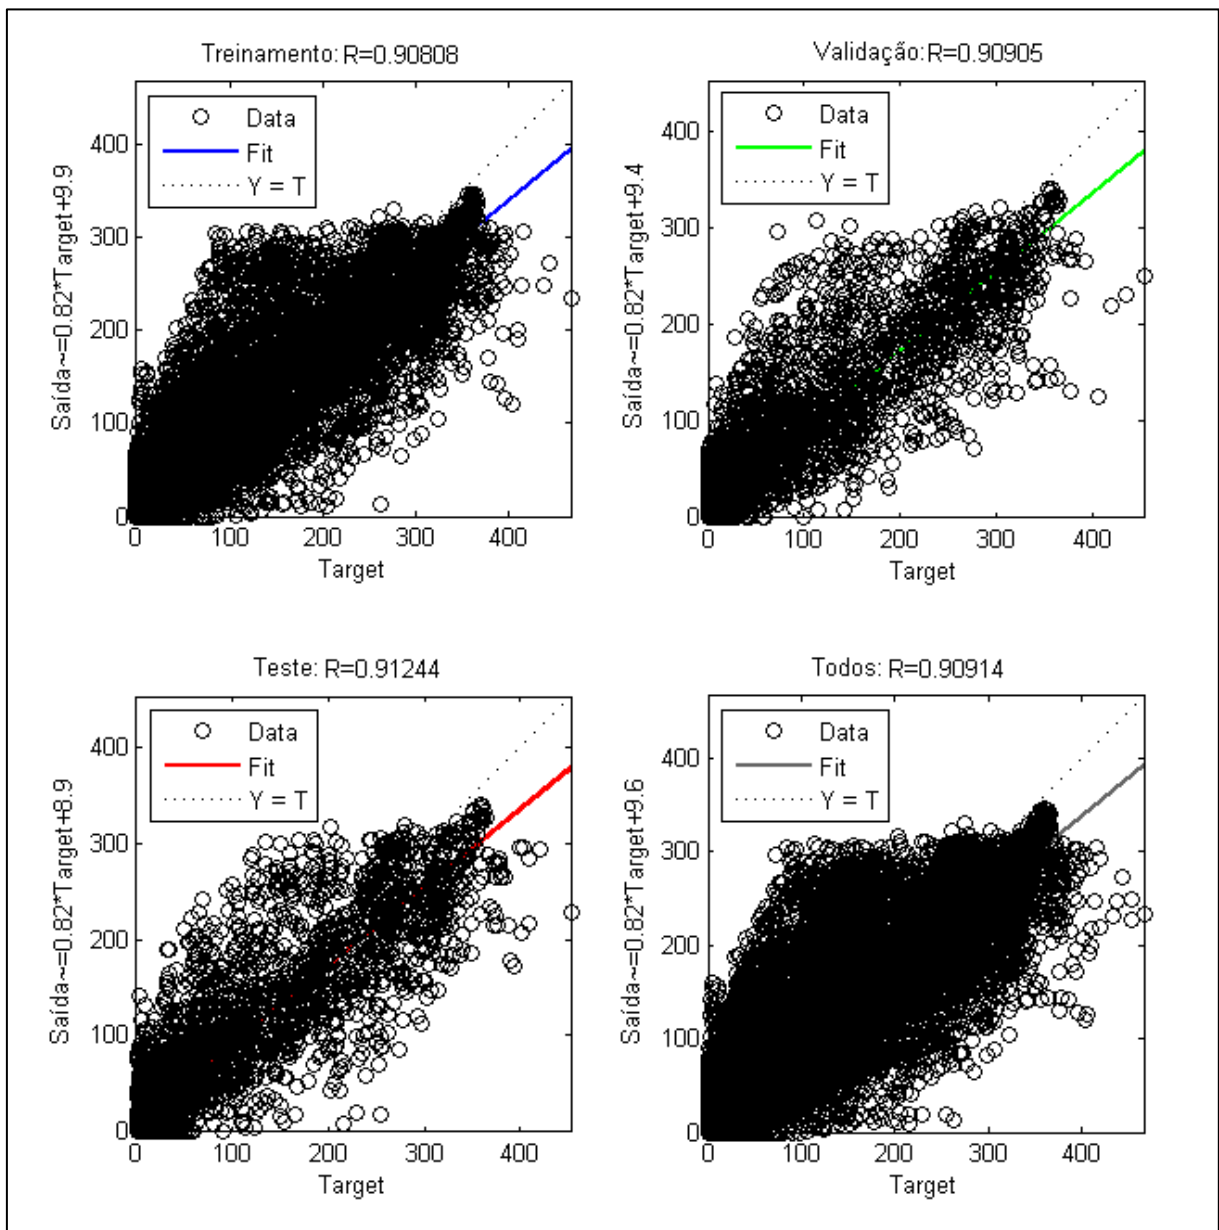


Figura 36 - Regression da estação inverno

Durante o processo de treinamento, o melhor desempenho da rede foi atingido na época 24 com o valor de validação de 1.523, como pode ser visto na Figura 40.

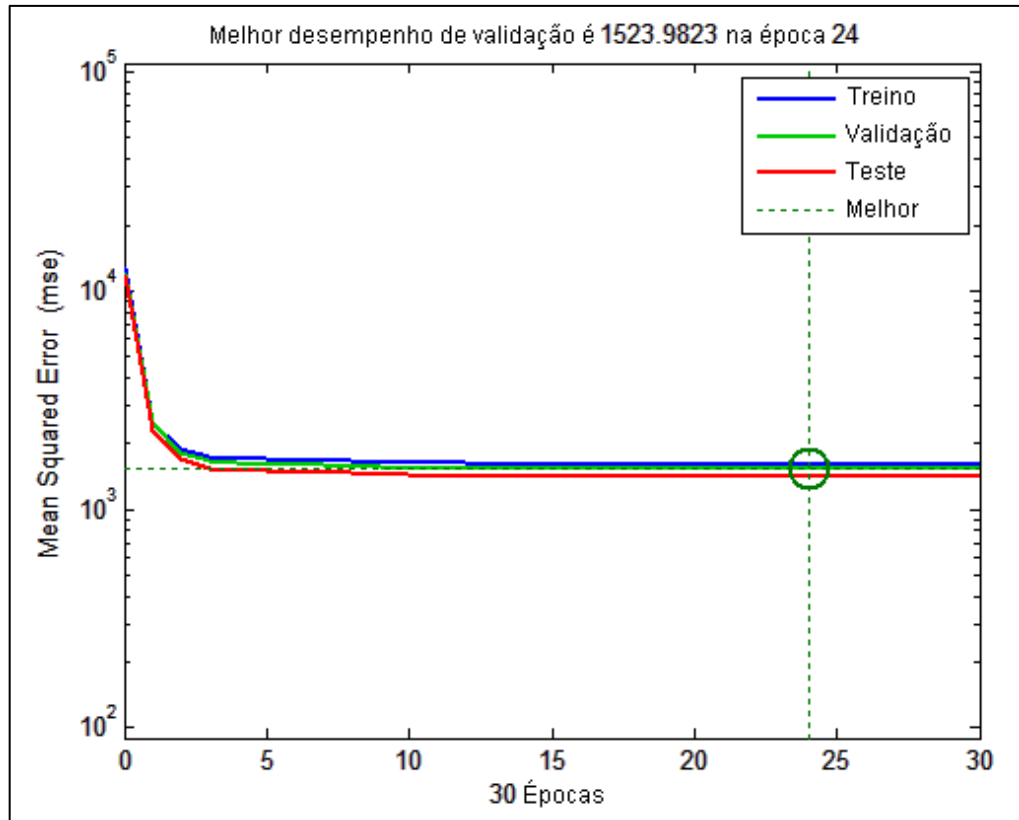


Figura 37 - Desempenho do treinamento da rede para os dados do inverno

Com esse resultado, foi possível calcular o RMSE, que atingiu o valor de 8,37%. Esses valores obtidos no RMSE, sempre alcançam patamares diferentes para cada estação, visto que os valores de entrada sempre variam de acordo com as condições climáticas.

3.4.4 Primavera

Os dados coletados nos meses de Outubro, Novembro e Dezembro, referentes à estação Primavera, trouxeram alguns problemas no momento da coleta, pois ora a estação coletava os dados de 5 em 5 minutos e ora coletava de 1 em 1 minuto. Com isso, foi necessário padronizar a disposição de dados conforme as demais estações, que no caso estavam sendo coletados de 5 em 5 minutos, o que resultou em um total de 21.984 dados.

Após o ajuste destes para importação no Matlab, os resultados obtidos não foram muito bons, indicando que ainda há necessidade de uma análise mais profunda dos dados, pois é possível que ainda restem alguns dados ruins que ainda estejam interferindo negativamente nos resultados.

O coeficiente de correlação encontrado para a estação da primavera foi de 0.74, conforme pode ser visto na Figura 41, sendo consideravelmente baixo quando comparado às demais estações do ano.

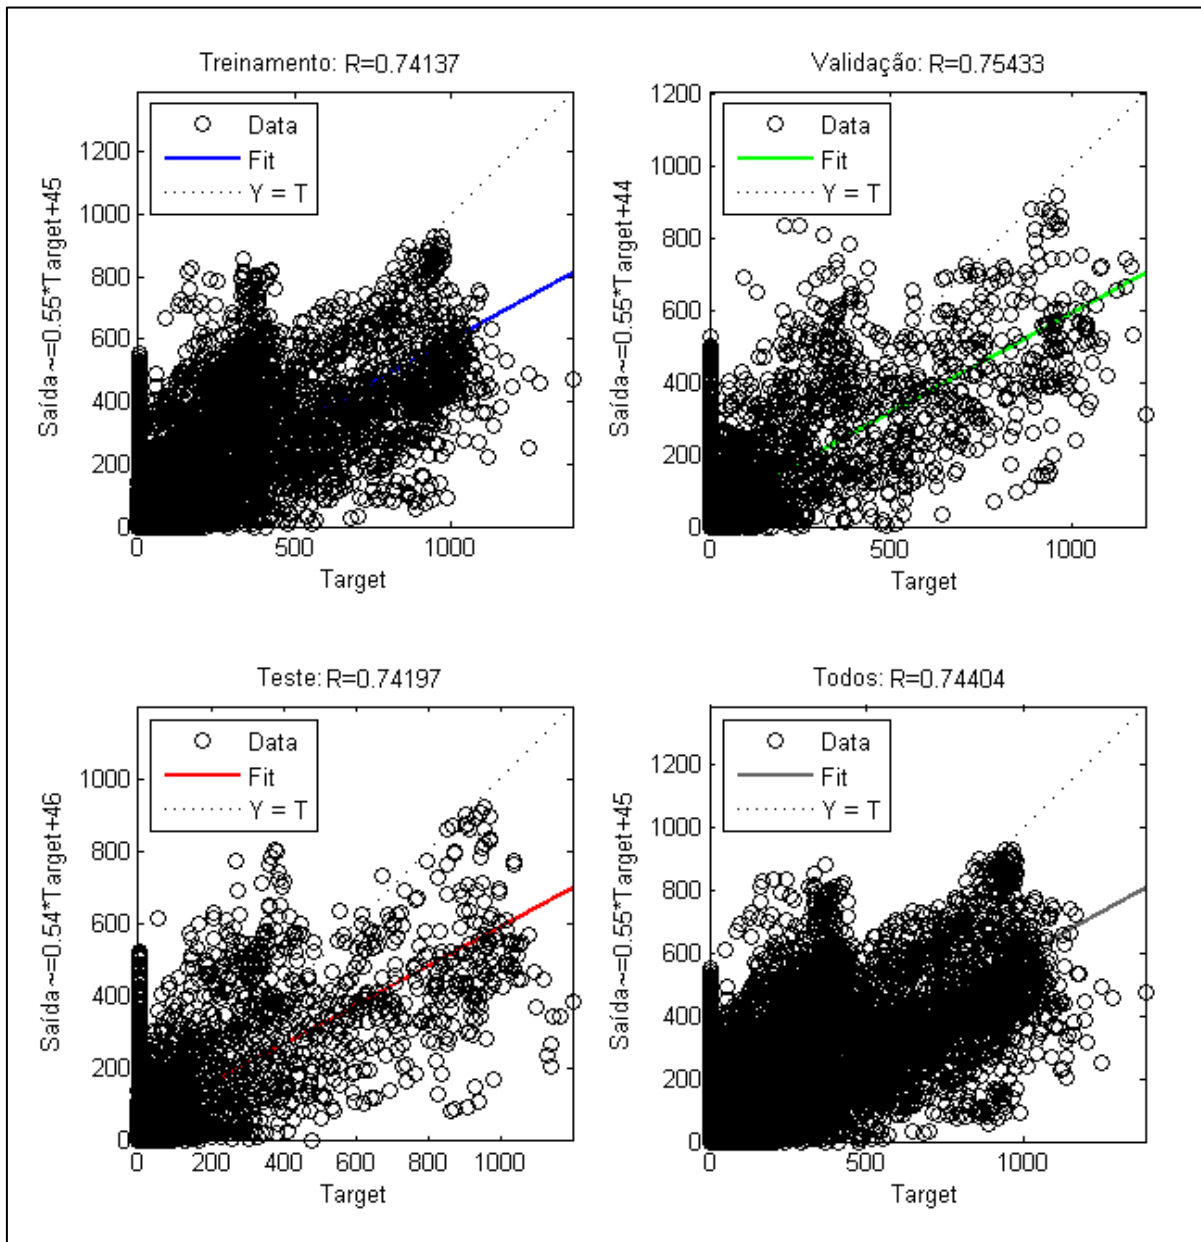


Figura 38 - Regression da estação primavera

O desempenho de validação e seu conseqüente erro quadrático (MSE) também não trouxeram bons números, conforme pode ser visto na Figura 42.

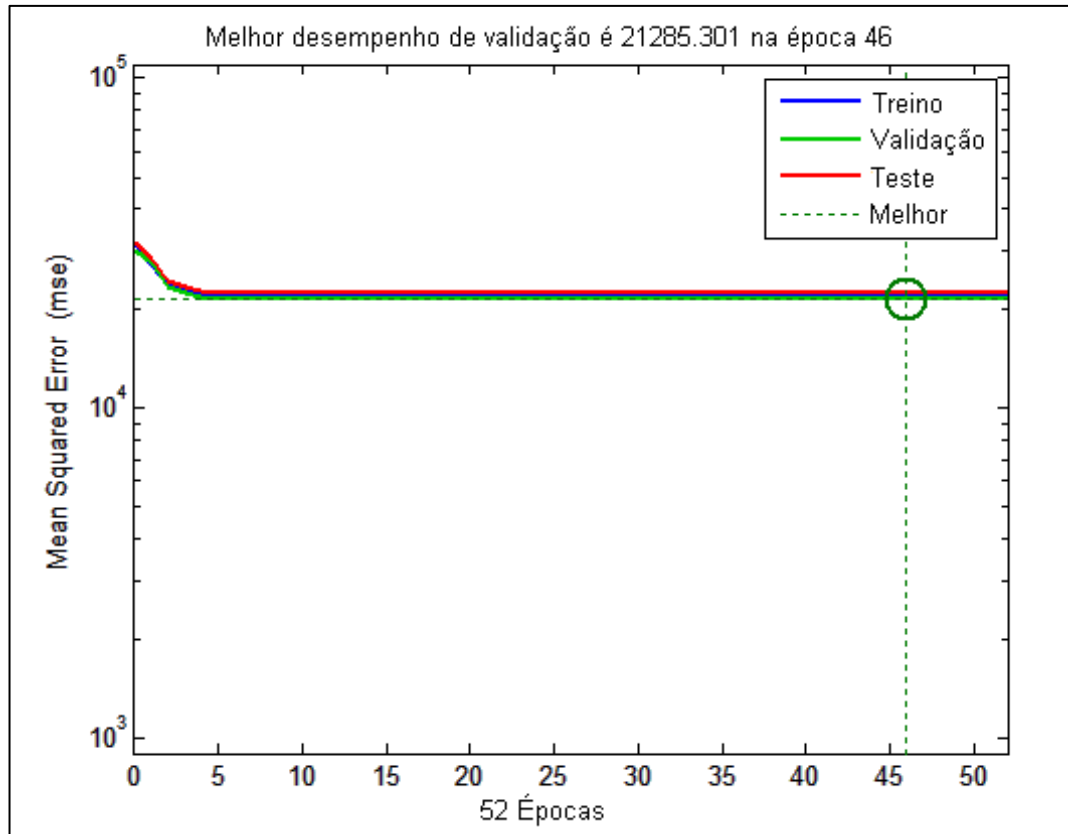


Figura 39 - Desempenho do treinamento da rede para os dados da primavera

Pode ser observado na Figura 42 que o desempenho na validação do treinamento foi de 21.285 e o RMSE resultou em 10,51%, o que pode ser considerado um erro alto e menos eficiente quando comparado com os demais resultados. Esses resultados demonstram que o desempenho da rede ainda deve ser melhorado através do ajuste dos dados coletados pela estação.

3.4.5 Análise dos trabalhos relacionados

O presente trabalho apresenta algumas características diferentes dos demais estudados. A primeira delas refere-se ao número de entradas utilizados, onde trabalhou-se com um vetor de 8 elementos (processo de treinamento da rede neural com uma camada oculta seção 3.2.1), sendo eles, temperatura, UV, umidade, velocidade do vento, pressão atmosférica, orvalho, precipitação de chuva e o horário da coleta, totalizando em 15.248 dados meteorológicos referentes aos meses de janeiro a abril do ano de 2015, com os quais foram realizados testes iniciais com redes de diferentes estruturas.

Estruturou-se uma rede neural de uma camada oculta onde aplicou-se uma variação nela de 6 até 20 neurônios, desta forma, analisando 15 diferentes modelos de rede neural. Atingiu-se o melhor coeficiente de correlação, equivalente a 0,97, com a rede de 20 neurônios e o menor erro encontrado com esta foi de 4,39% (RMSE). A explicação completa do desenvolvimento do processo, bem como, a apresentação dos resultados obtidos, está disposta na Seção 3.2.1.

O Quadro 10 apresenta um comparativo entre os trabalhos relacionados a este estudo.

COMPARATIVO TRABALHOS RELACIONADOS						
Referência	Entradas	Nº Camadas	Saídas	Método Utilizado	Dados Utilizados	Erros
Yadav et al. 2012	4	Levenberg-Marquardt
Ahmed et al. 2013	Equação de regressão: Angstrom-type	2007	...
Solmaz et al. 2010	3	1	1	Função Sigmóide	...	8,96% e 10,12%
Razafiarison et al. 2011	3	1 - 4 neurônios	1
Mellit et al. 2005	2	1 a 9 neurônios	1	Backpropagation	2000	menos de 1,5%
Khatib et al. 2012	4	1	1	log-sigmóide e backpropagation	1984 a 2004	...
Mubiru. 2011	6	1	1	Levenberg-Marquardt.	2003-2005	...
Lauret et al. 2013	backpropagation
Teixeira Júnior et al. 2014	10	1	...	Levenberg-Marquardt.
Wang et al. 2012	3	2	24	Levenberg-Marquardt.	2011	...
Chatziagorakis et al. 2014	2	1 - 10 neurônios	1	Levenberg-Marquardt.	2 anos	...
Vakili et al. 2015	4	...	1	Levenberg-Marquardt.	2012, 2013 e 2014	...
Faceira et al. 2015	2 e 5	20 neurônios	1	Levenberg-Marquardt.	2010, 2011	menor que 10%
Martins et al. 2012	36 e 8	...	1	Modelo Eta / CPTEC	2001 a 2005	...
Este trabalho	8	6 a 20 neurônios	1	Levenberg-Marquardt.	2015	4,39%

Quadro 10 - Comparativo entre trabalhos relacionados

Os trabalhos disponíveis na literatura não seguem um padrão para a criação de uma rede neural conforme visto no Quadro 10. Nota-se também que neste trabalho o foco está essencialmente na implementação de uma rede eficiente para prever a irradiação solar, pois a maioria dos trabalhos não descrevem o percentual do coeficiente de correlação R. Isso porque a ideia é usar esta rede para prever a irradiação solar no futuro. Adicionalmente, o número de variáveis usadas neste trabalho é maior que a maioria dos trabalhos disponíveis na literatura em função da variação do clima da Região Noroeste do Estado do Rio Grande do Sul.

Também é possível observar que nos trabalhos pesquisados, as informações não são detalhadas quanto as configurações utilizadas na estruturação da rede o que é um fator importante para uma possível continuação do estudo.

3.5 PROPOSTAS FUTURAS

O presente estudo certamente não esgotou todas as possibilidades de estruturação de modelos de redes neurais. Ao longo de sua elaboração foram identificados alguns aspectos interessantes mas que não faziam parte da delimitação do tema, e que, futuramente podem vir a ser melhorados.

A primeira proposta é a estruturação de uma rede neural com duas camadas ocultas utilizando uma função de ativação diferente da *log-sigmóide* e *tan-sigmóide*. Pois, neste estudo utilizou-se destas funções e não obteve-se bons resultados. Ainda para a rede com duas camadas ocultas, propõe-se testar diferentes números de neurônios.

Outra proposta de trabalho é utilizar um *time delay* para realizar previsões de curto prazo.

Por fim, uma vez obtida a irradiação, pode-se calcular a insolação por período de desenvolvimento das plantas, a qual é importante para agricultura.

CONCLUSÃO

Com o desenvolvimento de uma rede neural artificial, buscou-se avaliar a irradiação solar presente na região Noroeste do estado do Rio Grande do Sul utilizando como base os dados do ano de 2015 coletados pela estação meteorológica da instituição SETREM, para posteriormente poder utilizar o método em locais de clima semelhante.

O objetivo geral deste estudo consiste em avaliar a disponibilidade de energia provinda da irradiação solar, onde se encontrou nas redes neurais um instrumento factível de previsão apesar das dificuldades encontradas quando a integridade dos dados coletados pela estação meteorológica, pois como pode ser visto ao longo do relatório, houveram dados inconsistentes resultantes do processo de coleta, o que acarretou em significativas perdas de eficiência nos resultados apresentados pelos modelos de rede neural estruturados.

A primeira hipótese formulava que os dados meteorológicos da estação permitem avaliar a irradiação solar existente, e foi corroborada (conforme pode ser visto na Seção 3.2) pois a rede obteve um R de 0,97 quando utilizou os 15 mil dados.

A segunda hipótese dizia que os dados meteorológicos permitem avaliar a variação da irradiação solar nas quatro estações do ano. Esta hipótese foi corroborada pois obteve-se os resultados esperados quando os dados apresentavam integridade (conforme pode ser visto na Seção 3.4).

A terceira hipótese fala que a rede neural com duas camadas ocultas permite fazer avaliação da irradiação a partir dos dados meteorológicos. Esta foi falseada pois não se conseguiu atingir resultados confiáveis (conforme pode ser visto na Seção 3.3). Com isso, verificou-se que a configuração da rede e as funções utilizadas na mesma não trouxeram os resultados esperados e, assim, é necessário que se faça uma maior

análise de quais as melhores funções e configurações para a rede neural de duas camadas ocultas.

A arquitetura da rede projetada neste trabalho trouxe resultados eficientes. A mesma possui uma camada de entrada contendo um vetor de 8 elementos, uma camada oculta de 20 neurônios que utilizou o algoritmo *Levenberg-Marquardt* para treinamento da rede, as funções *purelin* e *log-sigmóide* de transferência e uma camada de saída.

A rede estruturada mostrou-se flexível quanto ao uso dos dados, podendo ser facilmente alterados sem grandes impactos em sua funcionalidade. Através dos resultados obtidos, notou-se que com uma rede relativamente simples, utilizando a função *log-sigmóide* atinge-se bons resultados.

Para justificar a relevância do estudo aplicado se faz necessário analisar se os objetivos específicos foram atingidos de forma efetiva. Desta forma, no Quadro 11 são apresentados todos os objetivos do trabalho, bem como se foram atingidos e o local no documento onde foram abordados.

Objetivo	Alcançado	Ocorrência
Identificar o problema da pesquisa e realizar o levantamento das hipóteses.	Sim	Seção 1.4 e 1.5
Verificar através de pesquisas bibliográficas, a utilização e aplicação de redes neurais artificiais.	Sim	Seção 2.1.1, 2.1.3 e 2.1.4
Estudar conceitos de fontes de energias renováveis, em particular a solar.	Sim	Seção 2.2
Pesquisar os métodos BPROP, PBPROP e <i>Levenberg-Marquardt</i> .	Sim	Seção 2.1.11, 2.1.12 e 2.1.13.
Analisar a situação atual de coleta de dados da Estação Meteorológica da SETREM.	Sim	Seção 3.1
Analisar os tipos de dados coletados pela Estação Meteorológica da SETREM.	Sim	Seção 3.1
Montar modelos de rede neural para analisar a viabilidade da rede na avaliação da irradiação solar através dos dados providos da estação meteorológica.	Sim	Seção 3.2
Analisar os resultados obtidos da aplicação da rede neural nas quatro estações do ano	Sim	Seção 3.4
Pesquisar e estudar trabalhos relacionados ao assunto	Sim	Seção 3.5

Quadro 11 - Alcance dos objetivos

Durante o desenvolvimento do trabalho, levantou-se o seguinte problema de pesquisa: a irradiação solar existente neste local é adequada para uso, como fonte de energia renovável?

A irradiação total medida no período de janeiro a abril de 2015 foi de 1.211.172 Wh/m², o que significa uma média diária de 1,01 kWh/m². Considerando que um hectare produz uma potência de 1000 kW = 1.000.000 W e uma lâmpada LED

consome 7,5 W (produzindo 700 lumens). Desta forma, um hectare é capaz de alimentar 133.333 lâmpadas. Se o sol brilhar, em média 6 horas por dia, serão 6.000.000 W-h por dia. Havendo uma perda de 50% deste valor devido à inclinação do sol, tem-se 3.000.000 W-h disponíveis para uso. Então as 133.333 lâmpadas podem ficar acesas 3 horas por dia. Assumindo uma eficiência de 15% a potência instalada seria de 150 W/m². Sendo assim, se uma casa tiver 7 lâmpadas acesas nessas três horas, haverá uma alimentação de 19.048 residências.

Além disso, conclui-se que a região em pauta teria sido capaz de gerar 1.211 kW/h de energia solar no período pesquisado, ou seja, uma potência de 750 kW para uma usina que ocupasse uma área de um hectare, visto que possui boas previsões de irradiação solar, essencial para essa atividade. O que responde ao problema da pesquisa.

REFERÊNCIAS BIBLIOGRÁFICAS

AHMED, Emad A., ADAM, El-Nouby. ***Estimate of Global Solar Radiation by Using Artificial Neural Network in Qena, Upper Egypt, In: Journal of Clean Energy Technologies***. Vol. 1, No. 2, April 2013.

AQUILANO, Nicholas; M., DAVIS Mark; J., B., CHASE Richard. **Fundamentos da Administração da Produção**. Porto Alegre: Bookman, 2001.

BRAGA, Antônio de Pádua, CARVALHO, André Ponce de Leon F. de e LUDERMIR, Teresa Bernarda. **Redes Neurais Artificiais Teoria e Aplicações**. Rio de Janeiro: LTC - Livros Técnicos e Científicos Editora, 2007.

BOUSFIELD, Paulo Marcondes. **Uso de uma Rede Neural para a previsão do volume de lodo gerado em estações de tratamento de efluente: Um estudo de caso**. UNIVILLE. Joinville : s.n., 2008. Dissertação.

CARNEIRO, Carlos E. I, PRADO, Carmen P. C. e SALINAS, Silvio R. A. **Introdução elementar às técnicas do cálculo diferencial e integral**. 2ª. São Paulo : São Paulo, 2011.

CARVALHO, André Ponce de Leon F. **Redes Neurais Artificiais. Perceptron Multi-Camadas (MLP)**. 2012.

CHATZIAGORAKIS P., N. GEORGOULAS, S. PAPADOPOULOU, C. ELMASIDES, D. GIAOURIS, P. SEFERLIS, G.Ch. SIRAKOULIS, I. KARAFYLLIDIS, A. I. PAPADOPOULOS, F. STERGIOPOULOS, I. ANDREADIS, C. ZIOGOU, D. IPSAKIS, S. VOUTETAKIS. **Application of Neural Networks Solar Radiation Prediction for Hybrid Renewable Energy Systems**. 2014.

CRESESB. 2008. **Tutorial de Energia Solar Fotovoltaica**. Disponível em: <http://cresesb.cepel.br/index.php?section=com_content&lang=pt&cid=291>. Acesso em 21 de março de 2016.

DAVIS. 2016. **Wireless Vantage Pro2™ with Standard Radiation Shield**. Disponível em:<http://www.davisnet.com/weather/products/weather_product.asp?pnum=06152>. Acesso em 01 de abril de 2016.

DIENSTMANN, Gustavo. **Energia Solar: uma comparação de tecnologias**. Porto Alegre : UFRGS, 2009.

FACEIRA, João, AFONSO, Paulo, SALGADO, Paulo. **Prediction of Solar Radiation Using Artificial Neural Networks**. Springer International Publishing Switzerland. *Lecture Notes in Electrical Engineering* 321. 2015.

FILHO, João Alves. **Matriz energética brasileira: da crise à grande esperança**. Mauad, 2003. ISBN 85-7478-100-2.

FOCUSOLAR. 2015. **Potencial Solar Brasileiro**. Disponível em: <<http://focusolar.com.br/potencial-solar-brasileiro/>>. Acesso em 01 de abril de 2016.

GOLDSCHMIDT, Ronaldo. **Data Mining: Conceitos, Técnicas, Algoritmos, Orientações e Aplicações**. 2ª ed. São Paulo: Campus. 2015. ISBN 978-85-352-7822-4.

GOLDSCHMIDT, Ronaldo, PASSOS, Emmanuel e BEZERRA, Eduardo. sa. **Data Mining: conceitos, técnicas, algoritmos, orientações e aplicações**. S.I. :Campus, 2015. ISBN 978-85-352-7822-4.

HAGAN, Martin T.; DEMUTH, Howard B.; BEALE, Mark Hudson; JESÚS, Orlando De. **Neural Network Design**. 2ª Ed. eBook. 2007. ISBN-13: 978-0-9717321-1-7.

HEATON, Jeff. **AIFH, Volume 3: Deep Learning and Neural Networks**. s.l. : Copyright, 2015. Vol. 3. ISBN-13: 978-1505714340.

HINRICHS, Roger A. e KLEINBACH, Merlin. **Energia e Meio Ambiente**. 3. São Paulo : Cengage, 2008. ISBN-13: 9788522107148.

JÚNIOR, Luiz Albino Teixeira, SOUZA, Rafael Moraes, MENEZES, Moisés Lima, CASSIANO, Keila Mara, PESSANHA, José Francisco Moreira, SOUZA, Reinaldo Castro. **Artificial Neural Network and Wavelet Decomposition in the forecast of Global Horizontal Solar Radiation**. SciELO - Scientific Electronic Library Online, São Paulo-SP, 2014.

KHATIB, Tamer, MOHAMED, Azah, SOPIAN, K., MAHMOUD, M. **Solar Energy Prediction for Malaysia Using Artificial Neural Networks**. In: Hindawi Publishing Corporation International Journal of Photoenergy. Volume 2012.

KOERICH, Alessandro L. 2005. **Redes Neurais Artificiais (RNAs). Aprendizagem de Máquina**. s.l. : PUCPR, 2005.

LAURET, Philippe, DIAGNE, Mainouna, DAVID, Mathieu. **A Neural Network Post-processing Approach To Improving NWP Solar Radiation Forecasts**. 2013. ISES Solar World Congress, France.

LIU, Hongwei. **On the Levenberg-Marquardt training method for feed-forward neural networks**. China, 2010.

MARTINS, Fernando Ramos. PEREIRA, Enio Bueno. GUARNIERI, Ricardo André. ***Solar Radiation Forecast Using Artificial Neural Networks***. 2012.

MELLIT, A., BENGHANEM, M. ***Artificial Neural Network Model for Prediction Solar Radiation Data: Application for Sizing Stand-alone Photovoltaic Power System***, El-Alia, Bab-Ezzouar 16111, Algiers, 2005, Algeria.

MUBIRU, J. ***Using Artificial Neural Networks to Predict Direct Solar Irradiation***. Department of Physics, Makerere University, P.O. Box 7062, Kampala, Uganda. 2014.

NETO, Luiz Garcia Palma e NICOLETTI, Maria do Carmo. 2010. ***Introdução às Redes Neurais Construtivas***. 1ª. São Paulo : EdUFSCar, 2010. p. 192.

PACHECO, Fabiana. ***Energias renováveis: breves conceitos. Conjuntura e Planejamento***. Salvador, 2006.

RAZAFIARISON, I.A.J., ANDRIAZAFIMAHAZO, L.F.G, RAMAMONJISOA, B.O.A., ZEGHMATI, B. ***Using multilayered neural networks for determining global solar radiation upon tilted surface in Fianarantsoa Madagascar***, 2011. *Revue des Energies Renouvelables*. Vol. 14 N°2 (2011) 329 – 342.

RIEDMILLER, Martin e Braun, HEINRICH. ***A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm***. 1993. ISBN 0-7803-0999-5.

RIEDMILLER, Martin. ***Rprop. Description and Implementation Details***. 1994. ISBN 978-3-319-12567-1.

RUMELHART, D. E., et al. ***Learning internal representations by error propagation. Parallel distributed processing: explorations and microstructure of cognition***. Cambridge : MIT Press, 1986.

RUSSEL, Stuart e NORVING, Peter. 2004. ***Inteligência Artificial***. 2. São Paulo: Elsevier, 2004. ISBN 9788535237016.

SCHAFFER, Steven. 2015. ***Code your own Neural Network***. S.I. : Shaffer Media Enterprises, 2015. eBook.

SILVA, Ivan Nunes, SPATTI, Danilo Hernane e FLAUZINO, Rogério Andrade. ***Redes Neurais Artificiais para engenharia e ciências aplicadas***. São Paulo: Artliber, 2010.

SOARES, Pablo Luiz Braga e SILVA, José Patrocínio da. ***Aplicação de redes neurais artificiais em conjunto com o método vetorial da propagação de feixes de análise de um acoplador direcional baseado em fibra ótica***. Passo Fundo : s.n., 2011, Revista Brasileira de Computação Aplicada.

SOLMAZ, Özgür, KAHRAMANLI, Humar, KAHRAMAN Ali, ÖZGÖREN Muammer. ***Prediction of daily solar radiation using anns for selected provinces in turkey*** - Selcuk University, Department of Mechanical Education, Konya, Turkey, 2010.

TISSOT, Hegler C., CAMARGO, Luiz C. e POZO, Aurora T. R. **Treinamento de Redes Neurais Feedforward. Comparativos dos algoritmos Backpropagation e Differential Evolution.**

VAKILI, Masoud, YAZDI, Sabbagh Saeed Reza, KALHOR, Koosha, KHOSROJERDI, Soheila. ***Using Artificial Neural Networks for Prediction of Global Solar Radiation in Tehran Considering Particulate Matter Air Pollution.*** *International Conference on Technologies and Materials for Renewable Energy, Environment and Sustainability, TMREES15.* 2015.

WANG, Fei, MI, Zengqiang, SU, Shi, ZHAO, Hongshan. ***Short-Term Solar Irradiance Forecasting Model Based on Artificial Neural Network Using Statistical Feature Parameters.*** 2012. *Energies.* ISSN 1996-1073.

YADAV, Amit Kumar, CHANDEL, S.S. **Artificial Neural Network based Prediction of Solar Radiation for Indian Stations** **Centre for Energy and Environment National Institute of Technology.** *International Journal of Computer Applications* (0975 – 8887) Volume 50 – No.9, July 2012.

APÊNDICES

Apêndice A: Cronograma

Apêndice B: Orçamento

Apêndice C: Tela inicial do *software* MATLAB.

Apêndice D: Processo de importação de dados de entrada no MATLAB.

APÊNDICE A

O cronograma representado pelo Quadro 11 apresenta todo o planejamento e execução das atividades propostas no estudo. O trabalho foi iniciado no mês de Novembro de 2015, seguindo até Agosto de 2016.

As etapas do projeto se deram inicialmente de acordo com a tabela apresentada a seguir:

Atividades/Etapas	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago
Definição do tema e desenvolvimento do Projeto	X									
Estudo dos conceitos sobre Redes Neurais e Energias Renováveis	X	X	x	x	X					
Entrega do Projeto		X								
Analisar os dados coletados					X					
Estudo dos Métodos BPROP, PBPROP e <i>Levenberg-Marquardt</i>					X					
Elaboração da Rede Neural					X					
Estudo de Trabalhos Relacionados						x	x			
Elaboração do Artigo Científico – REABTIC						x	x	x		
Análise dos Resultados							x	x		
Elaboração do Artigo padrão SETREM								x		
Entrega Final do Relatório e Artigo – TCC									x	
Apresentação dos resultados										

Legenda: ■ – Previsto; x - Realizado.

Quadro 12 - Cronograma de atividades.

APÊNDICE B

O orçamento apresenta uma relação de gastos relativos ao trabalho. Dentre eles: quantidade de impressão, encadernação, deslocamentos necessários, horas de trabalho, entre outras informações relevantes a serem destacadas.

No quadro a seguir, estão dispostos uma projeção de despesas que poderão ocorrer com o desenvolvimento deste projeto de pesquisa:

Descrição dos materiais	Quantidade	Valor Unitário (R\$)	Valor Total (R\$)
Impressão	1000	0,15	150,00
Encadernação	4	12,00	48,00
Deslocamento	80	15	1.200,00
Horas de Trabalho	320	25,00	8.000,00
Total			9.398,00

Fonte: BARTH; WOLFER (2016)

Quadro 13 - Orçamento

APÊNDICE C

Tela inicial do MATLAB.

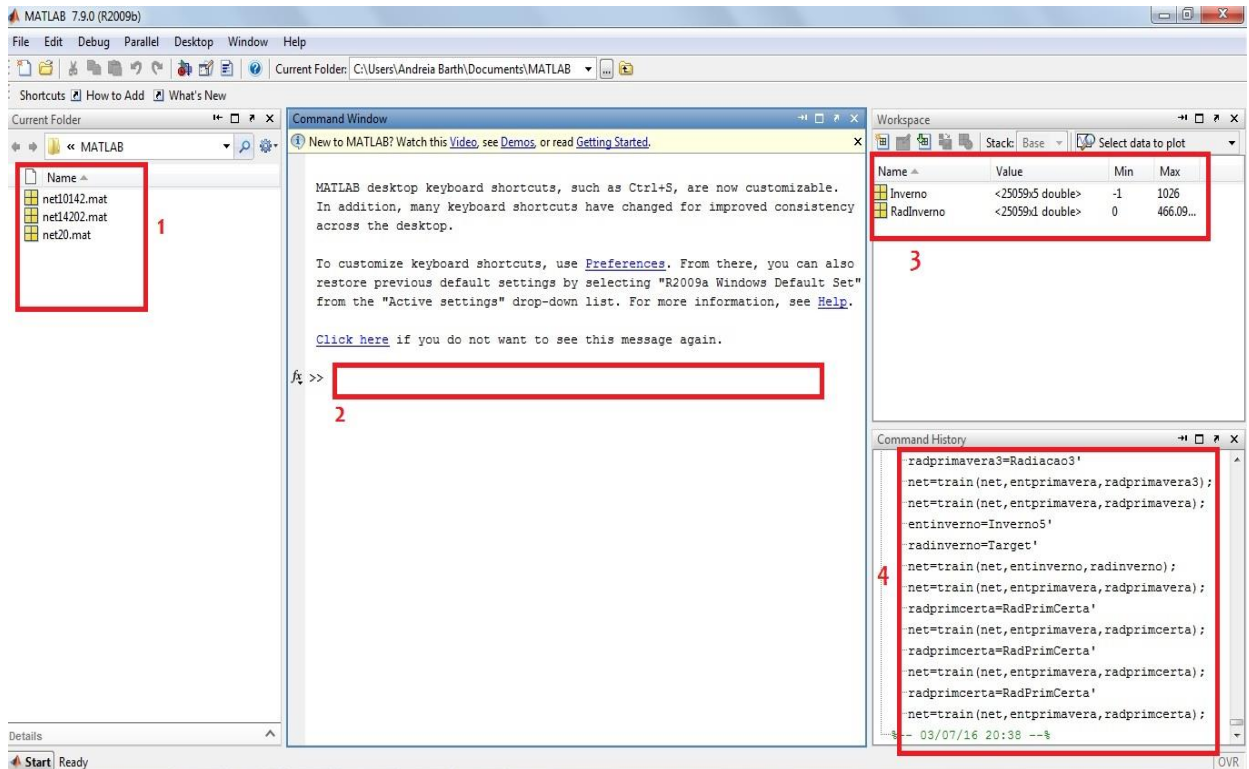


Figura 40 - Disposição de componentes no *software* MATLAB

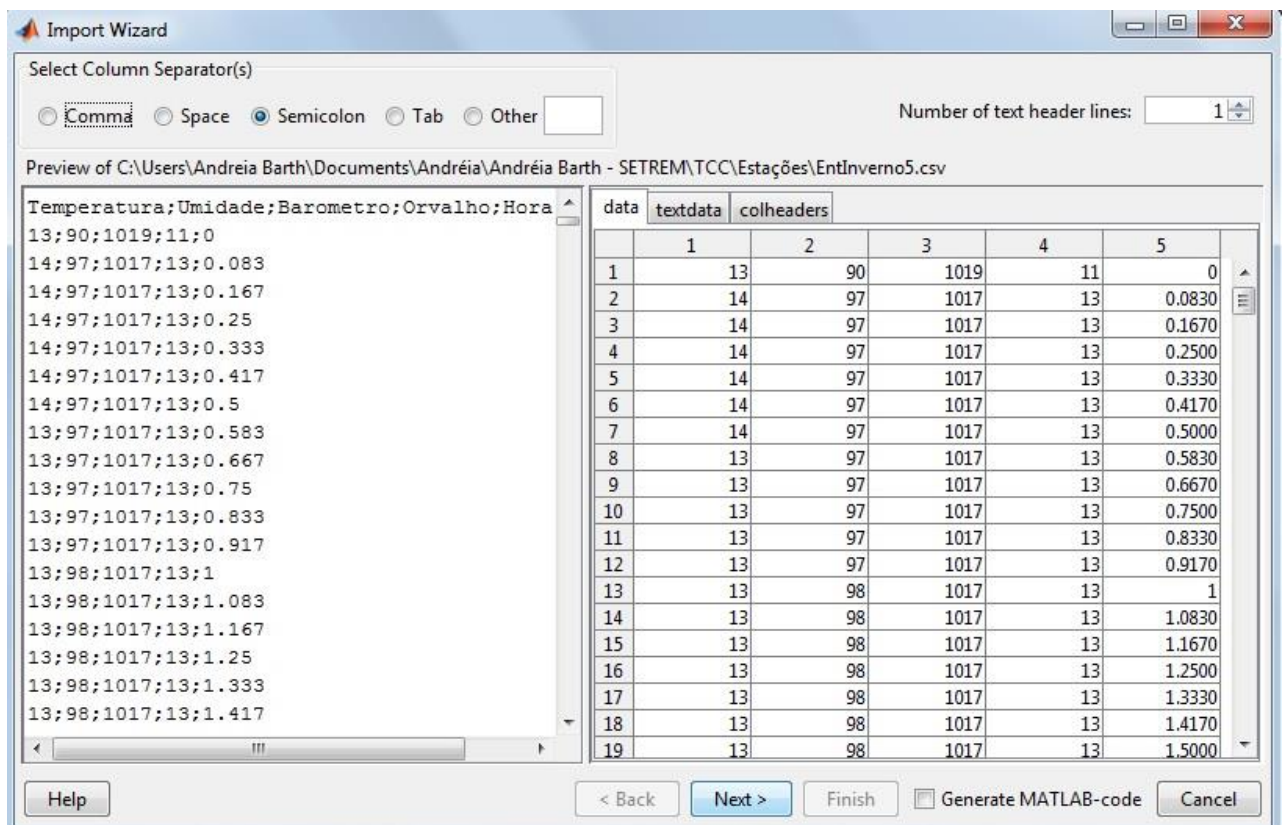
Abaixo a especificação de cada uma das numerações referenciadas na imagem acima:

- 1 – Redes criadas e salvas.
- 2 – Local onde são inseridos os comandos para elaboração da rede.
- 3 – Dados importados no MATLAB.
- 4 – Histórico de comandos utilizados na rede.

APÊNDICE D

O processo de importação dos dados ocorreu da seguinte forma: Os dados eram tratados no *software Excel* e posteriormente importados no MATLAB.

A imagem abaixo apresenta a forma de importação dos dados de entrada realizada no *software*.



Posterior a este processo, os dados estavam preparados para serem utilizados no treinamento da rede.

ANEXOS

Anexo A: Funções e especificações de Coleta da Estação Meteorológica SETREM.

ANEXO A

O Anexo A apresenta as funções de coleta de dados da estação meteorológica da SETREM.

Função	Vantage Pro 2	USA Units			Metric Units		
		Resolução	Alcance	Precisão	Resolução	Alcance	Precisão
Agrícola	Evapotranspiração	● 0.01"	0 a 199.99"	5%	0.1 mm	0 a 1999,9 mm	5%
	Graus crescentes-dia	○ 0.1 graus dia	Ilimitado		0.1 graus dia	Ilimitado	
	Aquecimento graus-dia	○ 0.1 graus dia	Ilimitado		0.1 graus dia	Ilimitado	
	Molhamento Foliar	● 1	0 a 15	0.5	1	0 a 15	0.5
	Umidade do solo	● 1 cb	0 a 200 cb		1 cb	0 a 200 cb	
Pressão Barométrica	Pressão Barométrica	√ 0.01" Hg	16" a 32.5" Hg	0.03" Hg mb	0,1 mm Hg 0,1 ou hPa	410 a 820 mm Hg 540 a 1100 mb	0,8 mm Hg 1,0 mb ou hPa
	Tendência de Três Horas	√ Hg	5 posições arrow		lento ≥ 0,5 mm (0,7 mb) Rapido ≥ 1,5 mm (2 mb)		
Umidade	Umidade no interior	√	1% 1 a 100%	3%		1% 1 a 100%	3%
	Umidade fora	√	1% 1 a 100%	3%		1% 1 a 100%	3%
	Ponto de Orvalho no interior	○ 0.1 °F	(-60°) a +140° F	3° F 0,1 °C		(-50°) a +60° C	1,5 °C
	Ponto de Orvalho fora	√ 1° F	(-105°) a +130° F	3° F 1 °C		(-76°) a +54° C	1,5 °C
Chuva	Chuva	√ 0.01"	0 a 199.99"	4%	0,2 mm	0 a 6553 mm	
	Taxa de chuva	√ 0.01"/hr	0 a 96"/hr	5% ≤ 5"/hr	0,1 mm/hr	0 a 2438 mm/hr	5% ≤ 127 mm/hr
Solar e UV	Radiação Solar	● 1 W/m2	0 a 1800 W/m2	5%	1 W/m2	0 a 1800 W/m2	5%
	Energia solar	● 0.1 Ly	1999.9 Ly	5%	0,1 Ly	1999,9 Ly	5%
	Dose UV	○ 0.1 MEDs	0 a 199 MEDs	5%	0,1 MEDs	0 a 199 MEDs	5%
	Índice UV	● 0.1	0 a 16	5%	0.1	0 a 16	5%
Temperatura	Temperatura dentro (interna)	● 0.1 °F	(+32°) a +140° F	1° F	0,1 °C	0° a +60° C	0,5 °C
	Temperatura externa (ISS)	√ 0.1 °F	(-40°) a +150° F	1° F	0,1 °C	(-40°) a +65° C	0,5 °C
	Outside temp (temp estação)	√ 1° F	(-40°) a +150° F	1° F	1 °C	(-40°) a +65° C	0,5 °C
	Temperatura Solo ou água	● 1° F	(-40°) a +150° F	1° F	1 °C	(-40°) a +65° C	0,5 °C
	Índice de aquecimento interr	○ 0.1 °F	(+30°F) a +165° F	3° F	0,1 °C	(-1°C) a +74° C	1,5 °C
	Índice de aquecimento exteri	○ 1° F	(-40°) a +165° F	3° F	1 °C	(-40°) a +74° C	1,5 °C
	Índice temperatura/sol/venti	√ 1° F	(-90°) a +165° F	4° F	1 °C	(-68°) a +74° C	2 °C
Vento Frio	● 1° F	(-110°) a +135° F	2° F	1 °C	(-79°) a +57° C	1 °C	
Tempo/ Data	Tempo	√ 1 minuto	12/24 horas	8 sec/mo	1 minuto	12/24 horas	8 sec/mo
	Data	√ Mês/dia	Ano bissexto	8 sec/mo	Mês/dia	Ano bissexto	8 sec/mo
	Nascer e Pôr do Sol	√ 1 minuto	12 horas	1 minuto	1 minuto	12 horas	1 minuto
Vento	Direção do Vento	√ 1°	0° a 360° C	3° 1°		0° a 360° C	3°
	Rosa dos Ventos	√ 22.5°	16 pontos cardeais 1 to 200 mph 1 a	22.5°		16 pontos cardeais 1 a 80 m/s 1 a	
	Velocidade do Vento	√ 1 mph 1knot	174 knots	5%	0,1 m/s 1 km/hr	320 km/hr	5%
	Direção de alta velocidade	√ 22.5°	16 pontos cardeais	22.5°		16 pontos cardeais	
	Vento run	○ 0.01 milhas 0.01 milhas náuticas	Ilimitado	5%	0,01 km	Ilimitado	5%

Fonte: Manual da Estação Meteorológica da SETREM.

Figura 41 - Funções de coleta de dados da Estação Meteorológica da SETREM.