

# ESTUDO DE APLICABILIDADE DO ALGORITMO LEVENBERG-MARQUARDT DE RNA PARA AVALIAÇÃO DE GERAÇÃO DE ENERGIA DE UM SISTEMA FV INSTALADO NO CENTRO OESTE BRASILEIRO

**Elisângela Pinheiro** - elisangelapinheirors@gmail.com

**Ricardo Rütther** - ruther@mbox1.ufsc.br

Universidade Federal de Santa Catarina, Departamento de Pós-Graduação em Engenharia Civil

**Adalberto Lovato** - proflovatosr@gmail.com

Faculdade Horizontina, Departamento de Graduação em Engenharia de Produção

**Resumo.** Este trabalho avalia o uso de redes neurais artificiais na análise de geração de eletricidade de um sistema instalado no município de Itiquira em Mato Grosso, sistema este conectado à rede. Inicialmente, são descritas as características e potencial matemático de tratamento de dados apresentados pelas redes. Em seguida, são testadas várias configurações com o objetivo de buscar a mais adequada ao caso. Foram utilizados 14 meses de dados de geração de energia, de temperatura ambiente, da incidência de radiação solar e da hora do dia para as tecnologias de silício cristalino (a-Si), silício policristalino (p-Si) e silício monocristalino (c-Si), de janeiro de 2015 até março de 2016. A aplicação utilizou o algoritmo de Levenberg-Marquardt. Foram testados modelos com uma camada oculta e uma camada de saída. Na camada oculta foram testadas sete configurações com 5, 10, 15, 20, 25, 30 e 60 neurônios. As funções de transferência foram logsigmoide e purelin. O algoritmo de Levenberg-Marquardt obteve coeficiente de correlação superior a 0,91 para a-si, 0,97, para p-si e 0,96 para c-si, revelando-se adequado a esse tipo de análise.

**Palavras-chave:** Energia solar fotovoltaica. Redes Neurais Artificiais. Estimativa de produção de energia.

## 1. INTRODUÇÃO

Atualmente o fornecimento de energia é um dos grandes problemas mundiais. Seu consumo é crescente, e, o desafio energético é satisfazer esta crescente demanda de energia, proteger as fontes usualmente utilizadas, buscar a exploração por fontes renováveis e, ao mesmo tempo, confrontar a ameaça das mudanças climáticas e redução de emissão de poluentes atmosféricos.

Com a evolução tecnológica de sistemas fotovoltaicos, com células cada vez mais eficientes, conforme apresenta NREL (2016), surgem desafios em áreas complementares, na previsão de incidência de irradiação em um instante futuro, e na avaliação de desempenho de sistemas fotovoltaicos, como é o caso deste estudo.

Essa previsão e avaliação é fundamental para determinar o potencial de energia solar fotovoltaica, auxiliar na administração do despacho de energia e analisar a qualidade da potência obtida.

Uma das formas mais comuns de previsão e avaliação de desempenho de energia solar é a utilização de *softwares*, métodos computacionais e algoritmos de computação inteligente, como as redes neurais artificiais (RNA) que buscam obter as previsões de incidência de radiação e analisar a geração de energias necessárias (GILMAN, DOBOS, & KASBERG, 2012).

Neste contexto, este estudo se propõe a utilizar o algoritmo de *Levenberg-Marquardt*, de rede neural artificial, para avaliar a geração de eletricidade de um sistema fotovoltaico instalado no Centro-Oeste Brasileiro no município de Itiquira/MT. Por meio deste estudo, busca-se analisar o uso de redes neurais artificiais para avaliar o desempenho de um sistema fotovoltaico conectado à rede, objetivando aquilatar se os algoritmos são adequados para este tipo de avaliação.

As contribuições deste artigo serão as seguintes:

a. Avaliar se algoritmos *Levenberg-Marquardt* de redes neurais artificiais é adequado para avaliação de potência gerada por um sistema fotovoltaico conectado à rede.

b. Avaliar se a análise de geração de eletricidade de sistema fotovoltaico conectado à rede utilizando dados de um ano é representativa.

Este artigo está organizado em seis seções: a seção 1 apresenta a importância da utilização de redes neurais na área de energia solar; na seção 2 são discutidos trabalhos relacionados sobre utilização de modelos de redes neurais, contendo uma descrição de como as redes contribuíram na área de geração de energia solar; na seção 3, é apresentada a metodologia utilizada no trabalho; a seção 4, descreve o desenvolvimento das redes e como elas foram testadas de acordo o algoritmo proposto; a seção 5 apresenta os resultados de qual algoritmo é mais adequado para o caso e a seção 6 apresenta uma breve conclusão do trabalho.

## 2. TRABALHOS RELACIONADOS

Os métodos estatísticos computacionais de redes neurais são muito utilizados, pois permitem avaliar o desempenho de sistemas fotovoltaicos (MEKKI et al., 2012), bem como, dimensionar sistemas fotovoltaicos, realizar levantamentos de disponibilidades do recurso solar (FIORIN et al., 2011). Para Mellit et al., (2009) a vantagem de usar uma base de redes neurais em sistemas fotovoltaicos é que a mesma proporciona modelos confiáveis, para estudos de incidência de irradiação, principalmente em áreas isoladas, onde os dados meteorológicos nem sempre são disponíveis, bem como, para a resolução de problemas desde modelagens, simulação e controle destes sistemas.

Alguns dos estudos relacionados com a aplicação de redes neurais artificiais na área de energia solar fotovoltaica foi abordado por Mellit e Kalogirou (2008) e Mellit e Kalogirou (2011), que apresentam uma revisão das principais aplicações e das mais variadas configurações de redes, aplicadas para a previsão de radiação solar.

Estudos em um sistema integrado à edificação e conectado à rede foi realizado em Hon Kong, com a finalidade de verificar o desempenho de uma previsão de curto prazo em tempo real (CHOW et al., 2012). Fiorin et al., (2011) fizeram um comparativo de desempenho de diferentes algoritmos de treinamento (Levenberg-Marquardt, *Resilient Backpropagation*, Gradiente conjugado escalar, Taxa de aprendizagem variável e Taxa de aprendizagem variável com momento) para a análise do parâmetro de radiação solar para São Martinho da Serra - RS.

Na Índia, os pesquisadores Yadav e Chandel, (2012) utilizaram o método Levenberg-Marquardt para a predição de radiação solar. Na Grécia, Chatziagorakis et.al. (2014), também utilizaram o Levenberg-Marquardt para melhorar a gestão de energia através da irradiação solar presente.

Os estudos realizados até o momento, que utilizaram métodos e algoritmos de redes neurais artificiais são mais aplicados em relação ao dimensionamento de sistemas fotovoltaicos para a predição de incidência de radiação, mas nenhum deles pesquisou se as redes neurais são adequadas para analisar a geração de energia de um sistema fotovoltaico integrado na edificação e conectado à rede, conforme proposta deste artigo.

## 3. MÉTODOS

A RNA foi estruturada com dados de desempenho elétrico, temperatura ambiente, temperatura do módulo, irradiância e intervalo de tempo. Sensores de irradiância eram capazes de medir a irradiância global e a total — horizontal e inclinada. O intervalo de tempo entre os registros foi de um em um minuto. O sistema fotovoltaico é composto por seis tecnologias com potência total de 9 kWp, destas seis três são abordadas neste artigo. Sendo: silício monocristalino (c-Si); silício amorfo (a-Si) e silício policristalino (p-Si). O Sistema com as seis tecnologias ocupa uma área de aproximadamente 2.280 m<sup>2</sup> (60x38m).

Primeiramente os dados foram normalizados e depurados, a seguir foram determinadas as variáveis de entrada da rede neural: irradiância, temperatura ambiente e a hora do dia — a um minuto, desde 07h00min até 18h00min. A saída da rede — *target* — foi a energia gerada.

Foi considerado o algoritmo *Levenberg-Marquardt*. Este método conforme apresentado por alguns pesquisadores tem se mostrado mais adequado para este tipo de estudo na área de energia solar e como função de ativação dos neurônios foi utilizada a função sigmoide (FIORIN et al., 2011; MARTINS et al., 2012; Chatziagorakis et al. 2014). O número de camadas ocultas foram duas, conforme (MELLIT et al., 2009; MARTINS et al., 2012). A medida de desempenho da rede foi dada pelo Erro Quadrático Médio (*Mean Squarer Error - MSE*) e pelo coeficiente de correlação R.

Quanto à arquitetura das redes, foram utilizados os parâmetros apresentados na Tab.1.

Tabela 1. Arquitetura da RNA: critérios e quantitativos definidos.

<b>Crítérios</b>	<b>Quantitativos definidos</b>
Número de entradas	(3)
Número de neurônios na camada escondida	{5, 10, 15, 20, 25, 30, 60}
Número de neurônios na camada de saída:	(1)
Função de ativação	Função sigmoide: $\varphi(v) = \frac{1}{1+e^{-v}}$
Função de ativação	Purelin
Algoritmo de rede neural	<i>Levenberg-Marquardt</i>
Crítério de parada	Número de época
Medida de erro adotado	Erro Quadrático Médio (EQM) e Correlação (R)

A arquitetura da RNA tem quatro dados de entrada, sendo: irradiação, temperatura ambiente, e tempo. Na camada escondida foram testados sete quantitativos de neurônios de 5 até 60. Na camada de saída, apenas um neurônio. Como função de ativação, para os neurônios na camada escondida foi utilizada a função sigmoide e para a camada de saída temos a função de ativação purelin. Como critério de parada do treinamento foram utilizados o número de épocas, o valor do Erro Quadrático Médio e o valor do coeficiente de Correlação.

Para processar o treinamento foi utilizado o software MATLAB versão R2015b, License Student.

A Fig. 1 mostra a sequência metodológica do estudo. Primeiramente foi realizada a seleção de dados de entrada e saída da rede. No segundo passo foi configurada a rede, a configuração do treinamento e os testes das redes. E por último aconteceu o treinamento das diversas redes, seguido da seleção da configuração que apresentou melhor resultado.

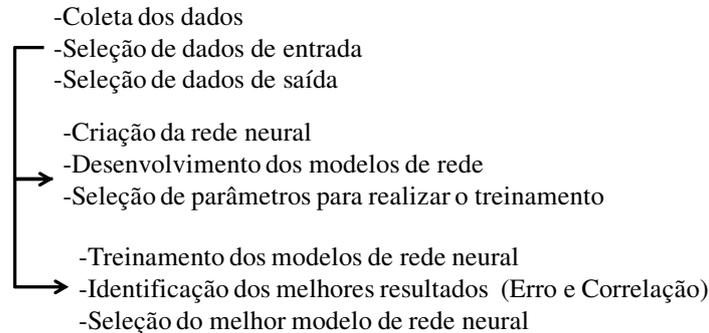


Figura 1 – Sequencia metodológica utilizada no estudo.

#### 4. DESENVOLVIMENTO

No desenvolvimento, primeiramente foram coletados 38266 registros meteorológicos referentes ao ano de 2012 da estação solarimétrica instalada junto ao sistema fotovoltaico. Como dados de entrada da rede, foram utilizados, irradiância incidente no mesmo plano inclinado que o dos módulos fotovoltaicos, temperatura ambiente, e horário da coleta. Como dados de saída, ou Target, foram utilizados dados de potência gerada pelo sistema fotovoltaico.

A Tab. 2 apresenta os valores máximos e mínimos dos dados de entrada e saída (target).

Tabela 2. Valores extremos de dados de entrada e saída utilizadas na estrutura das redes.

	Valores de entrada			Valores de saída		
	Irrad.	Temp. amb.	hora	a-Si	c-Si	p-Si
Máx.	1518,71	39,68	18,00	11140	10109	10120
Mín.	0,94	13,59	7,00	100	100	100

A Fig. 2 mostra a rede utilizada neste artigo, o modelo de rede neural apresenta quatro dados de entrada, uma camada escondida, com neurônios de ativação e uma camada de saída.

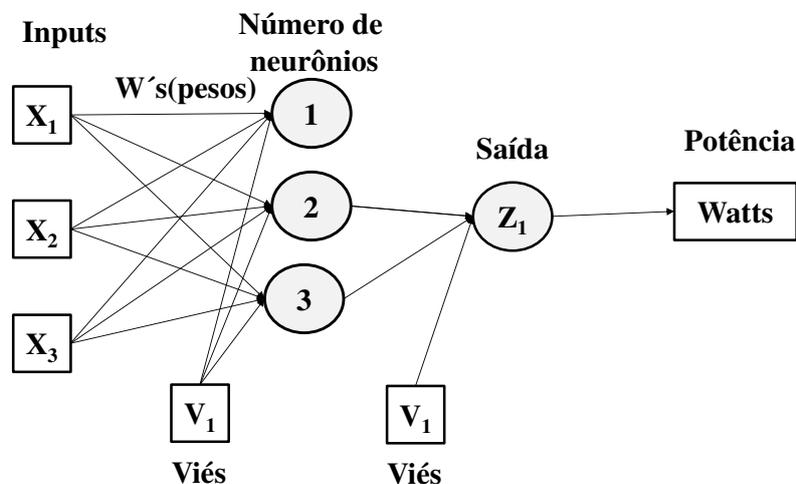
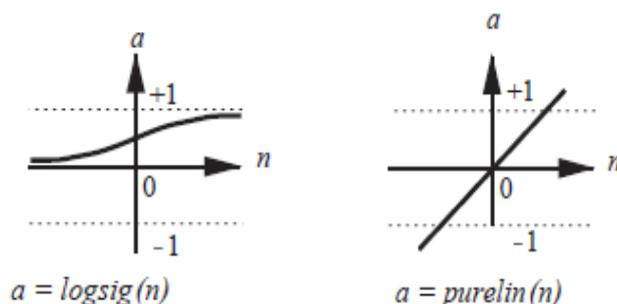


Figura 2 – Estrutura da rede neural artificial construída no estudo.

Como função de transferência neural na camada oculta a função Log Sigmóide e na camada de saída purelin. Estas funções são responsáveis pela realização dos cálculos a partir das variáveis de entrada. Foram realizados testes com 5, 10, 15, 20, 30 e 60 neurônios para cada um dos algoritmos.

A Fig. 3 apresenta o gráfico da função Log Sigmóide representada pela letra a e a letra b mostra o gráfico da função purelin.



Letra a) Função Log Sigmóide

Letra b) Função Purelin

Figura 3: Função Log Sigmoide e Função Purelin. Adaptado Hagan, (2015).

O processo de construção e treinamento da rede seguiu os seguintes passos:

- 1º. tratar os dados de entrada,
- 2º. definir o número de neurônios,
- 3º. definir o percentual de treinamento e validação da rede,
- 4º. desenvolver a rede e treinar a rede,
- 5º. gerar valores de saída,
- 6º. analisar os dados de saída,
- 7º. comparar os dados de saída da rede com valores do Target,
- 8º. Caso não tenha obtido dados satisfatórios retornar à etapa inicial.

Após cada uma das redes ter sido treinada, foram sorteados registros do banco de dados e realizadas simulações com cada uma das redes. Foi então comparado o target obtido na simulação com o target medido.

A Tab. 3 das letras a, b e c mostra três dias do ano que foram sorteados aleatoriamente para cada uma das três tecnologias, considerando um dia correspondente a cada estação do ano. Estes valores foram utilizados para fazer a simulação e para testar a rede neural. A simulação vai ser realizada com a rede mais adequada dos três métodos testados.

Tabela 3. Valores de dados de entrada e saída utilizadas na estrutura das redes.

Hora	Temp. Amb.	Irrad. Global	Pot c-Si Medida	Hora	Temp. Amb.	Irrad. Global	Pot a-Si Medida	Hora	Temp. Amb.	Irrad. Global	Pot p-Si Medida
07:00	23,2	19	135	07:00	23,7	110,5	75,0	07:00	24	110,5	117
08:00	24,4	280	1314	08:00	24,4	279,7	214,2	08:00	24,4	279,7	285
09:00	26,2	172	893	09:00	26,2	171,9	141,4	09:00	25,4	171,9	1478
10:00	27,7	673	3844	10:00	27,7	673,3	591,1	10:00	26,5	673,3	2445
11:00	29,4	571	3676	11:00	29,4	570,6	546,1	11:00	27,8	570,6	2422
12:00	29,8	774	3995	12:00	29,8	774,3	598,8	12:00	29,3	774,3	6533
13:00	30,8	774	5560	13:00	30,8	774,3	767,4	13:00	30,1	774,6	7296
14:00	32,5	135	3996	14:00	32,5	1134,9	850,2	14:00	30,2	1134,9	6822
15:00	30,3	900	5736	15:00	30,3	900,1	843,4	15:00	27,6	900,1	7454
16:00	31,7	758	4077	16:00	31,7	757,6	647,5	16:00	30,2	757,7	5474
17:00	28,6	530	2307	17:00	28,6	529,9	345,1	17:00	26,1	529,9	1484
18:00	25,8	240	931	18:00	25,8	248,4	179,5	18:00	26	248,4	920

## 5. RESULTADOS

Nesta seção estão apresentados os resultados obtidos. Para testar as redes, foram utilizados diversos treinamentos para cada estrutura de rede, com seus devidos pesos, conforme apresentado no desenvolvimento.

Foram aplicados os três mencionados algoritmos com estruturas de 5, 10, 15, 20, 25, 30 e 60 neurônios na camada oculta.

O resultado do MSE e R nas Tab. 4, 5 e 6 de acordo com o número de neurônios na camada oculta para as três tecnologias.

Todas as redes com algoritmos LM para a tecnologia a-Si apresentaram um coeficiente de correlação superior a 0,91 e o menor erro foi para a rede de 60 neurônio.

Tabela 4. Valores de simulações das redes Levenberg-Marquardt algorithm.

Neurônios	EQM (MSE)	Época	Correlação (R) Levenberg-Marquardt			
			Treinamento	Validação	Teste	Todos
5	0,0073	48	0,893	0,893	0,893	0,893
10	0,0073	14	0,894	0,896	0,893	0,894
15	0,0074	16	0,897	0,894	0,896	0,896
20	0,0071	46	0,900	0,899	0,897	0,900
25	0,0076	14	0,895	0,892	0,894	0,894
30	0,0068	207	0,904	0,902	0,902	0,903
<b>60</b>	<b>0,0067</b>	<b>205</b>	<b>0,906</b>	<b>0,905</b>	<b>0,906</b>	<b>0,906</b>

Para a tecnologia p-Si o coeficiente de correlação foi superior a 0,97 e o menor erro foi para a rede de 25 neurônio. Vide Tab. 4.

Tabela 5. Valores de simulações das redes Levenberg-Marquardt algorithm.

Neurônios	EQM (MSE)	Época	Correlação (R) Levenberg-Marquardt			
			Treinamento	Validação	Teste	Todos
5	4902041	3	5,855	7,605	-4,136	9,606
10	4884975	2	0,006	0	7,605	0,005
15	279212	50	0,971	0,971	0,969	0,971
20	273044	49	0,972	0,971	0,972	0,972
<b>25</b>	<b>260602</b>	<b>80</b>	<b>0,973</b>	<b>0,973</b>	<b>0,972</b>	<b>0,973</b>
30	271458	171	0,972	0,972	0,973	0,972
60	271030	91	0,973	0,971	0,972	0,973

Para a tecnologia c-Si o coeficiente de correlação foi superior a 0,96 e o menor erro foi para a rede de 15 neurônio. Vide Tab. 5.

Tabela 6. Valores de simulações das redes Levenberg-Marquardt algorithm.

Neurônios	EQM (MSE)	Época	Correlação (R) Levenberg-Marquardt			
			Treinamento	Validação	Teste	Todos
5	42641222	3	-9,52	-2,12	-1,37	1,31
10	306565	24	0,963	0,964	0,962	0,963
<b>15</b>	<b>275286</b>	<b>62</b>	<b>0,967</b>	<b>0,967</b>	<b>0,965</b>	<b>0,967</b>
20	282432	49	0,966	0,966	0,965	0,966
25	294757	75	0,964	0,965	0,964	0,964
30	295891	34	0,963	0,965	0,964	0,964
60	546348	101	0,933	0,934	0,931	0,933

São apresentados os gráficos de do MSE, dos gradientes, do Mu, a validação e a correlação para as melhores redes das três tecnologias.

O gradiente mostra o grau de inclinação da rede na superfície do erro quando busca alcançar o erro mínimo global. Em cada etapa do treinamento, o vetor de peso utilizado anteriormente é alterado com objetivo de provocar a maior queda na superfície deste erro.

O MU está relacionado com a abcissa. Ele é a distância entre o valor da abcissa do ponto mínimo e o valor no ponto em que a tangente a superfície intercepta esta abcissa. Por esta razão à medida que o erro se aproxima de zero o Mu aumenta.

A validação ocorre quando altera os pesos de uma iteração não existe mudança no valor do erro. Quando isso ocorre um certo número de vezes infere-se que foi atingido o ponto mínimo. Neste estudo o número de repetições sem alteração foi limitado em seis.

A verificação de validação, indica que foram realizadas seis iterações consecutivas e o resultado não sofreu mais alteração, com isso, o teste é finalizado, conforme destacado com um círculo na cor preta nos gráficos de todas as tecnologias.

As Fig. 4, 5 e 6 mostram o gráfico da correlação para a três tecnologias.

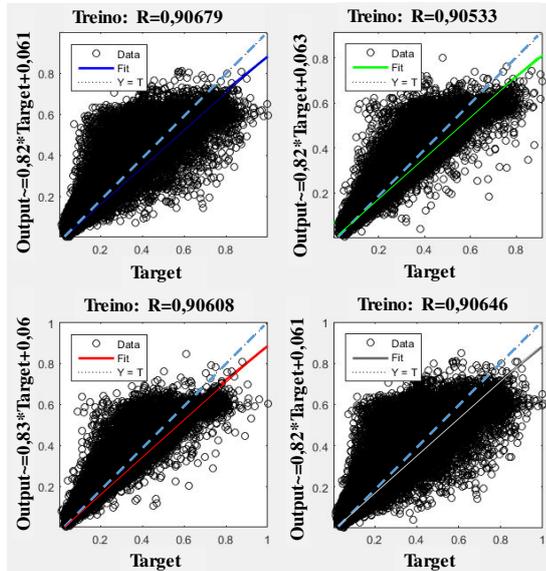


Figura4 - Regressão com 60 neurônios para a tecnologia a-Si.

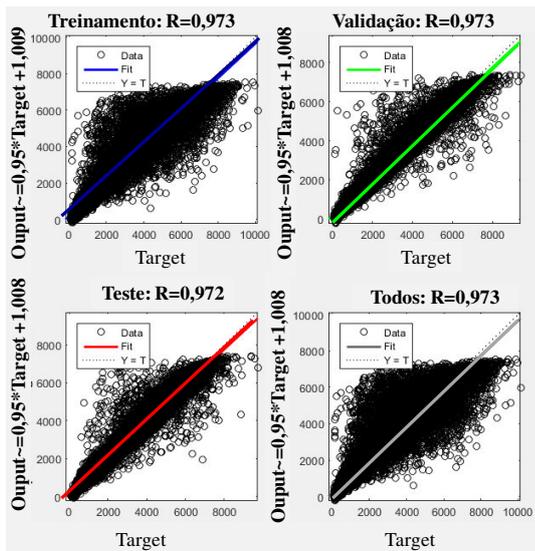


Figura 5 - Regressão com 25 neurônios para a tecnologia p-Si.

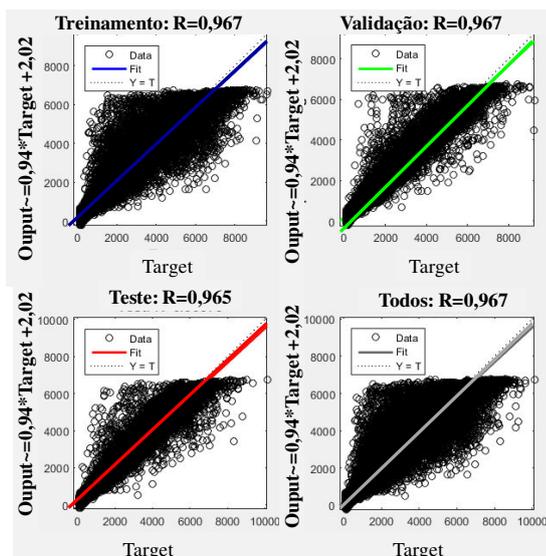


Figura 6 - Regressão com 15 neurônios para a tecnologia c-Si.

Diante dos resultados apresentados por cada uma das tecnologias, foram feitas simulações com a rede que apresentou uma melhor correlação pelo algoritmo LM. Foram selecionados aleatoriamente um dia do ano para cada tecnologia e a potência obtida pela simulação foi comparada com a potência medida no sistema fotovoltaico.

A Tab. 7 mostra valores dos dados de entrada, os valores das potências medidos e os valores de potência obtidos pela simulação. Os gráficos para cada um dos dias aparecem nas Fig. 7, 8 e 9. Nas abscissas está a hora do dia e na ordenadas a potência em Watts (W).

Tabela 7. Valores de simulações das redes.

Tecnologia	Hora	Temp.Amb.	Irrad. Global	Pot Medida	Pot. Simulada
a-si	07:00	23,70	110,52	75,00	<b>97,06</b>
	08:00	24,40	279,72	214,20	<b>210,84</b>
	09:00	26,20	171,96	141,48	<b>96,96</b>
	10:00	27,70	673,32	591,12	<b>501,72</b>
	11:00	29,40	570,6	546,12	<b>450,96</b>
	12:00	29,80	774,36	598,80	<b>678,72</b>
	13:00	30,80	774,36	767,40	<b>669,00</b>
	14:00	32,50	1134,96	850,20	<b>697,68</b>
	15:00	30,30	900,12	843,48	<b>706,32</b>
	16:00	31,70	757,68	647,52	<b>555,12</b>
p-si	17:00	28,60	529,92	345,12	<b>352,68</b>
	18:00	25,80	248,4	179,52	<b>185,64</b>
	07:00	23,7	110,5	117,0	<b>230,0</b>
	08:00	24,4	279,7	285,0	<b>386,8</b>
	09:00	26,2	171,9	1478,0	<b>2027,0</b>
	10:00	27,7	673,3	2445,0	<b>2919,0</b>
	11:00	29,4	570,6	2422,0	<b>6048,0</b>
	12:00	29,8	774,3	6533,0	<b>6860,0</b>
	13:00	30,8	774,6	7296,0	<b>7187,0</b>
	14:00	32,5	1134,9	6822,0	<b>6800,0</b>
15:00	30,3	900,1	7454,0	<b>6487,6</b>	
16:00	31,7	757,7	5474,0	<b>5753,5</b>	
17:00	28,6	529,9	1484,0	<b>1524,4</b>	

	18:00	25,8	248,4	920,0	<b>825,7</b>
	07:00	24	19	135	<b>265</b>
	08:00	24,4	280	1314	<b>1690</b>
	09:00	25,4	172	893	<b>773,54</b>
	10:00	26,5	673	3844	<b>4287</b>
	11:00	27,8	571	3676	<b>3866</b>
c-si	12:00	29,3	774	3995	<b>5311</b>
	13:00	30,1	774	5560	<b>5338</b>
	14:00	30,2	1135	3996	<b>6414</b>
	15:00	27,6	900	5736	<b>5667,3</b>
	16:00	30,2	758	4077	<b>4501</b>
	17:00	26,1	530	2307	<b>3087</b>
	18:00	26	240	931	<b>1292</b>

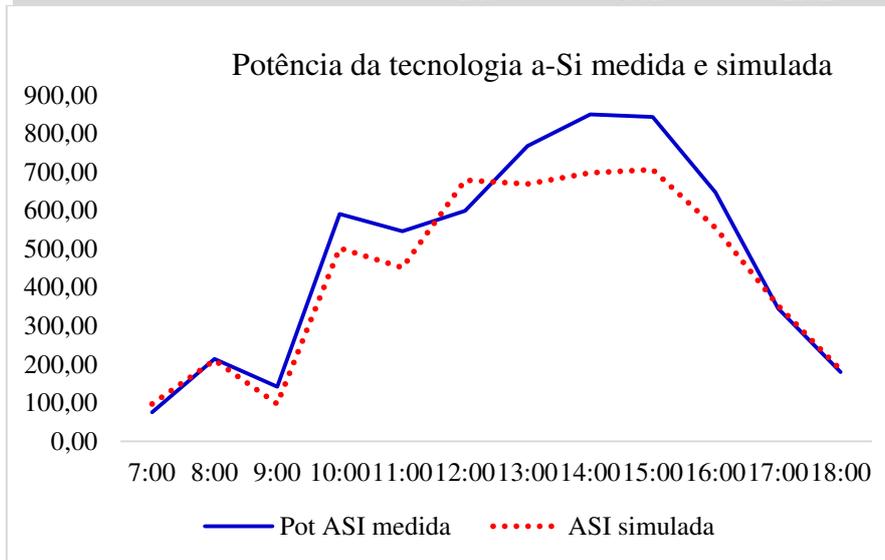


Figura 7- Comparativo de potência medida em Watts (W) com a potência simulada para a estação do Inverno.

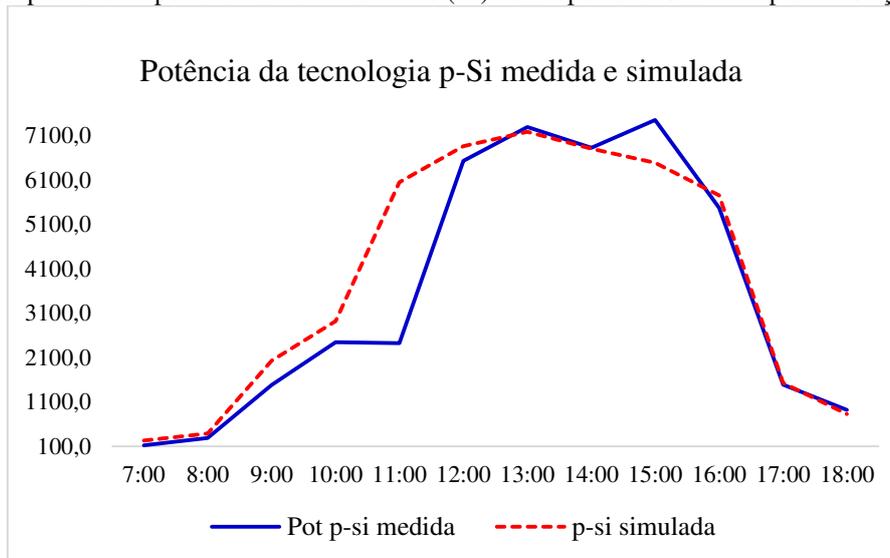


Figura 8 - Comparativo de potência medida em Watts (W) com a potência simulada para a estação do Outono.

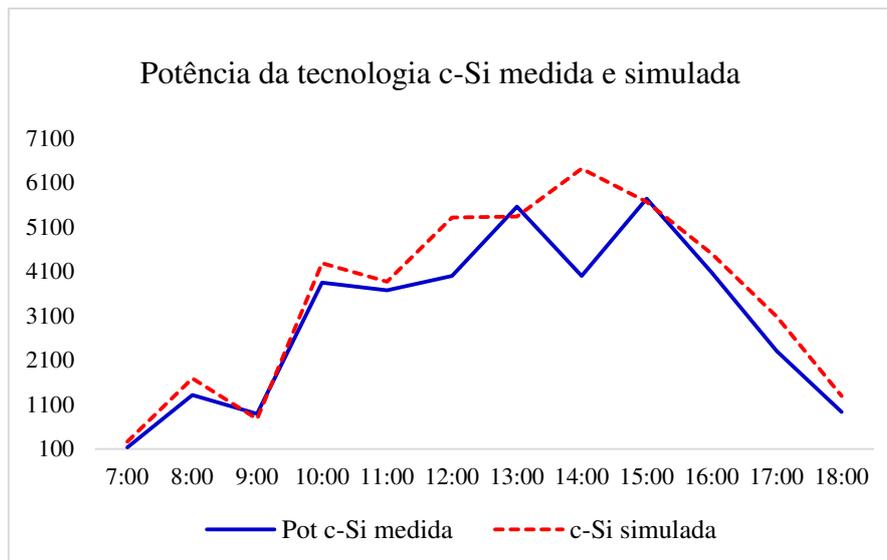


Figura 9- Comparativo de potência medida em Watts (W) com a potência simulada para a estação do Verão.

## 6. CONCLUSÕES

Com o desenvolvimento de redes neurais artificiais, buscou-se analisar a geração de eletricidade de um sistema fotovoltaico, conectado à rede, instalado no município de Itiquira-MT. As arquiteturas das redes construídas possuíam uma camada de entrada com três entradas, uma camada escondida com 5, 10, 15, 20, 25, 30 e 60 neurônios, como função de transferência a log Sigmóide e de saída a purelin. O algoritmo de treinamento foi Levenberg-Marquardt. Considerando os valores de entrada irradiação incidente na mesma inclinação que os módulos fotovoltaicos, temperatura ambiente e horários, comprovou-se que as redes propostas são capazes de realizar ótimas análises de potência de um sistema fotovoltaico com resultados de correlação de 0,90 até 0,97 e em destaque a rede construída com 20 neurônios na camada escondida que obteve uma correlação de 0,97 para o algoritmo Levenberg-Marquardt. Conforme resultados obtidos conclui-se que o método Levenberg-Marquardt é adequado para análise de potência de um sistema fotovoltaico.

## REFERÊNCIAS

- Chatziagoraki S.P., Georgoulas. Papadopoulou, S. Elmasides, C., Giaouris, D., Seferlis, P., Sirakoulis, CH.G., Karafyllidis, I., Papadopoulos, A. I., Stergiopoulos, F., Ziogou, C., Ipsakis, D., Voutetakis, S. e Andreadis, I. Application of Neural Networks Solar Radiation Prediction for Hybrid Renewable Energy Systems. *Engineering Applications of Neural Networks*, v. 459, p. 133-144, 2014.
- Chow, S. K. H.; Lee, E. W. M.; Li, D. H. W. Short-term prediction of photovoltaic energy generation by intelligent approach. *Energy and Buildings*, v. 55, p. 660–667, 2012. Elsevier B.V. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S037877881200415X>>.
- Fiorin, D. V; Martins, F. R.; Schuch, N. J. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. *Revista Brasileira de Ensino de Física*, v. 33, n. 1, p. 1309 1 – 1309 20, 2011.
- Gilman, A. Dobos; Kasberg, M. P50/P90 Analysis for Solar Energy Systems Using the System Advisor Model, NREL, May 13-17, 2012. Disponível em: <<http://www.nrel.gov/docs/fy12osti/54488.pdf>>.
- Hagan, Martin T.; Demuth, Howard B.; Beale, Mark Hudson; JESÚS, Orlando De. *Neural Network Design*. 2ª Ed. eBook, 2014.
- Martins, F. R.; Pereira, E. B.; Guarnieri, R. A. Solar radiation forecast using artificial neural networks. *International Journal of Energy Science*, v. 2, n. December, p. 217–227, 2012.
- Mekki, A., Aloui, F., Dhoub, A., Sayadi, S. Effects of Phanerochaete chrysosporium on biologic activity of soil amended with olive mill wastewaters. *Journal of Soil Science and Environmental Management* v. 3, n.1, p. 1-8, 2012.
- Mellit, A.; Kalogirou, S. A.; Hontoria, L.; Shaari, S. Artificial intelligence techniques for sizing photovoltaic systems: A review. *Renewable and Sustainable Energy Reviews*, v. 13, n. 2, p. 406–419, 2009. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1364032108000051>>.
- Mellit, A.; Kalogirou, S. A. Anfis-based modelling for photovoltaic power supply system: A case study. *Renewable Energy*, v. 36, n. 1, p. 250–258, 2011. Elsevier Ltd. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0960148110002843>>.
- Mellit, A.; Kalogirou, S. A. Artificial intelligence techniques for photovoltaic applications: A review. *Progress in Energy and Combustion Science*, v. 34, n. 5, p. 574–632, 2008.

NREL. National Renewable Energy Laboratory: Research Cell Efficiency Records. 2015. Disponível em: <<http://www.nrel.gov/ncpv/>>. Acesso em: junho de 2016. [http://www.nrel.gov/ncpv/images/efficiency\\_chart.jpg](http://www.nrel.gov/ncpv/images/efficiency_chart.jpg)  
Yadav, A. K.; Chandel, S. . Artificial Neural Network based Prediction of Solar Radiation for Indian Stations. International Journal of Computer Applications, v. 50, n. 9, p. 1–4, 2012.

#### **APPLICABILITY STUDY OF THE LEVENBERG-MARQUARDT ALGORITHM FOR EVALUATION OF ENERGY GENERATION OF A PV SYSTEM INSTALLED IN THE CENTER WEST BRAZILIAN**

**Abstract.** *This paper talk about the use of artificial neural networks in the analysis of electricity generation of a system installed in the county of Itiquira in Mato Grosso, system connected to the grid. First, the characteristics and mathematical potential of data processing presented by networks are described. Then, several configurations were tested in order to find the most appropriate one. It was used 14 months of energy generation data, ambient temperature, the incidence of solar radiation and time of day for the technologies of crystalline silicon (a-Si), polycrystalline silicon (p-Si) and monocrystalline silicon (c- Si), from January 2015 to March 2016. The application used the Levenberg-Marquard algorithm. Were tested models with a hidden layer and an output layer. In the hidden layer seven configurations were tested with 5, 10, 15, 20, 25, 30 and 60 neurons. The transfer functions were logsigmoid and purelin. The Levenberg-Marquard algorithm obtained a correlation coefficient higher than 0.91 for a-si, 0.97 for p-si and 0.96 for c-si, proving to be adequate for this type of analysis.*

**Key words:** *Photovoltaic solar energy, artificial neural networks, Estimate of energy production.*