

REVISTA BRASILEIRA DE ENERGIAS RENOVÁVEIS

APLICABILIDADE DE REDES NEURAS ARTIFICIAIS PARA ANÁLISE DE GERAÇÃO DE ENERGIA DE UM SISTEMA FOTOVOLTAICO CONECTADO A REDE ELÉTRICA¹

ARTIFICIAL NEURAL NETWORK OF APPLICATION FOR POWER GENERATION ANALYSIS OF A SYSTEM PHOTOVOLTAIC CONNECTED TO MAINS¹

ELISÂNGELA PINHEIRO², ADALBERTO LOVATO³, RICARDO RÜTHER⁴

¹Aceito para Publicação no 4º Trimestre de 2017.

²Doutoranda do Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Santa Catarina (UFSC), Florianópolis, SC. elisangelapinheirors@gmail.com;

³Professor do Curso de Graduação em Engenharia de Produção da Faculdade Horizontina (FAHOR), Horizontina, RS. proflovato@terra.com.br;

⁴Professor Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Santa Catarina (UFSC), Florianópolis, SC. ruther@mbox.ufsc.br.

Resumo

Fontes de energia flutuantes, como a solar, estão aumentando sua participação na matriz energética. Concomitantemente está aumentando a dependência dessa energia e consequentemente, novos métodos de previsão de suprimento precisam ser desenvolvidos. Redes neurais artificiais têm sido usadas para prever a irradiação solar com sucesso. No entanto seu uso na previsão da energia futura disponível não tem sido explorado. O algoritmo de *Levenberg-Marquard* foi usado em diversas configurações que foram treinadas com a aplicação da função de transferência *logssigmoide* na camada oculta e *purelin* na camada de saída. Os dados de entrada foram a irradiação solar, a temperatura ambiente, a temperatura dos módulos solares e a hora do dia. Os dados de target foram os valores da energia produzida. O treinamento

foi realizado com 5, 10, 15, 20, 25, 30 e 60 neurônios na camada oculta. O melhor resultado foi obtido com 30 neurônios, com coeficiente de correlação de 0,98.

Palavras-chave: Energia solar. Redes neurais artificiais. Simulação da produção de energia. Algoritmo de Levenberg-Marquard.

Abstract

Fluctuating power sources, like solar, are getting an increasing share in the integrated grid. As share are increasing, so also dependability is growing and new methods to foresee its availability are necessary. Artificial neural network has long been used to predict solar irradiation. However, actual accomplishment in predicting power output had to be tested. Levenberg-Marquard was used with several configurations and trained with *logsigmoid* transfer function in one hidden layer and *purelin* function in the output layer. Input data were local irradiance, ambient temperature, cell temperature and time of the day. Target data was power output. Training was done with 5, 10, 15, 20, 25, 30 and 60 neurons in the hidden layer. Best result was obtained with 30 neurons at 0.98 correlation coefficient.

Keywords: Solar power. Artificial neural network. Power output simulation. Levenberg-Marquard algorithm.

1 INTRODUÇÃO

A geração de energia elétrica é fator essencial para a qualidade de vida e para o desenvolvimento econômico e social. É uma componente essencial para o desenvolvimento produtivo e tanto seu custo, quanto a sua qualidade afetam diretamente os consumidores. Seu consumo é crescente, e, o desafio energético mundial 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 emissão de poluentes atmosféricos.

A utilização da radiação solar para a geração de energia, tem crescido nos últimos anos. O Brasil, dispõe de grande potencial, uma vez que recebe elevada radiação solar durante todo o ano. O crescimento de sua capacidade instalada, aliada a evolução tecnológica com células cada vez mais eficientes, que podem chegar a 44,4% em condições bastante específicas de laboratório (NREL, 2016). Mas existe um fator, que pode ser considerado como ponto fraco,

que é a flutuação da irradiação solar. O que torna a previsão de fornecimento de energia elétrica de usinas solares uma questão importante.

O setor de geração de energia elétrica de forma geral, enfrenta desafios e incertezas porque a energia elétrica se caracteriza pelo sincronismo entre consumo e geração. Deste modo, para que a demanda variável no tempo seja atendida, a disponibilidade de energia deve sempre corresponder ao exato valor da demanda. Qualquer desequilíbrio entre geração e demanda afeta negativamente a qualidade da eletricidade fornecida, (LACCHINI et al., 2016). Isto é, sua confiabilidade e estabilidade. Sendo assim, a análise de geração elétrica de fonte solar é fundamental para determinar o potencial de energia disponível, para auxiliar na administração de seu despacho.

Para a geração de energia elétrica de fonte solar, a variabilidade na incidência de radiação é um dos principais problemas, ocorrem devido à influência do clima como umidade, poeira, temperatura, aerossóis e espectro na produtividade de sistemas fotovoltaicos conforme abordado pelos seguintes estudos (BURGER; RÜTHER, 2006 ; RUTHER et al., 2008; RÜTHER et al., 2010; MEKHILEF et al., 2012; MERAL; DINER, 2011; YERLI et al., 2010; MARION, 2010; SINHA et al., 2013; GAETANI et al., 2014; GOTTSCHALG et al., 2004; MINEMOTO; TODA; et al., 2007; ISHII et al., 2011; ZORRILLA-CASANOVA et al., 2012).

A previsão da incidência de radiação solar tem sido objeto de estudos amplos e detalhados pois requer a consideração de um número considerável de variáveis de comportamento aleatório. A previsão da energia a ser fornecida por um sistema fotovoltaico eleva ainda mais essa complexidade pois acrescenta novas variáveis e novas restrições.

Uma das formas mais comuns de previsão e análise de geração de energia solar é a utilização de *softwares*, métodos computacionais e algoritmos de computação inteligentes, como as redes neurais artificiais que buscam obter as predições de incidência de radiação e analisar a geração de energia necessária (GILMAN & KASBERG, 2012).

Os métodos de redes neurais têm sido utilizados para solucionar problemas nas mais variadas áreas, como engenharia, economia, medicina, campo militar, campo marinho, entre outros. Eles também têm sido aplicados para a modelagem, identificação, otimização, previsão e controle de sistemas complexos (MELLIT 2008). Como exemplo destas aplicações, podemos citar o trabalho de Melo, (2012), que utilizou redes neurais para desenvolver um método de estimativa do consumo de energia de edificações comerciais. Temos também o trabalho de Versage, (2015), que desenvolveu metamodelos de redes neurais para estimar a carga térmica

de edificações condicionadas. Também Fonseca, (2015), utilizou rede neurais para um estudo de iluminação natural e consumo energético de edificações não residenciais.

No setor de energia solar fotovoltaica, os métodos computacionais de redes neurais foram utilizadas para a otimização do desempenho de inversores (MEKKI et al., 2007 e SABERIAN et al., 2014). Fiori, et.al. (2011) utilizaram para levantar a disponibilidades de irradiação solar. Para Mellit et al., (2009) a vantagem de usar uma base de redes neurais em sistemas fotovoltaicos é que a mesma proporciona boa previsão da incidência de irradiação, principalmente em áreas isoladas, onde os dados meteorológicos nem sempre são disponíveis. E também, para auxiliar a resolução de problemas de modelagens, de simulações e de controles destes sistemas (CHATZIAGORAKIS et al., 2014). Um dos problemas que ainda se enfrenta são os estudos referente a geração de energia, conforme Larson et al., (2016), pouco explorado a nível mundial. **Portanto, o problema desta pesquisa é: Existe uma rede neural adequada para a previsão de energia elétrica de um sistema fotovoltaico?**

No Brasil nenhum estudo de predição e análise de potência de sistemas fotovoltaicos foi realizado. Neste contexto, este estudo se propõe a utilizar os algoritmos de *Levenberg-Marquart*, de rede neural artificial, para estudo de análise de potência gerada de um sistema fotovoltaico conectado à rede (SFVCR) e integrado a uma edificação, instalado no Brasil, que se encontra em operação desde setembro de 1997, localizado no prédio de Engenharia Mecânica da Universidade Federal de Santa Catarina (UFSC) em Florianópolis.

Por meio deste, objetiva-se identificar se para o sistema em questão os métodos de redes neurais são adequados para a análise de potência do sistema.

Para tanto, os objetivos específicos são:

- a. Construir sete configurações diferentes de redes com 5, 10, 15, 20, 25, 30 e 60 neurônios.
- b. Identificar dos sete tipos de redes propostas, qual a rede que apresenta melhor coeficiente de desempenho.
- c. Utilizar a rede de melhor coeficiente de desempenho para comparar os dados de potência medidos no sistema fotovoltaico em relação aos dados de potência previstos pela rede.

Este artigo, está organizado em cinco 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 com o algoritmo; a seção 5 apresenta os resultados de qual rede é mais adequada para o estudo de caso e a seção 6 apresenta uma breve conclusão do trabalho.

2. TRABALHOS RELACIONADOS

Estudos relacionados com a aplicação de redes neurais na área de energia solar fotovoltaica foram abordados por Mellit e Kalogirou (2008) e Mellit e Kalogirou (2011), os quais, apresentam uma revisão das principais aplicações e várias configurações de redes neurais, aplicadas para a previsão de incidência de radiação solar.

Para um sistemas integrado à edificação em Hon Kong, foram realizados estudos para verificar o desempenho de uma previsão de radiação de curto prazo em tempo real (CHOW et al., 2012). Já Fiorin et al., (2011) realizaram 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 da incidência de radiação solar para São Martinho da Serra - RS.

Na Índia os pesquisadores Yadav; 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. Observou-se que, os estudos realizados até o momento, que utilizaram métodos e algoritmos de redes neurais artificiais são mais aplicados em relação ao dimensionamento de inversores em sistemas fotovoltaicos e para a predição de incidência de radiação. Nenhum deles utiliza redes neurais para analisar a geração de energia elétrica de um sistema fotovoltaico.

Portanto, este artigo apresenta algumas características diferentes das já estudadas e apresentadas. São utilizados quatro valores de entrada e realizados testes com redes de diferentes estruturas. Aplicou-se variações de 5, 10, 15, 20, 25, 30 e 60 neurônios na camada escondida, em que se obteve coeficientes de correlação superior a 0,98.

A Tabela 1 mostra os valores de entrada, o número de neurônios na camada de entrada, o número de neurônio de saída e a função de ativação. Mostra também, a estrutura deste estudo,

com quatro neurônios de entrada, uma camada escondida um neurônio de saída e função sigmoide.

Tabela 1 – Comparativo de trabalhos relacionados.

| Autores | Nº de entradas | Nº de camadas | Nº de saídas | Função de ativação | Neurônios |
|----------------------------|-----------------------|----------------------|---------------------|---------------------------|------------------|
| Solmaz e Ozgoren, 2010 | 3 | 1 | 1 | - | 10 |
| Mubiru, 2011 | 3 | 1 | 1 | Sigmóide | 6 |
| Yadav e Chandel. 2012 | 3 | 1 | 1 | Sigmóide | - |
| Martins et al., 2012 | 36 | 2 | 1 | Hiperbólica | 36/18 |
| Junior et al., 2014 | 10 | 1 | 1 | Hiperbólica | 19 |
| Chatziagorakis et.al. 2014 | 1 | 1 | 1 | - | 10 |
| Este estudo | 4 | 1 | 1 | Sigmóide | 30 |

O trabalho de Chatziagorakis et.al. (2014) estruturou uma rede neural para melhorar a gestão de energia com dados de irradiação e de uma estação solarimétrica em Xanthi na Grécia. A entrada foram valores históricos de irradiação e a saída, foi estimativa de um valor futuro desta irradiação. O objetivo daquele estudo foi similar ao presente, porem aplicado na administração de potência gerada para aquele cenário climático. Realizou testes com diversas redes para selecionar de melhor resultado e depois comparou dados simulados com dados de potência medidos. O diferencial do presente estudo, está na utilização de maior número de variáveis de entrada – temperatura ambiente, temperatura do módulo, irradiação e a hora do dia- seguido da seleção da rede de menor erro e melhor correlação e, por fim, a simulação da rede selecionada cujos resultados de saída foram comparados com valores reais de potência.

3 MÉTODOS

A base de dados utilizada para a estruturação da rede refere-se ao período de 21 de dezembro de 2011 até 20 de março de 2012. O sistema é de 2 kWp, composto por módulos de silício amorfo hidrogenado (a-Si:H) de dupla junção, sensores de irradiância direta e global, sensor de temperatura ambiente e de temperatura dos módulos. O sistema, acumula dados de desempenho elétrico, temperatura e irradiância a intervalos de cinco minutos.

Inicialmente, foram selecionadas as variáveis de entrada da rede, valores de irradiância, temperatura do módulo, temperatura ambiente e o tempo num intervalo de cinco em cinco minutos das 07h00min até 18h00min.. Os dados foram normalizados e depurados. As

saídas da rede, *targets*, foram os valores de energia gerada no mesmo período e nos mesmos intervalos.

O algoritmo utilizado para o treinamento de rede, foi o *Levenberg-Marquardt*, que, conforme estudos apresentados por autores Bousfield, (2008), Fiorin et al., (2011) e Chatziagorakis et al., (2014). É o mais adequado para o caso.

Na construção da arquitetura da rede, foram utilizados os parâmetros que estão apresentados na Tabela 2.

Tabela 2 – Arquitetura da rede neural proposta para o estudo.

| Critérios | Quantitativos definidos |
|---|--|
| Número de entradas | (4) |
| 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 do neurônio de saída | Purelin |
| Algoritmo de rede neural | <i>Levenberg-Marquardt</i> |
| Critério de parada | Número de épocas |
| Medida de erro adotado | Erro Quadrático Médio (EQM) |
| Correlação | R>0,90 |

Os cálculos foram realizados com o *software* MATLAB versão R2015b.

Para o treinamento das redes neurais os dados foram divididos em três subconjuntos, o primeiro utiliza 70% do total dos dados, selecionados aleatoriamente. Para validar os dados é utilizado outro subconjunto de 15% selecionado aleatoriamente entre os 30% não utilizados no treinamento. Para testar a rede foi utilizado o terceiro subconjunto de 15% dos dados.

Com os melhores resultados de erro e correlação, foi selecionado o melhor modelo de rede neural. Com este, foram realizadas simulações cujos resultados foram comparados com valores reais.

4 DESENVOLVIMENTO

O treinamento da rede foi realizado com dados de dezembro de 2011 e janeiro, fevereiro e março de 2012. Foram 14.513 informações meteorológicas (dados de temp. ambiente, temp. do módulo, irradiação e hora do dia). Os valores do *target* foram os da potência gerada nos mesmos intervalos.

A Tabela 3 apresenta os valores máximos e mínimos dos dados de entrada e saída (*target*) da rede.

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

| | Valores de entrada | | | Horário | Valores de saída |
|--------|--------------------|----------------------|-----------------------|---------|------------------|
| | Irradiância | Temperatura Ambiente | Temperatura Do módulo | | Potência |
| Máximo | 1244,62 | 42,3 | 66,81 | 18,00 | 1912,10 |
| Mínimo | 0,10 | 20,23 | 20,83 | 7,00 | 0,030 |

A construção da rede seguiu os seguintes passos:

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

A Figura 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.

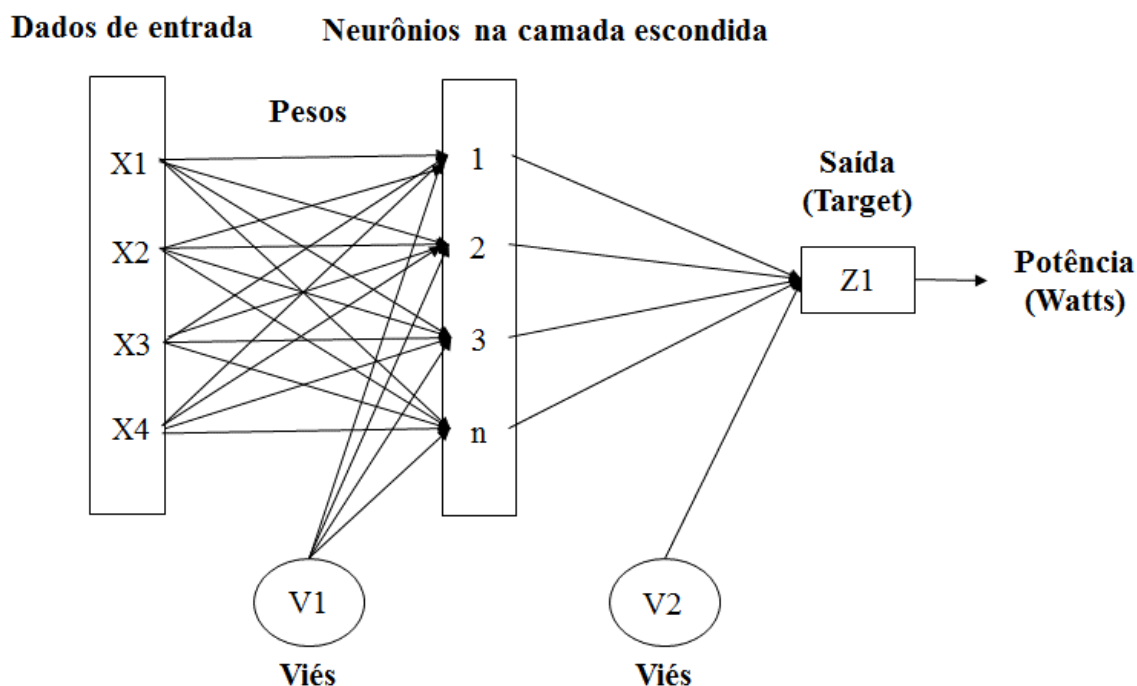



Figura 2 – Estrutura da rede neural artificial construída no estudo.

Na camada oculta, foi utilizada a função de transferência *Log Sigmóide* e na camada de saída a função *purelin*. A Figura 3(a) apresenta o gráfico da função *Log Sigmóide* e a Figura 3(b) representa o gráfico da função *purelin*.



Letra a) função Log Sigmóide Letra b) função Purelin

Figura 3: Função *Log Sigmóide* e Função *Purelin*. Adaptado Hagan et al. (2015)

Na simulação foram sorteados aleatoriamente registros do banco de dados, a fim de testar a rede.

A Tabela 4, mostra um conjunto de registros sorteados aleatoriamente.

Tabela 4 – Valores de dados de entrada e saída utilizadas na estrutura das redes.

| Valores Sorteados Data | Irrad. | Temp.Amb. | Temp.do Mód | Time | Pot. Target | |
|---------------------------|----------|-----------|----------------|-------|-------------|---------|
| JAN Verão | 07/01/12 | 250,31 | 26,05 | 26,24 | 8:10 | 86,80 |
| | 07/01/12 | 386,4 | 27,26 | 33,17 | 9:00 | 504,52 |
| | 07/01/12 | 618,69 | 31,48 | 44,73 | 10:00 | 928,35 |
| | 07/01/12 | 774,12 | 30,95 | 50,99 | 11:00 | 1240,00 |
| | 07/01/12 | 807,32 | 34,13 | 52,5 | 12:00 | 1333,68 |
| | 07/01/12 | 902,96 | 33,43 | 56,4 | 13:00 | 1480,00 |
| | 07/01/12 | 913,71 | 34,76 | 56,37 | 14:00 | 1461,89 |
| | 07/01/12 | 798,71 | 35,08 | 53,04 | 15:00 | 1226,76 |
| | 07/01/12 | 733,31 | 32,76 | 51,49 | 16:00 | 1086,60 |

5 RESULTADOS

Nesta seção, se apresentam os resultados obtidos no estudo. A rede que apresentou melhor correlação e menor erro foi a de 30 neurônios na camada escondida, seu coeficiente de correlação foi superior a 0,988. Observou-se também que as diferentes redes com diferentes números de neurônios apresentaram valores de MSE e R próximos do melhor resultado, conforme apresentados na Tabela 5.

Tabela 5 – Valores de simulações das redes *Levenberg-Marquardt* para o Verão.

| Neurônios | EQM (MSE) | Época | Correlação (R) <i>Levenberg-Marquardt</i> | | | |
|-----------|----------------|-----------|---|----------------|----------------|----------------|
| | | | Treinamento | Validação | Teste | Todos |
| 5 | 4528,52 | 206 | 0,98811 | 0,98796 | 0,9886 | 0,98816 |
| 10 | 5706,47 | 1000 | 0,98665 | 0,98672 | 0,98655 | 0,98665 |
| 15 | 5334,42 | 65 | 0,98727 | 0,98772 | 0,98594 | 0,98714 |
| 20 | 5110,25 | 77 | 0,9878 | 0,98818 | 0,98821 | 0,98792 |
| 25 | 4902,71 | 69 | 0,98817 | 0,98829 | 0,98934 | 0,98841 |
| 30 | 4086,02 | 76 | 0,98856 | 0,98854 | 0,98788 | 0,98845 |
| 60 | 5525,29 | 35 | 0,98759 | 0,98747 | 0,98489 | 0,98717 |

Fonte: Elaborado pelos autores

A Figura 4 mostra o gráfico dos resultados *Mean Square Error* (MSE), da rede neural, com 30 neurônios.

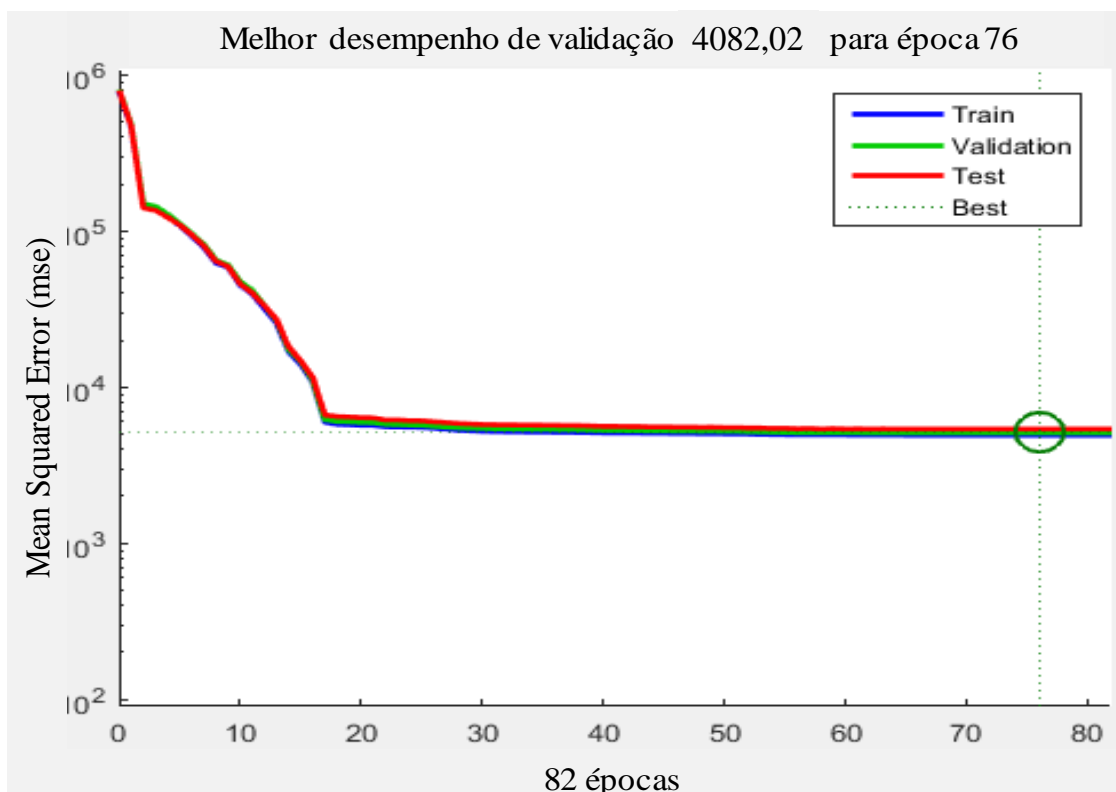


Figure 4 - Mean Square Error do algoritmo Levenberg-Marquardt (LM).

A Figura 5 apresenta o desempenho obtido pela rede selecionada. Para avaliar o desempenho do algoritmo *Levenberg-Marquardt* temos o gradiente, o mu (valor adaptativo para auxiliar no cálculo do desempenho da rede) e a verificação de validação.

O gradiente mostra o grau de inclinação da rede quando busca alcançar o erro mínimo global.

O Mu é um incremento adicionado na rede para poder chegar ao resultado final. A medida que o gradiente diminui o Mu deve aumentar. A validação ocorre quando o algoritmo em 6 iterações consecutivas não consegue alterar significativamente o valor do erro. Conforme destacado com um círculo nas 6 últimas iterações da Figura 5.

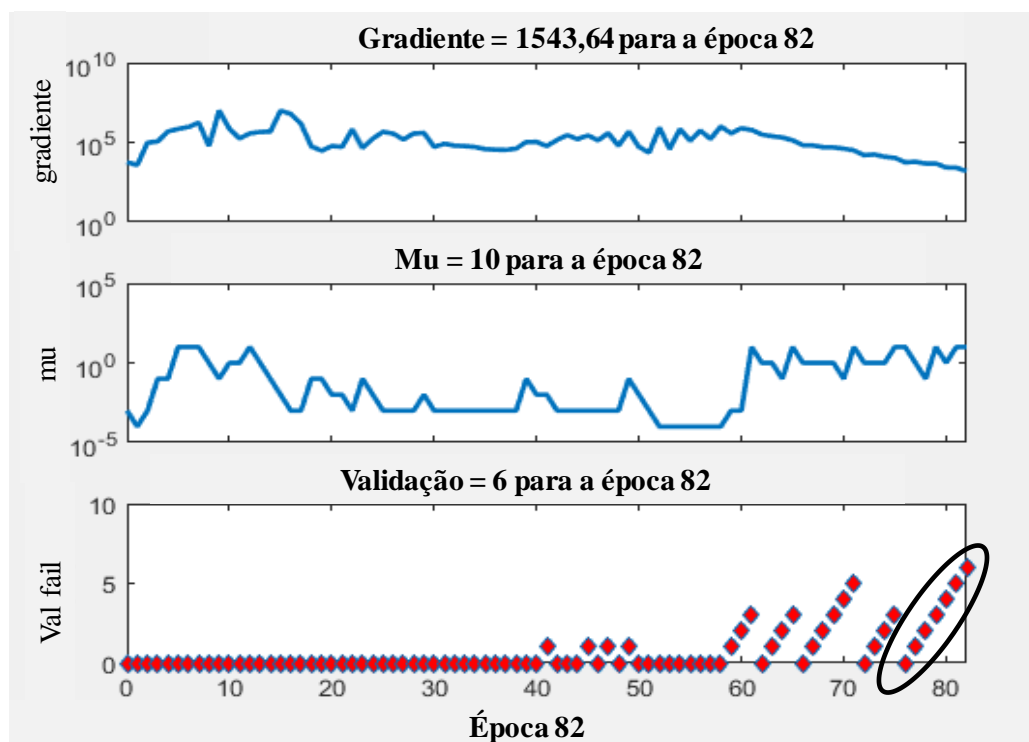


Figure 5- Desempenho da rede neural com 30 neurônios para o *Levenberg-Marquardt*.

A Figura 6 mostra os valores dos coeficientes de correlação (R). A linha pontilhada que atravessa o gráfico, apresenta a saída desejada a ser atingida e a linha contínua mostra a melhor regressão obtida no ajuste linear entre as saídas desejadas e as saídas reais.

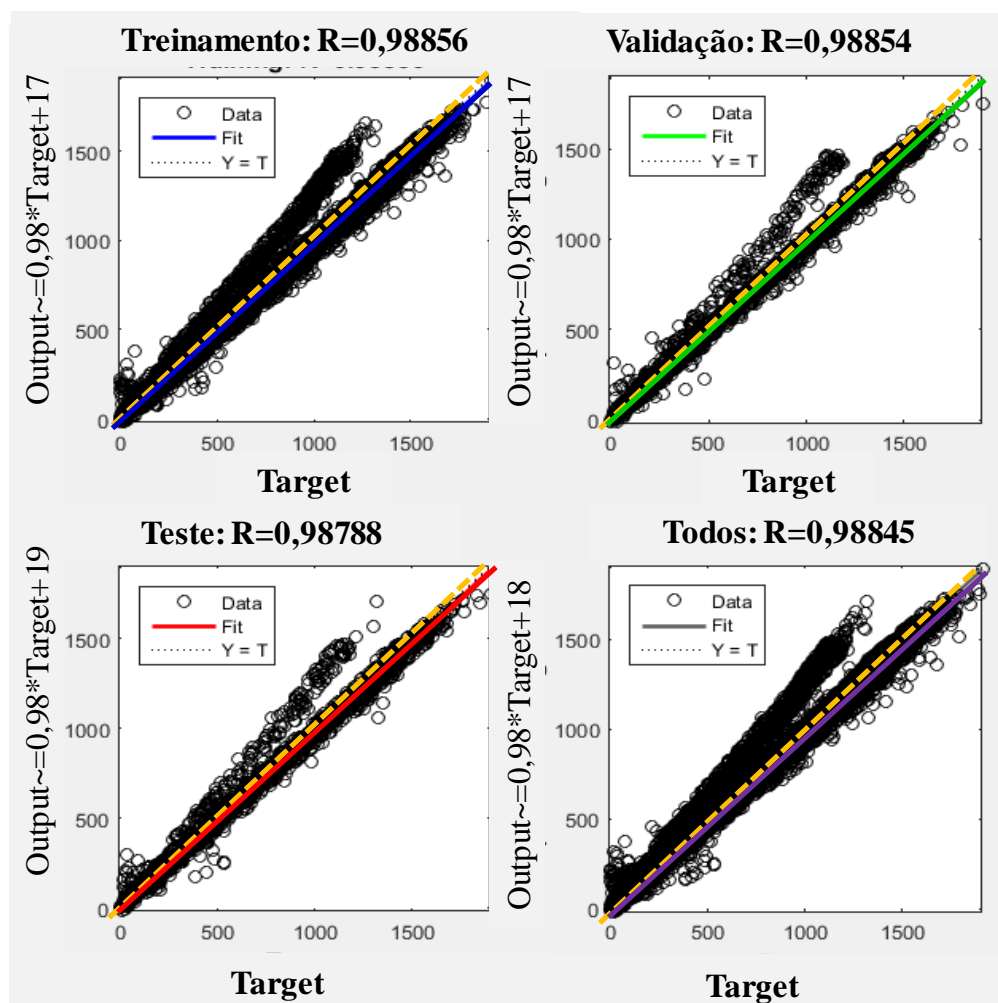


Figura 6 – Regressão com 30 neurônios da camada escondida para o *Levenberg-Marquardt*

A Tabela 6 mostra valores de simulação (vide Tabela 4).

Tabela 6 – Valores de simulações das redes.

| Valores Sorteados Data | Irradiância | Temp.Amb. | Temp.do Mód | Time | Pot Target | Pot Simulada | |
|---------------------------|-------------|-----------|----------------|-------|---------------|-----------------|---------------|
| 07/01/12 | 250,31 | 26,05 | 26,24 | 8:10 | 86,80 | 249,22 | |
| 07/01/12 | 386,4 | 27,26 | 33,17 | 9:00 | 504,52 | 529,44 | |
| 07/01/12 | 618,69 | 31,48 | 44,73 | 10:00 | 928,35 | 952,32 | |
| 07/01/12 | 774,12 | 30,95 | 50,99 | 11:00 | 1240,00 | 1172,2 | |
| JAN Verão | 07/01/12 | 807,32 | 34,13 | 52,5 | 12:00 | 1333,68 | 1260,5 |
| | 07/01/12 | 902,96 | 33,43 | 56,4 | 13:00 | 1480,00 | 1391,5 |
| | 07/01/12 | 913,71 | 34,76 | 56,37 | 14:00 | 1461,89 | 1419,1 |
| | 07/01/12 | 798,71 | 35,08 | 53,04 | 15:00 | 1226,76 | 1248,6 |
| | 07/01/12 | 733,31 | 32,76 | 51,49 | 16:00 | 1086,60 | 1119,4 |
| | 07/01/12 | 285,84 | 29,73 | 38,72 | 17:00 | 410,08 | 434,77 |
| | 07/01/12 | 140,88 | 27,51 | 32,95 | 18:00 | 201,08 | 208,60 |

A Figura 7 mostra os valores de potência medidos e simulados, (Vide Tabela 6).

A linha pontilhada mostra valores de potência reais em Watts (W) medidos no sistema fotovoltaico. A linha contínua mostra os valores obtidos pela simulação.

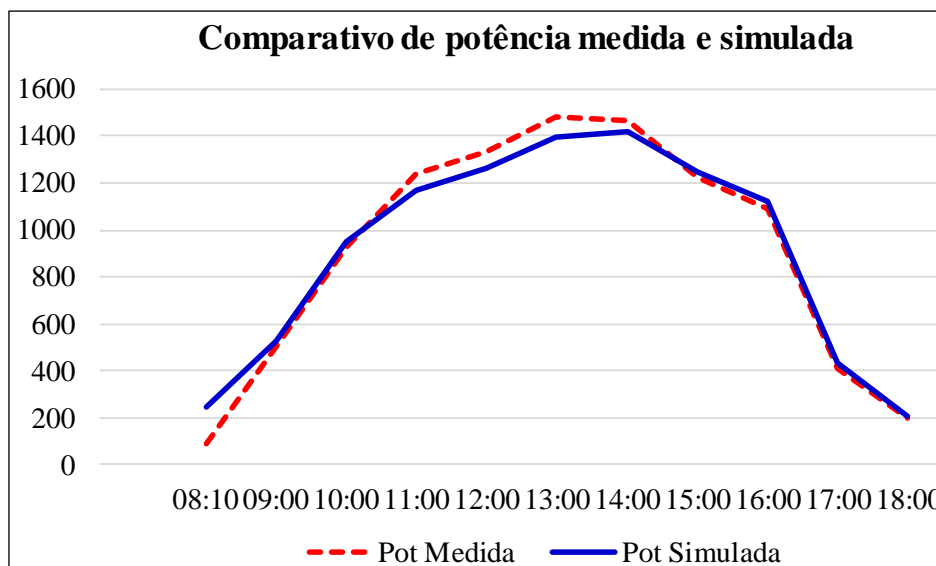


Figura 7: Comparativo de potência medida (Target) usado para treinar a rede com a potência simulada.

Os gráficos de regressão apresentados na literatura existentes referem-se à irradiação solar, no presente trabalho elas são relacionadas a efetiva geração de energia elétrica. Também o comparativo de previsão e de efetiva geração conforme mostrado na figura 7, para um inteiro período diurno, desde o nascer no sol até o caso, não são encontrados na literatura trabalhos que abordam sobre a potência de sistemas fotovoltaicos. Segundo Larson et al., (2016), estudo na previsão da produção de energia diária de plantas fotovoltaicas é pobremente entendido. Ainda para este mesmo autor a falta de conhecimento está relacionada com a dificuldade de obter dados de plantas fotovoltaicas operacionais, devido a restrições de segurança, e falta de infraestrutura na aquisição dos dados. Mas, acredita-se que ocorrerão melhorias para os próximos anos incentivadas por políticas energéticas que exigem a previsão de potência de sistemas fotovoltaicos.

6 CONCLUSÕES

Com o desenvolvimento de redes neurais artificiais buscou-se avaliar a adequação do algoritmo *Levenberg Marquart* para a previsão de geração de energia elétrica de um sistema fotovoltaico. As redes foram construídas com arquiteturas de uma camada de entrada com quatro variáveis, uma camada escondida com 5, 10, 15, 20, 25, 30 e 60 neurônios. A função de transferência foi a *log Sigmóide* e a de saída foi a *purelin*. O algoritmo de treinamento foram *Levenberg-Marquardt*. Considerando os valores de entrada, irradiação incidente, temperatura ambiente, temperatura dos módulos e horários, comprovou-se que as redes propostas são capazes de realizar adequadas análises que no presente estudo atingiram resultados de correlação superiores a 0,98, destacando-se a rede construída com 30 neurônios na camada escondida. Conforme resultados obtidos, conclui-se que o método *Levenberg-Marquardt* é adequado para estimativa da potência de um sistema fotovoltaico integrado à edificação.

REFERÊNCIAS

- BOUSFIELD, P. M. **Uso de uma Rede Neural para a Previsão do Volume de Lodo Gerado em estações de tratamento de efluente: Um estudo de caso**, 2008. Universidade da região de Joinville.
- BURGER, B.; RÜTHER, R. Inverter sizing of grid-connected photovoltaic systems in the light of local solar resource distribution characteristics and temperature. **Solar Energy**, v. 80, n. 1, p. 32–45, 2006. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0038092X05003099>>. .
- CHATZIAGORAKIS, P.; ELMASIDES, C.; SIRAKOULIS, G. C.; et al. Application of Neural Networks Solar Radiation Prediction for Hybrid Renewable Energy Systems. **Springer International Publishing Switzerland**, , n. 2001, 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.
- FONSECA, R. W. **Iluminação natural e consumo energético de edificações não residenciais : aplicação de redes neurais artificiais**, 2015. Universidade Federal de Santa Catarina.

- GAETANI, M.; HULD, T.; VIGNATI, E.; et al. The near future availability of photovoltaic energy in Europe and Africa in climate-aerosol modeling experiments. **Renewable and Sustainable Energy Reviews**, v. 38, p. 706–716, 2014. Elsevier. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1364032114004936>>. .
- GOTTSCHALG, R.; BETTS, T. R.; WILLIAMS, S. R.; et al. A critical appraisal of the factors affecting energy production from amorphous silicon photovoltaic arrays in a maritime climate. **Solar Energy**, v. 77, n. 6, p. 909–916, 2004.
- ISHII, T.; OTANI, K.; TAKASHIMA, T.; XUE, Y. Solar spectral influence on the performance of photovoltaic (PV) modules under fine weather and cloudy weather conditions. **Progress in Photovoltaics: Research and Applications**, v. 20, n. 1, p. 6–11, 2011. Disponível em: <<http://dx.doi.org/10.1002/pip.1160>>. .
- JUNIOR, L. A. T.; SOUZA, R. M.; PESSANHA, J. F. M.; SOUZA, R. C. ARTIFICIAL NEURAL NETWORK AND WAVELET DECOMPOSITION IN THE FORECAST OF GLOBAL HORIZONTAL SOLAR RADIATION. , v. 35, p. 73–90, 2014.
- LACCHINI, C.; PINHEIRO, E.; RÜTHER, R. AVALIAÇÃO DE UM SISTEMA FOTOVOLTAICO SOB A ÓTICA DA. **VI Congresso Brasileiro de Energia Solar – Belo Horizonte, 03 a 07 de abril de 2016**, v. VI, n. 9788586923432, p. 1–8, 2016.
- LARSON, D. P.; NONNENMACHER, L.; COIMBRA, C. F. M. Day-ahead forecasting of solar power output from photovoltaic plants in the American Southwest. **Renewable Energy**, v. 91, p. 11–20, 2016.
- MARION, B. Preliminary Investigation of Methods for Correcting for Variations in Solar Spectrum under Clear Skies Preliminary Investigation of Methods for Correcting for Variations in Solar Spectrum under Clear Skies. **NREL/TP-520-47277**, , n. March, p. 1–53, 2010. Disponível em: <http://digitalscholarship.unlv.edu/renew_pubs/16/>. .
- 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.
- MEKHILEF, S.; SAIDUR, R.; KAMALISARVESTANI, M. Effect of dust, humidity and air velocity on efficiency of photovoltaic cells. **Renewable and Sustainable Energy Reviews**, v. 16, n. 5, p. 2920–2925, 2012. Elsevier Ltd. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1364032112001050>>. .
- MEKKI, H.; MELLIT, A.; SALHI, H.; KHALED, B. Modeling and simulation of photovoltaic panel based on artificial neural networks and VHDL-language BT - 14th IEEE International Conference on Electronics, Circuits and Systems, ICECS 2007, December 11, 2007 - December 14, 2007. , p. 58–1424413788, 2007. Disponível em: <<http://dx.doi.org/10.1109/ICECS.2007.4510930>>. .

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.

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.; 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>>. .

MELO, A. P. **UNIVERSIDADE FEDERAL DE SANTA CATARINA PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL ATRAVÉS DA APLICAÇÃO DE REDES NEURAI**s Tese submetida à Universidade Federal de Santa Catarina como requisito parcial exigido pelo Programa de Pós-Graduação em Engenharia, 2012. Universidade Federal de Santa Catarina.

MERAL, M. E.; DINER, F. A review of the factors affecting operation and efficiency of photovoltaic based electricity generation systems. **Renewable and Sustainable Energy Reviews**, v. 15, n. 5, p. 2176–2184, 2011.

MINEMOTO, T.; TODA, M.; NAGAE, S.; et al. Effect of spectral irradiance distribution on the outdoor performance of amorphous Si//thin-film crystalline Si stacked photovoltaic modules. **Solar Energy Materials and Solar Cells**, v. 91, n. 2–3, p. 120–122, 2007.

MUBIRU, J. Using Artificial Neural Networks to Predict Direct Solar. , v. 2011, 2011.

NREL. Best Research-Cell Efficiencies. Disponível em: <http://www.nrel.gov/pv/assets/images/efficiency_chart.jpg>. Acesso em: 1/10/2016.

RUTHER, R.; CUETO, J. DEL; TAMIZH-MANI, G.; et al. Performance test of amorphous silicon modules in different climates - Year four: Progress in understanding exposure history stabilization effects. **Conference Record of the IEEE Photovoltaic Specialists Conference**, 2008.

RÜTHER, R.; NASCIME, L.; URBANETZ, J.; PFITSCHER, P.; VIANA, T. Long-term performance of the first grid-connected, building-integrated amorphous silicon PV installation in Brazi. **Conference Record of the IEEE Photovoltaic Specialists Conference**, , n. 1997, p. 2283–2286, 2010.

SABERIAN, A.; HIZAM, H.; RADZI, M. A M.; KADIR, M. Z. A A.; MIRZAEI, M. Modelling and Prediction of Photovoltaic Power Output Using Artificial Neural Networks. , v. 2014, 2014.

SINHA, P.; HAYES, W.; NGAN, L. Regional Atmosphere-Solar PV Interactions. , p. 8–13, 2013.

SOLMAZ, O.; OZGOREN, M. Prediction of Hourly Solar Radiation in Six Provinces in Turkey by Artificial Neural Networks. , v. 138, n. 4, p. 194–204, 2010.

VERSAGE, R. DE S. **Metamodelo para Estimar a Carga Térmica de Edificações Condicionadas Artificialmente**, 2015. Universidade Federal de Santa Catarina.

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.

YERLI, B.; KAYMAK, M. K.; ERCAN, İ.; ÖZTOPAL, A.; AHMET, D. Ş. Effect of Derating Factors on Photovoltaics under Climatic Conditions of Istanbul. , v. 4, n. 8, p. 1400–1404, 2010.

ZORRILLA-CASANOVA, J.; MIGUEL, P.; JESUS, C.; et al. Losses produced by soiling inthe incoming radiation to photovoltaic modules. **Progress in Photovoltaics: Research and Applications**, v. 20, n. 1, p. 6–11, 2012. Disponível em: <<http://dx.doi.org/10.1002/pip.1160>>. .