

UFRRJ

**INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
MATEMÁTICA E COMPUTACIONAL**

DISSERTAÇÃO

**Aplicação de Redes Neurais na Predição de Disponibilidade de Recursos
Energéticos Solares no Município de Seropédica**

Erylaine Reis Rubim Moreira Araujo

2019



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
MATEMÁTICA E COMPUTACIONAL – PPGMMC**

**APLICAÇÃO DE REDES NEURAIS NA PREDIÇÃO DE
DISPONIBILIDADE DE RECURSOS ENERGÉTICOS SOLARES NO
MUNICÍPIO DE SEROPÉDICA**

ERYLAINE REIS RUBIM MOREIRA ARAUJO

Sob a Orientação do Professor
Dr. Robson Mariano da Silva

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Ciências**, no Curso de Pós-Graduação em Modelagem Matemática e Computacional, Área Concentração em Modelagem Matemática e Computacional

Seropédica/RJ
Julho de 2019

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

658a Araujo, Erylaine Reis Rubim Moreira, 1989-
Aplicação de Redes Neurais na Predição de
Disponibilidade de Recursos Energéticos Solares no
Município de Seropédica / Erylaine Reis Rubim Moreira
Araujo. - Rio de Janeiro, 2019.
69 f.: il.

Orientador: Robson Mariano da Silva.
Dissertação (Mestrado). -- Universidade Federal Rural
do Rio de Janeiro, Programa de Pós-Graduação em
Modelagem Matemática e Computacional - PPGMMC, 2019.

1. Radiação Solar. 2. Redes Neurais Artificiais .
3. Regressão Linear Múltipla. I. Silva, Robson
Mariano da , 1963-, orient. II Universidade Federal
Rural do Rio de Janeiro. Programa de Pós-Graduação em
Modelagem Matemática e Computacional - PPGMMC III.
Título.

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA
E COMPUTACIONAL – PPGMMC

ERYLAINE REIS RUBIM MOREIRA ARAUJO

DISSERTAÇÃO SUBMETIDA COMO REQUISITO PARCIAL PARA OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS,
NO CURSO DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL, ÁREA DE
CONCENTRAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL.

DISSERTAÇÃO APROVADA EM 11/07/2019.

Prof. Dr. Robson Mariano da Silva (Dr.) – PPGMMC – UFRRJ
(Orientador)

Prof. Dr. Angel Ramon Sanchez Delgado – PPGMMC – UFRRJ

Dr. Eluã Ramos Coutinho – FAETERJ

Ao meu esposo Leandro

AGRADECIMENTOS

Primeiramente quero agradecer a Deus, pois ao longo dessa trajetória, nos mínimos detalhes tem demonstrado Seu amor e misericórdia em minha vida.

Ao meu esposo Leandro, por sempre acreditar e lutar pelo meu sucesso, pela paciência e apoio ao longo da minha caminhada acadêmica. Você é uma fonte de inspiração para mim, sem você este sonho não teria se concretizado. Te amo!

Aos meus pais Tânia e Rubim, e ao meu irmão Ery, pois nunca mediram esforços para me ajudar, sempre me incentivaram e acreditaram em mim.

Ao meu cunhado Lenilson, pelo suporte acadêmico nos momentos de desespero.

Ao professor Robson, pela atenção a mim dispensada e pelas preciosas orientações no desenvolvimento deste trabalho.

Ao corpo docente da Rural, em especial aos membros da banca que prontamente aceitaram o convite.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, e assim, deixo o meu agradecimento pelo auxílio financeiro da bolsa de mestrado (Processo 23038.013648/2018-51).

Ao Instituto Nacional de Meteorologia pela disponibilidade de dados meteorológicos da estação Ecologia Agrícola do município de Seropédica no Rio de Janeiro.

E aos demais amigos e familiares que de forma direta ou indireta contribuíram para a realização deste sonho.

RESUMO

ARAUJO, Erylaine R.R.M. **Aplicação de Redes Neurais na Predição de Disponibilidade de Recursos Energéticos Solares no Município de Seropédica**. 2019. 69p. Dissertação (Mestre em Ciência em Modelagem Matemática e Computacional). Instituto de Ciências Exatas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2019.

O presente estudo propõe o desenvolvimento e avaliação de uma metodologia para estimar a incidência de radiação solar no município de Seropédica, localizado no estado do Rio de Janeiro. O objetivo do trabalho é avaliar se o modelo de Redes Neurais Artificiais (RNAs) é apropriado para tal fim. Para tal foram obtidos dados horários correspondentes ao período de 01 de Maio de 2017 a 31 de Janeiro de 2019 do Instituto Nacional de Meteorologia (INMET) através da estação Ecologia Agrícola localizada na região de estudo. Primeiramente foi avaliada a necessidade de se utilizar todos os dados disponibilizados pela estação. Em seguida foram realizados experimentos variando o número de neurônios na camada escondida, treinando redes compostas por uma e duas camadas internas. Diferentes parâmetros estatísticos foram utilizados para avaliar o desempenho dos modelos (r , MAE, RMSE, D, R^2 , C e skill). Em cada etapa do trabalho, os modelos de RNAs foram comparados com modelos de Regressão Linear Múltipla (RLM) a fim de verificar qual método seria satisfatório. Como resultado, foi possível analisar que não há necessidade de se utilizar todas as variáveis disponibilizadas pela estação Ecologia Agrícola. Analisando a média das 50 simulações realizadas, foi possível constatar que a RNA com a arquitetura de uma camada escondida apresentou resultados mais apurados que as demais, apresentando índice de confiança médio (D) de 88% e coeficiente de determinação médio (R^2) de 85%. Mesmo mostrando-se superiores, os modelos de RNAs não apresentaram ganhos significativos frente aos modelos de RLM. Assim, foi possível concluir que RNAs são ferramentas adequadas para estimar a incidência de radiação solar.

Palavras-chave: radiação solar, redes neurais artificiais, regressão linear múltipla.

ABSTRACT

ARAUJO, Erylaine R.R.M. **Application of Neural Networks in the Prediction of Availability of Solar Energy Resources in the Municipality of Seropédica**. 2019. 69p. Dissertation (Master in Science in Mathematical and Computational Modeling). Institute of Exact Sciences, Federal Rural University of Rio de Janeiro, Seropédica, RJ, 2019.

The present study aims to develop and evaluate a methodology for estimating solar radiation in the city of Seropédica, located in the state of Rio de Janeiro. The objective of this work is to evaluate if the Artificial Neural Networks (ANNs) model is appropriate for this purpose. For that, were obtained hourly data corresponding to the period from May 1, 2017 to January 31, 2019 of the National Meteorological Institute (INMET) through the Agricultural Ecology station located in the region of study. Firstly, it was assessed whether there was a need to use all the data provided by the station. The following experiments were performed by varying the number of neurons in the hidden layer, training networks composed of one and two inner layers. Different statistical parameters were used to evaluate the performance of the models (r , MAE, RMSE, D , R^2 , C and skill). At each stage of the work, the ANN models were compared with the Multiple Linear Regression (MLR) to verify which method would be satisfactory. As a result, it was possible to analyze that there is no need to use all the variables made available by the Agricultural Ecology station. Analyzing the average of the 50 simulations performed, it was possible to verify that the RNA with the architecture of a hidden layer presented more accurate results than the others, with an average confidence index (D) of 88% and an average determination coefficient (R^2) of 85%. Even though they were superior, the RNA models did not show significant gains compared to RLM models. Thus, it was possible to conclude that ANNs are an adequate tools to estimate the incidence of solar radiation.

Keywords: solar radiation, artificial neural networks, multiple linear regression.

LISTA DE FIGURAS

1 – Irradiação média global no Brasil e na Europa.....	1
2 – Mapa do Rio de Janeiro com a região de estudo	3
3 – Neurônio de McCulloch e Pitts	7
4 – Estrutura de um neurônio biológico	10
5 – Estrutura de um neurônio artificial não-linear.....	11
6 – Função de ativação degrau	12
7 – Função de ativação linear	13
8 – Função de ativação logística.....	13
9 – Função de ativação tangente hiperbólica.....	14
10 – Rede feedforward de camada única.....	15
11 – Rede feedforward múltiplas camadas.....	15
12 – Rede recorrente.....	16
13 – Aprendizado supervisionado	17
14 – Estrutura de uma rede do tipo MLP.	18
15 – Ideia básica do algoritmo para uma função de uma variável	20
16 – Mecanismo de convergência do método Rprop	22
17 – Espectro da radiação solar com detalhamento da faixa visível humana.....	26
18 – Processos radiativos com constituintes atmosféricos	27
19 – Comparação do espectro eletromagnético da radiação solar.....	27
20 – Componentes da irradiância solar.	28
21 – Piranômetro de termopilha da estação Ecologia Agrícola.....	29
22 – Piranômetro de fotodiodo de silício	29
23 – Pirheliômetro	30
24 – Unidades consumidoras com geração solar fotovoltaica.....	31
25 – Matriz elétrica brasileira em maio de 2017.	32
26 – Estação Ecologia Agrícola	34
27 – Croqui do cercado das estações.....	35

28 – Arquitetura de rede utilizada no presente trabalho.....	40
29 – Fluxograma da metodologia adotada.....	43
30 – Comportamento do erro MAE para diferentes quantidades de neurônios na camada escondida	55
31 – Primeiro experimento do comportamento do erro MAE para diferentes quantidades de neurônios nas camadas escondidas.....	56
32 – Segundo experimento do comportamento do erro MAE para diferentes quantidades de neurônios nas camadas escondidas.....	56
33 – Diagrama de dispersão dos valores estimados de radiação solar do modelo <i>RNA-9-9-1</i> e de RLM.....	60
34 – Diagrama de dispersão dos valores estimados de radiação solar do modelo <i>RNA-9-6-5-1</i> e de RLM.....	60
35 – Arquitetura da rede MLP proposta	61

LISTA DE TABELAS

1 – IDHM e seus componentes - Seropédica - RJ.....	4
2 – Características de aquisição dos parâmetros nas EMAs do INMET.....	34
3 – Resumo do conjunto de dados e de um dos subconjuntos de treinamento e teste.....	36
4 – Resumo dos parâmetros do modelo proposto.....	39
5 – Critérios para avaliação e análise do desempenho de modelos com base no índice de confiança.....	42
6 – Experimento com diferentes variáveis preditoras.....	45
7 – Índices de avaliação calculados na seleção das variáveis preditoras.....	46
8 – Resumo do Índice de Confiança para topologias com uma e duas camadas escondidas ...	48
9 – Tempo médio computacional entre os modelos.....	48
10 – Avaliação das médias dos modelos para uma camada interna.....	49
11 – Avaliação das médias dos modelos para duas camadas internas.....	50
12 – Avaliação dos valores máximos de C dos modelos para uma camada interna.....	51
13 – Avaliação dos valores máximos de C dos modelos para duas camadas internas.....	52
14 – Avaliação dos valores mínimos de C dos modelos para uma camada interna.....	53
15 – Avaliação dos valores mínimos de C dos modelos para duas camadas internas.....	54
16 – Comparação entre RNA e RLM para previsão de radiação solar.....	57
17 – Diferentes topologias para uma camada escondida.....	58
18 – Diferentes topologias para duas camadas escondidas.....	59

SUMÁRIO

1 INTRODUÇÃO	1
1.1 JUSTIFICATIVA.....	3
1.1.1 A área de estudo.....	3
1.2 OBJETIVOS.....	5
1.2.1 Objetivo Geral.....	5
1.2.2 Objetivos Específicos	5
1.3 ORGANIZAÇÃO DA DISSERTAÇÃO.....	5
2 REVISÃO BIBLIOGRÁFICA	6
2.1 REDES NEURAIS ARTIFICIAIS	6
2.1.1 Conceitos básicos.....	6
2.1.2 Breve histórico	7
2.1.3 Predição de recursos de energia solar através das redes neurais artificiais	8
2.1.4 Descrição básica de um neurônio biológico	10
2.1.5 Descrição básica de um neurônio artificial.....	10
2.1.6 Principais funções de ativação	12
2.1.7 Arquiteturas de rede.....	14
2.1.8 Tipos de aprendizado de RNAs	16
2.1.9 Redes perceptrons de múltiplas camadas (MLP).....	18
2.1.9.1 Algoritmo back-propagation	19
2.1.9.2 Algoritmo resilient back-propagation (Rprop).....	20
2.2 REGRESSÃO LINEAR	23
2.2.1 Regressão Linear Simples (RLS).....	23
2.2.1 Regressão Linear Múltipla (RLM)	24
2.3 RADIAÇÃO SOLAR	25
2.3.1 Conceitos básicos.....	25
2.3.2 Sensores para registro de radiação solar	29
2.3.3 Aproveitamento do potencial fotovoltaico no Brasil.....	30

3 MATERIAIS E MÉTODOS.....	33
3.1 OBTENÇÃO DOS DADOS.....	33
3.1.1 Sobre o INMET	33
3.2 CONJUNTO DE DADOS	35
3.3 SELEÇÃO DOS GRUPOS DE PREDITORES.....	37
3.4 TREINAMENTO DA RNA PARA SELEÇÃO DA MELHOR TOPOLOGIA	37
3.5 AVALIAÇÕES DAS PREVISÕES	40
4 RESULTADOS E DISCUSSÃO	44
4.1 SELEÇÃO DOS GRUPOS DE PREDITORES.....	44
4.2 SELEÇÃO ENTRE OS MODELOS: COMPLETO, INSTANTÂNEO, MÁXIMO E MÍNIMO.....	47
4.3 COMPORTAMENTO DO ERRO MAE.....	55
4.4 RESULTADOS DE IRRADIAÇÃO SOLAR	57
5 CONCLUSÕES.....	62
6 TRABALHOS FUTUROS	64
REFERÊNCIAS BIBLIOGRÁFICAS	65

1 INTRODUÇÃO

Nos últimos anos a demanda por energia elétrica aumentou drasticamente, pois se tornou fundamental para a vida cotidiana e para a economia. Energia elétrica proveniente de combustíveis fósseis ou de hidrelétricas gera um grande impacto ambiental, seja pelo agravamento do efeito estufa, a poluição do ar, ou por causar alagamento de grandes áreas, interferindo na vegetação e fauna local, entre outros (Costa, 2016). Na busca por formas de geração de energia que menos agridam ao meio ambiente, que reduzam as emissões de gases de efeito de estufa, além da perspectiva de esgotamento do petróleo nas próximas décadas (Bentley, 2002) pode-se citar a energia solar como uma alternativa de energia renovável. Existe também a necessidade de expandir a credibilidade e a segurança do setor energético de uma nação e para isso, diversificar a matriz energética é uma boa forma de precaver possíveis imprevistos, como por exemplo, a geração de energia hidroelétrica possui inconstância em decorrência dos longos períodos de estiagem comuns no Brasil (Fiorin *et al.*, 2011).

Devido o Brasil estar localizado em uma região tropical e subtropical, recebe elevada irradiação solar durante todo o ano, o que propicia a utilização desse tipo de energia. O potencial de geração fotovoltaica no Brasil é tão grande de forma que, no local com menos incidência de radiação solar no país, é possível gerar mais eletricidade solar do que no local com maior incidência de radiação solar da Alemanha, por exemplo. Os níveis de irradiação solar observados em praticamente todas as partes do Brasil são superiores aqueles observados para a maioria dos países europeus. A figura 1 apresenta os mapas de irradiação média global no Brasil e na Europa (Martins *et al.*, 2007; Pereira *et al.*, 2017).

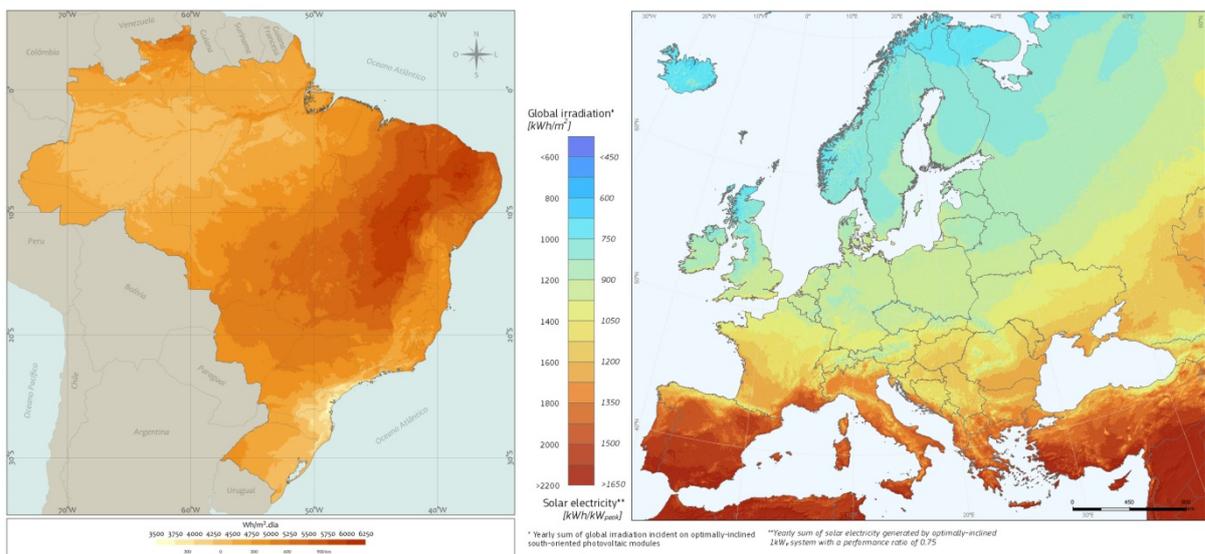


Figura 1 – Irradiação média global no Brasil e na Europa. FONTE: Pereira *et al.*, 2017, PVGIS, 2012

Interessante observar que Fiorin *et.al.* (2011), no ano de sua pesquisa, evidenciou alguns fatores que inviabilizam a comercialização dos recursos de energia solar como os altos custos se comparado às fontes de energia habituais, a carência de dados científicos sobre a variabilidade e disponibilidade espacial e temporal dos seus recursos e ao fato de depender das condições climáticas.

Contudo, de acordo com o Instituto de Pesquisa Econômica Aplicada (IPEA, 2019) a capacidade instalada no Brasil aumentou consideravelmente nos últimos dois anos, crescendo de 0,1% para 1,4% de 2016 a 2018. Entre esses dois anos, aproximadamente 41 mil novas usinas de energia solar foram instaladas no Brasil. Houve um aumento significativo no número de estabelecimentos comerciais, industriais e residenciais que passaram a produzir e consumir dessa fonte de energia. Este aumento se dá em virtude de vários fatores, como a diminuição nos custos de fabricação, o aumento na eficiência dos módulos fotovoltaicos e a facilidade na implementação de sistemas de pequeno e grande porte, no entanto o país ainda está em seus passos iniciais na geração de energia solar fotovoltaica. (Abdala, 2019)

Desenvolver tecnologias para o melhor aproveitamento de energia solar é o foco de muitas pesquisas científicas nas principais instituições de pesquisa do país objetivando o desenvolvimento de novas tecnologias para aproveitamento dos recursos de energia solar a um custo comparável ao apresentado por outras fontes de energia; e de aperfeiçoar a base de dados científicos que estão disponíveis para a elaboração de novos projetos. A previsão da incidência de radiação solar na superfície terrestre apresenta também a importância na gestão de sistemas de geração e distribuição de eletricidade (Martins, *et.al.*, 2008).

Por meio de variadas técnicas computacionais, muitas metodologias têm sido desenvolvidas com o objetivo de produzir estimativas e previsões de irradiação solar, como é o caso de Boata e Pop (2015) que fizeram uso do algoritmo Fuzzy de Takagi-Sugeno para estimar a radiação solar global diária em cinco locais da Europa: Budapeste, Galati, Innsbruck, Sofia e Timisoara, pode concluir que seu modelo proposto funciona com precisão aceitável para a maioria dos fins práticos, especialmente quando requer um equilíbrio entre simplicidade e precisão. Mutaz e Ahmad (2015) compararam alguns modelos computacionais com modelos de Função de Base Radial (RBF) e comprovou que este modelo apresentou melhor desempenho frente aos demais, além disso, em seu estudo concluiu que os modelos RBF podem ser utilizados como uma ferramenta preditiva por 24 horas para previsão de radiação solar em locais sem estações meteorológicas. Al-Hajj e Assi (2017) obtiveram bons resultados utilizando Algoritmo Genético para predição da incidência de radiação diária nos Emirados Árabes Unidos.

Os modelos numéricos que são utilizados em previsão meteorológica possuem códigos computacionais para parametrização dos processos radiativos na atmosfera e podem ser utilizados para previsão da irradiação solar na superfície. Porém, as previsões fornecidas por tais modelos, apresentam desvios elevados em relação a valores medidos em superfície para um ou dois dias de antecedência (Heinemann, 2004). Estudos indicam como principal motivo desses desvios elevados a dependência da irradiação solar em relação às condições meteorológicas que envolvem intrinsecamente processos físicos não-lineares de difícil parametrização (Mesinger, 2005).

Assim, o presente trabalho é um estudo sobre previsão de radiação solar incidente diária no Município de Seropédica, objetivando principalmente fornecer informações que atendam as atividades ligadas à geração de energia. Para isso utilizou-se o método computacional conhecido como Redes Neurais Artificiais (RNAs) com arquitetura do tipo

Perceptron de Múltiplas Camadas (MLP) pela sua notória capacidade de reconhecimento de padrões, além de gerar bons resultados para problemas que apresentam alto grau de não-linearidade. Foi feito também uma comparação com o método de Regressão Linear Múltipla (RLM) a fim de analisar qual método apresentaria melhores resultados.

1.1 Justificativa

Como citado anteriormente, o potencial brasileiro para a energia solar é enorme, em 2016 estimava-se que no ano de 2018 o Brasil estaria entre os 20 países com maior geração de energia solar (Brasil, 2016). As aplicações são visíveis em diversas áreas das atividades humanas como, por exemplo, a agricultura, a arquitetura, a saúde, a indústria e o lazer. Tudo depende do conhecimento da disponibilidade de energia solar na superfície de nosso planeta. O setor energético, tema recorrente no gerenciamento e planejamento de todas as nações do globo, tem envidado esforços para tornar a energia solar uma componente significativa entre as matrizes energéticas e esse fato tem gerado uma crescente demanda por estimativas e previsões da incidência de radiação solar. Este trabalho visa contribuir para o desenvolvimento e/ou otimização dos modelos de obtenção de estimativas e previsões da incidência da radiação solar no Município de Seropédica com o emprego de Redes Neurais Artificiais.

1.1.1 A área de estudo

Seropédica é um município do estado do Rio de Janeiro que se localiza aproximadamente 70 km da capital. De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE, 2017) sua área é de 283,762km². No último censo em 2010 sua população foi de 78.186 pessoas, garantindo a 31^a posição no ranking dos 92 municípios do estado do Rio de Janeiro e a 370^a posição entre os 5.565 municípios do Brasil. A estimativa populacional para 2018 foi de 86.743 pessoas e sua densidade demográfica é 275,53 hab/km².

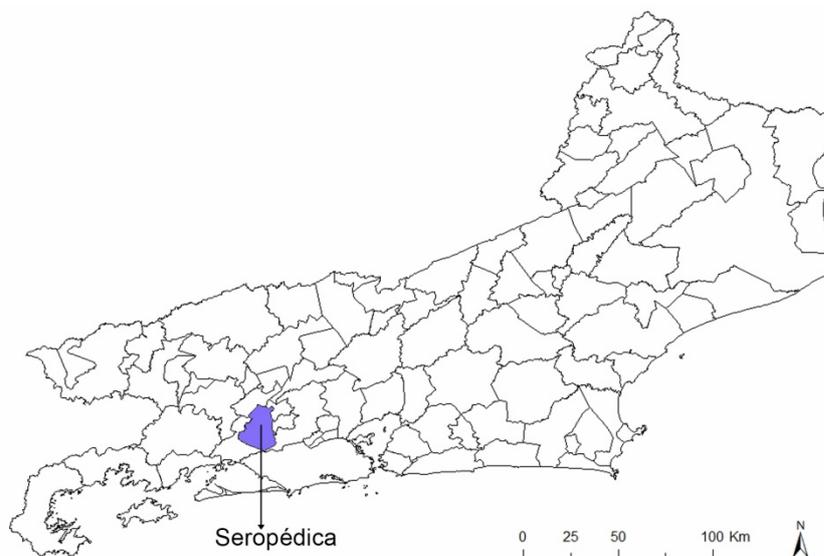


Figura 2 – Mapa do Rio de Janeiro com a região de estudo.

De acordo com o Atlas do Desenvolvimento Humano no Brasil (PNUD, IPEA, FJP, 2013) o Índice de Desenvolvimento Humano Municipal (IDHM) de Seropédica em 2010 foi de 0,713, o que caracteriza um IDHM alto (IDHM entre 0,700 e 0,799). As componentes do IDHM como Longevidade, Renda e Educação apresentam índices de 0,805; 0,695 e 0,648 respectivamente. Segundo o IDHM, Seropédica ocupa a 1514ª posição dos 5.565 municípios brasileiros. A tabela 1 apresenta o IDHM de Seropédica nos anos de 1991, 2000 e 2010.

A população de Seropédica cresceu a uma taxa anual de 1,82% entre os anos de 2000 e 2010, no mesmo período a população brasileira teve seu aumento a uma taxa de 1,17%. Isso se dá devido ao aumento da expectativa de vida e a redução da taxa de mortalidade. (PNUD, IPEA, FJP, 2013)

Tabela 1 – IDHM e seus componentes - Seropédica - RJ. FONTE: PNUD, IPEA, FJP, 2013.

IDHM e componentes	1991	2000	2010
IDHM Educação	0,264	0,423	0,648
% de 18 anos ou mais com fundamental completo	29,81	37,64	57,19
% de 5 a 6 anos na escola	40,45	76,42	95,21
% de 11 a 13 anos nos anos finais do fundamental REGULAR SERIADO ou com fundamental completo	31,99	56,90	81,87
% de 15 a 17 anos com fundamental completo	15,77	28,63	50,05
% de 18 a 20 anos com médio completo	10,92	17,51	48,95
IDHM Longevidade	0,668	0,726	0,805
Esperança de vida ao nascer	65,08	68,54	73,30
IDHM Renda	0,586	0,655	0,695
Renda per capita	307,02	471,07	604,82

As principais atividades econômicas da região são o comércio, a extração de mineral e a indústria (PMS, 2019). De acordo com o IBGE (2017) no ano de 2016 o cadastro central de empresas em Seropédica contava com 845 unidades locais em diversas áreas de atuação como agricultura, pecuária, produção florestal, pesca, indústrias extrativas, extração de minerais não-metálicos, indústrias de transformação, fabricação de produtos alimentícios, confecção de artigos do vestuário e acessórios, construção, educação, transporte, entre outros. No ranking do cadastro central de empresas entre os municípios, ocupa a 44ª posição dos 92 municípios do estado do Rio de Janeiro e ocupa a 914ª posição dos 5570 municípios do Brasil.

Em 2016 o PIB per capita de Seropédica foi de R\$ 24.602,97. No estado do Rio de Janeiro ocupou a 44ª posição de 92 municípios e se comparado aos 5570 municípios que o país possui, ocupou a 1560ª posição (IBGE, 2017).

De acordo com o Instituto Nacional de Meteorologia (INMET) a temperatura média compensada anual em Seropédica é de 23,80°C. Para a Fundação Instituto de Desenvolvimento Econômico e Social do Rio de Janeiro (FIDERJ, 1978, *apud* Castro *et.al.* 2009) o clima é subúmido e mesotérmico com calor bem distribuído ao longo do ano.

Devido ao fato da população e da economia local estar em crescimento, conseqüentemente haverá o aumento no consumo de energia elétrica. A região é propícia a extração dos recursos de energia solar, fato esse que justifica a escolha da área de estudo para o presente trabalho.

1.2 Objetivos

1.2.1 Objetivo Geral

Aplicar modelo baseado em Redes Neurais Artificiais para predição da radiação solar diária no Município de Seropédica/RJ.

1.2.2 Objetivos Específicos

- Avaliar as arquiteturas de redes neurais MLP.
- Comparar o modelo proposto com modelos existentes na literatura.
- Otimizar o modelo a partir dos resultados preliminares.
- Comparar o modelo proposto com Regressão Linear Múltipla.

1.3 Organização da Dissertação

O presente trabalho está dividido em seis capítulos. Após o capítulo de introdução alguns conceitos teóricos pertinentes à compreensão do mesmo são apresentados no capítulo de revisão bibliográfica, que se subdivide em conceitos sobre Redes Neurais Artificiais, Regressão Linear e radiação solar. Logo em seguida no capítulo 3 é apresentada a metodologia adotada. O capítulo 4 mostra os resultados e discussões obtidos. Os capítulos 5 e 6 apresentam as conclusões e sugestões para trabalhos futuros respectivamente.

2 REVISÃO BIBLIOGRÁFICA

2.1 Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são modelos de processamento de informações baseados numa analogia a estrutura neural biológica (Haykin, 2001; Silva, 2010). São ferramentas estatísticas que a partir de exemplos podem aprender, armazenar essas informações e apresentar soluções adequadas com base no conhecimento adquirido. Neste capítulo são apresentadas as redes neurais e algumas características principais, um breve histórico das RNAs e dentre os variados tipos de redes neurais existentes, será dado enfoque ao que se faz necessário para a compreensão deste trabalho.

2.1.1 Conceitos básicos

Inspirado no sistema nervoso biológico e no cérebro humano desenvolveu-se a estrutura das Redes Neurais Artificiais, que são compostas por unidades de processamento simples denominadas neurônios artificiais. RNAs são processadores paralelamente distribuídos que tem a capacidade de armazenar conhecimento experimental e disponibilizá-lo para uso. Assemelham-se ao cérebro em dois aspectos: através de um processo de aprendizagem, a rede obtém o conhecimento e este é armazenado nas forças de conexão entre os neurônios (pesos sinápticos) (Haykin, 2001).

Fausett (1993) em seu livro *Fundamentals of Neural Networks*, destaca que as redes neurais artificiais foram desenvolvidas inspiradas na biologia cerebral, com base nos pressupostos de que:

- O processamento de informações ocorre em unidades simples denominadas neurônios ou nós, que computam as funções matemáticas, em especial, não lineares;
- Os neurônios estão organizados em uma ou mais camadas interligadas. Os sinais são transmitidos entre os neurônios por inúmeras conexões, também chamados de sinapses. A estas conexões são associados valores, denominados pesos sinápticos.
- Cada neurônio possui uma função de ativação à sua entrada (geralmente não linear), essas por sua vez determinam o seu sinal de saída e consequentemente se o neurônio será ou não ativado.

As entradas recebidas por cada neurônio são ponderadas pelos pesos sinápticos, onde estes por sua vez, são encarregados pelo armazenamento do conhecimento representado pela RNA. As RNAs antes de apresentarem alguma solução, passam pela fase de treinamento, também chamada de fase de aprendizagem, onde um conjunto de dados é apresentado para a rede, daí os pesos das conexões são ajustados até apresentarem à rede a capacidade de adaptar-se ao problema. Após o treinamento, os pesos são fixados e a rede pode ser utilizada como um modelo estimando saídas a partir de um novo conjunto de dados de entrada. (Guarnieri, 2006)

O principal motivo para o uso das RNAs fundamenta-se na sua capacidade de reconhecimento de padrões, generalização, auto-organização e processamento temporal, o que viabiliza a solução de diversos problemas com os mais variados níveis de complexidade e apresenta bons resultados em problemas que possuam elevado grau de não linearidade, contudo as RNAs não apresentam a mesma eficiência para todos os problemas. (Fiorin *et.al.* 2011; Guarnieri, 2006)

2.1.2 Breve histórico

Warren McCulloch e Walter Pitts (1943) introduziram o primeiro modelo neural artificial de um neurônio biológico no trabalho intitulado *A logical Calculus of the Ideas Immanent in Nervous Activity*. De acordo com Haykin (2001), McCulloch foi um psiquiatra e neuroanatomista por treinamento e Pitts foi um prodigioso matemático, a associação entre ambos ocorreu em 1942. O modelo neural proposto dispunha de entradas x_i , onde $i = 1, \dots, n$, que são os dados de entrada da rede ou das saídas de outros neurônios, são ponderadas pelos pesos sinápticos não ajustáveis w_i , com $i = 1, \dots, n$. Assim o neurônio calcula o somatório dos produtos de $x_i w_i$, se o resultado for igual ou superior a um limiar θ , o sinal de saída y do neurônio é igual a um, ativando o neurônio. Caso o valor desse produto seja menor que o limiar, a saída é zero e o neurônio não é ativado. (Guarnieri, 2006) A figura a seguir mostra este modelo de neurônio:

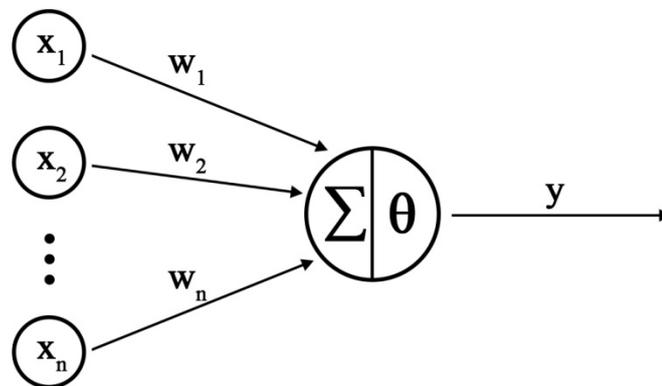


Figura 3 – Neurônio de McCulloch e Pitts. FONTE: adaptado de Braga *et.al.*, 2000

Depois do artigo de McCulloch e Pitts, alguns trabalhos foram desenvolvidos sobre o tema, dentre eles, ganhou destaque significativo o livro *The Organization of Behavior* de Hebb em 1949. Onde propôs o primeiro método de treinamento para as redes neurais artificiais, o seu postulado de aprendizagem, onde afirma que “a eficiência de uma sinapse variável entre dois neurônios é aumentada pela ativação repetida de um neurônio causada pelo outro neurônio, através daquela sinapse”. (Haykin, 2001; Silva *et.al.*, 2010)

A rede neural Perceptron foi proposta por Frank Rosenblatt (1958) no seu trabalho *The perceptron: a probabilistic model for information storage and organization in the brain*. A rede Perceptron, formada por neurônios de McCulloch e Pitts com a diferença de que possuía a capacidade de ajuste para pesos e vieses sinápticos, foi desenvolvida para classificar padrões linearmente separáveis. Este modelo é conhecido como Perceptron de uma camada.

Bernard Widrow e Marcian Edward Hoff (1960) propuseram a rede Adaline (adaptative linear elemento) no trabalho intitulado *Adaptive Switching Circuits*, a diferença entre esta e o Perceptron encontra-se na forma de aprendizagem. Em 1962 Widrow e seus estudantes introduziram a Madaline (multiple-adaline) que foi uma das primeiras redes neurais dispostas em camadas treináveis com diversos elementos adaptativos. (Haykin, 2001)

Marvin Minsky e Seymour Papert (1969) publicaram o livro *Perceptrons – An Introduction to Computational Geometry* onde foram evidenciadas as limitações das redes neurais de camada única como a Perceptron e a Adaline. Resumidamente, o livro demonstra a impossibilidade das redes classificarem corretamente os padrões para classes não linearmente separáveis. (Silva *et.al.*, 2010)

Após essa publicação a quantidade de pesquisas relacionadas ao tema diminuiu consideravelmente. Para Haykin (2001) dois trabalhos foram os mais influentes para o ressurgimento do interesse dos pesquisadores em redes neurais nos anos 80 que foram: o artigo intitulado *Neural networks and physical systems with emergent collective computational abilities* de 1982 de John Hopfield, onde o princípio do armazenamento de informação em redes dinamicamente estáveis foi explicitado pela primeira vez e o livro *Parallel Distributed Processing: Explorations in the Microstructure of Cognition* de 1986 em dois volumes de David Rumelhart e James McClelland, que foi um grande influenciador na utilização de aprendizagem por retropropagação.

No mesmo ano, David Rumelhart, Geoffrey Hinton e Ronald Williams descreveram no artigo *Learning representations by backpropagation errors* o algoritmo de retropropagação conhecido como back-propagation propondo a sua utilização para aprendizagem de máquina e demonstraram o funcionamento do mesmo.

RNAs oferecem diversas possibilidades de utilização em várias áreas do conhecimento e em virtude disso, muitos trabalhos sobre o tema foram realizados, como por exemplo: Gambogi (2013) fez uso de redes neurais artificiais para tomada de decisão no mercado de ações, Martins *et al.* (2016) usou RNAs para estimar o afilamento do fuste de árvores de eucalipto (conversão do fuste em produtos da madeira). Barreto *et.al.* (2018) mostrou com sucesso que RNAs podem ser usadas como um sistema de suporte na decisão clínica para o diagnóstico de câncer cervical. Freitas *et al.* (2019) utilizou RNA como uma ferramenta auxiliar na classificação de neoplasias mamárias, obtendo bons resultados e comprovando a eficácia do modelo proposto. Esses são apenas alguns exemplos das inúmeras aplicabilidades de RNAs e é interessante observar que desde seu ressurgimento na década de 80 o seu uso é frequente pelos pesquisadores até os dias atuais.

2.1.3 Predição de recursos de energia solar através das redes neurais artificiais

Muitas metodologias aplicando Redes Neurais Artificiais (RNAs) estão sendo desenvolvidas e utilizadas para avaliação e previsão da disponibilidade de recursos de energia solar, como é o caso de Kalogirou *et.al.* (2002) estimaram a radiação solar máxima através do uso de um método periódico da rede neural fazendo uso de dados de entrada como a temperatura e a umidade relativa do ar. Foi possível constatar um coeficiente de correlação variando entre 98.6% e 98.8%.

Soares *et.al.* (2004) onde foi utilizado redes do tipo MLP de 3 camadas, treinadas com o algoritmo Backpropagation, a fim de modelar a radiação solar difusa horária na cidade de São Paulo. No estudo, foi possível verificar que os valores medidos de irradiação solar no

topo da atmosfera (TDA), a irradiação solar global na superfície, valores de umidade relativa e da irradiação de onda longa são informações significativas para este experimento de RNA. Foi constatado que a temperatura do ar e a pressão atmosférica não influenciavam na precisão e confiabilidade estimadas, foi enfatizado também que medidas de irradiação de onda longa podem substituir dados de nebulosidade na ausência dos mesmos.

No estudo realizado por Mellit *et.al.* (2005) usaram RNAs do tipo Radial Basis Function obtendo resultados satisfatórios para a previsão de séries temporais de radiação solar global diária, obtendo dados como valores de temperatura do ar e duração do brilho do sol no período de um ano.

Em 2006, Guarnieri fez uso de redes do tipo MLP, treinadas pelo algoritmo Rprop, no refinamento estatístico das previsões de radiação solar global do modelo de mesoescala (modelo Eta/CPTEC). O seu estudo objetivou fornecer previsão com maior confiabilidade de irradiação solar na superfície do que as fornecidas pelo modelo de mesoescala. Foi possível observar também que o emprego de RNAs não se mostrou superior quanto às regressões lineares múltiplas se aplicadas com o mesmo intuito.

O uso de Redes Neurais Artificiais na previsão de radiação solar mostrou-se aprovável como aproximação computacional concedendo um método alternativo para modelagem complexa e problemas de difícil definição em diversas áreas da ciência, foi o que constatou Krishnaiah *et.al.* (2007) em seu trabalho, onde fez uso de RNAs para estimar a radiação solar global horária (RSGH) na Índia.

Coutinho (2016) Fez uso de Redes Neurais Artificiais do tipo Perceptrons de Múltiplas Camadas (MLP) e Função de Base Radial (RBF) para realizar a predição de um passo à frente em séries de dados meteorológicos. Além disso, realizou a comparação de tais métodos com modelos de Regressão Linear Múltipla (RLM) onde comprovou que as RNAs MLP e RBF são mais adequadas para tal estudo, pois suas estimativas foram consideravelmente próximas aos dados reais.

O trabalho proposto por Mendes *et.al.* (2017) utilizou as medições de dados meteorológicos em intervalos de 1 minuto durante os meses de julho e agosto de 2016, provenientes do Sistema de Organização Nacional de Dados Ambientais (SONDA) para prever a radiação de energia solar global através das Redes Neurais. A RNA utilizada foi do tipo MLP de três camadas, cujo treinamento foi realizado com o algoritmo *backpropagation*. Foram realizados testes variando a quantidade de neurônios na camada intermediária. Foi possível observar que a melhor configuração da rede neural foi com a de 10 neurônios na camada intermediária. Como resultado obteve que as Redes Neurais são uma boa ferramenta para previsão de dados de modelos com características não lineares e obteve êxito na previsão de radiação solar global.

Dando continuação ao estudo do aproveitamento dos recursos de energia solar, não focando na estimativa de incidência da radiação solar, mas na previsão de geração de energia elétrica de um sistema fotovoltaico, encontra-se o trabalho de Pinheiro *et.al.* (2017), onde também fez uso de Redes Neurais Artificiais. Ao realizar diversos experimentos com a rede, concluiu que a melhor configuração foi a de 30 neurônios na camada escondida, obtendo com isso um coeficiente de correlação superior a 0,98. O que indica que as redes utilizadas são capazes de realizar adequados resultados ao estudo proposto.

2.1.4 Descrição básica de um neurônio biológico

O sistema nervoso cerebral possui como célula elementar o neurônio. Este por sua vez, depois de estabelecidas as condições de operação, possui o papel de conduzir estímulos elétricos provenientes de reações físico-químicas, tais estímulos são responsáveis pelo funcionamento do corpo. Um neurônio biológico é constituído basicamente por dendritos, corpo celular e axônio. Os dendritos são formados por muitos prolongamentos finos formando a árvore dendrital, sua missão principal é captar os estímulos oriundos de outros neurônios ou do meio externo em que possam estar em contato. As informações recebidas pelos dendritos são encaminhadas para o corpo celular, onde são processadas com o intuito de gerar um potencial de ativação que definirá se o neurônio irá transmitir esse impulso elétrico ao longo do axônio. Formado por um único prolongamento, o axônio tem a função de transportar os impulsos elétricos, a terminação do axônio é constituída também de ramificações conhecidas como terminações sinápticas. A comunicação entre neurônios é feita por meio de impulsos eletroquímicos, conhecida também como sinapses (Silva *et.al.*, 2010; Machado, 2005). Na figura 4 é possível observar a estrutura de um neurônio biológico.

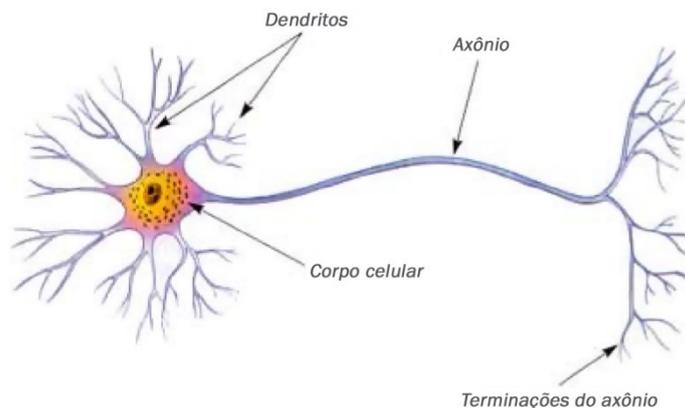


Figura 4 – Estrutura de um neurônio biológico. FONTE: Machado, 2005.

2.1.5 Descrição básica de um neurônio artificial

Como mencionado anteriormente, os neurônios artificiais são modelos computacionais simplificados dos neurônios biológicos, são não-lineares, geram saídas tipicamente contínuas e executam funções simples, como coletar os sinais de entrada, realiza os cálculos de acordo com a função operacional e gera uma resposta, considerando a sua função de ativação. O funcionamento de um neurônio artificial se dá da seguinte maneira: um conjunto de dados é apresentado a rede, estes valores representam as variáveis de entrada do neurônio. Cada entrada do neurônio é multiplicada pelo o peso sináptico correspondente. Realizando o somatório dessas multiplicações e subtraindo o limiar de ativação obtém-se o potencial de ativação. O valor gerado no potencial de ativação é então aplicado na função de ativação, que limita a saída do neurônio. A partir da função de ativação escolhida o neurônio poderá ser ativado ou não. (Silva *et.al.*, 2010)

O modelo matemático de um neurônio artificial pode ser observado na figura a seguir:

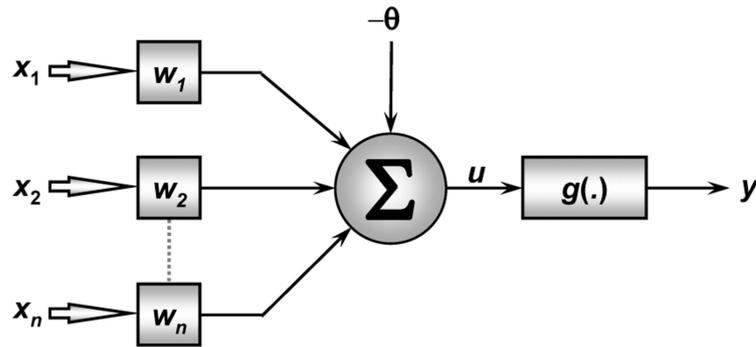


Figura 5 – Estrutura de um neurônio artificial não-linear. FONTE: Silva *et.al.*, 2010.

De acordo com Silva *et.al.* (2010), o neurônio artificial é constituído de sete elementos básicos, além disso, pode ser descrito matematicamente por:

$$u = \sum_{i=1}^n w_i x_i - \theta \quad (2.1)$$

$$y = g(u) \quad (2.2)$$

- **Sinais de entrada** $\{x_1, x_2, \dots, x_n\}$ são os sinais ou medidas oriundos do meio externo, são similares aos impulsos elétricos externos captados pelos dendritos do neurônio biológico. Para cada aplicação específica, os sinais de entrada representam os valores das variáveis. Com o propósito de aumentar a eficiência computacional dos algoritmos de aprendizagem, geralmente os sinais de entrada são normalizados.
- **Pesos sinápticos** $\{w_1, w_2, \dots, w_n\}$ são valores aleatórios que tem a função de ponderar cada um dos sinais de entrada. Dessa forma é possível verificar as relevâncias das variáveis de entrada no que diz respeito a funcionalidade do neurônio correspondente.
- **Combinador linear** $\{\Sigma\}$ agrega todos os sinais de entrada já ponderados pelos pesos sinápticos correspondentes e produz um valor de potencial de ativação.
- **Limiar de ativação** $\{\theta\}$ também conhecido como bias, é uma variável que determina o patamar adequado para que o resultado gerado pelo combinador linear produza um valor de disparo em direção a saída do neurônio. Além disso, para Haykin (2001) o bias tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação caso seja positivo ou negativo respectivamente.
- **Potencial de ativação** $\{u\}$ é a diferença entre os valores gerados pelo combinador linear e o limiar de ativação. Se este valor for positivo ($u \geq \theta$) o neurônio será ativado, caso seja negativo ($u < \theta$) neurônio não será ativado.
- **Função de ativação** $\{g\}$ tem a função de limitar a saída do neurônio em um intervalo específico.
- **Sinal de saída** $\{y\}$ resultado final gerado pelo neurônio a partir de determinado conjunto de sinais de entrada. O sinal de saída de um neurônio pode ser o sinal de entrada para a próxima camada ou a saída final da rede.

2.1.6 Principais funções de ativação

Existem diversas funções de ativação que podem ser divididas em dois grupos: funções parcialmente diferenciáveis e funções totalmente diferenciáveis. O primeiro grupo refere-se às funções que possuem pontos os quais não existem derivadas de primeira ordem, já o segundo grupo pertence às funções que possuam derivadas de primeira ordem existentes e conhecidas em todos os pontos de seu domínio. Para cada grupo, apenas as principais funções de ativação serão mencionadas. (Silva *et.al.*, 2010; Haykin, 2001; Braga *et.al.*, 2000)

- **Função degrau:** pertence ao grupo das funções parcialmente diferenciáveis. Seu resultado será igual a um quando o potencial de ativação do neurônio for maior ou igual a zero e será zero para o caso contrário, em termos matemáticos:

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (2.3)$$

O comportamento da função degrau pode ser analisado graficamente na figura 6:

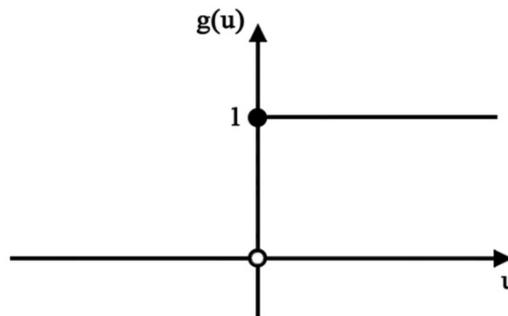


Figura 6 – Função de ativação degrau FONTE: Silva *et.al.*, 2010

- **Função linear:** também conhecida como função identidade. Esta função pertence ao grupo das funções totalmente diferenciáveis. Os valores de saída são iguais ao potencial de ativação {u} e sua expressão matemática é definida por:

$$g(u) = u \quad (2.4)$$

O gráfico da função linear é ilustrado na figura 7

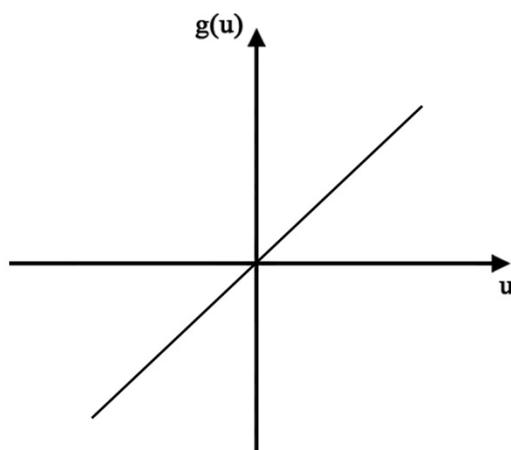


Figura 7 – Função de ativação linear FONTE: Silva *et.al.*, 2010

• **Função Logística:** pertencente ao grupo das funções totalmente diferenciáveis, a função logística assumirá valores reais entre zero e um. Matematicamente sua expressão é dada por:

$$g(u) = \frac{1}{1+e^{-\beta}} \quad (2.5)$$

β é uma constante real associada ao nível de inclinação da função logística em relação ao seu ponto de inflexão. Na medida em que β cresce, o gráfico da função logística tenderá a ser similar ao da função degrau, com a diferença dela ser diferenciável em todo o seu domínio. O gráfico dessa função é ilustrado na figura 8.

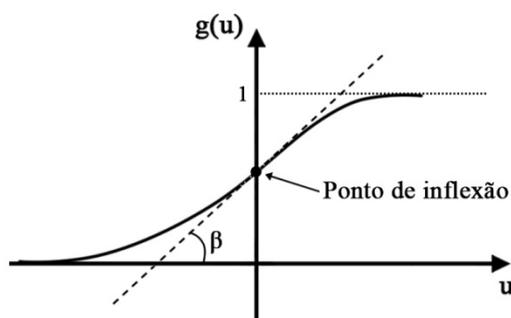


Figura 8 – Função de ativação logística FONTE: Silva *et.al.*, 2010

• **Função Tangente Hiperbólica:** Seu gráfico se comporta similar ao da função logística, porém assume valores reais entre -1 e 1. Faz parte também do grupo das funções totalmente diferenciáveis. Em notação matemática:

$$g(u) = \frac{1-e^{-\beta u}}{1+e^{-\beta u}} \quad (2.6)$$

assim como na função logística, β também está relacionado ao nível de inclinação da função tangente hiperbólica em relação ao seu ponto de inflexão. O gráfico dessa função é representado na figura 9:

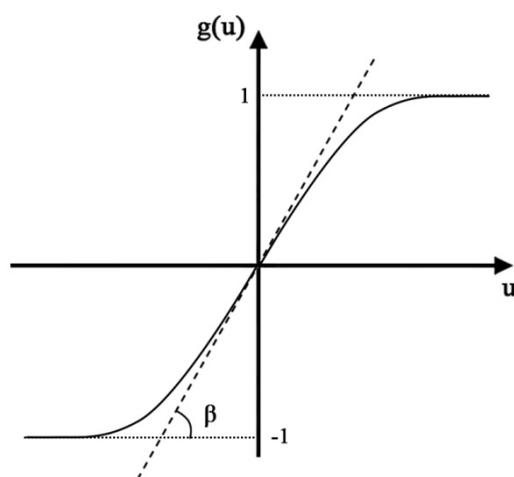


Figura 9 – Função de ativação tangente hiperbólica FONTE: Silva *et.al.*, 2010

É possível observar que as funções de ativação possuem valores de saída que diferem de uma para a outra. Assim, a decisão para a utilização de uma dessas funções varia dependendo da aplicação desejada.

2.1.7 Arquiteturas de rede

A arquitetura de uma rede neural artificial define a configuração da disposição dos neurônios e o direcionamento das conexões sinápticas. Em termos práticos, uma rede neural pode ser dividida em três partes: camada de entrada, camada intermediária ou oculta e camada de saída. A camada de entrada recebe os dados, sinais, características ou medições oriundas do meio externo. No geral são normalizadas com respeito as faixas de variações criadas pelas funções de ativação. A camada intermediária é responsável pelo processamento dos dados obtidos na camada de entrada, ou seja, seus neurônios realizam a extração das características relacionadas ao processo ou sistema a ser inferido. A camada de saída, composta também de neurônios produz e apresenta os resultados finais da rede. (Silva *et.al.*, 2010)

Haykin (2001) apresenta três classes de arquiteturas de rede: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes, que são descritas mais detalhadamente a seguir.

- **Redes alimentadas adiante com camada única**

Conhecida como redes *feedforward*, possui apenas uma camada de entrada de nós de fonte e uma camada de saída de neurônios, ou nós computacionais. É ilustrado na figura 10 um exemplo onde a rede possui quatro nós tanto na camada de entrada como na de saída. Esse tipo de rede recebe a nomenclatura de rede de camada única, pois apenas a camada de saída de nós computacionais é contada como camada, uma vez que na camada de entrada de nós de fonte não é realizada qualquer computação.

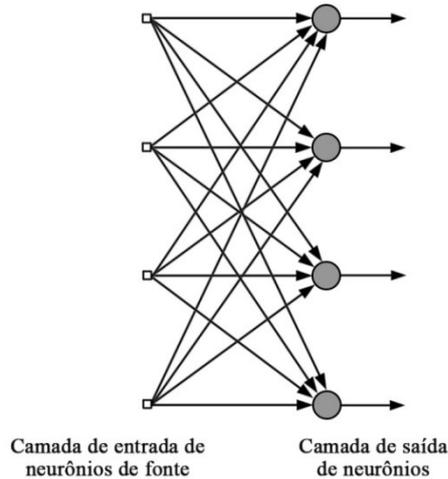


Figura 10 – Rede feedforward de camada única FONTE: Haykin, 2001

• **Redes alimentadas diretamente com múltiplas camadas**

Também conhecida como redes *feedforward* de múltiplas camadas, diferenciam-se da rede de camada única por possuírem uma ou mais camadas escondidas de nós computacionais. Os neurônios ocultos possuem notória habilidade de extrair melhor as características dos dados quando o tamanho da camada de entrada é grande.

Os nós de fonte da camada de entrada fornecem os sinais de entrada aos neurônios da segunda camada. Os sinais de saída da segunda camada são usados como entrada para os neurônios da terceira camada e esse processo é repetido para o restante da rede. A figura 11 apresenta uma rede neural *feedforward* de múltiplas camadas, com apenas uma camada escondida. É comum referir-se a rede da figura 11 como uma rede 10-4-2, uma vez que ela possui 10 neurônios de fonte, 4 neurônios ocultos e 2 neurônios de saída, além disso ela também é dita totalmente conectada, ou seja, cada um de seus nós de uma camada está conectado a todos os nós da camada seguinte.

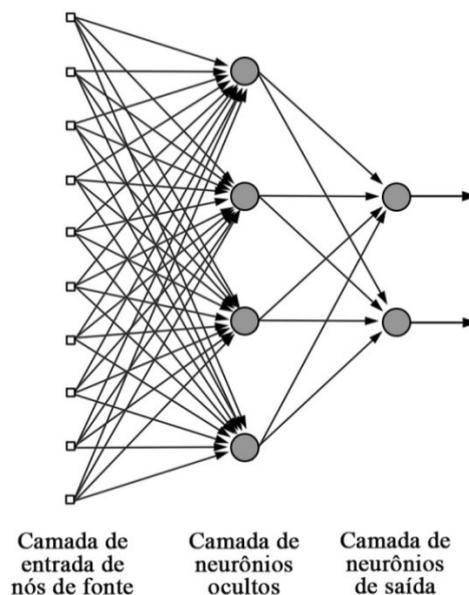


Figura 11 – Rede feedforward múltiplas camadas FONTE: Haykin, 2001

• Redes recorrentes

A principal diferença entre uma rede neural recorrente e uma rede neural alimentada adiante se dá ao fato de existir pelo menos um laço de realimentação, ou seja, as saídas dos neurônios são realimentadas para as entradas de outros neurônios. Uma rede recorrente pode conter tanto uma única camada de neurônios como uma ou mais camadas ocultas. Os laços de realimentação em uma rede influenciam bastante na capacidade de aprendizagem da rede e no seu desempenho.

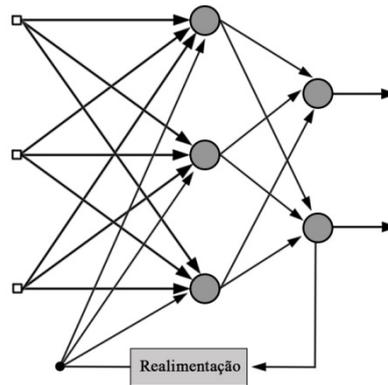


Figura 12 – Rede recorrente FONTE: adaptado de Silva *et.al.*, 2010

2.1.8 Tipos de aprendizado de RNAs

De acordo com Braga *et.al.*, (2000) as RNAs são capazes de aprender através de exemplos, ou seja, a partir de um conjunto de dados são capazes de extrair as características que o representam. Entende-se aprendizagem como o processo onde os parâmetros de uma RNA são ajustados no decorrer de uma forma continuada de estímulo pelo ambiente externo. Existem muitos métodos de treinamento de redes, dentre eles destacam-se: o aprendizado supervisionado e o aprendizado não supervisionado.

No método de treinamento não supervisionado, o processo de aprendizado acontece sem o acompanhamento de um supervisor ou professor. Assim sendo, são fornecidos para a rede apenas os dados de entrada, que por sua vez deve se auto-organizar reconhecendo as características existentes entre os elementos pertencentes ao conjunto total de amostras, a partir daí organiza os dados em diferentes subconjuntos que possuam similaridades, também conhecidos como clusters. O algoritmo de aprendizagem ajusta os pesos sinápticos e limiares dos neurônios da rede de maneira que leve a refletir esta representação internamente na própria rede. (Silva *et.al.*, 2010)

O método de aprendizado supervisionado é o mais comum no treinamento das RNAs. São fornecidos por um professor ou supervisor os dados de entrada e saída desejadas para a rede, com o intuito de encontrar uma ligação entre os pares de entrada e saída através do ajuste dos parâmetros da rede (figura 13).

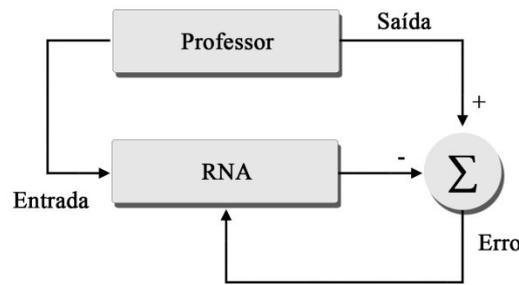


Figura 13 – Aprendizado supervisionado FONTE: adaptado de Braga *et.al.*, 2000

A saída fornecida pela rede é comparada a saída desejada, a partir desse momento ajusta-se os pesos sinápticos a fim de minimizar o erro. Assim é possível obter o erro $e_k(n)$ escrito como a diferença entre a saída desejada $d_k(n)$ e a saída calculada pela rede $y_k(n)$ (Haykin, 2001):

$$e_k(n) = d_k(n) - y_k(n) \quad (2.7)$$

onde n representa o instante de tempo discreto, ou seja, o passo de tempo de um processo iterativo envolvido no ajuste dos pesos sinápticos do neurônio k . Dessa forma, pequenas alterações nos pesos sinápticos são feitas a cada fase do treinamento. A forma genérica para a alteração dos pesos, que tem por objetivo minimizar o erro na próxima iteração ($n+1$) é obtida por:

$$w_{kj}(n + 1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (2.8)$$

onde $w_{kj}(n)$ é o peso da conexão do neurônio k com o neurônio j da camada anterior.

Pode-se entender $\Delta w_{kj}(n)$ como o ajuste a ser incrementado ao peso, assumindo assim um novo valor na iteração seguinte $w_{kj}(n + 1)$. É possível obter este ajuste através da minimização da função de custo:

$$E(n) = \frac{1}{2} \sum_k e_k^2(n) \quad (2.9)$$

A minimização desta função resulta na regra do delta ou também conhecida como regra de Widrow-Hoff. Segundo esta regra, considerando que η é a taxa de aprendizado, $e_k(n)$ o erro e x_j é a entrada da sinapse, o ajuste $\Delta w_{kj}(n)$ aplicado ao peso sináptico w_{kj} no passo de tempo n é calculado através da equação (Haykin, 2001):

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n) \quad (2.10)$$

2.1.9 Redes perceptrons de múltiplas camadas (MLP)

De acordo com a classificação de arquiteturas de redes expostas acima as redes perceptrons de múltiplas camadas, também conhecidas por *multilayer perceptron* ou simplesmente MLP, pertencem à classe de RNAs conhecida como *feedforward*. São caracterizadas pela existência de pelo menos uma camada intermediária (escondida) de neurônios, dessa forma uma rede MLP possui no mínimo duas camadas de neurônios (camada escondida e camada de saída). Seu treinamento é feito de forma supervisionada, além disso, são redes caracterizadas por sua vasta gama de aplicabilidade em diversas áreas do conhecimento, como por exemplo, reconhecimento de padrões, previsão de séries temporais, otimização de sistemas, aproximação universal de funções e identificação e controle de processos (Silva *et.al.*, 2010).

Uma rede do tipo MLP é formada por um conjunto de neurônios organizados em camadas, compreendendo uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída, conforme a figura 14. Os neurônios da camada de entrada estão conectados a todos os neurônios da camada intermediária, estes por sua vez, estão conectados a todos os neurônios da próxima camada e o processo se repete até a camada de saída. (Haykin, 2001)

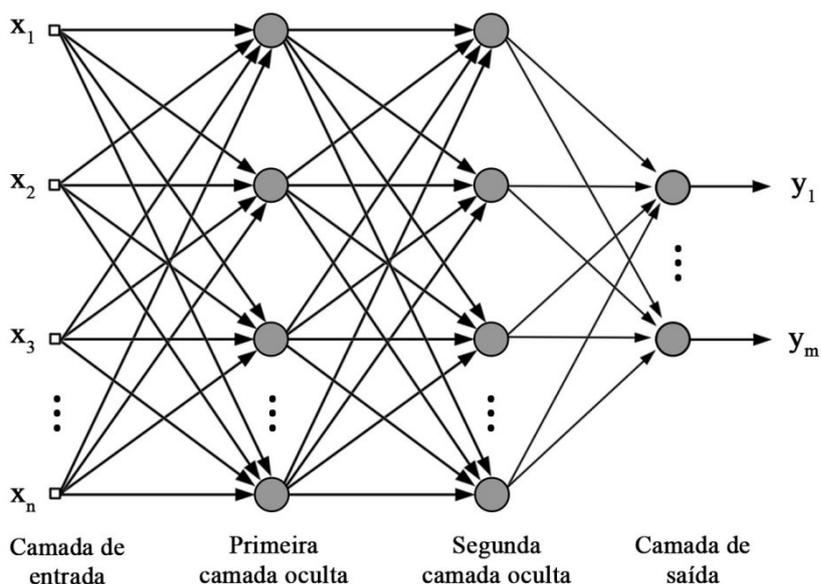


Figura 14 – Estrutura de uma rede do tipo MLP. FONTE: adaptado de Silva *et.al.*, 2010

De acordo com Haykin (2001), o modelo de neurônio proposto por McCulloch e Pitts fornecia apenas saídas binárias (zero ou um), já as redes do tipo MLP tem a capacidade de fornecer quaisquer saídas. O algoritmo de treinamento supervisionado mais popular das redes MLP é o algoritmo de retropropagação do erro, também conhecido como back-propagation.

2.1.9.1 Algoritmo back-propagation

O algoritmo back-propagation se divide em duas fases (Haykin, 2001):

- **Forward:** As entradas apresentadas a rede são propagadas através das camadas até a geração de uma saída, nessa etapa os pesos das sinapses são fixos.
- **Backward:** É calculada a diferença entre o valor estimado pela rede e o valor esperado, gerando um erro e a partir desse erro o ajuste dos pesos vai sendo realizado desde a camada de saída a entrada.

O algoritmo back-propagation é baseado na regra do delta, porém apresenta uma maneira de ajustar os pesos das sinapses de todas as camadas da rede neural e não somente da camada de saída. No treinamento deste algoritmo, a cada passo n , o sinal de erro pode ser calculado para cada neurônio k de saída da rede. Considerando K o conjunto de todos os neurônios da camada de saída de rede, pode-se então redefinir a função custo como o somatório dos K sinais de erro (Haykin, 2001; Guarnieri, 2006):

$$E(n) = \frac{1}{2} \sum_{k=1}^K e_k^2(n) \quad (2.11)$$

A alteração em cada peso de um neurônio k de saída, através do método de minimização do erro é dada pela derivada parcial de $E(n)$ em relação ao peso em questão, fazendo uso da regra da cadeia (Haykin, 2001; Guarnieri, 2006):

$$\Delta w_{kj}(n) = -\eta \frac{\partial E(n)}{\partial w_{kj}} = \eta \cdot e_k(n) \cdot \varphi'_k(v_k(n)) \cdot x_j(n) \quad (2.12)$$

onde η é a taxa de aprendizado do algoritmo de retropropagação que deve ser mantida entre 0 e 1, $\varphi'_k(v_k(n))$ é a derivada da função de ativação aplicada ao nível de atividade interna do neurônio e $x_j(n)$ é o valor de entrada de uma conexão do neurônio k . Pode-se reescrever a equação acima como:

$$\Delta w_{kj}(n) = \eta \delta_k(n) \cdot x_k(n) \quad (2.13)$$

onde $\delta_k(n)$ também conhecido como *gradiente local* é definido por:

$$\delta_k(n) = e_k(n) \cdot \varphi'_k(v_k(n)) \quad (2.14)$$

O erro cometido na camada de saída de rede é consequência dos erros dos neurônios das camadas ocultas e dessa forma, o sinal de erro deve ser retropropagado a fim que os pesos das camadas ocultas possam ser ajustados. Levando em consideração um neurônio oculto k , conectado a neurônios i da camada de saída, o algoritmo obtém o gradiente local por:

$$\delta_k(n) = \varphi'_k(v_k(n)) \cdot \sum_i \delta_i(n) w_{ik}(n) \quad (2.15)$$

Assim, calcula-se o gradiente local para um neurônio oculto k através do somatório dos gradientes locais de cada neurônio i da camada seguinte ponderados pelas ligações sinápticas que ligam cada neurônio i ao neurônio k . Através da equação 2.13 calcula-se o ajuste dos pesos das camadas ocultas com a diferença de que se utiliza $\delta_k(n)$ da equação 2.15.

Em termos práticos, o algoritmo back-propagation modifica os pesos de uma rede neural, a fim de encontrar um mínimo local da função de erro. Portanto, o gradiente da função de erro $\left(\frac{\partial E(n)}{\partial w_{kj}}\right)$ é calculado em relação aos pesos que são modificados indo na direção oposta das derivadas parciais até que um mínimo local seja alcançado. A figura 15 ilustra uma ideia básica do algoritmo para uma função de uma variável. (Günther e Fritsch, 2010)

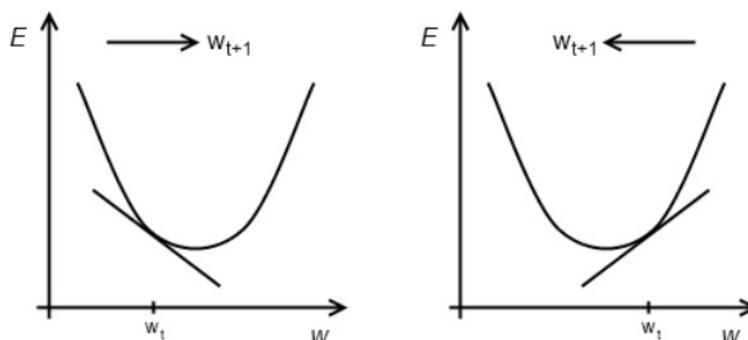


Figura 15 – Ideia básica do algoritmo para uma função de uma variável. FONTE: Günther e Fritsch, 2010

Braga *et.al.* (2000), destacam que para várias aplicações o algoritmo back-propagation é muito lento, inviabilizando o seu uso, pois seu desempenho piora sensivelmente para problemas mais complexos. Assim, foram propostas diversas modificações deste algoritmo com o objetivo de acelerar seu tempo de treinamento e melhorar seu desempenho, como por exemplo: *Quickprop*, *Rprop*, *Levenberg-Marquardt* e outros.

2.1.9.2 Algoritmo resilient back-propagation (Rprop)

O algoritmo de treinamento Rprop foi desenvolvido por Riedmiller e Braun (1993) com o propósito de oferecer uma ferramenta que levasse a rede neural a uma convergência mais rápida, além de ser um modelo mais robusto. O Rprop é um esquema de aprendizagem eficiente, pois a partir de informações do gradiente local, realiza uma adaptação direta da atualização dos pesos.

A principal diferença entre o Rprop em comparação as outras técnicas desenvolvidas, como o Back-propagation, se dá devido o processo de atualização dos pesos não ser influenciado pelo valor do gradiente, apenas o sinal da derivada é considerado para indicar a direção da atualização dos pesos. (Riedmiller, 1994).

Para alcançar esse objetivo, Riedmiller e Braun (1993) introduziram para cada peso um valor de atualização Δ_{ij} que determina o tamanho da atualização dos pesos sinápticos. Este valor adaptativo no decorrer do processo de treinamento evolui a partir da visão local da função de erro E , conforme a regra de aprendizagem:

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ * \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial w_{ij}} * \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ \eta^- * \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial w_{ij}} * \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (2.16)$$

Onde t é o número de épocas do treinamento e $0 < \eta^- < 1 < \eta^+$. Em outras palavras, a regra de aprendizagem funciona da seguinte maneira: toda vez que a derivada parcial que corresponde ao peso w_{ij} mudar seu sinal, significa que a última atualização foi muito grande e o algoritmo saltou sobre um mínimo local, daí o valor de atualização Δ_{ij} é reduzido pelo fator η^- . No caso da derivada manter o mesmo sinal, o valor de atualização é ligeiramente aumentado a fim de acelerar a convergência. Após o ajuste dos novos pesos, a própria atualização segue uma regra bem simples: se a derivada é positiva, ou seja, tornando o erro maior, o peso é reduzido pelo seu valor de atualização e se a derivada é negativa, o valor de atualização torna-se positivo, conforme mostra a regra a seguir (Riedmiller e Braun 1993):

$$\Delta w_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)}, & \text{se } \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}^{(t)}, & \text{se } \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (2.17)$$

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + \Delta w_{ij}^{(t)} \quad (2.18)$$

Contudo, há uma exceção no caso da derivada parcial mudar de sinal, ou seja, se o passo anterior for muito grande e o mínimo for perdido, a atualização do peso anterior é revertida:

$$\Delta w_{ij}^{(t)} = -\Delta w_{ij}^{(t-1)}, \text{ se } \frac{\partial E^{(t-1)}}{\partial w_{ij}} * \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \quad (2.19)$$

Devido a essa etapa, a derivada deve alterar novamente o seu sinal para que no passo seguinte não ocorra outra mudança no valor de atualização, em outras palavras, não deve haver adaptação do valor de atualização na etapa seguinte para evitar uma dupla punição nesse valor. Uma maneira de evitar que isso ocorra pode ser feita definindo $\frac{\partial E^{(t-1)}}{\partial w_{ij}} = 0$ na regra de adaptação Δ_{ij} acima. Os valores de atualização e os pesos são alterados toda vez que o conjunto de treinamento é apresentado à rede, aprendendo por época (Riedmiller e Braun 1993).

Os parâmetros utilizados pelo Rprop são Δ_0 , Δ_{min} , $\Delta_{máx}$, η^- e η^+ , onde:

- Δ_0 é o valor inicial de atualização de Δ_{ij} . Ele determina diretamente o tamanho da primeira etapa de ajuste dos pesos sinápticos, é preferencialmente escolhido numa proporção razoável ao tamanho dos pesos iniciais. A bibliografia sugere que uma boa escolha pode ser $\Delta_0 = 0,1$, afirma ainda que a escolha deste parâmetro não é de todo crítica e mesmo para valores muito maiores ou muito menos de Δ_0 a convergência é rápida.

- Δ_{min} é o limite inferior que o valor de atualização Δ_{ij} pode assumir. Assim, por sugestão da literatura, assume-se $\Delta_{min} = 1e^{-6}$.
- $\Delta_{máx}$ é o limite superior que o valor de atualização Δ_{ij} pode assumir. Serve para evitar que aconteça uma grande variação nos pesos. $\Delta_{máx} = 50$ como recomenda a bibliografia.
- η^- é o fator de decrescimento. Caso o algoritmo salte um ponto de mínimo, significa que o valor de atualização anterior era muito grande. Por não saber exatamente o ponto em que o mínimo foi ultrapassado, em média é um bom palpite reduzir o valor de atualização pela metade, ou seja, $\eta^- = 0,5$.
- η^+ é o fator de acréscimo. Este fator deve ser grande o suficiente para que haja um crescimento rápido do valor de atualização, por outro lado se for muito grande, o processo de aprendizagem pode ser consideravelmente perturbado. Assim baseados em experimentos, fixou-se esse valor em $\eta^+ = 1,2$.

Pequenas variações desses valores não melhoraram nem deterioraram o tempo de convergência, portanto com o intuito de tornar a escolha de parâmetros mais simples, os mesmos foram fixados nos valores acima citados. Uma das principais vantagens do Rprop reside no fato de que, para muitos problemas não é necessário fazer a escolha dos parâmetros a fim de obter ótimos tempos de convergência ou pelo menos bem próximo do tempo ótimo.

Para facilitar a visualização do processo de convergência do algoritmo, Silva *et.al.* (2010) apresenta uma ilustração do mecanismo de convergência do método Rprop, onde os passos (I), (II), (III) e (V) implicam em incrementos positivos no valor de atualização, devido as variações dos sinais do gradiente também serem positivos; por outro lado os passos (IV), (VI) e (VII) implicam em incrementos negativos, em virtude das variações de sinais serem igualmente negativas.

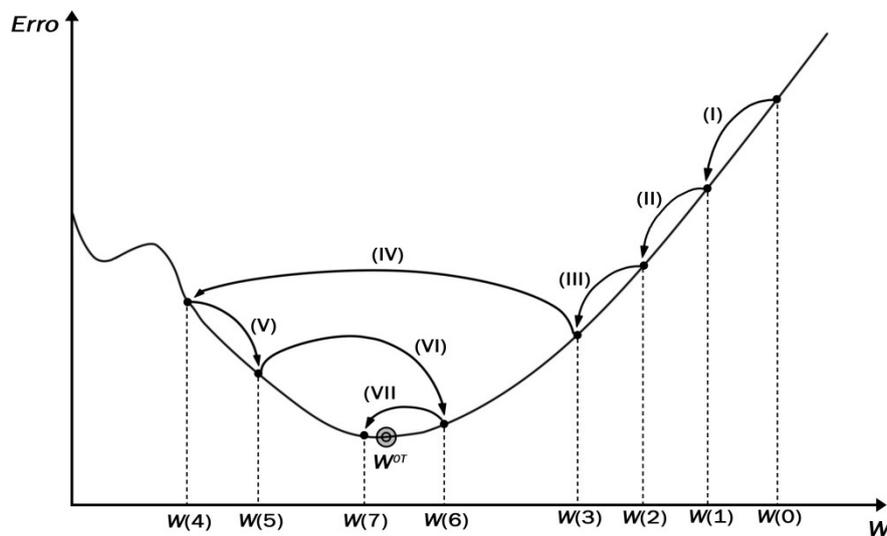


Figura 16 – Mecanismo de convergência do método Rprop FONTE: adaptado de Silva *et.al.*, 2010

2.2 Regressão Linear

A Regressão é um método que busca investigar a relação entre variáveis de problemas de diversas áreas do conhecimento. Em termos práticos, tal método procura aferir a influência de uma variável explicativa X sobre o valor esperado de uma variável resposta Y . Dentre os modelos de Regressão, os mais comuns são o modelo de Regressão Linear Simples e o modelo de Regressão Linear Múltipla. No primeiro caso, trata-se de um modelo que busca relacionar apenas uma variável explicativa X com a variável resposta Y , já no segundo caso, objetiva-se relacionar a variável resposta Y com mais do que uma variável explicativa X (Silva, 2016).

2.2.1 Regressão Linear Simples (RLS)

Neste método busca-se criar um modelo matemático que relacione a variável resposta Y (também conhecida como variável dependente) com a variável explicativa X (ou variável independente). O intuito é analisar e verificar como o valor esperado da variável resposta $E[Y]$, é influenciado de acordo com as alterações em Y conforme a equação 2.20 (Silva, 2016).

$$E[Y_i] = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (2.20)$$

Onde β_0 representa o coeficiente linear, também denominado intercepto, β_1 representa o coeficiente angular ou de regressão, i denota a referência de cada observação onde $i = 1, 2, \dots, n$ e ε_i corresponde o desvio entre cada observação real Y_i e o valor correspondente estimado pelo modelo $E[Y_i]$. ε_i são erros que possuem o valor médio zero e variância σ^2 .

Para estimar os parâmetros β_0 e β_1 utiliza-se o método dos mínimos quadrados, que objetiva a minimização da soma dos quadrados dos desvios ε_i (S), conforme a equação 2.21.

$$S = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \quad (2.21)$$

A partir de uma amostra de n pares de valores (X_i, Y_i) , busca-se determinar as estimativas $\hat{\beta}_0$ e $\hat{\beta}_1$ minimizando a equação 2.21 em relação aos parâmetros β_0 e β_1 . Dessa forma, o primeiro passo é obter as derivadas parciais com respeito a cada parâmetro (equações 2.22 e 2.23).

$$\frac{\partial S}{\partial \beta_0} = -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) \quad (2.22)$$

$$\frac{\partial S}{\partial \beta_1} = -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) x_i \quad (2.23)$$

O passo seguinte é encontrar os pontos críticos dessa função de duas variáveis e para isso, basta igualar a zero as expressões das derivadas parciais, ou seja:

$$-2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0 \quad (2.24)$$

$$-2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) x_i = 0 \quad (2.25)$$

Daí é possível obter o sistema:

$$\begin{cases} n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_i = \sum_{i=1}^n y_i \\ \hat{\beta}_0 \sum_{i=1}^n x_i + \hat{\beta}_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i y_i \end{cases} \quad (2.26)$$

E assim é possível obter que:

$$\hat{\beta}_0 = \frac{\sum_{i=1}^n y_i}{n} - \frac{\hat{\beta}_1 \sum_{i=1}^n x_i}{n} \Leftrightarrow \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad (2.27)$$

Onde \bar{x} e \bar{y} são as médias das variáveis X e Y. A partir daí obtém-se $\hat{\beta}_1$:

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.28)$$

$\hat{\beta}_0$ e $\hat{\beta}_1$ são conhecidos como estimadores dos mínimos quadrados pois são a solução da reta ajustada pelo método dos mínimos quadrados obtida pela equação:

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X \quad (2.29)$$

A fim de garantir análises precisas sobre as inferências realizadas, deve-se estimar a variância residual σ^2 , que pode ser calculada por:

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n \varepsilon_i^2}{n-2} \quad (2.30)$$

ou seja, a variância residual se dá através da soma dos quadrados dos resíduos dividido pelos graus de liberdade (obtido por meio da subtração dos n casos e a quantidade de parâmetros do modelo linear, que no caso é n-2), assumindo que os erros são independentes e a média é igual a zero. $\hat{\sigma}^2$ também é conhecido como Quadrado Médio dos Erros (QME), dado pela seguinte equação:

$$\begin{aligned} QME &= \sum_{i=1}^n (y_i - \bar{y})^2 - \frac{(\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}))^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \\ QME &= \frac{\sum_{i=1}^n (y_i - \bar{y})^2 - \hat{\beta}_1 \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-2} \end{aligned} \quad (2.31)$$

2.2.1 Regressão Linear Múltipla (RLM)

Neste método objetiva-se criar um modelo matemático de previsão e estimação de valores de uma variável resposta Y através de um conjunto de variáveis explicativa X_j (ou variáveis regressoras) com j=1, 2,..., k. (Rawlings *et.al.*, 1998; Silva, 2016; Azzi, 2018) A equação geral de Regressão Linear Múltipla é dada pela equação 2.31.

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon_i \quad (2.31)$$

Onde Y é a variável dependente, β_0, \dots, β_k são os coeficientes de regressão, x_1, \dots, x_k são as variáveis regressoras (ou independentes) e ε_i são os erros.

A equação 2.31 pode ser representada também na forma matricial:

$$Y = X\beta + \varepsilon \quad (2.32)$$

onde

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix}, \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \text{ e } \varepsilon = \begin{bmatrix} \varepsilon_0 \\ \varepsilon_1 \\ \vdots \\ \varepsilon_k \end{bmatrix}$$

Dessa forma Y representa a matriz coluna das n respostas, X representa a matriz cujas linhas contém os valores das variáveis independentes, β é a matriz coluna dos coeficientes de regressão e ε representa a matriz coluna dos erros.

Assim como no modelo de Regressão Linear Simples, para estimar os coeficientes de regressão, usa-se também o método dos mínimos quadrados, que não serão aprofundados no presente trabalho, visto que busca-se focar apenas nos aspectos mais relevantes e salientar as informações pertinentes à compreensão do mesmo. Maiores informações e detalhes podem ser encontrados em Rawlings *et.al.* (1998) e Silva (2016).

O parâmetro utilizado para avaliar um modelo de regressão é o Coeficiente de Determinação (R^2).

2.3 Radiação Solar

A energia solar é praticamente a única fonte de energia que influencia os movimentos atmosféricos e os vários processos nas camadas da atmosfera e da superfície da crosta terrestre. O sol é composto primariamente de Hidrogênio (75%) e Hélio (25%). Considerando a escala de tempo da vida do planeta Terra, a energia solar é uma fonte inesgotável, porém a rigor teórico essa fonte de energia não é considerada renovável. A taxa de energia emitida pelo Sol é quase constante há bilhões de anos e sua potência atual é da ordem de $3,86 \cdot 10^{26} W$. A temperatura na superfície do sol é da ordem de $5505^\circ C$. A energia solar é tida como uma das alternativas energéticas mais promissoras para os desafios do novo milênio (Pereira *et al.*, 2017; Kondratyev, 1969).

2.3.1 Conceitos básicos

A energia proveniente do sol cobre uma faixa contínua de comprimentos de onda (λ) do espectro eletro magnético, como ilustra a figura 17. Aproximadamente 81% da energia que chega ao sistema Terra-Atmosfera compreende uma faixa de comprimentos de onda que vai do visível ao infravermelho-próximo. Ao analisar a transferência de energia na atmosfera, a

porção mais significativa do espectro varia do ultravioleta ao infravermelho próximo (Pereira *et al.*, 2017; Peixoto e Oort, 1992).

Pode-se dividir aproximadamente o total de energia emitida pelo sol em 43% para a radiação visível, 49% para a radiação na faixa do infravermelho-próximo, 7% para radiação ultravioleta e menos de 1% da radiação solar é emitida com raios X, gama e ondas de rádio (Fiorin *et al.* 2011).

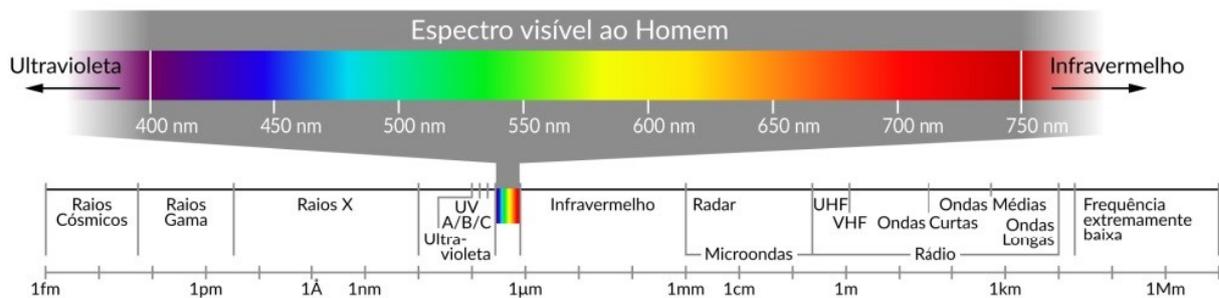


Figura 17 – Espectro da radiação solar com detalhamento da faixa visível humana.
 FONTE: Pereira *et al.* 2017

De acordo com Pereira *et al.* (2017) em um ponto qualquer da superfície da Terra, a quantidade de energia solar incidente e a duração do dia apresentam variabilidade temporal caracterizada por dois ciclos: o ciclo anual que é uma consequência da inclinação do eixo axial da Terra com relação ao plano orbital do planeta ao redor do Sol em 23,45 graus e o ciclo diário que está inerentemente associado as estações do ano.

Entende-se por transferência radiativa o processo onde o sistema Terra-Atmosfera interage e atenua a intensidade da radiação solar por toda a extensão do seu percurso até atingir a superfície terrestre. Uma propriedade fundamental da radiação eletromagnética é que ela pode transportar energia. A taxa de transferência de energia pela radiação eletromagnética é conhecida como fluxo radiante, expresso em joules por segundo ($J \cdot s^{-1}$) ou Watts (W). A densidade do fluxo radiante é o fluxo radiante atravessando uma unidade de área, expressa em watts por metro quadrado ($W \cdot m^{-2}$). A Irradiância é a densidade do fluxo radiante incidente numa área (Pereira *et al.*, 2017; Kidder e Vonder Haar, 1995).

A atmosfera é composta por uma combinação de aerossóis (particulados) e gases atmosféricos, dentre eles os predominantes são o Nitrogênio (N_2) e Oxigênio (O_2) que constituem 78,08% e 20,95% da camada atmosférica respectivamente, 0,93% corresponde ao Argônio (Ar) e os demais constituintes compreendem o percentual restante, como o vapor d'água (H_2O), o dióxido de carbono (CO_2), o Ozônio (O_3), entre outros. (Wallace e Hobbs, 2006).

Após adentrar a atmosfera terrestre, a radiação solar interage com esses constituintes atmosféricos e sofre processos físicos de absorção e espalhamento (figura 18). No processo de absorção as moléculas de gases adquirem a energia incidente que por sua vez transformam-se em movimento molecular interno e resulta no aquecimento da atmosfera, ocorre com moléculas de vapor d'água (H_2O), dióxido de carbono (CO_2), Oxigênio (O_2) e Ozônio (O_3). O espalhamento, por sua vez, é um processo físico onde uma onda eletromagnética perde energia quando encontra uma molécula de gás ou particulado ao longo do seu percurso. Um exemplo de espalhamento da luz visível por gases atmosféricos é a cor azul do céu, acontece quando a radiação se depara com partículas de dimensões muito menores que seu

comprimento de onda, mais especificamente quando o espalhamento é inversamente proporcional à 4ª potência do comprimento de onda ($E_{\lambda_s} \sim 1/\lambda^4$), também conhecido como espalhamento Rayleigh (Fiorin *et al.*, 2011; Pereira *et al.*, 2017).

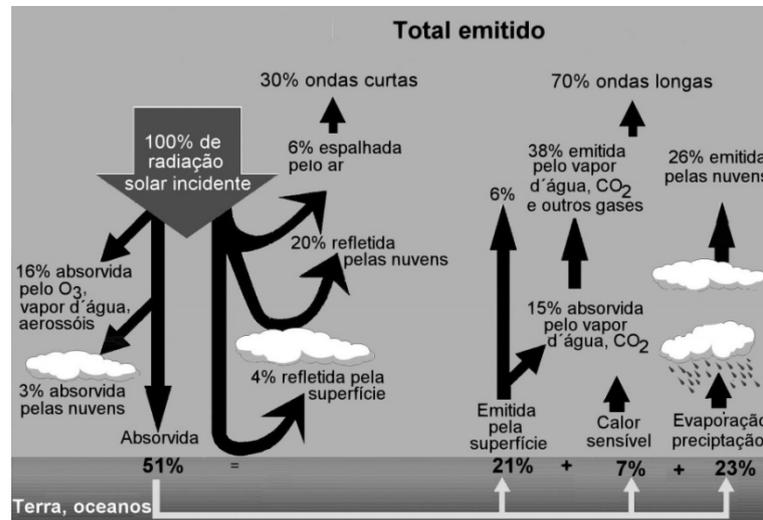


Figura 18 – Processos radiativos com constituintes atmosféricos. FONTE: Fiorin *et al.* 2011

O espectro eletromagnético da radiação solar ao longo do seu percurso pela atmosfera terrestre é alterado em virtude dos processos de espalhamento e absorção. Na figura 19 é possível observar o espectro contínuo de radiação eletromagnética emitido pelo Sol quando atinge o topo da atmosfera e a superfície terrestre no nível do mar, evidenciando a diminuição da radiação pelos processos radiativos na atmosfera. Através da figura é possível notar que alguns comprimentos de onda da radiação solar são completamente atenuados de forma que não incidem na superfície terrestre. Também é mostrada para fins de comparação uma curva de emissão de um corpo negro 6000K.

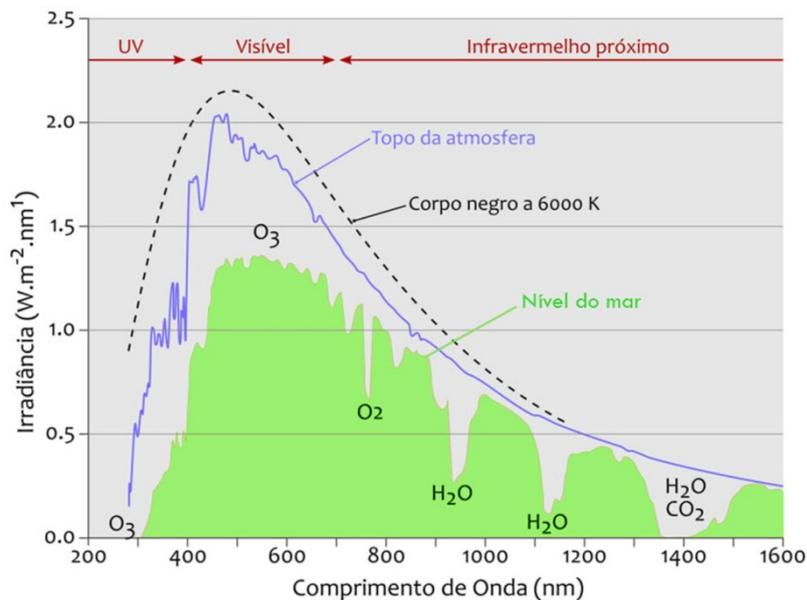


Figura 19 – Comparação do espectro eletromagnético da radiação solar. FONTE: adaptado de Pereira *et al.*, 2017

A irradiância solar (W/m^2) incidente em uma superfície é formada por suas componentes:

- **Direta:** parcela da radiação solar que não sofreu os processos radiativos de absorção e espalhamento na camada atmosférica.
- **Difusa:** parcela da radiação solar que sofreu os processos radiativos de absorção e espalhamento na camada atmosférica.

Segundo Pereira *et al.* (2017) as componentes da irradiância solar (figura 20) podem ser definidas como:

- **Irradiância extraterrestre (G_0):** conhecida como irradiância no topo da atmosfera ou G_{TOA} , é a taxa de energia incidente por unidade de área em um plano horizontal imaginário no topo da atmosfera terrestre.
- **Irradiância direta normal (G_n):** é a taxa de energia por unidade de área vinda diretamente do sol que incide na superfície perpendicularmente.
- **Irradiância difusa horizontal (G_{dif}):** é a taxa de energia que incide sobre uma superfície horizontal por unidade de área, proveniente do espalhamento do feixe solar direto pelos constituintes atmosféricos (nuvens, material particulado, moléculas, entre outros)
- **Irradiância direta horizontal (G_{dir}):** é a taxa de energia por unidade de área do feixe solar direto numa superfície horizontal.
- **Irradiância global horizontal (G):** é a taxa de energia total por unidade de área que incide numa superfície horizontal, ou seja, é a soma dada por $G = G_{\text{dif}} + G_{\text{dir}}$.
- **Irradiância no plano inclinado (G_i):** é a taxa de energia total por unidade de área que incide num plano inclinado na latitude do local em relação à superfície terrestre.

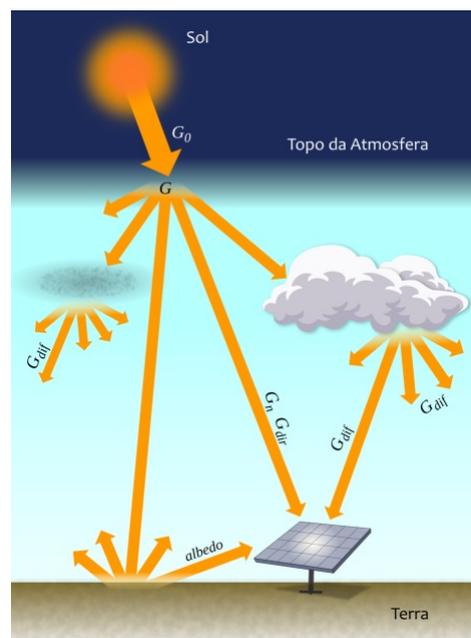


Figura 20 – Componentes da irradiância solar. FONTE: Pereira *et al.*, 2017

2.3.2 Sensores para registro de radiação solar

Além dos processos radiativos que ocorrem na camada atmosférica, a radiação solar que incide na superfície terrestre varia de acordo com os ciclos anual e diário. Assim, faz-se necessário investir em equipamentos que sejam capazes detectar todas essas variações. Pereira *et al.* (2017) apresenta três tipos de sensores:

- **Piranômetro de termopilha:** instrumento designado a mediar a irradiância solar por meio de uma termopilha que converte energia térmica em energia elétrica. Este equipamento é o instrumento com menor incerteza para medir a radiação solar nos dias atuais e dependendo de sua classificação, apresenta desvios menores que 1%. Este tipo de sensor foi utilizado para a aquisição dos dados do presente estudo e o aparelho da estação Ecologia Agrícola pode ser visualizado na figura 21:



Figura 21 – Piranômetro de termopilha da estação Ecologia Agrícola. FONTE: Acervo pessoal.

- **Piranômetro de fotodiodo:** este tipo de sensor é menos preciso que o piranômetro de termopilha, em contra partida, são mais robustos e apresentam menor custo. Este equipamento converte diretamente a radiação solar em corrente elétrica de acordo com a irradiância solar incidente através de uma célula semicondutora (fotodiodo). Pode ser visualizado na figura 22:



Figura 22 – Piranômetro de fotodiodo de silício. FONTE: Pereira *et al.*, 2017

- **Pirheliômetro:** é um radiômetro que utiliza o mesmo princípio de medida da radiação solar utilizado no piranômetro de termopilha, com a diferença de que apenas a componente direta normal da radiação solar (G_n) é capturada por este sensor e para isso, deve ser conectado a um sistema rastreador solar a fim de sempre estar direcionado para o Sol.



Figura 23 – Pirheliômetro. FONTE: Pereira *et al.*, 2017

Segundo Pereira *et al.* (2017), instrumentos de alta qualidade em uma estação solarimétrica podem ter grande exatidão em suas medições se instalados, operados e mantidos conforme as recomendações do fabricante e os procedimentos indicados pelas normatizações WMO e ISO. Caso as instalações e os procedimentos de operação estejam fora do adequado, suas medições podem apresentar incertezas maiores que a de equipamentos de qualidade inferior.

2.3.3 Aproveitamento do potencial fotovoltaico no Brasil

O Brasil é um país que é bastante propício para o aproveitamento de recursos energéticos solares. Com o passar dos anos a crescente demanda por energia elétrica tem alterado o perfil de consumo e demanda no Brasil. A maior demanda por energia encontra-se nos meses e horários cuja disponibilidade de radiação solar é mais propícia para o aproveitamento de geração fotovoltaica (Pereira *et al.*, 2017).

De acordo com Silva (2015) governo brasileiro tem buscado incentivar o aproveitamento e fornecer benefícios para o uso dessa fonte de energia, destacam-se entre eles:

- Programa Luz para Todos, onde painéis solares são instalados em comunidades que não têm acesso à energia elétrica.
- Descontos na Tarifa de Uso de Sistemas de Transmissão e de Distribuição, até dezembro de 2017, foram disponibilizados descontos de 80% para empreendimentos onde a potência injetada nos sistemas de transmissão ou distribuição fosse menor ou igual a 30.000 kW e a partir de janeiro de 2018 dispõe 50% de desconto a partir do 11º ano de operação da usina solar.

- Venda Direta a Consumidores Especiais, ou seja, com carga entre 500 kW e 3.000 kW¹¹. Permite a comercialização da energia elétrica proveniente de fonte solar ou de outras fontes alternativas para esse segmento de consumidores e estes por sua vez, ao adquirir tal energia são beneficiados com descontos.
- Redução de Imposto de Renda para projetos de setores prioritários implantados nas áreas de atuação da Superintendência do Desenvolvimento da Amazônia (SUDAM), da Superintendência do Desenvolvimento do Nordeste (SUDENE), e da Superintendência do Desenvolvimento do Centro-Oeste (SUDECO).
- Sistema de Compensação de Energia Elétrica para Microgeração e Minigeração Distribuídas para empreendimentos com potencia máxima de 1.000 kW (1MW) denominado de *net metering*. Instituído pela Resolução Normativa nº 482, de 17 de abril de 2012 da Agência Nacional de Energia Elétrica (ANEEL), contanto que sejam obedecidos os procedimentos técnicos estabelecidos pela ANEEL, os consumidores poderão fornecer energia para a rede da distribuidora na qual estão conectados. Os consumidores poderão abater a energia injetada daquela consumida, assim pagarão apenas a diferença entre o consumido e o injetado para as distribuidoras.

Essas regras estabelecidas pela ANEEL para micro e minigeração distribuída possibilitou o mecanismo de compensação de energia, onde um telhado solar pode ser conectado na rede elétrica pública e fornecer o excedente na rede elétrica como se ela fosse uma bateria de capacidade infinita, acumulando créditos a serem compensados em kWh. Esses créditos de energia injetados na rede elétrica têm validade de 60 meses para serem compensados. Em março de 2016, a ANEEL estendeu a abrangência dos telhados solares para os conceitos de condomínio, consórcio, cooperativa e também autoconsumo remoto. Dessa forma, quem mora em apartamento e não tem um telhado para instalar painéis solares pode gerar eletricidade solar em outro local de sua propriedade e utilizar os créditos de energia gerados em seu apartamento na cidade, uma vez que esteja dentro da área de concessão da distribuidora (Pereira *et.al.*, 2017).

No Brasil, a geração distribuída de energia solar fotovoltaica começou a avançar de fato após a implantação do sistema *net metering*. Houve um grande crescimento do número de unidades consumidoras com painéis fotovoltaicos a partir de 2014, atingindo um total de 8.818 e 67 MWp de capacidade instalada até fevereiro de 2017, conforme mostra a figura 24 (Nascimento, 2017)



Figura 24 – Unidades consumidoras com geração solar fotovoltaica. FONTE: Nascimento, 2017

Campanhas de esclarecimento aos consumidores sobre os benefícios de instalação da micro e minigeração distribuída tem sido realizadas. A ANEEL publicou o “Caderno Temático de Mini e Microgeração Distribuída”, objetivando o esclarecimento de condições ao acesso de micro e minigeradores, demonstrar e exemplificar também o mecanismo de compensação e faturamento da energia gerada. (Nascimento, 2017)

Considerando o potencial fotovoltaico do Brasil, o aproveitamento desta fonte de energia ainda está aquém se comparado a outros países que não são tão favoráveis ao aproveitamento deste recurso. Analisando a matriz elétrica brasileira, observa-se que ainda existe um longo caminho a ser percorrido para que a energia solar ocupe uma parcela significativa desta matriz.

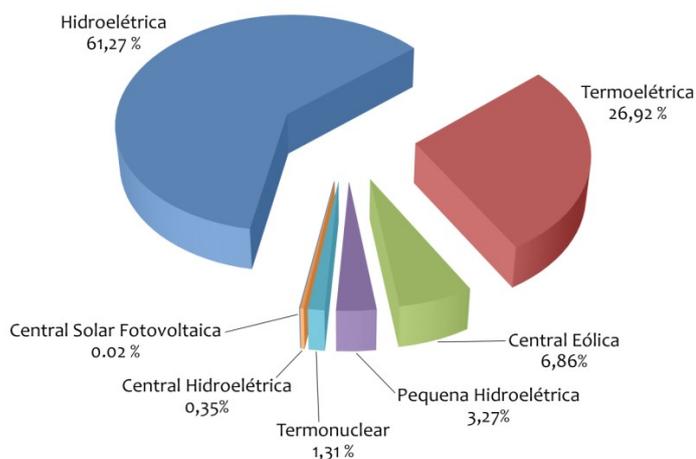


Figura 25 – Matriz elétrica brasileira em maio de 2017. FONTE: Pereira *et.al.*, 2017

3 MATERIAIS E MÉTODOS

É possível prever a radiação solar incidente em um instante futuro desde que sejam conhecidas as estimativas das condições atmosféricas no respectivo instante, visto que a incidência de radiação solar na superfície é modelada por tais condições (Guarnieri, 2006). Para isso faz-se necessário analisar minuciosamente cada fase do processo de obtenção e manipulação dos dados disponíveis, bem como esquematizar estrategicamente todos os passos do desenvolvimento da metodologia a fim de que o objetivo seja alcançado. Assim, o propósito do presente capítulo é descrever as etapas que foram realizadas no trabalho proposto, desde a obtenção e preparação dos dados aos parâmetros de avaliação do desempenho dos modelos.

3.1 Obtenção dos Dados

3.1.1 Sobre o INMET

A área de estudo e investigação da pesquisa compreende os dados obtidos do Instituto Nacional de Meteorologia (INMET). Espalhadas pelo Brasil, o INMET conta com 201 Estações Meteorológicas Convencionais e 584 Estações Meteorológicas Automáticas (EMA), destas 26 estão localizadas no estado do Rio de Janeiro. É a rede de coleta de dados de maior abrangência no território brasileiro (Pereira *et al.*, 2017).

A estação selecionada para o levantamento de dados do presente estudo faz parte da rede de Estações Meteorológicas Automáticas (EMA), a estação Ecologia Agrícola (A601), situada no município de Seropédica (Latitude: -22.75°, Longitude: -43.68°, Altitude: 35 metros) localizada no estado do Rio de Janeiro (RJ).

A cada minuto a EMA coleta informações meteorológicas como umidade, precipitação, temperatura, direção, velocidade e rajada dos ventos, pressão atmosférica e radiação solar. Estes dados são integralizados a cada hora e também são transmitidos por meio de telefonia celular ou satélite para a sede do INMET em Brasília. Por meio de um controle de qualidade, os dados são validados e armazenados em um banco de dados para posteriormente serem disponibilizados gratuitamente, em tempo real no site do INMET. (BRASIL, 2011)

Cada EMA deve ser instalada em uma área de no mínimo 50m², fechada com cerca de tela metálica de 14x18 metros e deverá ser gramada. O espaço utilizado pela estação requer que não tenha qualquer tipo de obstrução, seja natural ou não (ex.: prédios). Para garantir a operacionalidade do sistema ao longo dos anos, são realizados convênios com instituições parceiras de caráter permanente, estas por sua vez assumem algumas responsabilidades sobre as estações, como por exemplo, garantir a segurança do patrimônio, manutenção da área, entre outras. A manutenção dos equipamentos é feita por técnicos do INMET regularmente. Na figura 26 é apresentada a estação Ecologia Agrícola de onde foram extraídos os dados para o presente estudo e na figura 27 é apresentado o croqui do cercado das estações.

É possível observar as características de aquisição dos parâmetros na EMA do INMET descritas no Atlas Rio Solar (2016) através da tabela 2:

Tabela 2 – Características de aquisição dos parâmetros nas EMAs do INMET

Parâmetro	Tipo de medição	Período de amostragem, s	Valor registrado
Temperatura do Ar	Analógica	5	Média de 1 minuto
Temperatura do Ponto de Orvalho	Analógica	5	Média de 1 minuto
Umidade Relativa do Ar	Analógica	5	Média de 1 minuto
Pressão Atmosférica do Ar	Digital	5	Média de 1 minuto
Velocidade do Vento	Digital	0,25	Máxima média móvel de 3 s cada 10 min
Direção do Vento	Digital	0,25	Máxima média móvel de 3 s cada 10 min
Intensidade da Rajada do Vento	Digital	0,25	Máxima média móvel de 3 s cada 10 min
Irradiância Solar	Analógica	5	Média de 1 minuto
Precipitação acumulada	Digital	10	Soma cumulativa

No interior do cercado tem um mastro metálico de 10 metros de altura, protegido por para-raios e aterrado eletricamente (malha de cobre), nele são fixados os sensores e demais instrumentos. Ainda dentro do cercado, mas não fixados ao mastro, tem os aparelhos para as medições de chuva (pluviômetro) e radiação solar (piranômetro).

Todas as Estações Meteorológicas Automáticas possuem um sub-sistema que é responsável pelo fornecimento de energia para o funcionamento das mesmas, o que as tornam autossustentáveis e independentes de energia elétrica externa.



Figura 26 – Estação Ecologia Agrícola FONTE: acervo pessoal

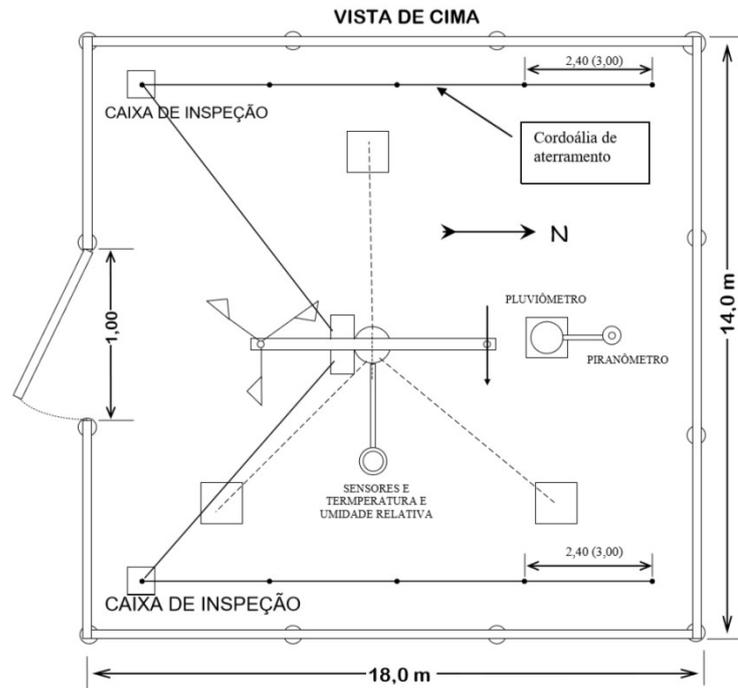


Figura 27 – Croqui do cercado das estações. FONTE: BRASIL, 2011

3.2 Conjunto de Dados

Os dados foram selecionados no período de 01 de Maio de 2017 a 31 de Janeiro de 2019, no horário compreendido entre 10h e 20h (hora UTC), devido a corresponder a um período significativo de incidência de radiação solar.

Como citado anteriormente, as informações meteorológicas da EMA são coletadas por minuto e estes dados são integralizados a cada hora. A partir destes dados, depois da seleção dos horários de interesse para o presente estudo, foram obtidas através da formação de rotinas computacionais as médias diárias de cada uma das variáveis. Optou-se por calcular as médias diárias para evitar a ocorrência de grandes erros, visto que isso ocorreria caso fossem utilizadas todas as medições horárias coletadas.

Após a obtenção das médias diárias os dados foram normalizados a fim de melhorar a eficiência do treinamento da rede. Dessa forma, tanto as variáveis de entrada como as de saída assumem valores entre 0 e 1. É calculado através da equação (Perboni *et.al.*, 2014):

$$x_{norm} = \frac{x_0 - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

Onde: x_{norm} é a variável normalizada, x_0 a variável original, x_{max} o valor máximo observado entre as variáveis e x_{min} o valor mínimo observado entre as variáveis.

Na tabela 3 é possível visualizar o resumo dos dados que foram utilizados pelo modelo, e também um exemplo de um dos conjuntos de treinamento e teste utilizados. Realizadas essas etapas, os dados estavam aptos para serem utilizados pelas redes neurais.

Tabela 3 – Resumo do conjunto de dados e de um dos subconjuntos de treinamento e teste

		Radiação	Temp_Inst.	Temp_Max.	Temp_Min.	Umi_Inst.	Umi_Max.	Umi_Min.	Pto. Orv_Max.	Pto. Orv_Min.	Vel_vento
Dados	Mínimo	146,9	17,36	17,55	16,94	26,27	29,45	24,55	9,491	7,745	0,6364
	1º Quartil	1049,8	23,42	24,02	22,36	52,18	57,55	49,09	16,309	14,691	2,0000
	Mediana	1440,2	26,18	26,87	25,23	61,91	66,73	58,45	18,709	17,218	2,6727
	Média	1480,0	26,26	26,89	25,27	62,00	66,52	58,97	18,438	16,909	2,7022
	3º Quartil	1976,8	28,78	29,59	27,75	71,09	75,27	67,91	20,700	19,282	3,3182
	Máximo	2686,1	34,85	35,77	33,69	93,18	93,73	92,45	24,245	22,800	5,8273
Treinamento	Mínimo	146,9	17,36	17,55	16,94	26,27	29,45	24,55	9,491	7,745	0,6364
	1º Quartil	1049,8	23,40	24,00	22,34	52,18	57,55	49,09	16,309	14,745	2,0000
	Mediana	1438,2	26,13	26,85	25,15	62,00	67,00	58,36	18,682	17,164	2,6909
	Média	1473,8	26,20	26,83	25,20	62,06	66,00	59,03	18,396	16,865	2,7077
	3º Quartil	1976,8	28,77	29,60	27,67	71,18	75,55	68,09	20,700	19,227	3,3182
	Máximo	2686,1	34,85	35,77	33,69	93,18	93,73	92,45	24,245	22,800	5,8273
Teste	Mínimo	328,9	18,37	18,89	18,02	29,00	32,73	27,36	10,71	8,855	0,6545
	1º Quartil	1058,0	23,50	24,26	22,47	52,48	57,91	49,45	16,51	14,618	2,0068
	Mediana	1440,3	26,47	27,20	25,81	61,50	66,73	58,50	19,05	17,550	2,5864
	Média	1505,2	26,48	27,13	25,51	61,77	66,21	58,76	18,61	17,088	2,6806
	3º Quartil	1955,3	28,93	29,49	28,03	70,52	74,43	67,34	20,91	19,579	3,2559
	Máximo	2639,6	34,50	35,08	33,35	91,00	92,00	89,91	23,68	22,391	5,1000

Os dados foram divididos randomicamente em 80% para treinamento e 20% para teste. É importante ressaltar que mesmo sendo selecionados randomicamente, os dados dos conjuntos de treinamento e teste possuem amostras igualmente distribuídas, consistindo assim numa divisão homogênea de todo o conjunto de dados.

3.3 Seleção dos Grupos de Preditores

A estação Ecologia Agrícola oferece dados como temperatura, umidade, ponto de orvalho, pressão atmosférica, direção e velocidade dos ventos, precipitação e radiação solar. Para as variáveis temperatura, umidade, ponto de orvalho e pressão atmosférica, são disponibilizadas medições instantâneas, máximas e mínimas, ao todo são 16 variáveis que podem ser utilizadas como preditores de radiação solar.

A fim de otimizar o grupo de preditores objetivando selecionar as variáveis que mais contribuíssem para a predição de radiação solar, foram realizados experimentos utilizando Regressão Linear através do software R, com a função `glm`. Por meio dessa função foram obtidos as estimativas pontuais, os erros padrão das estimativas pontuais e o nível de significância (p). Foi adotado um nível de significância de 5% ($p < 0,05$), ou seja, um intervalo de confiança de 95%. Nessa etapa foram evidenciadas as variáveis que apresentaram um nível de significância superior a 5%.

Logo em seguida iniciaram-se os experimentos com RNA. O primeiro experimento contou com as 16 variáveis disponibilizadas, e a partir daí as variáveis com $p > 0,05$ foram excluídas do modelo uma a uma.

De acordo com Guarnieri (2006), para redes que possuem um grande número de entradas, determinadas topologias levam a resultados incoerentes ou até resultados negativos de radiação. Assim para um grupo de preditores com muitas entradas, o autor sugere a topologia para o treinamento das RNAs a estrutura $RNA-(n)-(n)-(0,5n)-1$, onde n é o número de neurônios, portanto nesta etapa do trabalho a recomendação do autor foi seguida.

Em todos os experimentos para cada topologia da RNA foram repetidas 50 simulações, concomitantemente para cada conjunto de treino e teste/validação, usou-se RLM para fins de comparação. Nesta etapa a RLM foi utilizada como uma ferramenta norteadora dos ajustes das variáveis predictoras, ficando como critério de seleção das mesmas a análise dos Índices: Índice de Confiança (C), Erro Médio Absoluto (MAE – Mean Absolute Error) e Raiz do Erro Médio Quadrático (RMSE – Root Mean Squared Error).

3.4 Treinamento da RNA para seleção da melhor topologia

A metodologia adotada foi a de RNA do tipo Perceptron de múltiplas camadas (MLP) pertencente à classe de RNAs conhecida como *Feedforward*. Com o intuito de identificar qual topologia seria mais adequada para a estimação de radiação solar, a partir dessa etapa o presente estudo foi dividido em dois subgrupos de teste. Ambos consistiram em realizar experimentos variando o número de neurônios na camada escondida, com a diferença de que no primeiro foram treinadas redes compostas apenas por uma camada interna e no segundo redes compostas por duas camadas internas.

Depois das variáveis meteorológicas selecionadas, das médias diárias calculadas e dos dados normalizados, o próximo passo foi definir quais variáveis seriam utilizadas na entrada da rede. Como citado no item anterior as variáveis: temperatura, umidade, ponto de orvalho e pressão atmosférica, possuíam medições instantâneas, máximas e mínimas, assim foram feitos testes utilizando cada uma dessas medições individualmente e também com todas de uma vez a fim de verificar qual geraria melhor resultado. Com o intuito de facilitar a referência aos experimentos realizados, uma nomenclatura personalizada foi adotada:

- **Modelo completo:** experimento que utiliza todas as variáveis preditoras indicadas como relevantes para predição de radiação solar.
- **Modelo instantâneo:** experimento que utiliza as medições instantâneas das variáveis preditoras indicadas como relevantes para predição de radiação solar.
- **Modelo máximo:** experimento que utiliza as medições máximas das variáveis preditoras indicadas como relevantes para predição de radiação solar.
- **Modelo mínimo:** experimento que utiliza as medições mínimas das variáveis preditoras indicadas como relevantes para predição de radiação solar.

Logo em seguida os dados foram divididos em conjuntos de treinamento e teste. O software foi programado para dividir randomicamente o conjunto de dados em 80% para treinamento da rede e os 20% restante foram reservados para a teste/validação do modelo.

Os dados foram divididos desta maneira com o intuito de realizar a validação cruzada, que de acordo com Robinson e Metternicht (2006) é obtida através da estimativa de um conjunto de dados amostrais, onde no geral um valor é estimado por vez. Posteriormente, obtém-se a diferença entre o valor real e o valor estimado para cada dado desse conjunto.

A literatura sugere que a determinação da quantidade de neurônios nas camadas ocultas e a quantidade de camadas ocultas são definidas fazendo uso do bom senso, geralmente são determinados de acordo com a experiência do especialista. Deve-se sempre ter em mente que quanto maior a quantidade de camadas escondidas numa Rede Neural, a mesma terá melhores condições de extrair as características pertinentes aquele conjunto de dados, entretanto se acrescentar em demasia a quantidade de camadas ocultas e neurônios, a RNA memorizará os padrões daquele conjunto específico, perdendo assim sua capacidade de generalização. Contudo a RNA não deve possuir um número muito pequeno de camadas escondidas e neurônios para não perder a capacidade de armazenar os padrões necessários comprometendo assim a modelagem dos dados e também para que não leve muito mais tempo para alcançar a precisão desejada. (Coutinho, 2014)

Após as simulações de diversas topologias para investigação de qual seria a mais adequada, foi feito um estudo sobre o comportamento do erro MAE a fim de verificar a necessidade de se realizar simulações de outras topologias além das inicialmente propostas.

A função de ativação utilizada foi a logística. O algoritmo de treinamento utilizado foi o resilient backpropagation (Rprop+) através do pacote neuralnet. Para cada arquitetura de rede, foram realizadas 50 simulações. Quanto à escolha dos parâmetros livres como os pesos e os bias, o próprio pacote neuralnet selecionou automaticamente.

Os critérios de parada também são selecionados automaticamente pelo pacote, como o threshold que é definido como 0,01, ou seja, se a alteração no erro durante uma época for menor que 1%, nenhuma otimização adicional será realizada pelo modelo, o outro critério de parada é o stepmax que é fixado em 100.000 épocas, ou seja, se durante o treinamento a rede ultrapassar 100.000 épocas, o algoritmo é interrompido. A tabela 4 apresenta um resumo dos parâmetros utilizados pelo modelo proposto.

Tabela 4 – Resumo dos parâmetros do modelo proposto

Parâmetros	Valor
Nº de simulações por topologia	50
Nº máximo de épocas	100.000 iterações
Função de ativação	Logística
Likelihood	Falsa
Nº de repetições da rede no treinamento	1
Algoritmo de treinamento	<i>Resilient backpropagation</i>
Inicialização dos pesos	Randomico
Threshold (critério de parada)	0,01
Métrica usada erro de treinamento	SSE (Sum of Squared Errors)

Fazendo uso do mesmo conjunto de dados de entrada, foram calculadas regressões lineares múltiplas (RLMs) para fins de comparação com os resultados da RNA.

Por causa da normalização dos dados, os resultados das RNAs do presente estudo pertencem ao intervalo de 0 a 1. Logo, para poder analisar tais resultados foi indispensável realizar o procedimento de desnormalização dos dados, ou seja, tornar os valores para a escala real, conforme a seguinte equação (Coutinho, 2014):

$$V_j = (x_j * x_{max}) - (x_j * x_{min}) + x_{min} \quad (3.2)$$

Onde V_j é a variável desnormalizada, x_j variável predita pela rede, x_{max} o valor máximo observado entre as variáveis e x_{min} o valor mínimo observado entre as variáveis.

Após as simulações das redes e avaliar as estruturas com diferentes quantidades de neurônios nas camadas ocultas, a arquitetura mais adequada foi determinada. A primeira análise foi avaliar qual dentre os modelos (completo, instantâneo, máximo ou mínimo) geraria melhores resultados. Posteriormente foi feita uma análise entre as redes que possuíam o mesmo número de camadas, selecionando também as que apresentariam melhores resultados e por fim foram comparadas as melhores redes com uma e duas camadas escondidas. O capítulo 4 do presente estudo apresenta as discussões sobre a quantidade de camadas da rede e a quantidade de neurônios utilizados em cada camada mais detalhadamente. A figura 28 apresenta o modelo de arquitetura utilizado no presente trabalho.

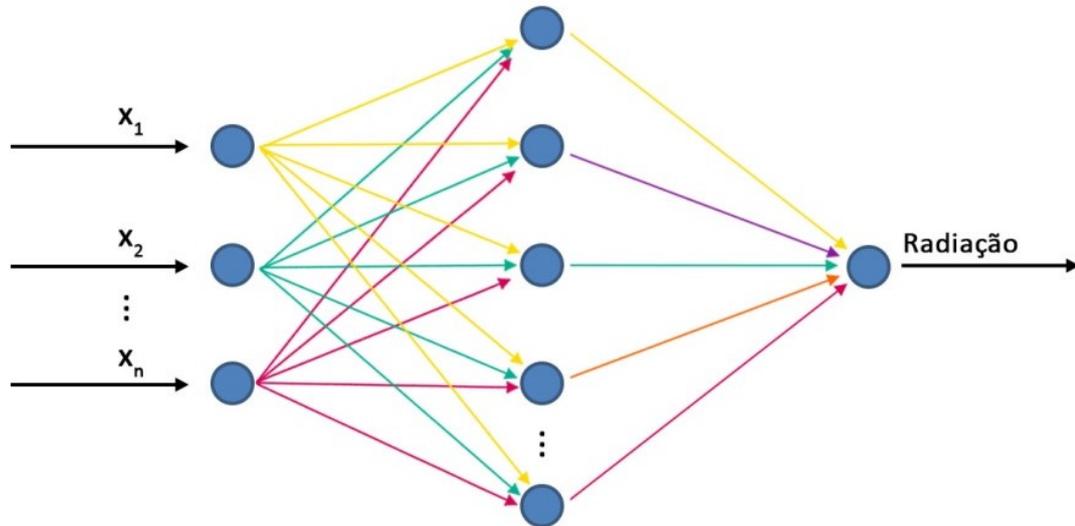


Figura 28 – Arquitetura de rede utilizada no presente trabalho

3.5 Avaliações das Previsões

Para comparar o desempenho dos modelos serão utilizadas diferentes medidas estatísticas, que geralmente são utilizadas na literatura, além de também serem descritas por vários autores (Pezzopane *et al.*, 2012; Guarnieri, 2006; Deshmukh e Ghatol, 2010; Fonseca *et al.*, 2012), são elas:

- **Coefficiente de Correlação de Pearson (r):**

Por definição o coeficiente de correlação representa uma medida do grau de dependência linear entre duas variáveis, que no presente estudo são os valores estimados pela rede (x_j) e os valores observados pela estação (O_j) é calculado por:

$$r = \frac{\sum_{j=1}^N (x_j - \bar{x})(O_j - \bar{O})}{n \sqrt{\frac{\sum_{j=1}^N (x_j - \bar{x})^2}{n}} \cdot \sqrt{\frac{\sum_{j=1}^N (O_j - \bar{O})^2}{n}}} \quad (3.3)$$

Onde \bar{x} é a média dos valores estimados e \bar{O} é a média dos valores observados e n representa o número de dados utilizados. O resultado do coeficiente de correlação varia no intervalo de $[-1,1]$, onde 1 representa que existe uma correlação linear positiva perfeita entre x_j e O_j . Por não depender da escala e não levar em conta o viés da previsão, existe a possibilidade de encontrar uma correlação elevada para uma previsão com grandes erros (viés).

• **Erro Médio Absoluto (MAE – Mean Absolute Error):**

Através do MAE é possível obter a magnitude média dos erros de previsão. O resultado varia no intervalo de $[0, \infty)$ onde 0 representa o valor para a previsão perfeita. É calculado através da seguinte equação:

$$MAE = \frac{\sum_{j=1}^n |O_j - x_j|}{n} \quad (3.4)$$

• **Raiz do Erro Médio Quadrático (RMSE – Root Mean Squared Error):**

É o valor que representa a magnitude média dos erros de previsão. O resultado varia no intervalo de $[0, \infty)$ onde 0 representa o valor para a previsão perfeita. É obtido por:

$$RMSE = \sqrt{\frac{\sum_{j=1}^n (O_j - x_j)^2}{n}} \quad (3.5)$$

• **Índice de Concordância (D):**

Fornece o grau de exatidão entre as variáveis envolvidas, pois relaciona a diferença entre os valores estimados em relação aos valores observados. O resultado varia no intervalo de $[0, 1]$ onde 0 representa nenhuma concordância e 1 significa que houve uma concordância perfeita.

$$D = 1 - \frac{\sum_{j=1}^n (O_j - x_j)^2}{\sum_{j=1}^n \left(\left| x_j - \overline{O} \right| + \left| O_j - \overline{O} \right| \right)^2} \quad (3.6)$$

• **Coefficiente de Determinação (R^2):**

O R^2 é uma medida que descreve a qualidade do ajuste do modelo. Seu resultado varia de 0 a 1, representado de 0 a 100% da variância total das observações explicadas pelos valores estimados. Sua equação é dada por:

$$R^2 = \frac{\sum_{j=1}^N (x_j - \overline{O})^2}{\sum_{j=1}^N (O_j - \overline{O})^2} \quad (3.7)$$

• **Índice de Confiança (C):**

Através do índice de confiança, é possível analisar simultaneamente a precisão e a exatidão dos resultados obtidos. Ele é calculado através do produto do coeficiente de correlação (r) pelo índice de concordância:

$$C = (r * D) \quad (3.8)$$

A Tabela 5 demonstra os critérios para avaliação de desempenho.

Tabela 5 – Critérios para avaliação e análise do desempenho de modelos com base no índice de confiança

Valor de C	Desempenho
> 0,85	Ótimo
0,76 a 0,85	Muito bom
0,66 a 0,75	Bom
0,61 a 0,65	Mediano
0,51 a 0,60	Sofrível
0,41 a 0,50	Mau
≤ 0,40	Péssimo

• **Skill:**

Este índice é utilizado para comparar dois modelos em termos de ganho (ou aperfeiçoamento), é obtido relacionando um modelo a outro adotado como referência. Sua fórmula é dada por:

$$Skill(\acute{I}NDICE, ref) = \frac{\acute{I}NDICE - \acute{I}NDICE_{ref}}{\acute{I}NDICE_{perf} - \acute{I}NDICE_{ref}} \quad (3.9)$$

onde $\acute{I}NDICE$ pode assumir qualquer um dos índices anteriormente citados, $\acute{I}NDICE_{perf}$ é o valor onde este índice assume a previsão perfeita, ou seja, assume o valor 0 para erros como MAE ou RMSE e assume o valor 1 para r , D ou R^2 , $\acute{I}NDICE_{ref}$ é o valor deste índice calculado para uma outra previsão adotada como referência.

Quando o Skill assume valor igual a 1 representa que a previsão atingida foi perfeita, quando se iguala a 0 significa que não houve ganho se comparado a previsão de referência e por fim, quando se obtém valores negativos quer dizer que a previsão avaliada é inferior a previsão de referência.

Em termos práticos, os passos metodológicos utilizados na realização do presente trabalho são apresentados no fluxograma da figura 29:

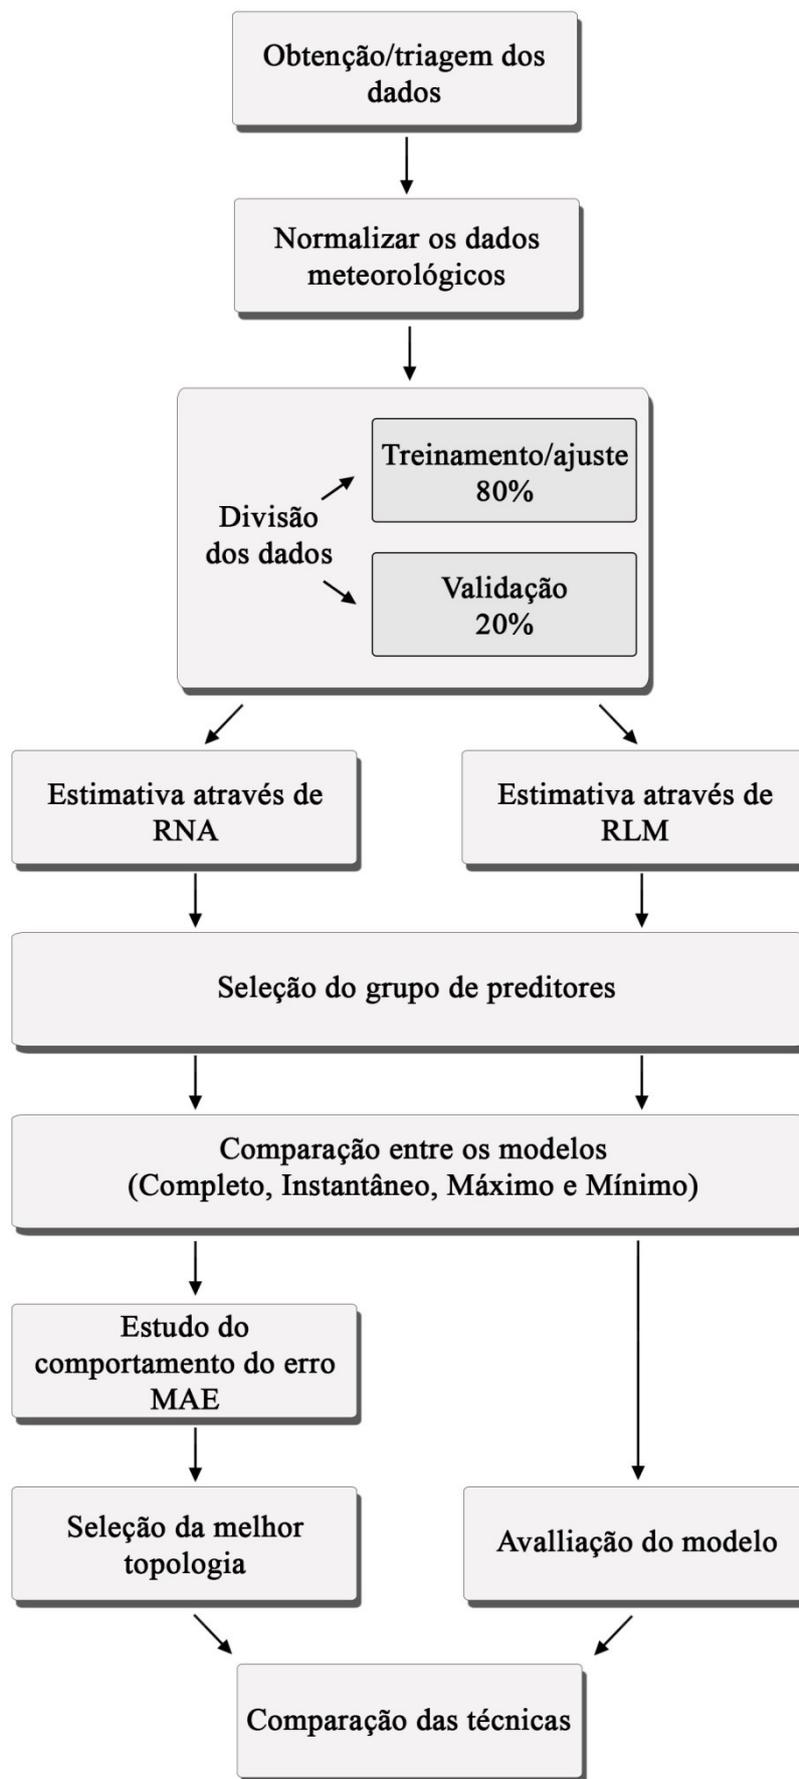


Figura 29 – Fluxograma da metodologia adotada

4 RESULTADOS E DISCUSSÃO

Neste capítulo são exibidos e discutidos os resultados alcançados pelos modelos aplicados no presente estudo. Primeiramente são apresentados testes com diferentes grupos de preditores objetivando encontrar um grupo mínimo que gere uma previsão satisfatória, logo em seguida é apresentado qual dos modelos entre o completo, o instantâneo, o máximo ou o mínimo aponta melhores resultados. Em sequência, são mostrados os experimentos das diversas topologias de RNA com uma e duas camadas escondidas, detalhando a comparação entre os modelos de RNA com RLM, por fim foram evidenciadas as topologias que apresentaram melhores desempenhos.

4.1 Seleção dos Grupos de Preditores

Conforme descrito no capítulo 3 foram realizados experimentos com o intuito de determinar o conjunto de preditores para treinamento das RNAs. Como mencionado anteriormente, a estação Ecologia Agrícola fornece dados que podem ser utilizados como conjunto de preditores de radiação solar como velocidade, direção e rajada dos ventos, chuva, temperatura, umidade, ponto de orvalho e pressão atmosférica. Assim com o intuito de otimizar esse conjunto, foram feitos experimentos reduzindo alguns grupos de preditores.

Inicialmente o experimento contou com os 16 preditores fornecidos e a partir do uso de RLM (como descrito no capítulo anterior), as variáveis que menos influenciavam na predição de radiação foram sendo excluídas do grupo de preditores. Assim foram realizados experimentos excluindo os grupos: chuva, pressão atmosférica instantânea, pressão atmosférica máxima, pressão atmosférica mínima, direção dos ventos, rajada dos ventos, ponto de orvalho instantâneo, temperatura máxima e umidade instantânea respectivamente, conforme mostrado na tabela 6.

Para cada topologia adotada foram realizadas 50 simulações e para os mesmos conjuntos de treino, teste/validação foram calculadas RLM objetivando a comparação entre ambas. Como critério de seleção utilizou-se o Índice de Confiança (C), o Erro Médio Absoluto (MAE – Mean Absolute Error) e A Raiz do Erro Médio Quadrático (RMSE – Root Mean Squared Error), por serem índices que evidenciam a precisão e a exatidão dos resultados além de representam a magnitude média dos erros de previsão. Os erros MAE e RMSE mensuram o tamanho médio dos módulos dos desvios entre previsões e observações, a diferença entre ambos é que enquanto o MAE é a média aritmética dos módulos dos desvios, o RMSE representa uma média quadrática dos desvios, pode-se pensar nele como uma medida análoga ao desvio padrão.

Dos dados obtidos nas 50 simulações realizados, foram calculadas as médias tanto para a RNA quanto para RLM. Foram selecionados também os casos que apresentaram índice de Confiança (C) máximo e mínimo, conforme mostra a tabela 7.

Tabela 6 – Experimento com diferentes variáveis preditoras

Experimentos	Variáveis preditoras
16 preditores	temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (instantâneo, máximo, mínimo), pressão atmosférica (instantânea, máxima, mínima), vento (velocidade, rajada, direção), chuva
15 preditores	temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (instantâneo, máximo, mínimo), pressão atmosférica (instantânea, máxima, mínima), vento (velocidade, rajada, direção)
14 preditores	temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (instantâneo, máximo, mínimo), pressão atmosférica (máxima, mínima), vento (velocidade, rajada, direção)
13 preditores	temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (instantâneo, máximo, mínimo), pressão atmosférica (mínima), vento (velocidade, rajada, direção)
12 preditores	temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (instantâneo, máximo, mínimo), vento (velocidade, rajada, direção)
11 preditores	temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (instantâneo, máximo, mínimo), vento (velocidade, rajada)
10 preditores	temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (instantâneo, máximo, mínimo), vento (velocidade)
9 preditores	temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (máximo, mínimo), vento (velocidade)
8 preditores	temperatura (instantânea, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (máximo, mínimo), vento (velocidade)
7 preditores	temperatura (instantânea, mínima), umidade (máxima, mínima), ponto de orvalho (máximo, mínimo), vento (velocidade)

Ao analisar a tabela 7 observou-se que ao remover as variáveis chuva, pressão atmosférica instantânea e pressão atmosférica máxima, não houve mudanças significativas nos índices de avaliação. Ao mesmo tempo notou-se que para os experimentos com 14, 13 e 12 preditores a RLM mostrou desempenho superior a RNA, apresentando em termos de média, índice de confiança superior e menores erros MAE e RMSE.

Como o esperado as variáveis chuva e pressão atmosférica (instantânea, máxima e mínima) influenciam negativamente no desempenho do modelo, ou seja, a presença destas variáveis prejudica o modelo. Os experimentos com 11, 10 e 9 preditores mostraram índices de avaliação bastante similares entre si, contudo apresentaram melhores índices se comparados aos experimentos anteriores. Quanto aos experimentos com 8 e 7 preditores o Índice de Confiança tornou a diminuir e os erros aumentaram.

É importante notar que, embora para alguns dos experimentos a média seja aparentemente boa, analisando os valores máximos e mínimos atingidos pela RNA nas 50 simulações realizados, observa-se que em todos os casos os valores máximos de C apresentam desempenho ótimo ($C > 0,85$), entretanto ao analisar os valores mínimos obtidos, em alguns dos casos apresentaram desempenho sofrível (0,51 a 0,60), mau (0,41 a 0,50) ou até mesmo péssimo ($C \leq 0,40$).

Após uma análise detalhada das médias obtidas nos experimentos, foi possível verificar e definir o caso onde os melhores resultados foram encontrados, ou seja, maior Índice de Confiança e menores MAE e RMSE, concluindo assim que o experimento que

Tabela 7 – Índices de avaliação calculados na seleção das variáveis preditoras

Experimento		Índices	MAE	RMSE	C
16 preditores (16-16-8-1)	RNA	Máx	0,0712	0,0965	0,8854
		Min	0,1146	0,2039	0,5775
		Média	0,0928	0,1344	0,7917
	RLM	Máx	0,0639	0,0787	0,9265
		Min	0,2375	1,7792	0,0084
		Média	0,0956	0,2891	0,7729
15 preditores (15-16-8-1)	RNA	Máx	0,0678	0,0889	0,9053
		Min	0,1581	0,7681	0,1071
		Média	0,0896	0,1465	0,7850
	RLM	Máx	0,0723	0,0922	0,9086
		Min	0,2743	2,2341	0,0044
		Média	0,1098	0,4431	0,6878
14 preditores (14-14-7-1)	RNA	Máx	0,0674	0,0848	0,9054
		Min	0,0966	0,3030	0,4272
		Média	0,0813	0,1141	0,8451
	RLM	Máx	0,0728	0,0906	0,9117
		Min	0,0833	0,1091	0,8361
		Média	0,0784	0,1000	0,8757
13 preditores (13-14-7-1)	RNA	Máx	0,0671	0,0849	0,9155
		Min	0,1264	0,5638	0,1613
		Média	0,0828	0,1219	0,8296
	RLM	Máx	0,0709	0,0881	0,9044
		Min	0,0866	0,1135	0,8158
		Média	0,0787	0,0998	0,8730
12 preditores (12-12-6-1)	RNA	Máx	0,0656	0,0855	0,9161
		Min	0,1022	0,3046	0,4488
		Média	0,0778	0,1090	0,8565
	RLM	Máx	0,0692	0,0868	0,9082
		Min	0,0882	0,1142	0,8242
		Média	0,0779	0,0996	0,8752
11 preditores (11-12-6-1)	RNA	Máx	0,0656	0,0844	0,9158
		Min	0,0817	0,1454	0,7763
		Média	0,0752	0,1012	0,8734
	RLM	Máx	0,0666	0,0849	0,9080
		Min	0,0883	0,1182	0,8172
		Média	0,0796	0,1018	0,8687
10 preditores (10-10-5-1)	RNA	Máx	0,0646	0,0823	0,9142
		Min	0,0816	0,1118	0,8329
		Média	0,0751	0,1011	0,8729
	RLM	Máx	0,0699	0,0894	0,8972
		Min	0,0983	0,1264	0,8119
		Média	0,0828	0,1055	0,8589
9 preditores (9-10-5-1)	RNA	Máx	0,0591	0,0747	0,9317
		Min	0,0901	0,1297	0,8145
		Média	0,0748	0,1004	0,8741
	RLM	Máx	0,0737	0,0901	0,8996
		Min	0,0955	0,1189	0,8223
		Média	0,0820	0,1050	0,8599
8 preditores (8-8-4-1)	RNA	Máx	0,0681	0,0867	0,9155
		Min	0,0861	0,1185	0,8180
		Média	0,0751	0,1018	0,8707
	RLM	Máx	0,0730	0,0917	0,8956
		Min	0,0891	0,1210	0,8092
		Média	0,0820	0,1047	0,8618
7 preditores (7-8-4-1)	RNA	Máx	0,0646	0,0907	0,9014
		Min	0,0850	0,1195	0,8139
		Média	0,0760	0,1047	0,8625
	RLM	Máx	0,0782	0,0997	0,8894
		Min	0,0929	0,1227	0,8043
		Média	0,0844	0,1086	0,8490

contava com 9 preditores foi o mais indicado para ser usado no treinamento das RNAs. Foi observado também que em termos do Índice de Confiança, dentre as 50 simulações realizadas, o valor mínimo obtido apresentou um desempenho muito bom (0,76 a 0,85), o valor máximo e a média apresentaram um ótimo desempenho ($C > 0,85$).

Nesta etapa foi possível notar que excetuando os casos onde a RLM mostrou-se superior a RNA, nos demais experimentos a RNA superou a RLM, houve também uma melhora significativa no modelo com a redução das variáveis de 16 para 9 preditores, constatando que de fato existem variáveis que podem ser excluídas do mesmo. Além disso, verificou-se que as 9 variáveis preditoras selecionadas possuem informação suficiente para gerar uma boa estimativa de radiação solar incidente em Seropédica.

4.2 Seleção Entre os Modelos: Completo, Instantâneo, Máximo e Mínimo

Como especificado no capítulo anterior, foi adotada uma nomenclatura personalizada para os experimentos nesta fase do trabalho, que consistiram em modelo completo (utiliza todas as variáveis preditoras selecionadas na etapa anterior de uma única vez), modelo instantâneo, modelo máximo e modelo mínimo que utiliza as variáveis preditoras individualmente.

Foram realizados experimentos para as RNAs de uma e duas camadas internas com a função de ativação logística. Para cada topologia adotada foram repetidas 50 simulações. Como critério de avaliação, foram também utilizados o Índice de Confiança (C), o Erro Médio Absoluto (MAE) e A Raiz do Erro Médio Quadrático (RMSE). Para cada um desses índices foram realizadas as médias que podem ser observadas nas tabelas 10 para as RNAs de uma camada interna e 11 para RNAs de duas camadas internas. Foram selecionados os valores máximos, mínimos do Índice de Confiança, bem como o MAE e o RMSE associados a ele. Nas tabelas 12 e 13 são apresentados os Índices de Confiança máximos para uma e duas camadas internas respectivamente. Os casos em que apresentaram valores mínimos do Índice de Confiança podem ser observados nas tabelas 14 para redes de uma camada interna e 15 para redes de duas camadas internas.

Observou-se assim que para cada topologia entre os modelos instantâneo, máximo e mínimo não havia grande variação entre as médias dos índices, apresentando valores aproximados entre si. No que se refere a comparação entre os modelos instantâneo, máximo e mínimo com o modelo completo, notou-se que este supera os demais substancialmente, pois os maiores valores médios do Índice de Confiança atingidos pelos modelos individuais não superaram os valores de C atingidos pelo modelo completo, além disso o modelo completo apresenta menores valores de MAE e RMSE.

Analisando o Índice de Confiança para cada topologia entre os modelos, observou-se que o valor máximo dos modelos individuais não supera o do modelo completo (tabelas 12 e 13), ao mesmo tempo, foi constatado que para cada topologia, o valor mínimo do modelo completo supera os valores apresentados pelos modelos individuais (tabelas 14 e 15).

Ainda analisando o Índice de Confiança foi possível observar que o desempenho dos modelos, tanto para uma quanto para duas camadas escondidas, variou bastante. A tabela 8 apresenta um resumo dos índices observados dos experimentos. A fim de abreviar a tabela, foi adotado o uso de siglas para representar o desempenho do modelo. Assim:

- OT: Ótimo ($> 0,85$)
- MB: Muito bom (0,76 a 0,85)
- BO: Bom (0,66 a 0,75)
- ME: Mediano (0,61 a 0,65)
- SO: Sofrível (0,51 a 0,60)
- MA: Mau (0,41 a 0,50)
- PE: Péssimo ($C \leq 0,40$)

Tabela 8 – Resumo do Índice de Confiança para topologias com uma e duas camadas escondidas

Modelo \ nº de camadas	Valores Médios		Valores Máximos		Valores Mínimos	
	Uma	Duas	Uma	Duas	Uma	Duas
Instantâneo	MB	BO e MB	MB e OT	MB e OT	BO, ME e MA	BO, ME, SO e PE
Máximo	MB	BO e MB	MB e OT	MB e OT	BO, MB e PE	BO, ME, SO e PE
Mínimo	MB	BO e MB	MB e OT	MB e OT	BO, SO, MA	BO, ME, SO, PE e MA
Completo	OT	OT	OT	OT	MB	MB

Fazendo a análise dos modelos em termos de tempo médio computacional necessário para a conclusão do treinamento da RNA, obteve-se a tabela 9. Antes mesmo das simulações serem realizadas, esperava-se que o modelo completo levasse mais tempo para convergência que os demais modelos, visto que a quantidade de dados na camada de entrada era maior. Essa suspeita foi corroborada após a mensuração do tempo médio computacional, contudo, o modelo completo mostrou ser o mais indicado, pois leva a menores erros e a maior Índice de Confiança. Assim o modelo completo demonstrou ser o mais adequado para estimar a radiação solar e, portanto foi adotado no presente trabalho.

Tabela 9 – Tempo médio computacional entre os modelos

RNA \ Modelo	Completo	Instantâneo	Máximo	Mínimo
1 Camada	99s	14s	21s	10s
2 Camadas	55s	23s	24s	13s

Tabela 10– Avaliação das médias dos modelos para uma camada interna

Topologia	Índices		MAE	RMSE	C
	Modelo				
(4-5-1)	Instantâneo		0,0931	0,1234	0,8045
	Máximo		0,0915	0,1228	0,8048
	Mínimo		0,0970	0,1286	0,7882
(9-5-1)	Completo		0,0720	0,0968	0,8827
(4-6-1)	Instantâneo		0,0949	0,1284	0,7903
	Máximo		0,0914	0,1218	0,8107
	Mínimo		0,0963	0,1285	0,7861
(9-6-1)	Completo		0,0719	0,0961	0,8843
(4-7-1)	Instantâneo		0,0941	0,1250	0,7975
	Máximo		0,0909	0,1219	0,8093
	Mínimo		0,0976	0,1282	0,7877
(9-7-1)	Completo		0,0722	0,0966	0,8818
(4-8-1)	Instantâneo		0,0944	0,1253	0,7998
	Máximo		0,0916	0,1226	0,8072
	Mínimo		0,0965	0,1274	0,7907
(9-8-1)	Completo		0,0731	0,0980	0,8786
(4-9-1)	Instantâneo		0,0935	0,1247	0,8006
	Máximo		0,0930	0,1250	0,7979
	Mínimo		0,0988	0,1324	0,7753
(9-9-1)	Completo		0,0714	0,0947	0,8879
(4-10-1)	Instantâneo		0,0950	0,1269	0,7892
	Máximo		0,0937	0,1257	0,7999
	Mínimo		0,0987	0,1320	0,7759
(9-10-1)	Completo		0,0729	0,0972	0,8800
(4-11-1)	Instantâneo		0,0924	0,1222	0,8068
	Máximo		0,0919	0,1236	0,8020
	Mínimo		0,0968	0,1279	0,7887
(9-11-1)	Completo		0,0742	0,1004	0,8723
(4-12-1)	Instantâneo		0,0952	0,1267	0,7933
	Máximo		0,0936	0,1263	0,7966
	Mínimo		0,0986	0,1311	0,7771
(9-12-1)	Completo		0,0739	0,0994	0,8758
(4-13-1)	Instantâneo		0,0933	0,1244	0,7993
	Máximo		0,0953	0,1280	0,7873
	Mínimo		0,0994	0,1341	0,7720
(9-13-1)	Completo		0,0738	0,1005	0,8739
(4-14-1)	Instantâneo		0,0946	0,1260	0,7967
	Máximo		0,0992	0,1877	0,7789
	Mínimo		0,0991	0,1316	0,7751
(9-14-1)	Completo		0,0736	0,0991	0,8760
(4-15-1)	Instantâneo		0,0938	0,1255	0,7958
	Máximo		0,0947	0,1298	0,7863
	Mínimo		0,0996	0,1313	0,7788
(9-15-1)	Completo		0,0751	0,1007	0,8725

Tabela 11 – Avaliação das médias dos modelos para duas camadas internas

Topologia	Índices		MAE	RMSE	C
	Modelo				
(4-5-4-1)	Instantâneo		0,0948	0,1266	0,7946
	Máximo		0,0944	0,1274	0,7905
	Mínimo		0,0973	0,1303	0,7818
(9-5-4-1)	Completo		0,0728	0,0979	0,8796
(4-6-5-1)	Instantâneo		0,0976	0,1316	0,7789
	Máximo		0,0930	0,1256	0,7984
	Mínimo		0,1019	0,1382	0,7514
(9-6-5-1)	Completo		0,0723	0,0982	0,8800
(4-7-5-1)	Instantâneo		0,0984	0,1321	0,7806
	Máximo		0,0956	0,1349	0,7795
	Mínimo		0,0992	0,1345	0,7674
(9-7-5-1)	Completo		0,0729	0,0982	0,8807
(4-7-6-1)	Instantâneo		0,1004	0,1356	0,7647
	Máximo		0,0984	0,1481	0,7555
	Mínimo		0,1011	0,1349	0,7628
(9-7-6-1)	Completo		0,0733	0,0987	0,8787
(4-8-5-1)	Instantâneo		0,0984	0,1329	0,7734
	Máximo		0,0965	0,1341	0,7748
	Mínimo		0,1023	0,1379	0,7578
(9-8-5-1)	Completo		0,0745	0,1005	0,8736
(4-8-6-1)	Instantâneo		0,0991	0,1325	0,7755
	Máximo		0,0976	0,1331	0,7776
	Mínimo		0,1010	0,1364	0,7642
(9-8-6-1)	Completo		0,0749	0,1015	0,8708
(4-8-7-1)	Instantâneo		0,0993	0,1349	0,7677
	Máximo		0,0981	0,1353	0,7662
	Mínimo		0,1002	0,1345	0,7686
(9-8-7-1)	Completo		0,0739	0,0998	0,8767
(4-9-5-1)	Instantâneo		0,1003	0,1361	0,7604
	Máximo		0,0963	0,1307	0,7836
	Mínimo		0,1013	0,1344	0,7703
(9-9-5-1)	Completo		0,0738	0,0995	0,8765
(4-9-6-1)	Instantâneo		0,1020	0,1490	0,7537
	Máximo		0,1002	0,1430	0,7619
	Mínimo		0,1049	0,1434	0,7435
(9-9-6-1)	Completo		0,0738	0,1008	0,8734
(4-10-5-1)	Instantâneo		0,1058	0,2125	0,7606
	Máximo		0,0962	0,1305	0,7828
	Mínimo		0,1026	0,1389	0,7563
(9-10-5-1)	Completo		0,0743	0,1000	0,8746

Tabela 12 – Avaliação dos valores máximos de C dos modelos para uma camada interna

Topologia	Índices		MAE	RMSE	C
	Modelo				
(4-5-1)	Instantâneo		0,0801	0,1023	0,8784
	Máximo		0,0793	0,1009	0,8706
	Mínimo		0,0838	0,1101	0,8475
(9-5-1)	Completo		0,0641	0,0834	0,9233
(4-6-1)	Instantâneo		0,0819	0,1057	0,8566
	Máximo		0,0709	0,1042	0,8690
	Mínimo		0,0819	0,1087	0,8525
(9-6-1)	Completo		0,0613	0,0823	0,9257
(4-7-1)	Instantâneo		0,0802	0,1025	0,8670
	Máximo		0,0779	0,1028	0,8682
	Mínimo		0,0863	0,1104	0,8513
(9-7-1)	Completo		0,0628	0,0817	0,9208
(4-8-1)	Instantâneo		0,0840	0,1104	0,8505
	Máximo		0,0780	0,1035	0,8617
	Mínimo		0,0815	0,1070	0,8639
(9-8-1)	Completo		0,0633	0,0833	0,9142
(4-9-1)	Instantâneo		0,0853	0,1093	0,8547
	Máximo		0,0747	0,1024	0,8540
	Mínimo		0,0845	0,1108	0,8509
(9-9-1)	Completo		0,0628	0,0804	0,9229
(4-10-1)	Instantâneo		0,0780	0,1031	0,8718
	Máximo		0,0843	0,1095	0,8602
	Mínimo		0,0868	0,1148	0,8481
(9-10-1)	Completo		0,0615	0,0821	0,9182
(4-11-1)	Instantâneo		0,0779	0,1004	0,8740
	Máximo		0,0779	0,1075	0,8591
	Mínimo		0,0823	0,1031	0,8635
(9-11-1)	Completo		0,0683	0,0890	0,9063
(4-12-1)	Instantâneo		0,0787	0,1076	0,8552
	Máximo		0,0848	0,1109	0,8548
	Mínimo		0,0874	0,1119	0,8359
(9-12-1)	Completo		0,0668	0,0855	0,9098
(4-13-1)	Instantâneo		0,0856	0,1064	0,8657
	Máximo		0,0893	0,1157	0,8427
	Mínimo		0,0906	0,1168	0,8304
(9-13-1)	Completo		0,0639	0,0847	0,9166
(4-14-1)	Instantâneo		0,0833	0,1056	0,8598
	Máximo		0,0794	0,1024	0,8613
	Mínimo		0,0853	0,1085	0,8455
(9-14-1)	Completo		0,0633	0,0842	0,9111
(4-15-1)	Instantâneo		0,0873	0,1116	0,8480
	Máximo		0,0822	0,1086	0,8536
	Mínimo		0,0887	0,1155	0,8373
(9-15-1)	Completo		0,0601	0,0818	0,9165

Tabela 13 – Avaliação dos valores máximos de C dos modelos para duas camadas internas

Topologia	Índices		MAE	RMSE	C
	Modelo				
(4-5-4-1)	Instantâneo		0,0891	0,1147	0,8406
	Máximo		0,0830	0,1114	0,8505
	Mínimo		0,0876	0,1168	0,8390
(9-5-4-1)	Completo		0,0591	0,0792	0,9246
(4-6-5-1)	Instantâneo		0,0861	0,1163	0,8479
	Máximo		0,0849	0,1113	0,8488
	Mínimo		0,0879	0,1109	0,8439
(9-6-5-1)	Completo		0,0598	0,0782	0,9294
(4-7-5-1)	Instantâneo		0,0848	0,1129	0,8482
	Máximo		0,0898	0,1175	0,8455
	Mínimo		0,0828	0,1124	0,8468
(9-7-5-1)	Completo		0,0621	0,0795	0,9290
(4-7-6-1)	Instantâneo		0,0810	0,1049	0,8674
	Máximo		0,0807	0,1032	0,8670
	Mínimo		0,0894	0,1134	0,8450
(9-7-6-1)	Completo		0,0633	0,0808	0,9100
(4-8-5-1)	Instantâneo		0,0793	0,1015	0,8670
	Máximo		0,0846	0,1143	0,8566
	Mínimo		0,0854	0,1162	0,8409
(9-8-5-1)	Completo		0,0636	0,0877	0,9137
(4-8-6-1)	Instantâneo		0,0760	0,1032	0,8772
	Máximo		0,0810	0,1063	0,8572
	Mínimo		0,0830	0,1070	0,8572
(9-8-6-1)	Completo		0,0661	0,0838	0,9085
(4-8-7-1)	Instantâneo		0,0829	0,1139	0,8372
	Máximo		0,0788	0,1058	0,8561
	Mínimo		0,0763	0,1083	0,8523
(9-8-7-1)	Completo		0,0673	0,0838	0,9218
(4-9-5-1)	Instantâneo		0,0865	0,1099	0,8607
	Máximo		0,0772	0,1049	0,8665
	Mínimo		0,0946	0,1217	0,8260
(9-9-5-1)	Completo		0,0596	0,0792	0,9225
(4-9-6-1)	Instantâneo		0,0850	0,1144	0,8414
	Máximo		0,0817	0,1119	0,8531
	Mínimo		0,0893	0,1136	0,8373
(9-9-6-1)	Completo		0,0632	0,0834	0,9187
(4-10-5-1)	Instantâneo		0,0805	0,1055	0,8562
	Máximo		0,0762	0,1071	0,8542
	Mínimo		0,0892	0,1139	0,8382
(9-10-5-1)	Completo		0,0601	0,0806	0,9222

Tabela 14 – Avaliação dos valores mínimos de C dos modelos para uma camada interna

Topologia	Índices		MAE	RMSE	C
	Modelo				
(4-5-1)	Instantâneo		0,1068	0,1476	0,7417
	Máximo		0,1036	0,1412	0,7473
	Mínimo		0,1130	0,1413	0,7255
(9-5-1)	Completo		0,0841	0,1172	0,8352
(4-6-1)	Instantâneo		0,1270	0,2714	0,4467
	Máximo		0,1027	0,1394	0,7546
	Mínimo		0,1056	0,1473	0,7113
(9-6-1)	Completo		0,0819	0,1151	0,8330
(4-7-1)	Instantâneo		0,1045	0,1434	0,7168
	Máximo		0,1034	0,1351	0,7617
	Mínimo		0,1101	0,1433	0,7079
(9-7-1)	Completo		0,0856	0,1201	0,8215
(4-8-1)	Instantâneo		0,1111	0,1413	0,7380
	Máximo		0,1016	0,1403	0,7563
	Mínimo		0,1046	0,1382	0,7326
(9-8-1)	Completo		0,0834	0,1169	0,8320
(4-9-1)	Instantâneo		0,1032	0,1413	0,7103
	Máximo		0,1011	0,1353	0,7565
	Mínimo		0,1124	0,2032	0,5955
(9-9-1)	Completo		0,0811	0,1217	0,8235
(4-10-1)	Instantâneo		0,1180	0,1841	0,5843
	Máximo		0,1016	0,1377	0,7447
	Mínimo		0,1203	0,2175	0,5349
(9-10-1)	Completo		0,0914	0,1233	0,8208
(4-11-1)	Instantâneo		0,1092	0,1399	0,7432
	Máximo		0,1042	0,1440	0,7328
	Mínimo		0,1079	0,1456	0,7261
(9-11-1)	Completo		0,0822	0,1167	0,8171
(4-12-1)	Instantâneo		0,1081	0,1403	0,7175
	Máximo		0,1017	0,1425	0,7298
	Mínimo		0,1012	0,1563	0,6958
(9-12-1)	Completo		0,0860	0,1157	0,8169
(4-13-1)	Instantâneo		0,1018	0,1368	0,7283
	Máximo		0,1111	0,1473	0,7100
	Mínimo		0,1272	0,2696	0,4266
(9-13-1)	Completo		0,0871	0,1162	0,8327
(4-14-1)	Instantâneo		0,1087	0,1494	0,7236
	Máximo		0,3879	3,2192	-0,0018
	Mínimo		0,1053	0,1525	0,7037
(9-14-1)	Completo		0,0858	0,1183	0,8230
(4-15-1)	Instantâneo		0,1039	0,1468	0,7284
	Máximo		0,1277	0,2744	0,3811
	Mínimo		0,1044	0,1423	0,7282
(9-15-1)	Completo		0,0891	0,1391	0,7677

Tabela 15 – Avaliação dos valores mínimos de C dos modelos para duas camadas internas

Topologia	Índices		MAE	RMSE	C
	Modelo				
(4-5-4-1)	Instantâneo		0,1062	0,1420	0,7429
	Máximo		0,1027	0,1429	0,7235
	Mínimo		0,1200	0,1603	0,6904
(9-5-4-1)	Completo		0,0821	0,1125	0,8400
(4-6-5-1)	Instantâneo		0,1081	0,1506	0,6972
	Máximo		0,1014	0,1380	0,7308
	Mínimo		0,1274	0,2688	0,3473
(9-6-5-1)	Completo		0,0813	0,1175	0,8249
(4-7-5-1)	Instantâneo		0,1118	0,1540	0,7205
	Máximo		0,1300	0,4677	0,2607
	Mínimo		0,1087	0,2160	0,5046
(9-7-5-1)	Completo		0,0841	0,1147	0,8290
(4-7-6-1)	Instantâneo		0,1116	0,1820	0,6199
	Máximo		0,1346	0,6028	0,1165
	Mínimo		0,1171	0,1510	0,6504
(9-7-6-1)	Completo		0,0899	0,1212	0,8301
(4-8-5-1)	Instantâneo		0,1186	0,1633	0,6347
	Máximo		0,1019	0,1905	0,6559
	Mínimo		0,1470	0,2685	0,4070
(9-8-5-1)	Completo		0,0905	0,1279	0,8009
(4-8-6-1)	Instantâneo		0,1101	0,1542	0,6775
	Máximo		0,1196	0,1566	0,6757
	Mínimo		0,1033	0,1620	0,6497
(9-8-6-1)	Completo		0,0860	0,1249	0,8061
(4-8-7-1)	Instantâneo		0,1075	0,1991	0,5915
	Máximo		0,1056	0,2030	0,5398
	Mínimo		0,1231	0,1625	0,6496
(9-8-7-1)	Completo		0,0810	0,1225	0,7982
(4-9-5-1)	Instantâneo		0,1191	0,1789	0,5776
	Máximo		0,1133	0,1544	0,6948
	Mínimo		0,1102	0,1431	0,7101
(9-9-5-1)	Completo		0,0856	0,1226	0,8098
(4-9-6-1)	Instantâneo		0,1639	0,8241	0,1171
	Máximo		0,1501	0,6128	0,0924
	Mínimo		0,1281	0,2663	0,4064
(9-9-6-1)	Completo		0,0784	0,1672	0,7060
(4-10-5-1)	Instantâneo		0,4575	4,0903	0,0057
	Máximo		0,1134	0,1538	0,7093
	Mínimo		0,1204	0,2046	0,5726
(9-10-5-1)	Completo		0,0843	0,1243	0,8276

4.3 Comportamento do Erro MAE

Fazendo uso das mesmas topologias utilizadas na seção anterior e considerando a média do modelo completo, realizou-se então um estudo do comportamento do erro MAE em relação aos diferentes números de neurônios nas camadas escondidas, com o propósito de verificar se haveria a necessidade de acrescentar outras topologias ao estudo.

Assim, foi observado o comportamento do erro MAE para as RNAs de uma e duas camadas escondidas com quantidades diferentes de neurônios em cada uma. Primeiramente foram analisadas as RNAs com uma camada escondida (figura 30).

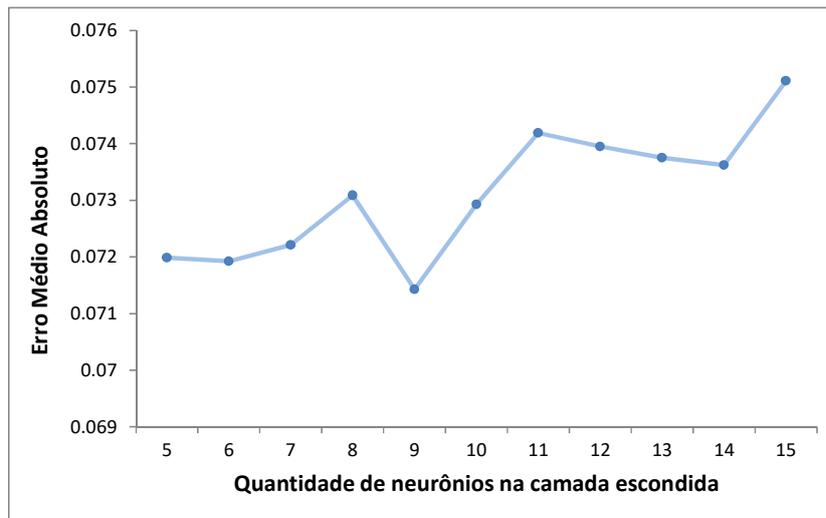


Figura 30 – Comportamento do erro MAE para diferentes quantidades de neurônios na camada escondida

Notou-se que quanto maior a quantidade de neurônios na camada escondida o erro MAE cresceu consideravelmente. E, portanto verificou-se que não haveria a necessidade de treinar outras redes além dessas visto a tendência do erro.

Para redes com duas camadas escondidas, a um primeiro momento, foram treinadas todas as redes apresentadas na tabela 4.8 com exceção da topologia (*RNA-9-10-5-1*) e até esta etapa foi obtido como resultado a figura 31, onde foi possível analisar que a um primeiro momento o erro MAE diminui, logo em seguida torna a crescer, porém a partir da topologia (*RNA-9-8-7-1*) não foi possível verificar um comportamento expressivo do erro, impossibilitando afirmar se o mesmo iria aumentar ou diminuir.

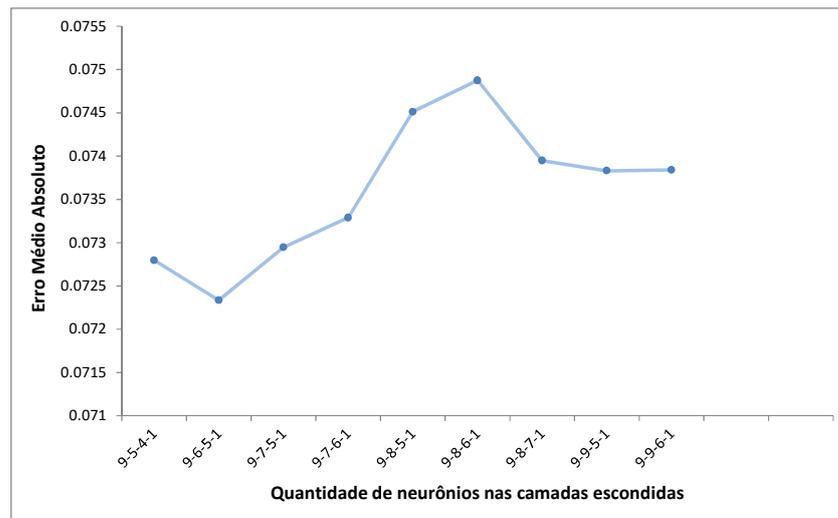


Figura 31 – Primeiro experimento do comportamento do erro MAE para diferentes quantidades de neurônios nas camadas escondidas

Por esse motivo foi realizado um teste adicional utilizando a topologia (*RNA-9-10-5-1*) para investigar qual seria a tendência do erro MAE e assim obteve-se a figura 32, na qual percebe-se claramente que o erro voltou a crescer. Portanto, foi verificado que para as RNAs tanto para uma camada escondida quanto para duas, na medida em que se aumenta a quantidade de neurônios nas camadas escondidas o erro aumenta. Constatando assim que não há a necessidade de se fazer uso de RNAs com um número muito elevado de neurônios nas camadas internas, visto que os desempenhos das redes são aproximados entre si e, além disso, erro e o custo computacional no treinamento aumentam.

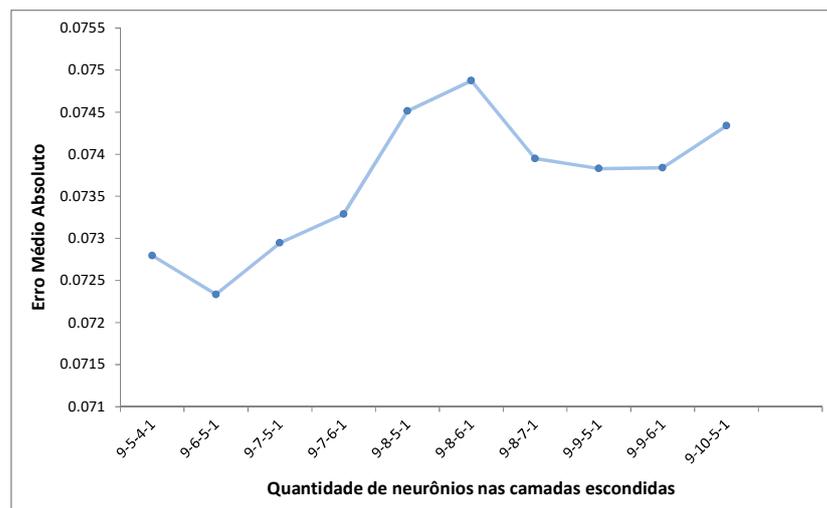


Figura 32 – Segundo experimento do comportamento do erro MAE para diferentes quantidades de neurônios nas camadas escondidas

4.4 Resultados de Irradiação Solar

Após a seleção do modelo completo, buscou-se fazer uma análise mais detalhada do mesmo a fim de definir qual seria a topologia mais adequada para estimar a radiação solar, para isso foram examinadas as médias das 50 simulações para cada topologia, tanto para uma quanto para duas camadas escondidas, tabelas 4.12 e 4.13 respectivamente. Nas tabelas também é possível verificar os valores máximos e mínimos do Índice de Confiança (C) para cada topologia, bem como os valores dos demais índices associados a ele. Para cada simulação das RNAs foram estimadas Regressão Linear Múltipla (RLM) utilizando os mesmos conjuntos de treinamento e teste/validação objetivando a comparação entre os métodos, os dados de RLM também se encontram nas tabelas 4.12 e 4.13.

Observou-se que em nenhum caso a média da RLM superou a RNA, tanto para uma quanto para duas camadas. Notou-se também que os Índices de Confiança não apresentaram valores muito distantes entre si, quando analisado os casos de valor máximo e mínimo para cada topologia.

Dessa forma, as redes que demonstraram melhores desempenhos médios foram *RNA-9-9-1* e *RNA-9-6-1* (tabela 17) para uma camada escondida e *RNA-9-6-5-1* e *RNA-9-7-5-1* (tabela 18) para duas camadas escondidas. Dentre essas topologias, a que apresentou maiores Índice de Confiança (C) e Coeficiente de Determinação (R^2), além de menores erros MAE, MSE e RMSE foi a *RNA-9-9-1*. Quando comparada ao modelo de RLM, a RNA mostrou uma redução em termos de *Skill* de aproximadamente de 12% do MAE, 14% do MSE e 7% do RMSE, em termos de R^2 e C apresentou um ganho de 14% e 15% respectivamente, conforme a tabela 16.

Tabela 16 – Comparação entre RNA e RLM para previsão de radiação solar

	MAE	MSE	RMSE	R^2	C
RNA-9-9-1	0,071	0,009	0,095	0,853	0,888
RLM	0,081	0,011	0,102	0,830	0,868
SKILL	0,12	0,14	0,07	0,14	0,15

Dentre as 50 simulações realizadas para a topologia *RNA-9-9-1*, o Índice de Confiança (C) máximo atingido foi de aproximadamente 92% mostrando um ótimo desempenho. A figura 33 apresenta o gráfico de dispersão dos valores estimados pelo método (X) e os valores observados pela estação Ecologia Agrícola (O) para o valor máximo atingido pela topologia *RNA-9-9-1*. As linhas tracejadas possuem coeficientes angulares unitários e passam pelas origens dos gráficos, elas denotam os casos onde as previsões seriam perfeitas, ou seja, os valores estimados se igualam aos valores observados ($X = O$). Na figura 33 encontram-se também as retas que representam o comportamento geral das previsões (linhas contínuas), os dados estimados pela RNA e pela RLM.

Observa-se nos diagramas de dispersão da figura 33 que a linha de tendência do modelo de RNA aproxima-se consideravelmente da linha de previsão perfeita, ao passo que a linha de tendência do modelo de RLM encontra-se abaixo da linha de previsão perfeita, o que indica que este modelo estima intensidades de radiação menores do que as observadas pela estação, ou seja, os dados estimados por RLM subestimam a radiação solar.

Tabela 17 – Diferentes topologias para uma camada escondida

Índices		épocas	MAE	MSE	RMSE	R ²	C	
Topologia								
(9-5-1)	RNA	Máx	68254	0,0641	0,0070	0,0834	0,8953	0,9233
		Min	40783	0,0841	0,0137	0,1172	0,7789	0,8352
		Média		0,0720	0,0094	0,0968	0,8456	0,8827
	RLM	Máx		0,0748	0,0087	0,0932	0,8692	0,9008
		Min		0,0947	0,0149	0,1222	0,7597	0,8118
		Média		0,0819	0,0110	0,1044	0,8207	0,8621
(9-6-1)	RNA	Máx	75693	0,0613	0,0068	0,0823	0,8995	0,9257
		Min	45576	0,0819	0,0133	0,1151	0,7774	0,8330
		Média		0,0719	0,0093	0,0961	0,8494	0,8843
	RLM	Máx		0,0776	0,0087	0,0935	0,8707	0,9026
		Min		0,0917	0,0142	0,1192	0,7614	0,8152
		Média		0,0815	0,0109	0,1040	0,8236	0,8631
(9-7-1)	RNA	Máx	53688	0,0628	0,0067	0,0817	0,8968	0,9208
		Min	36257	0,0856	0,0144	0,1201	0,7666	0,8215
		Média		0,0722	0,0094	0,0966	0,8452	0,8818
	RLM	Máx		0,0693	0,0075	0,0866	0,8841	0,9114
		Min		0,0941	0,0153	0,1238	0,7522	0,8045
		Média		0,0813	0,0108	0,1034	0,8228	0,8630
(9-8-1)	RNA	Máx	55727	0,0633	0,0069	0,0833	0,8893	0,9142
		Min	42704	0,0834	0,0137	0,1169	0,7627	0,8320
		Média		0,0731	0,0097	0,0980	0,8409	0,8786
	RLM	Máx		0,0691	0,0081	0,0902	0,8702	0,8994
		Min		0,0938	0,0156	0,1250	0,7287	0,8120
		Média		0,0830	0,0112	0,1058	0,8150	0,8571
(9-9-1)	RNA	Máx	24040	0,0628	0,0065	0,0804	0,8998	0,9229
		Min	49744	0,0811	0,0148	0,1217	0,7533	0,8235
		Média		0,0714	0,0091	0,0947	0,8533	0,8879
	RLM	Máx		0,0691	0,0077	0,0879	0,8766	0,9048
		Min		0,0873	0,0128	0,1133	0,7881	0,8344
		Média		0,0810	0,0105	0,1024	0,8297	0,8683
(9-10-1)	RNA	Máx	96165	0,0615	0,0067	0,0821	0,8932	0,9182
		Min	48777	0,0914	0,0152	0,1233	0,7582	0,8208
		Média		0,0729	0,0095	0,0972	0,8425	0,8800
	RLM	Máx		0,0723	0,0081	0,0902	0,8762	0,9063
		Min		0,0979	0,0159	0,1260	0,7478	0,8103
		Média		0,0812	0,0108	0,1035	0,8218	0,8622
(9-11-1)	RNA	Máx	54232	0,0683	0,0079	0,0890	0,8774	0,9063
		Min	93757	0,0822	0,0136	0,1167	0,7571	0,8171
		Média		0,0742	0,0102	0,1004	0,8325	0,8723
	RLM	Máx		0,0708	0,0083	0,0909	0,8649	0,8954
		Min		0,0903	0,0144	0,1200	0,7477	0,8020
		Média		0,0832	0,0113	0,1063	0,8126	0,8551
(9-12-1)	RNA	Máx	46060	0,0668	0,0073	0,0855	0,8793	0,9098
		Min	70725	0,0860	0,0134	0,1157	0,7588	0,8169
		Média		0,0739	0,0099	0,0994	0,8373	0,8758
	RLM	Máx		0,0718	0,0089	0,0942	0,8702	0,9010
		Min		0,0934	0,0150	0,1225	0,7505	0,8066
		Média		0,0827	0,0112	0,1054	0,8176	0,8584
(9-13-1)	RNA	Máx	77180	0,0639	0,0072	0,0847	0,8910	0,9166
		Min	32861	0,0871	0,0135	0,1162	0,7801	0,8327
		Média		0,0737	0,0099	0,0990	0,8390	0,8774
	RLM	Máx		0,0714	0,0078	0,0885	0,8790	0,9094
		Min		0,0901	0,0144	0,1199	0,7653	0,8215
		Média		0,0819	0,0110	0,1045	0,8212	0,8624
(9-14-1)	RNA	Máx	88951	0,0633	0,0071	0,0842	0,8837	0,9111
		Min	85266	0,0858	0,0140	0,1183	0,7696	0,8230
		Média		0,0736	0,0099	0,0991	0,8376	0,8760
	RLM	Máx		0,0731	0,0088	0,0940	0,8608	0,8942
		Min		0,0967	0,0154	0,1239	0,7472	0,8045
		Média		0,0822	0,0111	0,1052	0,8176	0,8586
(9-15-1)	RNA	Máx	63620	0,0601	0,0067	0,0818	0,8879	0,9165
		Min	87117	0,0891	0,0194	0,1391	0,6811	0,7677
		Média		0,0751	0,0102	0,1007	0,8329	0,8725
	RLM	Máx		0,0708	0,0083	0,0911	0,8702	0,8997
		Min		0,0944	0,0155	0,1246	0,7342	0,7992
		Média		0,0827	0,0110	0,1046	0,8208	0,8614

Tabela 18– Diferentes topologias para duas camadas escondidas

Topologia		Índices		n.epochs	MAE	MSE	RMSE	R ²	C
		Máx	Mín						
(9-5-4-1)	RNA	Máx	53442	0,0591	0,0063	0,0792	0,9014	0,9246	
		Mín	38530	0,0821	0,0127	0,1125	0,7905	0,8400	
		Média		0,0728	0,0097	0,0979	0,8423	0,8796	
	RLM	Máx		0,0708	0,0077	0,0878	0,8759	0,9047	
		Mín		0,0899	0,0143	0,1194	0,7526	0,8048	
		Média		0,0826	0,0111	0,1050	0,8196	0,8604	
(9-6-5-1)	RNA	Máx	43931	0,0598	0,0061	0,0782	0,9069	0,9294	
		Mín	45830	0,0813	0,0138	0,1175	0,7589	0,8249	
		Média		0,0723	0,0097	0,0982	0,8424	0,8800	
	RLM	Máx		0,0715	0,0078	0,0882	0,8816	0,9091	
		Mín		0,0935	0,0149	0,1223	0,7530	0,8048	
		Média		0,0820	0,0110	0,1047	0,8214	0,8617	
(9-7-5-1)	RNA	Máx	47310	0,0621	0,0063	0,0795	0,9076	0,9290	
		Mín	52997	0,0841	0,0132	0,1147	0,7662	0,8290	
		Média		0,0729	0,0097	0,0982	0,8426	0,8807	
	RLM	Máx		0,0677	0,0079	0,0887	0,8850	0,9121	
		Mín		0,0905	0,0141	0,1190	0,7486	0,8117	
		Média		0,0823	0,0110	0,1046	0,8219	0,8628	
(9-7-6-1)	RNA	Máx	73357	0,0633	0,0065	0,0808	0,8832	0,9100	
		Mín	36628	0,0899	0,0147	0,1212	0,7746	0,8301	
		Média		0,0733	0,0098	0,0987	0,8405	0,8787	
	RLM	Máx		0,0748	0,0085	0,0922	0,8569	0,8912	
		Mín		0,0909	0,0134	0,1158	0,7793	0,8272	
		Média		0,0814	0,0108	0,1037	0,8245	0,8642	
(9-8-5-1)	RNA	Máx	39366	0,0636	0,0077	0,0877	0,8873	0,9137	
		Mín	44741	0,0905	0,0164	0,1279	0,7346	0,8009	
		Média		0,0745	0,0102	0,1005	0,8331	0,8736	
	RLM	Máx		0,0728	0,0082	0,0906	0,8683	0,8984	
		Mín		0,0831	0,0125	0,1117	0,7664	0,8193	
		Média		0,0824	0,0111	0,1050	0,8190	0,8595	
(9-8-6-1)	RNA	Máx	50477	0,0661	0,0070	0,0838	0,8809	0,9085	
		Mín	59942	0,0860	0,0156	0,1249	0,7303	0,8061	
		Média		0,0749	0,0104	0,1015	0,8292	0,8708	
	RLM	Máx		0,0798	0,0098	0,0989	0,8475	0,8888	
		Mín		0,0962	0,0160	0,1264	0,7202	0,7850	
		Média		0,0822	0,0111	0,1053	0,8172	0,8587	
(9-8-7-1)	RNA	Máx	97294	0,0673	0,0070	0,0838	0,8940	0,9218	
		Mín	36781	0,0810	0,0150	0,1225	0,7333	0,7982	
		Média		0,0739	0,0100	0,0998	0,8366	0,8767	
	RLM	Máx		0,0732	0,0084	0,0914	0,8712	0,9008	
		Mín		0,0905	0,0145	0,1204	0,7458	0,8011	
		Média		0,0815	0,0108	0,1035	0,8250	0,8646	
(9-9-5-1)	RNA	Máx	43900	0,0596	0,0063	0,0792	0,8989	0,9225	
		Mín	63025	0,0856	0,0150	0,1226	0,7463	0,8098	
		Média		0,0738	0,0100	0,0995	0,8364	0,8765	
	RLM	Máx		0,0665	0,0079	0,0889	0,8726	0,9031	
		Mín		0,0932	0,0141	0,1187	0,7674	0,8206	
		Média		0,0818	0,0109	0,1043	0,8214	0,8626	
(9-9-6-1)	RNA	Máx	81172	0,0632	0,0070	0,0834	0,8935	0,9187	
		Mín	72834	0,0784	0,0280	0,1672	0,5478	0,7060	
		Média		0,0738	0,0103	0,1008	0,8314	0,8734	
	RLM	Máx		0,0706	0,0082	0,0905	0,8752	0,9047	
		Mín		0,0875	0,0134	0,1159	0,7632	0,8191	
		Média		0,0813	0,0107	0,1035	0,8244	0,8641	
(9-10-5-1)	RNA	Máx	30924	0,0601	0,0065	0,0806	0,8986	0,9222	
		Mín	25855	0,0843	0,0155	0,1243	0,7516	0,8276	
		Média		0,0743	0,0101	0,1000	0,8342	0,8746	
	RLM	Máx		0,0710	0,0082	0,0908	0,8711	0,8997	
		Mín		0,0921	0,0145	0,1205	0,7530	0,8037	
		Média		0,0814	0,0108	0,1039	0,8218	0,8621	

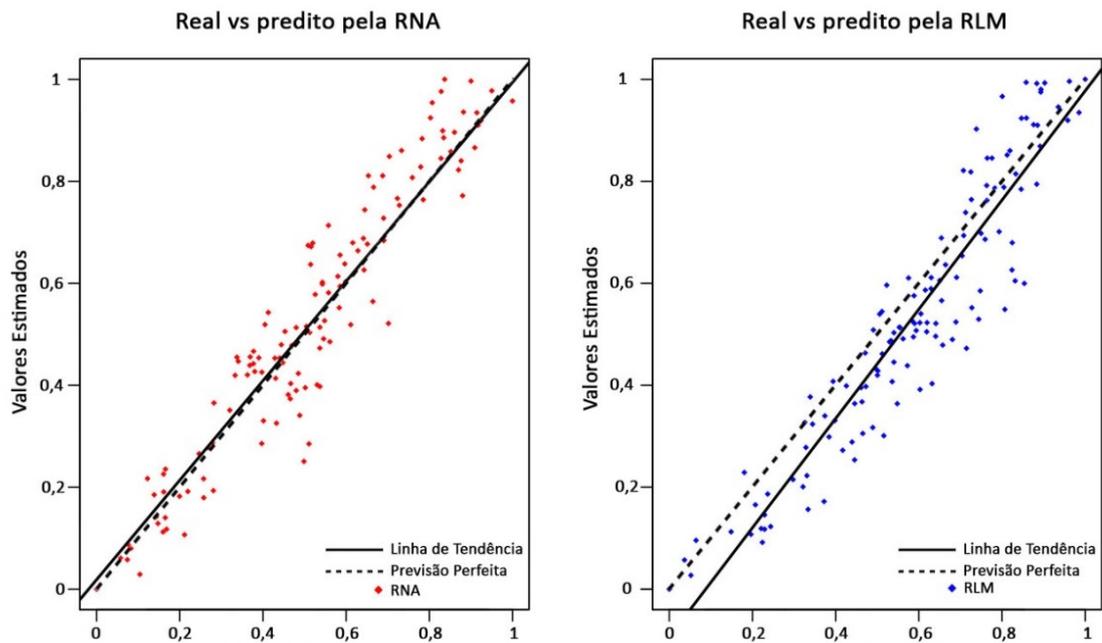


Figura 33 – Diagrama de dispersão dos valores estimados de radiação solar do modelo *RNA-9-9-1* e de RLM

Inclusive, constataram-se também os casos que apresentaram Índice de Confiança (C) máximo tanto para uma como para duas camadas escondidas. Assim as topologias *RNA-9-5-1* e *RNA-9-6-1* (tabela 4.12) destacaram-se para uma camada e as topologias *RNA-9-6-5-1* e *RNA-9-7-5-1* (tabela 4.13) destacaram-se para duas camadas. Dentre elas, a que apresentou melhor resultado foi a *RNA-9-6-5-1*, onde o Índice de Confiança (C) foi de aproximadamente 93% indicando um ótimo desempenho. A figura 34 apresenta o diagrama de dispersão dos valores estimados pelo método (X) e os valores observados pela estação Ecologia Agrícola (O) para a topologia *RNA-9-6-5-1*.

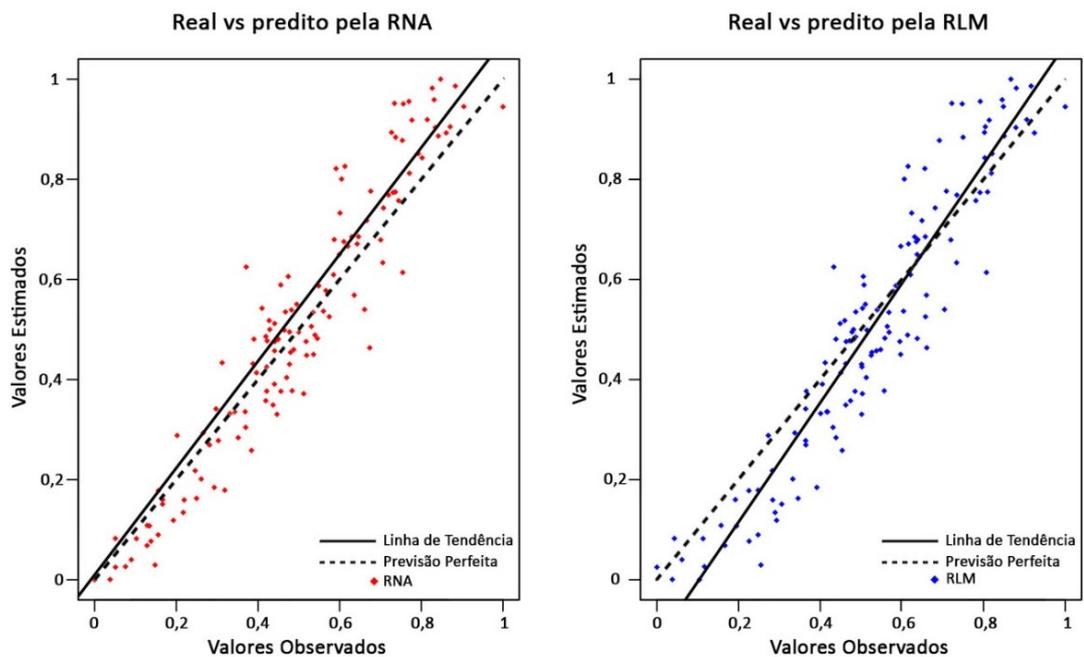


Figura 34 – Diagrama de dispersão dos valores estimados de radiação solar do modelo *RNA-9-6-5-1* e de RLM

Como já foi mencionado anteriormente as topologias *RNA-9-9-1* e *RNA-9-6-5-1* apresentaram Índice de Confiança (C) de 92% e 93% respectivamente e embora a topologia *RNA-9-6-5-1* tenha se mostrado ligeiramente superior, analisando os gráficos de dispersão das figuras 33 e 34 foi possível notar que os valores estimados pela RNA desta topologia mostraram-se menos dispersos em torno da linha de tendência, porém a linha de tendência está localizada acima da linha de previsão perfeita ($X = O$), o que indica que este modelo estima intensidades de radiação maiores do que as observadas pela estação, ou seja, os dados estimados por essa topologia superestimam a radiação solar. Ao mesmo tempo, os valores estimados pela RNA da topologia *RNA-9-9-1* mostram-se um pouco mais dispersos da linha de tendência se comparado a topologia *RNA-9-6-5-1*, porém, como mencionado anteriormente, a linha de tendência do modelo de RNA aproxima-se imensamente da linha de previsão perfeita. O que corrobora com a afirmação que de fato para o presente estudo, a topologia *RNA-9-9-1* é a mais indicada para ser utilizada na estimativa de radiação solar.

É apresentada na figura 35 a arquitetura da RNA que demonstrou melhor resultado no modelo proposto. Interessante observar que a rede que demonstrou melhor desempenho consta com apenas uma camada interna de neurônios ocultos. Resultado semelhante foi encontrado por Fiorin *et.al.* (2011), que em seu estudo comparou diferentes algoritmos de treinamento como Levenberg-Marquardt, Resilient Backpropagation, entre outros, a fim de analisar a incidência de radiação solar em São Martinho da Serra no Rio Grande do Sul. Como resultado obteve que as redes neurais podem fornecer estimativas confiáveis para avaliação da disponibilidade de energia solar, apresentando também melhor desempenho em comparação a outras técnicas estatísticas utilizadas em sua pesquisa e constatou também que uma camada oculta é suficiente para gerar uma boa estimativa.

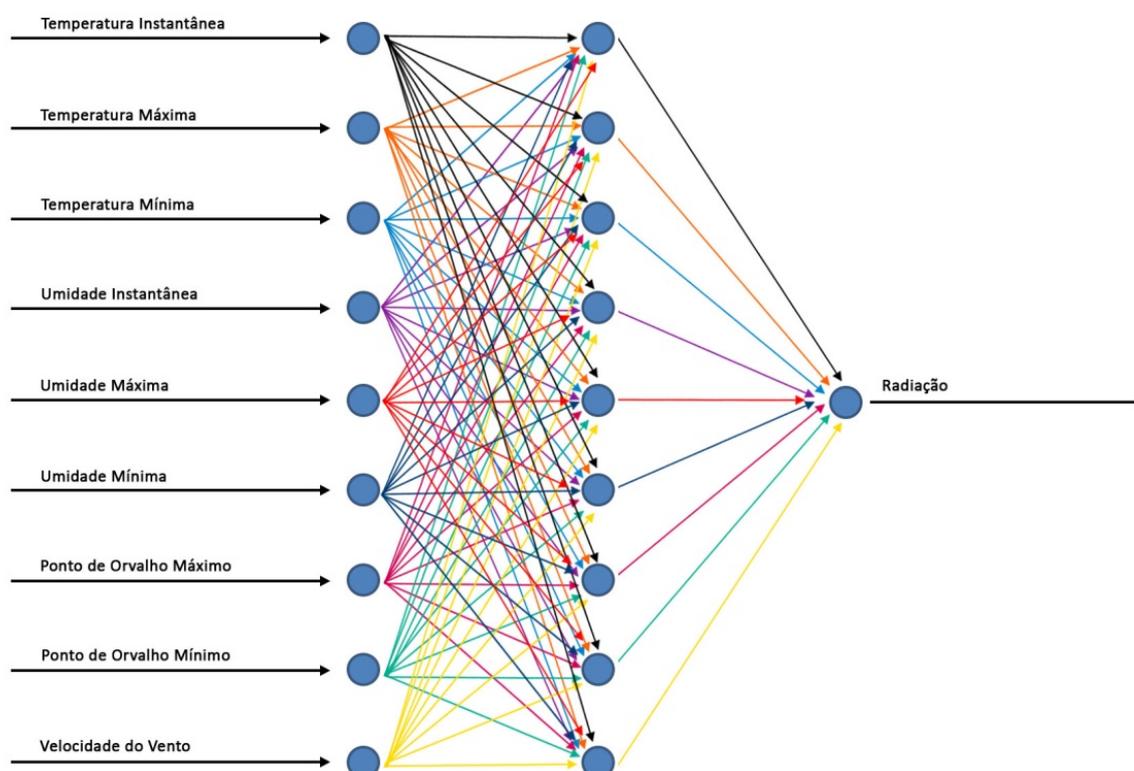


Figura 35 – Arquitetura da rede MLP proposta

5 CONCLUSÕES

O presente estudo propôs uma metodologia utilizando Redes Neurais Artificiais (RNAs) do tipo Múltiplas Camadas (MLP) para estimar a incidência de radiação solar no município de Seropédica localizado no estado do Rio de Janeiro. Foi feito também uma comparação do método de RNAs com Regressão Linear Múltipla (RLM) a fim de avaliar qual deles seria mais indicado para ser utilizado na estimativa de radiação solar.

No que diz respeito à comparação do desempenho entre as RNAs e os modelos de RLM, notou-se que o método de Redes Neurais Artificiais superou a RLM, contudo não apresentaram ganhos significativos frente a estas. Acredita-se que a similaridade entre os métodos se dá em virtude do período relativamente curto de coleta de dados.

Foi possível observar também que para estimar a radiação solar não se faz necessário o uso de todas as variáveis disponibilizadas pelo Instituto Nacional de Meteorologia através da estação Ecologia Agrícola. Assim, as variáveis consideradas foram temperatura (instantânea, máxima, mínima), umidade (instantânea, máxima, mínima), ponto de orvalho (máximo, mínimo), velocidade do vento.

Na análise entre os modelos: completo, instantâneo, máximo e mínimo, comprovou-se que embora o tempo computacional gasto pelo modelo completo seja maior do que os outros modelos, ele leva a melhores resultados.

Para cada topologia de RNA utilizada no trabalho foram repetidas 50 simulações e analisando as médias dos resultados apresentados pelas RNAs com arquiteturas de uma ou duas camadas, é possível concluir que a estrutura com uma única camada oculta apresenta resultados mais apurados, destacando-se a topologia *RNA-9-9-1* que apresentou um ótimo desempenho de Índice de Confiança (C) médio de 88% e coeficiente de determinação médio (R^2) de 85%. Dentre as 50 simulações da topologia *RNA-9-9-1* o maior Índice de Confiança (C) alcançado foi de 92% apresentando também um ótimo desempenho. Concluindo que não é viável investir em redes muito grandes tendo em vista que os resultados são muito próximos a redes com menos camadas e neurônios ocultos, além disso, notou-se que em redes com muitas camadas e neurônios ocultos o erro e o custo computacional no treinamento aumentam.

Tendo em vista a tendência atual por formas de geração de energia que menos agridam ao meio ambiente, nos últimos anos a energia solar fotovoltaica tem se mostrado bastante promissora. O Brasil possui um território propício para o aproveitamento desse tipo de energia. O município de Seropédica localizado no estado do Rio de Janeiro possui uma vasta área onde poderia ser aproveitada para instalação de painéis solares, a própria Universidade Federal Rural do Rio de Janeiro, situada no município, dispõe de uma ampla área que também poderia ser utilizada para tal fim. Dessa forma, caso o Brasil continue desenvolvendo sua capacidade de geração fotovoltaica fica em evidência, neste trabalho, o elevado potencial da região de Seropédica para investimentos desta natureza.

Por fim, objetivo do presente estudo foi alcançado com êxito, que foi avaliar a aplicabilidade de RNAs do tipo MLP para estimar a incidência de radiação solar em Seropédica, concluindo que este método computacional é apropriado para tal fim, pois é um recurso que gera boas estimativas com pequenos erros. Além disso, foi possível comprovar também que o software R com o uso do algoritmo *resilient backpropagation* é uma boa ferramenta para a proposta do presente estudo.

6 TRABALHOS FUTUROS

Como sugestão para trabalhos futuros baseados nas análises feitas no presente estudo, recomenda-se:

- Ampliar a base de dados: o presente trabalho conta com quase dois anos de dados meteorológicos e acredita-se que ao aumentar a base de dados, a capacidade do modelo poderá ser avaliada com maior precisão.
- Realizar estudos similares para outras localidades: neste trabalho foram utilizados os dados do Instituto Nacional de Meteorologia (INMET) da estação Ecologia Agrícola localizada em Seropédica para estimar a incidência de radiação solar. sugere-se fazer uso da mesma metodologia para outras estações automáticas do INMET do estado do Rio de Janeiro, podendo assim estudar o comportamento das previsões de radiação em outras regiões.
- Aplicar outras arquiteturas de redes e outros algoritmos de treinamento: sugere-se utilizar redes como redes neurais convolucionais, entre outras e algoritmo de treinamento como Levenberg Marquardt.
- Aplicar mesma metodologia para estimar velocidade do vento: substituir nas variáveis de entrada da rede a velocidade do vento por radiação solar a fim de verificar a viabilidade do aproveitamento deste recurso na região e avaliar a possibilidade de investir em sistemas híbridos do tipo solar/eólico.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDALA, P.J.P. Energia Solar e Eólica. Ponta Grossa (PR): Atena Editora; v. 1. 2019.

AL-HAJJ, R.; ASSI, A. Estimating solar irradiance using genetic programming technique and meteorological records. AIMS Energy. Volume 5, Issue 5, p.798-813. 2017.

ATLAS RIO SOLAR: atlas solarimétrico do Estado do Rio de Janeiro / organização: IEPUC - Instituto de Energia da PUC-Rio; [realizado pela EGPEnergia e PUC-Rio]. - Rio de Janeiro : Ed. PUC-Rio, 2016.

AZZI, J.B.; Utilização de Técnicas de Inteligência Computacional na Caracterização de Pacientes com Doenças Cardiovasculares. Dissertação. UFRRJ, Seropédica, 2018.

BARRETO, R.G.; MARINHO, G.M.G.A.; BARRETO, G.F.M.; BARRETO, R.G.; AVERSAN, L.O.C.; DANTAS, B.L. Utilizando Redes Neurais Artificiais para o Diagnóstico de Câncer Cervical. Revista Saúde e Ciência online, v. 7, n. 2, p. 59-67. 2018.

BENTLEY, R.W., Energy Policy 30, 189, 2002.

BOATA,R.; POP,N. Estimation of Global Solar Irradiation by Using Takagi-Sugeno Fuzzy Systems. Rom. Journ. Phys., Vol. 60, Nos. 3–4, P. 593–602, Bucharest, 2015.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDEMIR, T.B. Redes Neurais Artificiais: Teoria e Aplicações. LTC. p. 262, 2000.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Redes de Estações Meteorológicas Automáticas do INMET. Instituto Nacional de Meteorologia. Nota Técnica nº 001/2011/ SEGER/LAIME/INMET, 2011.

_____. Portal Brasil. Disponível em:<
<http://www.brasil.gov.br/infraestrutura/2016/01/brasil-estara-entre-os-20-paises-com-maior-geracao-solar-em-2018>> Acesso em 21/02/2018

CASTRO, J.O; TEIXEIRA, R.O; OLIVEIRA, A.D E CARVALHO, A. G. Comportamento de Coleópteros Degradadores de Madeira em Plantio de *Mimosa caesalpiniaefolia* (Sabiá) Seropédica, RJ. XIII Encontro Latino Americano de Iniciação Científica e IX Encontro Latino Americano de Pós-Graduação – Universidade do Vale do Paraíba, 2009.

COSTA, R. C. Modelos Preditivos de Velocidade de Vento para Sistemas Eólicos Baseados em Redes Neurais Artificiais. Monografia, UFPB, João Pessoa, 2016.

COUTINHO, E. R. Aplicação de Técnicas de Inteligência Computacional no preenchimento de Falhas de Séries Temporais Climatológicas. Dissertação. UFRRJ, Seropédica, 2014.

_____, E. R. SILVA, R. M.; DELGADO, A. R. S. Utilização de Técnicas de Inteligência Computacional na Predição de Dados Meteorológicos. *Revista Brasileira de Meteorologia*, v. 31, n. 1, p. 24-36, 2016.

DESHMUKH, R. P.; GHATOL, A. A. Comparative Study of Temporal Neural Networks for Short Term Flood Forecasting. *International Journal of Computer Applications*, v. 5, n. 12, p. 24-28, 2010.

FAUSETT, L. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. London: Pearson, 1993. 461p.

FIORIN, D.V., MARTINS, F.R, SCHUCH, N.J., PEREIRA, E.B. Aplicações de Redes Neurais e Previsões de disponibilidade de Recursos Energéticos Solares. *Revista Brasileira de Ensino de Física*, v. 33, n. 1, 1309, 2011.

FONSECA, J. S.; MARTINS, G. A.; TOLEDO, G. L. *Estatística Aplicada*. Ed. 2, p. 267. 2012.

FREITAS, A.G.S.; FERREIRA, P.M.; SILVA, R.M. Redes Neurais na Classificação de Neoplasias Mamárias. DOI 10.18605/2175-7275/cereus.v11n1p140-149. *Revista Cereus*. Vol. 11, Nº 1, 2019.

GAMBOGI, J.A. *Aplicação de Redes Neurais na Tomada de Decisão no Mercado de Ações*. Dissertação de Mestrado, USP, São Paulo, 2013.

GUARNIERI, R.A., *Emprego de Redes Neurais Artificiais e Regressão Linear Múltipla no Refinamento das Previsões de Radiação Solar do Modelo Eta*. Dissertação de Mestrado, INPE, São José dos Campos, 2006.

GÜNTHER, F.; FRITSCH, S. neuralnet: Training of Neural Networks. *The R Journal*, vol. 2/1, p. 30-38, 2010.

HAYKIN, Simon. *Redes Neurais: Princípios e Prática*; trad.Paulo Martins Engel, 2.ed., Porto Alegre: Bookman, 2001.

HEINEMANN, D., LORENZ, E. and GIRODO, M., in: *Proc. International Workshop on Solar Resource from the Local Level to Global Scale in Support to the Resource Management of Renewable Electricity Generation*. Institute for Environment and Sustainability, Joint Research Center, Ispra. 2004.

HOPFIELD, J. J. Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences of the United States of America*, vol. 79, p. 2554-2558, 1982.

IBGE – Instituto Brasileiro de Geografia e Estatística. v4.3.16.1 Brasília: IBGE. 2017. Disponível em <<https://www.ibge.gov.br/>> acesso em 31/01/2019.

IPEA – Instituto de Pesquisa Econômica Aplicada. *Caderno ODS: Assegurar o Acesso Confiável, Sustentável, Moderno e a Preço Acessível à Energia para Todos*. 2019. Disponível em <http://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=34715&Itemid=444> Acesso em 10/05/2019.

INMET, Instituto Nacional de Meteorologia. BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa. Disponível em: <<http://www.inmet.gov.br/portal/>> Acesso em 01/02/2019

KALOGIROU, S., MICHANELIDES, S., TYMBIOS, F., Prediction of maximum solar radiation using artificial neural networks. In: Proceedings of the WREC VII, Germany. 2002.

KIDDER, S. Q.; VONDER HAAR, T. H. Satellite meteorology: an introduction. San Diego: Academic Press, 466p. 1995.

KONDRATYEV, K. Ya. Radiation in the atmosphere. New York: Academic Press, 912p. 1969.

KRISHNAIAH, T. E RAO, S. S. E MADHUMURTH, K. Y. and REDDY, K.S. Neural Network Approach for Modelling Global Solar Radiation. Journal of Applied Sciences Research, 3(10): 1105-1111. 2007.

MACHADO, F. W. Modelagem Chuva-Vazão Mensal Utilizando Redes Neurais Artificiais. 174 p. Dissertação (Programa de Pós-graduação em Engenharia de Recursos Hídricos e Ambiental - Mestre em Engenharia Hidrológica). Universidade Federal do Paraná, Curitiba-PR, 2005.

MARTINS, E. R.; BINOTI, M.L.M.S; LEITE, H.G; BINOTI, D.H.B; DUTRA,G.C, Configuração de Redes Neurais Artificiais para Estimação do Afilamento do Fuste de Árvores de Eucalipto. Agrária, Recife, v.11, n.1, p.33-38, 2016

MARTINS, F.R., PEREIRA, E.B., SILVA, S.A.B., S.L. ABREU e S. COLLE, Energy Policy 36, 2843. 2008.

_____, F.R., PEREIRA, E.B., S.L. ABREU, Satellite-derived solar resource maps for Brazil under SWERA Project. Elsevier. Solar Energy 81, p.517–528. 2007.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, v. 5, p. 115-133, 1943.

MELLIT, A., BENGHANEM, M. and BENDEKHIS, M., Artificial Neural Network Model for Prediction Solar Radiation Data: Application for Sizing Stand-alone Photovoltaic Power System. IEEE Power Engineering Society General Meeting. 2005.

MENDES, I.A., REZENDE, R.A.D., NASCIMENTO, T.H.F., SILVA, J.S.F. e SILVA, O. F. A Utilização das Redes Neurais Artificiais na Previsão de Radiação Solar Global. Congresso Técnico Científico da Engenharia e da Agronomia. Belém – PA 2017.

MESINGER F., in: Proceedings of ICTP Regional Weather Predictability and Modeling Workshop, CPTEC/INPE, São José dos Campos 2005. Disponível em <ftp://ftp1.cptec.inpe.br/etamd/Download/model/EtaGuide>. 2008.8.pdf. Acesso em 21/02/2018

MINSKY, M.; PAPERT, S. Perceptrons: An Introduction to Computational Geometry. Massachusetts: MIT Press, 1969.

MUTAZ, T.; AHMAD, A. Solar Radiation Prediction Using Radial Basis Function Models. International Conference on Developments of E-Systems Engineering. P.77-82. 2015.

NASCIMENTO, R.L. Energia Solar no Brasil: Situação e Perspectivas. Brasília: Consultoria Legislativa da Câmara dos Deputados, 2017.

PEIXOTO, J.P. e OORT, A.H., Physics of climate. American Institute of Physics Press, New York, 520 p. 1992.

PERBONI, A; FRIZZONE, J.A.; CAMARGO, A. P. Artificial Neural Network Based Equation to Estimate Head Loss Along Dripp Irrigation Laterals. Revista Brasileira de Agricultura Irrigada v.8, nº. 2, p. 77 - 85, 2014

PEREIRA, E.B., MARTINS, F.R., GONÇALVES, A.R; COSTA, R.S.; LIMA, F.J.L.; RUTHER, R.; ABREU, S.L.;TIEPOLO, G.M.; PEREIRA, S.V.; SOUZA, J.G. Atlas Brasileiro de Energia Solar: Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP. 2ªed. 88p. 2017.

PEZZOPANE, J.E. M.; CASTRO, F.S.; PEZZOPANE, J.R.M.; CECÍLIO, R.A. AGROMETEOROLOGIA: Aplicações para o Espírito Santo. Alegre, ES: CAUFES. 2012.

PINHEIRO, E.; LOVATO, A.; RÜTHER, R. Aplicabilidade de Redes Neurais Artificiais para Análise de Geração de Energia de um Sistema Fotovoltaico Conectado a Rede Elétrica. Revista Brasileira de Energias Renováveis. v.6, n.5, p. 875-892, 2017.

PMS - Prefeitura Municipal de Seropédica. Dados Gerais. 2019. Disponível em <<http://www.seropedica.rj.gov.br/>> Acesso em 31/01/2019.

PNUD – Programa das Nações Unidas para o Desenvolvimento; IPEA – Instituto de Pesquisa Econômica Aplicada; FJP - Fundação João Pinheiro. Atlas do Desenvolvimento Humano no Brasil. 2013. Disponível em: <http://www.atlasbrasil.org.br/2013/pt/perfil_m/seropedica_rj.> Acesso em 31/01/2019.

PVGIS - Photovoltaic Geographical Information System. 2012. Disponível em <http://re.jrc.ec.europa.eu/pvg_download/map_index.html> Acesso em 17/05/2019.

RAWLINGS, J.O; PANTULA, S.G; DICKEY, D.A. Applied Regression Analysis: A Research Tool. 2ª ed. Springer. 1998.

RIEDMILLER, M. Rprop - Description and Implementation Details. Technical Report, University of Karlsruhe, Karlsruhe. 1994.

_____, M.; BRAUN, H. A direct adaptative method for faster backpropagation learning: the RPROP algorithm', Proceedings of the IEEE International Conference on Neural Networks, San Francisco, EUA, 586–591. 1993.

ROBINSON, T.P.; METTERNICHT, G. Testing the Performance of Spatial Interpolation Techniques for Mapping Soil Properties. Computers and Eletronics in Agriculture, v. 50, p. 97-108, 2006.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychol. Rev., v. 65, p. 386-408, 1958.

RUMELHART, D. E.; MCCLELLAND, J.L. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, vol.1, Cambridge, MA: MIT Press, 1986.

_____, D. E.; HINTON G.E.; WILLIAMS, R. J. Learning Representations by Backpropagation Errors. *Nature*, v. 323, p. 533-536, 1986.

R Documentation. Trainin of neural networks. Disponível em: <<http://127.0.0.1:24810/library/neuralnet/html/neuralnet.html>> Acesso em 06/12/2018.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático*. São Paulo: Artliber, 2010.

SILVA, J.P.B.C. *Modelos de Regressão Linear e Logística Utilizando o Software R*. 2016. p.146. Dissertação. UAB. Portugal, 2016.

SILVA, R. M. *Energia Solar: dos incentivos aos desafios. Texto para discussão nº 166*. Brasília. Senado Federal, 2015.

SOARES J., OLIVEIRA A.P., BOZNAR M.Z., MLAKAR P., ESCOBEDO J.F. e MACHADO A.J., *Applied Energy* 79, 201. 2004.

WALLACE, J. M.; HOBBS, P. V. *Atmospheric science: an introductory survey*. Amsterdam: Elsevier Academic Press, 2006.

WIDROW, B.; HOFF, M. B. Adaptive switching circuits. *IRE WESCON Convention Record*, pp.96-104, 1960.