

Avaliação da Irradiação Solar como Fonte de Energia Renovável no Noroeste do Estado do Rio Grande do Sul Através de Uma Rede Neural

Andréia Luísa Barth¹, Camila Wolfer¹, Adalberto Lovato¹, Dalvan Griebler^{1,2}

¹ Bacharelado em Sistemas de Informação – Faculdade Três de Maio (SETREM),
Três de Maio – RS – Brasil

² Programa de Pós-Graduação em Ciência da Computação – Pontifícia Universidade
Católica do Rio Grande do Sul (PUCRS), Porto Alegre – RS – Brasil

{andreiabarth, camilawolfer}@migrate.com.br, proflovato@terra.com.br,
dalvan.griebler@acad.pucrs.br

Abstract. *Solar irradiation is one of the cleanest renewable energy sources of nowadays. In this work, the goal was to implement a neural network capable of evaluating the solar irradiation in the Northwest region of Rio Grande do Sul. In case, this assessment targets meteorological data, from January to April 2015. The network Perceptron was implemented and trained using MATLAB software. The results have indicated that the system obtained a highly accurate and that the region is a good enough place for stemmed energy production of solar irradiation.*

Resumo. *A irradiação solar é uma das fontes de energia renovável mais limpas na atualidade. Neste trabalho, o objetivo foi implementar uma rede neural Perceptron, capaz de avaliar a irradiação solar na região Noroeste do Estado do Rio Grande do Sul. No caso, esta avaliação tem como alvo dados meteorológicos, no período de janeiro a abril de 2015. A rede foi implementada e treinada usando o software MATLAB. Os resultados indicaram que a rede obteve uma precisão alta e que a região é um local suficientemente bom para a produção de energia provinda da irradiação solar.*

1. Introdução

O uso de energias renováveis tem se tornado cada vez mais um fator relevante, visto a necessidade atual de consumo [Dienstmann 2009]. Entre as renováveis, a energia solar está entre aquelas que apresentam perspectivas mais promissoras. Porém, dado que os diversos países e suas regiões possuem diferenças climáticas, é necessário encontrar métodos que possam avaliar a quantidade de irradiação presente no local.

A irradiação solar, fundamental nos processos naturais, pode ser utilizada também nos processos artificiais. Uma maneira de fazê-lo é utilizar esta como energia fotovoltaica, que transforma a luz solar diretamente em energia elétrica.

A Inteligência Artificial e seus componentes, principalmente as Redes Neurais Artificiais (RNA), é uma grande aliada nos estudos referente a irradiação solar, pois com ela é possível realizar as previsões e avaliações a partir de dados meteorológicos disponíveis [Ahmed et al. 2013].

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

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

Portanto, a contribuição primordial deste trabalho é o desenvolvimento de um método de avaliação de clima. Paralelamente, como corolário, abre a oportunidade de se conhecer melhor o que hoje se classifica como “instabilidade climática”.

A Seção 2 discute os trabalhos relacionados ao assunto, contendo uma breve comparação com o atual desenvolvimento. Na sequência, na seção 3, é especificada a metodologia utilizada no trabalho, desde a coleta de dados até a apresentação dos resultados. Na seção 4, se apresenta o desenvolvimento da rede, como a mesma foi criada e quais dados foram utilizados. Os resultados obtidos com a rede proposta são apresentados na seção 5. Finaliza-se com a seção 6 uma breve conclusão.

2. Trabalhos Relacionados

Durante o desenvolvimento do trabalho, foi realizado um estudo em artigos relacionados que utilizaram o mesmo método de treinamento da rede, o algoritmo *Levenberg-Marquardt*, e que mensuram o nível de irradiação solar, com o objetivo de contextualizar e diferenciar as contribuições científicas.

O trabalho de [Yadav et al. 2012] buscou, através do uso do método *Levenberg-Marquardt*, mensurar a previsão de radiação solar utilizando como base 12 estações Indianas com diferentes condições climáticas. Para estruturação da rede, utilizou dados de latitude, longitude e insolação (luz do sol) como parâmetros de entrada, contendo apenas uma camada escondida com a função de ativação tan-sigmóide, uma camada de saída com a função de ativação Purelin. A estruturação da rede ocorreu no *software* MATLAB. A proposta de rede neural desenvolvida obteve resultados satisfatórios após sua aplicação, tornando-se adequada para utilização em aplicações de energia solar.

O trabalho de [Mubiru 2011] buscou desenvolver um modelo de previsão capaz de estimar a média diária mensal da radiação solar direta na Uganda, através de dados coletados de 4 diferentes estações meteorológicas, utilizando redes neurais artificiais (RNAs). Através do uso do método *Levenberg-Marquardt*, estruturou uma rede de 6 neurônios capaz de prever a irradiação solar utilizando dados de horas de sol e irradiação (de 2003 a 2005) e temperatura máxima (de 1993 a 2005). Três funções de

transferência foram investigadas, o que incluiu a tangente sigmóide, ingresse sigmóide e função linear. Para a montagem da rede, foi usado o *software* MATLAB. Quando comparada a um modelo empírico, a rede proposta no trabalho mostrou-se superior, trazendo dados mais confiáveis sobre a previsão de irradiação.

O trabalho de [Faceira et al. 2015] propôs um algoritmo capaz de prever a radiação solar horária a curto e médio prazo, transformando os dados de radiação solar medidos em dados de radiação úteis para aplicações de energia. Fazendo uso do método de aprendizagem *Levenberg-Marquardt* e da função Sigmóide de ativação, foram propostos três modelos de RNAs, capazes de prever a radiação solar. Os dados utilizados no estudo foram coletados diariamente de janeiro de 2010 á Dezembro de 2011 em Ponte da Barca - Portugal. Os três modelos propostos foram dispostos da seguinte forma: os modelos I e II continham duas entradas e o modelo III cinco entradas com uma estrutura de feedback, todas utilizando 20 neurônios na camada oculta. Entre todos os dados disponíveis, utilizou-se 75% dos dados, por uma escolha aleatória, para a formação e o restante foi utilizado na fase de teste. Quando comparados, o modelo III trouxe um melhor resultado uma vez que possui um erro menor que 10%, considerado um bom índice de acordo com o estudo.

O trabalho de [Chatziagorakis et al. 2014] estruturou uma rede neural capaz de melhorar a gestão de energias renováveis através da irradiação solar presente. Os dados utilizados na rede foram coletados em um período de dois anos (não especificados) em uma estação próxima a Xanthi, na Grécia. A rede possui uma camada oculta contendo 10 neurônios, onde utilizou-se o algoritmo *Levenberg-Marquardt* para seu aprendizado. O modelo proposto recebe como entrada a medição da irradiação dos três últimos dias, para assim estimar o valor futuro de irradiação. Os testes foram realizados com 96, 24 e 4 amostras/dia, onde foi provado que 24 amostras/dia proporcionou os melhores resultados em termos de precisão e velocidade computacional. Para reduzir o valor de erro, foram retirados os valores de irradiação coletados á noite, que eram sempre igual a zero. Como resultado, o modelo proposto pode ser utilizado para prever a saída dos sistemas fotovoltaicos híbridos e fornecer um *feedback* valioso para sistemas de Gestão de Energia Estratégica.

O trabalho de [Teixeira Júnior et al. 2014] propôs um método que combina uma RNA com uma função de decomposição (*Wavelet*) para gerar a curto prazo uma previsão da irradiação solar. Para estruturação da rede, foi utilizado o *software* MATLAB, contendo 10 dados de entrada, uma camada escondida composta por 19 neurônios artificiais, contendo a função de ativação: tangente hiperbólica e um neurônio na camada de saída com a função de ativação linear. Utilizou 7008 amostras desde janeiro a dezembro para utilizar como entrada. A aplicação do trabalho ocorreu na cidade de Cuiabá. Com palavras próprias, os autores afirmam que a utilização de um método de decomposição junto a RNA, lhes trouxe melhores resultados, quando comparado a um modelo empírico de RNA.

O trabalho de [Vakili et al. 2015] estruturou uma rede neural contendo quatro dados de entrada, sendo eles: velocidade do vento, umidade relativa do ar, temperatura máxima e mínima. Para aprendizado da rede foram utilizados dados de 2012 e 2013 e para testes foram utilizados dados de 2013 e 2014, totalizando em 226 dias utilizados para análise e aplicação do estudo. O autor não especifica a quantidade de neurônios utilizados nas camadas escondidas, nem mesmo o número total de dados de entrada,

citando apenas as variáveis utilizadas, no entanto, aplica o método *Levenberg-Marquardt* para treinamento da rede. Os resultados obtidos com essa rede foram ótimos, pois atingiram um coeficiente de correlação de 0,992, o que representa um valor muito próximo a 1, indicando que a rede atinge quase 100% de confiabilidade.

O presente trabalho apresenta algumas características diferentes dos demais estudados. A primeira delas refere-se ao número de entradas, onde trabalhou-se com 8, sendo elas, temperatura, UV, umidade, velocidade do vento, pressão atmosférica, orvalho, precipitação de chuva e o horário da coleta, totalizando em 15.248 dados meteorológicos de janeiro a abril do ano de 2015, já tratados para importação no *software* MATLAB. Foram realizados testes com redes de diferentes estruturas. Aplicou-se uma variação de 6 até 20 neurônios, onde, atingimos o melhor coeficiente de correlação de 0,97 com a rede de 20 neurônios, a explicação do desenvolvimento do processo, bem como, a apresentação completa dos resultados, está disposta nos próximos capítulos deste estudo. A Tabela 1 apresenta um comparativo entre os trabalhos relacionados a este estudo.

Tabela 1. Comparativo dos Trabalhos Relacionados.

Trabalho	Entradas	Camadas	Saídas	Coeficiente de Correlação	Período/Qtd Dados	Neurônios
[Yadav et al 2012]	4	1	1
[Mubiru 2011]	6	1	1	...	2003 - 2005	6
[Teixeira Júnior et al. 2014]	10	1	1	...	7008	19
[Chatziagorakis et al. 2014]	1	1	1	...	2 anos (não citados)	10
[Faceira et al. 2015]	2 e 5	1	1	20
[Vakili et al. 2015]	4	1	1	0,992	226	...
Este trabalho	8	1	1	0,97	15248	6 á 20

Os trabalhos disponíveis na literatura não seguem um padrão para a criação de uma rede neural conforme visto na Tabela 1. Nota-se também que neste trabalho o foco está essencialmente na implementação de uma rede eficiente, pois a maioria dos trabalhos não descrevem o percentual do coeficiente de correlação R. Isso porque a ideia é usar esta rede para prever a irradiação solar no futuro. Adicionalmente, o número de variáveis usadas neste trabalho é maior que a maioria dos trabalhos disponíveis na literatura em função da variação do clima da Região Noroeste do Estado do Rio Grande do Sul.

3. Metodologia

Para estruturação dos modelos de rede neural, utilizou-se como base para a pesquisa realizada a estação meteorológica¹ da instituição SETREM (Sociedade Educacional Três de Maio), a qual realiza a coleta de dados na latitude 27° 46' e 24" S, longitude 54° 14' e 24" W, altitude 343m. A coleta de dados meteorológicos é realizada pela estação de 1 em 1 minuto, contemplando as 24 horas do dia. A estação meteorológica contém as seguintes funções de coleta de dados:

- pluviômetro (mede a precipitação pluviométrica);
- sensor de temperatura do ar (barômetro);

¹ <http://estacao.setrem.com.br/>

- sensor de umidade;
- anemômetro (mede a velocidade do vento e sua direção);
- sensor de radiação solar;
- sensor de radiação ultravioleta (UV);
- módulo de interface dos sensores (SIM).

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

O SIM envia dados para uma estação de controle chamada Console, que contém um display capaz de apresentar os seguintes dados e informações: velocidade do vento; direção do vento; umidade do ar externo; umidade do ar interno; temperatura externa; temperatura interna; sensação térmica externa; índice temperatura/umidade/insolação/vento; ponto de orvalho; pressão atmosférica atual; tendência da pressão atmosférica nas últimas três horas; precipitação pluviométrica acumulada do mês e do ano; precipitação pluviométrica acumulada no dia atual (desde zero hora); precipitação pluviométrica acumulada nas últimas 24 horas; taxa de precipitação pluviométrica (na últimos 15 minutos); precipitação pluviométrica do último evento ocorrido depois de um período de 24 horas sem chuva; evapotranspiração atual; evapotranspiração acumulada no mês e no ano.

O console, por sua vez, é capaz de comunicar-se com o *software* proprietário *WeatherLink* instalado em um computador com sistema operacional *Windows* (diversas versões). Essa comunicação se faz por meio de uma conexão USB ou por comunicação serial. Na estação meteorológica as medições dos sensores são analógicas e a apresentação das mesmas no console é contínua. No entanto, o registro no banco de dados é determinado por parâmetros do *software WeatherLink*.

Dentre todos os dados coletados pela estação, neste estudo foram utilizados os seguintes como métrica: temperatura; índice UV; umidade do ar; velocidade do vento; barômetro; orvalho; precipitação e hora - totalizando em 8 entradas.

Em busca da utilização de um algoritmo para treinamento da rede neural, realizou-se pesquisas sobre 3 diferentes tipos de métodos para treinamento de redes, sendo eles, BPROP [Bousfield et al. 2008], PBPROP [Carvalho 2009] e *Levenberg-Marquardt* [Carvalho 2009]. Após avaliação de alguns estudos aplicados identificamos que o método *Levenberg-Marquardt* é o mais adequado para o tipo de estudo a ser aplicado, pois, apresenta bons resultados tanto em redes que contém apenas uma camada escondida, como em redes com mais camadas.

A elaboração das RNA's ocorreu através da utilização do *software* MATLAB versão R2009b, de forma estruturada, com base em comandos manuais inseridos no *software* para determinar o número de entradas da rede, camadas escondidas, neurônios e *Target* (y_i). Na Figura 1, apresenta-se a metodologia utilizada no presente estudo, desde a seleção dos dados de entrada até a determinação do melhor modelo de rede neural. Sendo assim, na primeira fase foi feita uma seleção de dados e configuração do treinamento e testes de rede. Na terceira fase, foram desenvolvidos os modelos e selecionados os parâmetros para o treinamento. Por fim, vários modelos de rede foram

treinados, identificados os melhores resultados de erro e a escolha do melhor modelo de rede neural.

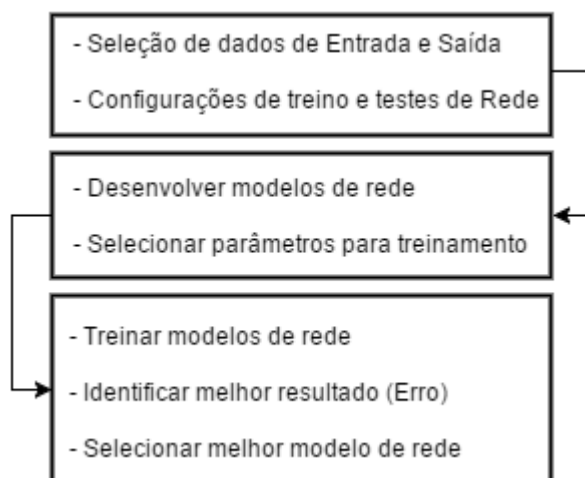


Figura 1. Metodologia utilizada no estudo.

4. Desenvolvimento

Para se dar início a etapa de desenvolvimento do estudo, primeiramente foram coletados da Estação Meteorológica da SETREM os dados referentes aos meses de janeiro até abril do ano de 2015. Contabilizados os dados, totalizaram em 15.248 informações meteorológicas, que foram utilizados como entradas dos modelos de rede neural. Dentre todos os dados que são coletados pela estação, foram selecionados para teste os dados de Temperatura, UV, Umidade, Velocidade do vento, Pressão atmosférica, Orvalho, Precipitação de chuva e o Horário da coleta. Para processar as informações coletadas foram estruturados 15 modelos de rede neural, onde na camada escondida variou-se de 6 a 20 neurônios.

A Tabela 2 apresenta uma amostra dos valores de entradas que foram utilizadas para estruturação das redes neurais, apresentados em forma de colunas. Além destes, mostra-se os resultados mínimos e máximos de cada entrada.

Tabela 2. Dados de Entrada utilizados na estruturação das redes.

	Temparatura	UV	Umidade	Vel. do vento	Barômetro	Orvalho	Precipitação	Hora
	22,2	0	93	1,34	1010	21	0,99	0
Máximo	32,1	10,8	99	6,71	1022	25	36,4	0,997
Mínimo	0	0	0	0	1002	0	0	0

Nos dados, após a coleta realizada pela estação meteorológica, houve a necessidade de realizar alguns ajustes, uma depuração, para posteriormente serem importados no *software* MATLAB. A Figura 2 apresenta o modelo de rede neural utilizado no presente estudo, contendo 8 dados de entrada, conforme especificadas acima, uma camada escondida com os neurônios e funções de ativação.

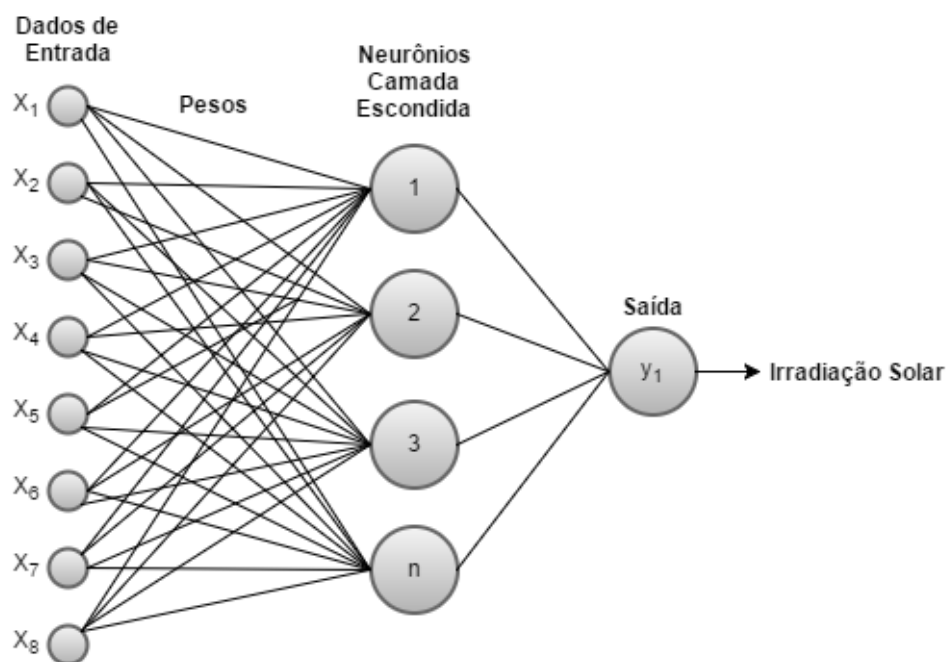



Figura 2. Modelo da estrutura da Rede Neural Artificial.

Para o presente estudo, optou-se por utilizar a função *Log Sigmóide* na camada oculta, e na camada de saída a função *Purelin*, que é uma função de transferência neural responsável por realizar cálculos a partir das entradas disponibilizadas. Uma única camada foi utilizada na rede, testando-a com um número de 6 a 20 neurônios. Quanto maior o número de neurônios, mais flexível a rede se torna, havendo assim mais parâmetros para serem otimizados.



A seguir um resumo da formação da rede:

- 1- Tratar os dados de entrada.
- 2 - Definir o tamanho da matriz de acordo com o conjunto de dados a serem utilizados.
- 3 - Definir o tipo de treinamento e as validações da rede.
- 4 - Criar e Treinar a rede neural.
- 5 - Gerar os valores de saída.
- 6 - Analisar os dados de saída.
- 7 - Comparar os dados de saída com o valor desejado, verificando assim o desempenho da rede. Na Tabela 3, estão dispostos os dados utilizados como pesos, bem como o valor da *target*, onde P representam dados aleatórios provindos da estação meteorológica e

target é a irradiação esperada. Todos estes foram essenciais para realização dos testes de treinamento das redes neurais:

Tabela 3. Pesos e *target* utilizados para testes da rede.

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

5. Resultados

Neste capítulo estão demonstrados os resultados obtidos com o desenvolvimento do trabalho. Nos testes de simulações da rede, foram realizados diversos treinamentos para cada rede estruturada, utilizando os pesos que foram apresentados no desenvolvimento. Para cada estrutura de rede, foram realizadas 10 diferentes combinações utilizando cada uma das redes. Obteve-se os seguintes resultados apresentados na Tabela 4. Na Figura 3, apresenta-se o resultado do *Mean Square Error* (MSE), da rede neural com 20 neurônios na camada oculta.

Tabela 4. Resultados verificados variando o número de neurônio na camada oculta.

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




Figura 3. Mean Square Error (MSE).

Épocas, por definição significa usar todos os dados disponíveis. Na rede que possui 15 mil dados, ele considera somente dez mil e quinhentos (10500), então, desses valores ele percorre grupos de 20 dados e atualiza os parâmetros da rede. Posteriormente, considera outros 20 vetores e assim repetidamente. Desta forma, avaliando o resultado do gráfico apresentado acima (Figura 3), ele considerou 71 vezes esses 10500 vetores de 8 elementos (70% dos 15 mil dados).

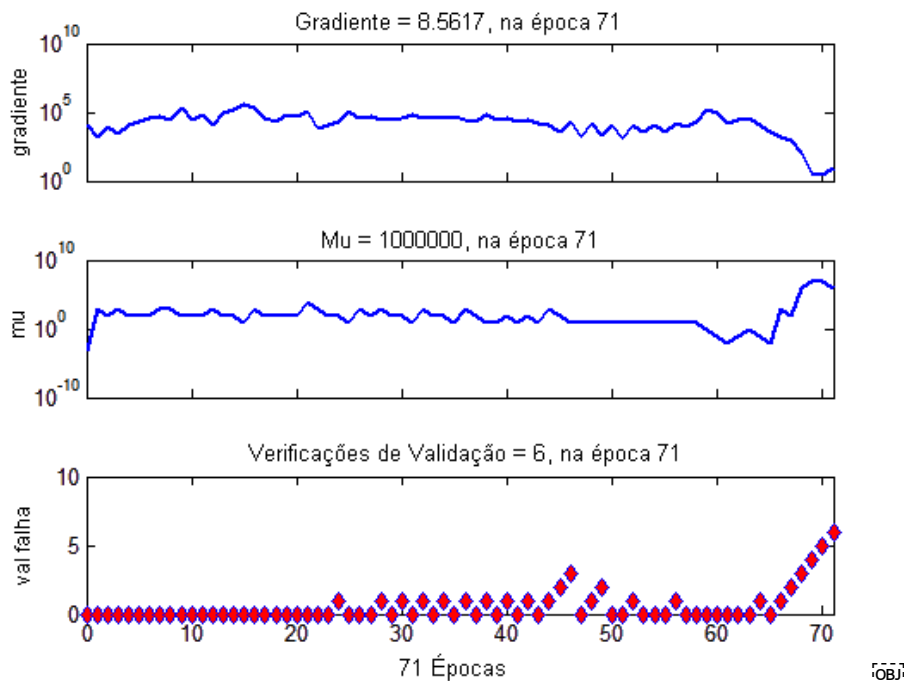


Figura 4. Desempenho do treinamento.

O gradiente representa o grau de inclinação na superfície de erro, e tem como objetivo alcançar o erro mínimo global. Para isso, em cada passo do treinamento, o vetor de pesos utilizado anteriormente é alterado com o objetivo de produzir uma maior

queda na superfície de erro. Quando a inclinação do gradiente diminui, aumenta a distância do erro. E vice-versa.

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

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

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

A rede neural é baseada em uma regressão, onde é apresentada a reta dos dados e com base nisso ele faz uma regressão. Para resultado, quanto mais próximo de 1 melhor. O R diz o quanto ela está próxima dos valores reais.

Nos gráficos da Figura 5, a linha pontilhada na diagonal que parte da origem significa a saída desejada a ser atingida. A linha colorida e contínua, representa a melhor linha de regressão obtida no ajuste linear entre as saídas reais e as saídas desejadas. O valor do Coeficiente de Correlação (R) significa a relação entre a saída real e a saída desejada. Se R for igual a 1, há uma relação linear exata entre a saída real e saída desejada. Caso R for próximo a zero, então a relação linear não existe.

A Figura 5(a) apresenta os resultados de saídas reais de treinamento. A linha é a reta de regressão obtida. Na Figura 5(b), se observa o processo de validação da rede, que apresentou um coeficiente de correlação de 0.97. A Figura 5(c) apresenta os resultados do teste.

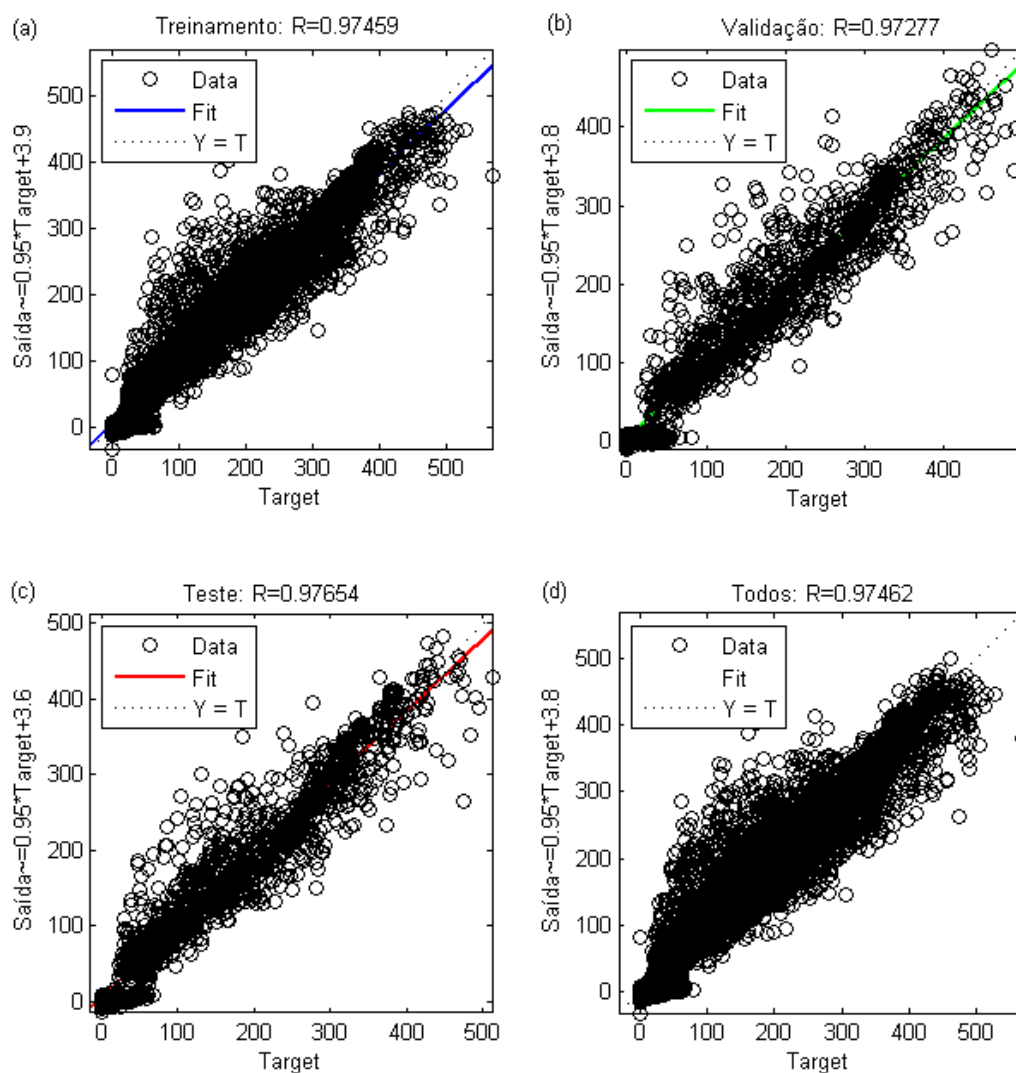


Figura 5. Regression.

Na Tabela 5 encontram-se os resultados obtidos para o *Root Mean Square Error* (RMSE), responsável por medir o desempenho da Rede (que representa a soma dos quadrados dos erros). Os parâmetros de entrada são representados por: TP (temperatura), UV (índice UV), UM (umidade), VV (velocidade do vento), B (barômetro), OR (orvalho), PR (precipitação de chuva), HR (hora).

Tabela 5. RMSE obtido a partir dos modelos de rede criados.

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

Notou-se que a Rede Neural com 20 camadas trouxe os melhores resultados, visto que obteve um melhor desempenho (erro quadrático médio) e o erro menor encontrado (RMSE %), havendo uma pequena diferença entre o resultado previsto e o resultado esperado, conforme visto na Tabela 4. Observou-se também que alguns neurônios trouxeram resultados semelhantes, o que demonstra que quanto mais diferenciado o número de neurônios, mais distantes serão seus resultados, podendo trazer uma melhor visão da importância em utilizar o número correto de neurônios para otimizar o funcionamento da rede.

A irradiação total medida no período de janeiro a abril de 2015 foi de 1211172 W/m², o que significa uma média diária de 1,01 kW/m². Assumindo uma eficiência de 15% a potência instalada seria de 150 W/m². Considerando uma ocupação de 150% da área de um hectare com placas fotovoltaicas, obter-se-ia uma instalação com uma potência de 750 kW. É preciso observar que o período de coleta de dados coincidiu com os meses de verão.

7. Conclusão

Através do desenvolvimento de uma rede neural, buscou-se avaliar a irradiação solar presente na região Noroeste do estado do Rio Grande do Sul, podendo utilizar o método em locais de clima semelhante. A arquitetura da rede projetada possui uma camada de entrada contendo 8 entradas, uma camada escondida com até 20 neurônios, utilizando a função *Purelin* de transferência e uma camada de saída. O algoritmo de treinamento utilizado foi o *Levenberg-Marquardt*.

Considerando os valores de entrada utilizados, temperatura, índices UV, precipitação de chuva, umidade, velocidade do vento, pressão atmosférica, orvalho e hora, comprovou-se que a rede proposta é capaz de realizar uma avaliação de irradiação solar presente na região, pois o coeficiente de correlação a partir dos resultados é de 0.97, de acordo com os dados disponibilizados. A rede mostrou-se flexível quanto ao uso dos dados, podendo ser facilmente alterados sem grandes impactos em sua

funcionalidade. Através dos resultados obtidos, notou-se que com uma rede relativamente simples, utilizando a função log-sigmóide atinge-se bons resultados. Além disso, conclui-se que a região em pauta teria sido capaz de gerar 1.211 kW/h de energia solar (de janeiro a abril do ano de 2015), ou seja, uma potência de 750 kW para uma usina que ocupasse uma área de um hectare, visto que possui boas previsões de irradiação solar, essencial para essa atividade.

Como trabalho futuro, propõem-se estruturar uma Rede com duas camadas ocultas a fim de avaliar o desempenho dela quando comparada a de uma camada oculta. Outro possível trabalho é utilizar um *time delay* para realizar previsões de curto prazo. Por fim, uma vez obtida a irradiação, pode-se calcular a insolação por período de desenvolvimento das plantas, a qual é importante para agricultura.

Referências

- Ahmed, E. A. and Adam, E. (2013) "Estimate of Global Solar Radiation by Using Artificial Neural Network in Qena, Upper Egypt", In: Journal of Clean Energy Technologies, Vol. 1, No. 2, April 2013.
- Bousfield, P. M. (2008) "Uso de uma Rede Neural para a Previsão do Volume de Lodo Gerado em Estações de Tratamento de Efluente: Um Estudo de Caso". UNIVILLE. Joinville: s.n., 2008. Dissertação.
- Carvalho, A. P. L. F. (2009), "Redes Neurais Artificiais. Perceptron Multi-Camadas (MLP)". 2ª ed. São Paulo: Campus. 2009.
- Chatziagorakis, P., Georgoulas, N., Papadopoulou, S., Elmasides, C., Giaouris, D., Seferlis, P., Sirakoulis, G. C., Karafyllidis, I., Papadopoulos, A. I., Stergiopoulos, F., Ziogou, C., Ipsakis, D., Voutetakis, S. and Andreadis, I. (2014) "Application of Neural Networks Solar Radiation Prediction for Hybrid Renewable Energy Systems" In: V. Mladenov et al. (Eds.): EANN 2014, CCIS 459, pp. 133–144, 2014.
- Dienstmann, G. (2009) "Energia Solar: uma Comparação de Tecnologias." Porto Alegre: UFRGS, 2009.
- Faceira, J. A. P. and Salgado, P. (2015) "Prediction of Solar Radiation Using Artificial Neural Networks", In: Springer International Publishing Switzerland. Lecture Notes in Electrical Engineering 321. 2015.
- Mubiru, J. (2011) "Using Artificial Neural Networks to Predict Direct Solar Irradiation", In: Department of Physics, Makerere University, P.O. Box 7062, Kampala, Uganda 2011.
- Júnior, L. A. T., Souza, R. M., Menezes, M. L., Cassiano, K. M., Pessanha, J. F. M. and Souza, R. C. (2014) "Artificial Neural Network and Wavelet Decomposition in the forecast of Global Horizontal Solar Radiation", In: SciELO - Scientific Electronic Library Online, São Paulo-SP 2014.
- Vakili, M., Yazdi, S. S. R., Kalhor, K. and Khosrojerdi, S. (2015) "Using Artificial Neural Networks for Prediction of Global Solar Radiation in Tehran Considering Particulate Matter Air Pollution", In: International Conference on Technologies and Materials for Renewable Energy, Environment and Sustainability, TMREES15. 2015.

Yadav, A. K. and Chandel, S. S. (2012) "Artificial Neural Network based Prediction of Solar Radiation for Indian Stations Centre for Energy and Environment National Institute of Technology", In: International Journal of Computer Applications (0975 – 8887) Volume 50 – No.9, July 2012.