

# Rede Neural Artificial para Previsão da Potência de Saída de Sistemas Fotovoltaicos Conectados à Rede

Rodrigo Pizetti Martins  
Departamento de Eng. Elétrica  
Universidade Federal Fluminense, UFF  
Niterói-RJ, Brasil  
rodrigo.pizetti@gmail.com

Vitor Hugo Ferreira, Thales Terrola e Lopes  
Departamento de Eng. Elétrica  
Universidade Federal Fluminense, UFF  
Niterói-RJ, Brasil  
vhferreira@id.uff.br, thalesterrola@id.uff.br

**Resumo**—O presente artigo aborda o uso de uma rede neural artificial para estimar a produção da energia elétrica a partir de um sistema fotovoltaico qualquer conectado à rede de distribuição de energia, usando um ou dois parâmetros na camada de entrada – radiação solar no plano do arranjo e/ou temperatura ambiente – e um parâmetro na camada de saída – potência na saída do inversor. Paralelamente, são avaliados diferentes algoritmos de treinamento, de modo a determinar qual o melhor modelo de rede a ser aplicada. Os resultados obtidos mostram que as redes neurais avaliadas apresentam bom desempenho para a solução do problema proposto, que pode ser comprovado pelo baixo erro de estimação.

**Palavras-chave**—rede neural artificial; sistemas fotovoltaicos; energia.

**Abstract**—This article discusses the use of an artificial neural network to estimate the production of electricity from a any photovoltaic system connected to the power distribution network using one or two parameters in the input layer - solar radiation on the tilted surface and/or ambient temperature - and a parameter in the output layer - power at the inverter output. At the same time, different training algorithms are evaluated in order to determine the best network model to be applied. The results show that the evaluated neural networks perform well for the solution of the proposed problem, which can be evidenced by the low estimation error.

**Keywords**—artificial neural network; photovoltaic systems; energy.

## I. INTRODUÇÃO

O avanço das redes inteligentes vem propiciar a inserção maciça de sistemas de geração de energia elétrica, caracterizados como geração distribuída e baseados em fontes renováveis. Uma das mais utilizadas, a solar fotovoltaica, vem sendo amplamente adotada por suas facilidades e comodidades, como a facilidade de instalação, o baixo índice de manutenção, tecnologia amplamente difundida e a abundância do recurso energético.

O desafio agora se concentra no gerenciamento do balanço energético na rede de energia, uma vez que a geração solar fotovoltaica é uma fonte intermitente, que sofre com a influência de uma série de parâmetros climáticos, como a radiação solar, a temperatura ambiente, a velocidade do vento,

a umidade do ar, a precipitação pluviométrica e a nebulosidade.

Na grande maioria dos sistemas fotovoltaicos instalados, a previsão da geração de energia vem sendo feita com o uso dos modelos analíticos [1], [2] e [3]. Os modelos analíticos são trabalhosos e complexos, e, ainda assim, não conseguem representar com fidelidade o comportamento real de um sistema quando exposto a certas condições [4].

O modelo térmico de Fuentes [1] estima a temperatura do arranjo a partir de uma série de parâmetros, dentre eles a radiação solar incidente na superfície do arranjo, usando para isso um elaborado estudo de transferência de calor que envolve a aplicação de cerca de 30 equações através de um processo iterativo. O modelo proposto por King [2] estima o desempenho de painéis e arranjos fotovoltaicos. O modelo proposto por King, Kratochvil e Boyson [3] apresenta uma experiência de campo com um novo procedimento para avaliar o desempenho dos arranjos solares, envolvendo a influência do espectro solar e a influência do ângulo de incidência do sol sobre os principais parâmetros elétricos do gerador, e o modelo proposto por Martin [5] modela a eficiência dos inversores. A principal desvantagem desses métodos é o grande número de parâmetros envolvidos, inclusive com a necessidade de medição *in loco*, abrangendo um grande número de equações.

Um modelo que cada vez mais vem sendo utilizado na solução de problemas de qualquer natureza é a rede neural artificial. Trata-se de um modelo computacional baseado no funcionamento do sistema nervoso central, mais especificamente no funcionamento do cérebro, que apresenta a capacidade de realizar o aprendizado de máquina e o reconhecimento de padrões.

Na área da energia solar fotovoltaica, alguns trabalhos vêm sendo publicados para a previsão da radiação solar e para a previsão da geração de energia. Almonacid, Pérez-Higueras, Fernández e Hontoria propuseram em seu trabalho uma metodologia baseada na rede neural artificial dinâmica para prever, com antecedência de uma hora, a potência de saída de um gerador fotovoltaico [6]. Chupong e Plangklang apresentaram um modelo para previsão da potência de saída de um sistema fotovoltaico conectado à rede na Tailândia, que

não adota a radiação solar como parâmetro de entrada na rede neural [7].

Nesse modelo, a rede é treinada a partir de um conjunto de dados que representa o comportamento real do sistema que se deseja prever. A propriedade primordial que uma rede neural deve apresentar é a habilidade de aprender a partir de seu ambiente e melhorar o seu desempenho com o tempo através da aprendizagem [8].

A rede neural permite a substituição dos métodos analíticos tradicionais por modelos mais simples, que necessitam de algumas poucas variáveis na entrada e que apresentem um resultado mais confiável na saída, sem a necessidade de se conhecer a modelagem de cada um dos equipamentos do sistema.

O propósito desse trabalho consiste no desenvolvimento de um modelo baseado na rede neural artificial para auxílio no gerenciamento da rede de distribuição de energia elétrica, através da previsão da geração de energia elétrica de um sistema solar fotovoltaico conectado à rede, sem a necessidade de se modelar todos os componentes do sistema de equações.

A rede neural permite avaliar o desempenho do sistema e a identificar problemas na operação e no monitoramento de maneira simples e direta, diferentemente dos usuais métodos matemáticos adotados.

Para a previsão da energia elétrica gerada, dada pela potência na saída do inversor, foi modelada uma rede neural artificial do tipo perceptron de múltiplas camadas (PMC), que foi treinada com diferentes algoritmos e parâmetros. Para cada algoritmo de treinamento, a rede PMC foi avaliada para os dados horários de radiação solar no plano do arranjo e para os dados horários de temperatura ambiente.

## II. METODOLOGIA

Para prever a produção de energia elétrica pelo sistema fotovoltaico conectado à rede, foi modelada no MATLAB uma rede neural artificial. Essa rede neural será utilizada para comparar a influência dos parâmetros de entrada selecionados sobre a resposta desejada na saída. Para isso, serão realizadas duas análises, sendo que, em todas elas, o parâmetro de saída será o mesmo, ou seja, a potência fornecida pelo sistema. O parâmetro de entrada, entretanto, variará de acordo com os seguintes conjuntos:

- 1) Radiação solar no plano do arranjo; e
- 2) Radiação solar no plano do arranjo e temperatura ambiente.

### A. Rede Neural

A arquitetura da rede neural artificial modelada foi baseada no perceptron de múltiplas camadas. O processo de aprendizagem de uma rede PMC é feito de forma supervisionada, tendo sido adotado o treinamento por retropropagação do erro (back-propagation) [8].

O número de camadas ocultas e o número de neurônios em cada camada foram definidos de forma a ser obter o melhor resultado nas simulações.

Quatro algoritmos de treinamento foram avaliados: Levenberg-Marquardt (LM), Treinamento Bayesiano (TB), Gradiente Conjugado (GC) e Gradiente Descendente (GD).

### B. Série de Dados

Os dados de radiação solar e temperatura ambiente adotados para a elaboração desse trabalho são referentes à localidade de latitude 22,5°Sul e longitude 43,32°Oeste, referentes à cidade do Rio de Janeiro-RJ. Os dados da potência injetada na rede são provenientes dos resultados obtidos com a simulação de um sistema solar fotovoltaico instalado na referida localidade, simulado no programa PVsyst v5.73 [9]. O PVsyst utiliza complexos modelos matemáticos para estimar a energia gerada, sendo utilizado também para avaliar o desempenho de sistemas fotovoltaicos a partir da comparação dos dados medidos com os resultados das simulações [10].

O resultado da simulação é apresentado em médias horárias para o período de um ano, perfazendo, assim, uma série de dados com 8760 horas de informação. Considerando que o período de incidência dos raios solares ocorre de, aproximadamente, 06:00 as 18:00 horas, é possível reduzir a quantidade de dados que seriam repassados à rede neural. Assim, optou-se por deixar apenas o primeiro e o último zero que contornam os extremos da curva de radiação solar.

Os dados de entrada e de saída, apresentados à rede neural, foram normalizados no intervalo entre -1 e 1, em função dos limites mínimos e máximos identificados em cada conjunto de dados, de acordo com a expressão 1:

$$y = \frac{(y_{max} - y_{min}) \times (x - x_{min})}{(x_{max} - x_{min})} + y_{min} \quad (1)$$

onde:  $y_{max}$  é igual a 1;  
 $y_{min}$  é igual a -1;  
 $x$  é o valor a ser convertido;  
 $x_{min}$  é o menor valor da série a ser convertida; e  
 $x_{max}$  é o maior valor da série a ser convertida.

### C. Sistema Fotovoltaico

O gerador fotovoltaico do sistema simulado é composto por módulos do fabricante Trina Solar, modelo TSM-255 PDG5, de potência de 255 watts de pico [9]. O arranjo é composto por 10 módulos ligados em série, perfazendo uma potência total de 2550 watts de pico.

O sistema de conversão de energia é composto por um inversor do fabricante Fronius International, modelo IG 30, de potência nominal de 2500 watts [9].

### D. Análise da Série Gerada

A precisão das séries geradas pelas redes neurais será avaliada a partir de dois métodos estatísticos, conforme mostrado a seguir.

#### 1) Erro Sistemático Médio

O erro sistemático médio [10], dado pela expressão 2, permite verificar se a previsão está subestimada ou superestimada, ou seja, se está apresentando mais valores estimados negativos ou positivos.

$$ESM = 1/N \sum_{i=1}^N (y_i - y_{pi}) \quad (2)$$

onde:  $y_i$  é o valor real do período  $i$ ;  
 $y_{pi}$  é a previsão para o período  $i$ ; e  
 $N$  é o número de períodos no conjunto de validação.

## 2) Erro Médio Percentual

O erro médio percentual é dado pela expressão 3.

$$EMP = 1/N \sum_{i=1}^N |(y_i - y_{pi})/y_i| \quad (3)$$

onde:  $y_i$  é o valor real do período  $i$ ;  
 $y_{pi}$  é a previsão para o período  $i$ ; e  
 $N$  é o número de períodos no conjunto de validação.

## 3) Erro Relativo Percentual

O erro relativo percentual, dado pela expressão 4, permite a comparação entre um valor aproximado e um valor exato.

$$Erro = \frac{|y_p - y|}{y} \times 100\% \quad (4)$$

onde  $y_p$  é o valor aproximado e  $y$  é o valor exato.

## III. MODELAGEM DA REDE NEURAL E DO CONJUNTO DE DADOS

### A. Organização do Conjunto de Dados

Para serem apresentados à rede neural, os dados coletados foram distribuídos em três categorias, de acordo com a seguinte proporção: 64% para os dados de treinamento, 20% para os dados de validação e 16% para os dados de teste, num total de 5.110 horas de medição.

Os conjuntos de dados de teste foram selecionados, aleatoriamente, de acordo com as datas apresentadas na Tabela I, mantendo-se inalterado o perfil de radiação solar diário, ou seja, a ordenação horária diária da curva de radiação solar.

O restante dos dados, 84%, foram apresentados, aleatoriamente, hora a hora à rede neural para as fases de treinamento e validação.

TABELA I. DIAS SELECIONADOS PARA O TESTE DA REDE NEURAL.

| Mês       | Dias do mês       |
|-----------|-------------------|
| Janeiro   | 5, 9, 14, 23, 28  |
| Fevereiro | 2, 3, 19, 24, 27  |
| Março     | 1, 11, 16, 22, 26 |
| Abril     | 4, 15, 17, 22, 25 |
| Mai       | 8, 13, 15, 20, 31 |
| Junho     | 9, 17, 20, 28, 30 |
| Julho     | 7, 8, 10, 18, 25  |
| Agosto    | 3, 6, 19, 23, 31  |
| Setembro  | 6, 7, 13, 24, 29  |
| Outubro   | 4, 12, 17, 21, 31 |
| Novembro  | 3, 11, 12, 27, 29 |
| Dezembro  | 8, 10, 14, 23, 27 |

### B. Modelagem da Rede Neural

A Fig. 1 apresenta a estrutura geral da rede neural modelada, considerando o uso de dois parâmetros na camada de entrada. Nos resultados apresentados, testou-se também a

hipótese de apenas um único parâmetro na camada de entrada. Neste caso, o parâmetro temperatura ambiente deve ser descartado, preservando-se o restante da estrutura apresentada.




Fig. 1. Estrutura geral da rede neural modelada, mostrando a camada de entrada, os três neurônios na camada oculta e a camada de saída.

O número de neurônios na camada oculta foi especificado em função de uma série de análises realizadas nas fases de treinamento e validação, em que se obteve o número de três neurônios para a camada oculta. Com relação à quantidade de camadas ocultas a serem adotadas na rede neural para a resolução do problema, os resultados obtidos corroboraram o teorema da aproximação universal, que diz que um perceptron multicamadas com apenas uma camada oculta pode aproximar com precisão qualquer função contínua arbitrária [8].

As funções de ativação utilizadas na camada oculta e na camada de saída foram, respectivamente, a função de ativação tangente hiperbólica e a função de ativação linear.

A taxa de aprendizagem utilizada na etapa de treinamento foi definida em  $10^{-6}$ , enquanto o parâmetro de ajuste de Marquardt em  $1 \times 10^{-3}$  e o número máximo de épocas de treinamento em 30.000 épocas.

## IV. RESULTADOS

Nos subitens a seguir são apresentados os resultados das simulações realizadas, representados pelos parâmetros de treinamento e pelos parâmetros de previsão.

### A. Estudo de caso I

O estudo de caso I aborda a previsão da geração de energia elétrica a partir de um único parâmetro de entrada: a radiação solar incidente no plano do arranjo.

Para realizar a previsão, quatro redes neurais do tipo PMC, modeladas a partir da Fig. 1, foram treinadas, conforme citado anteriormente. A Tabela II apresenta os resultados obtidos ao final do treinamento. Alguns dados são usados como critério de parada para finalizar o treinamento da rede neural, como o número de épocas de treinamento (Épocas), o fator de ajuste de Marquardt (MU) e o erro quadrático médio entre duas épocas (EQM). O coeficiente de correlação de Pearson (Correlação  $R^2$ ), que avalia a dispersão entre os dados reais e os dados estimados, é usado para avaliar o desempenho da rede neural.

Analisando os resultados da etapa de treinamento, é possível observar que as redes LM e GC têm o seu processo interrompido pelo critério do gradiente, enquanto a rede TB é interrompida pelo MU e a rede GD é interrompida por exceder o número máximo de épocas de treinamento.

TABELA II. RESULTADOS DO TREINAMENTO DAS REDES NEURAIS PARA O ESTUDO DE CASO I

|                           | Redes Neurais         |                       |                       |                       |
|---------------------------|-----------------------|-----------------------|-----------------------|-----------------------|
|                           | LM                    | TB                    | GC                    | GD                    |
| Épocas                    | 60                    | 181                   | 345                   | 30.000                |
| EQM                       | $7,78 \times 10^{-7}$ | $1,37 \times 10^{-2}$ | $9,36 \times 10^{-7}$ | $1,19 \times 10^{-3}$ |
| MU                        | $1,00 \times 10^{-8}$ | $1,00 \times 10^{-4}$ | -                     | -                     |
| Critério de Parada        | Gradiente (EQM)       | MU                    | Gradiente (EQM)       | Número de Épocas      |
| Correlação R <sup>2</sup> | 0,99936               | 0,99941               | 0,99935               | 0,99888               |

Os resultados das previsões horárias podem ser consultados na Tabela III, que apresenta a energia elétrica real gerada pelo sistema fotovoltaico ( $E_R$ ), a energia elétrica estimada ( $E_E$ ), o erro relativo percentual (Erro), o erro médio percentual (EMP) e o erro sistemático médio (ESM).

TABELA III. RESULTADOS DAS SIMULAÇÕES DO ESTUDO DE CASO I

|             | Redes Neurais |        |        |        |
|-------------|---------------|--------|--------|--------|
|             | LM            | TB     | GC     | GD     |
| $E_R$ (kWh) | 539,62        | 539,62 | 539,62 | 539,62 |
| $E_E$ (kWh) | 538,77        | 538,24 | 539,00 | 539,67 |
| Erro (%)    | -0,16         | -0,26  | -0,11  | 0,01   |
| EMP (%)     | 4,98          | 4,87   | 4,74   | 8,15   |
| ESM (Wh)    | -2,20         | -1,73  | -2,10  | 1,51   |

Analisando os resultados das previsões horárias é possível afirmar que praticamente todas as redes neurais treinadas apresentaram resultados satisfatórios com relação à estimação da geração de energia elétrica a partir dos dados de radiação solar, o que é comprovado pelo baixo valor do erro relativo e do EMP. O ESM mostra também que as séries apresentaram pouca tendência para a subestimação ou superestimação dos resultados. A série que apresenta o menor erro relativo para a estimação da energia gerada é, também, a série com o EMP mais elevado, ou seja, com o pior índice de precisão. Analisando os gráficos e os diferentes erros, é possível afirmar que o EMP mais elevado ocorre em função dos altos erros de estimação para baixos valores de radiação solar, visto que esses erros impactam o EMP e não impactam o erro relativo, não influenciando no somatório da energia estimada. A rede GD foi a rede que apresentou o melhor resultado de previsão, apesar do seu treinamento ser o mais complexo e lento, sendo interrompido apenas ao final das épocas.

A Fig. 2, a Fig. 3 e a Fig. 4 mostram o resultado da previsão realizada pelos algoritmos de treinamento avaliados, considerando a geração entre 5 e 19 horas, para um dia de cada mês listado na Tabela I. Pelas figuras é possível observar que ora a previsão de um dia é levemente subestimada, ora a previsão é levemente superestimada, mantendo-se um equilíbrio entre as previsões diárias. Em nenhum dos casos citados analisados é possível observar a ocorrência de *underfitting* ou *overfitting*, o que comprova que as redes neurais foram dimensionadas corretamente para o problema em estudo.




Fig. 2. Gráfico da energia elétrica real gerada pelo fotovoltaico e da energia elétrica estimada para o estudo de caso I (janeiro, fevereiro, março e abril).




Fig. 3. Gráfico da energia elétrica real gerada e da energia elétrica estimada para o estudo de caso I (maio, junho, julho e agosto).




Fig. 4. Gráfico da energia elétrica real gerada e da energia elétrica estimada para o estudo de caso I (setembro, outubro, novembro e dezembro).

A Fig. 5 mostra o erro percentual diário das previsões realizadas. É possível observar que a rede GD apresenta o maior erro percentual diário, apesar de apresentar um pequeno erro percentual horário médio. O melhor resultado de previsão, nesse caso, deu-se para a rede GC.




Fig. 5. Gráfico do erro percentual para o conjunto de teste das redes avaliadas para o estudo de caso I.

### B. Estudo de caso II

O estudo de caso II aborda a previsão da geração de energia elétrica a partir de dois parâmetros de entrada: a radiação solar incidente no plano do arranjo e a temperatura ambiente.

A Tabela IV apresenta os resultados obtidos ao final do treinamento das redes neurais, e mostra que não houve qualquer alteração com relação ao critério utilizado para finalizar o treinamento das diferentes redes neurais propostas.

TABELA IV. RESULTADOS DO TREINAMENTO DAS REDES NEURAIS PARA O ESTUDO DE CASO II

|                    | Redes Neurais         |                       |                       |                       |
|--------------------|-----------------------|-----------------------|-----------------------|-----------------------|
|                    | LM                    | TB                    | GC                    | GD                    |
| Épocas             | 131                   | 291                   | 5.088                 | 30.000                |
| EQM                | $9,37 \times 10^{-7}$ | $6,25 \times 10^{-4}$ | $9,76 \times 10^{-7}$ | $1,09 \times 10^{-3}$ |
| MU                 | $1,00 \times 10^{-7}$ | $1,00 \times 10^{-4}$ | -                     | -                     |
| Critério de Parada | Gradiente (EQM)       | MU                    | Gradiente (EQM)       | Número de Épocas      |
| Correlação $R^2$   | 0,99997               | 0,99997               | 0,99997               | 0,99921               |

Os resultados das previsões realizadas para o estudo de caso II são apresentados na Tabela V. Mais uma vez é possível afirmar que, praticamente, todas as redes neurais apresentaram resultados satisfatórios com relação à previsão da geração de energia elétrica. Comparando esses resultados com os resultados do caso I, é possível dizer que, apesar de ter havido um aumento do erro relativo, houve uma redução do EMP, havendo, consequentemente, uma melhora na precisão da previsão da rede. Entretanto, é percebida uma piora na série gerada pela rede GD, conforme pode ser observado a partir dos valores do erro relativo e do EMP. A rede TB apresentou o melhor resultado de previsão, com o menor erro relativo, o menor ESM e o menor EMP.

TABELA V. RESULTADOS DAS SIMULAÇÕES PARA O ESTUDO DE CASO II

|             | Redes Neurais |        |        |        |
|-------------|---------------|--------|--------|--------|
|             | LM            | TB     | GC     | GD     |
| $E_R$ (kWh) | 539,62        | 539,62 | 539,62 | 539,62 |
| $E_E$ (kWh) | 540,28        | 539,94 | 540,25 | 538,28 |
| Erro (%)    | 0,12          | 0,06   | 0,12   | -0,25  |
| EMP (%)     | 3,46          | 3,23   | 3,69   | 8,37   |
| ESM (Wh)    | 0,29          | -0,13  | -0,32  | 0,76   |

A Fig. 6, a Fig. 7 e a Fig. 8 mostram a energia elétrica real gerada e da energia elétrica estimada para o estudo de caso II, considerando a geração entre 5 e 19 horas, para um dia de cada mês listado na Tabela I. Analisando os gráficos é possível observar que houve uma melhora na predição da maioria dos valores analisados, fato comprovado pela superposição das curvas da energia gerada. Nos meses de abril, junho e dezembro observa-se o bom desempenho das redes neurais para a previsão de geração de energia elétrica para dias com alto índice de nebulosidade.




Fig. 6. Gráfico da energia elétrica real gerada e da energia elétrica estimada para o estudo de caso II (janeiro, fevereiro, março e abril).




Fig. 7. Gráfico da energia elétrica real gerada e da energia elétrica estimada para o estudo de caso II (maio, junho, julho e agosto).

A Fig. 9 mostra o gráfico do erro percentual da previsão realizado pelas redes avaliadas. Nesse caso é possível perceber que, do caso I para o caso II, houve uma melhora significativa

na previsão dos dados para quase todas as redes, exceto para a rede GD.




Fig. 8. Gráfico da energia elétrica real gerada e da energia elétrica estimada para o estudo de caso II (setembro, outubro, novembro e dezembro).




Fig. 9. Gráfico do erro percentual para o conjunto de teste das redes avaliadas para o estudo de caso II. Índices de acertos: LM (98,1 a 100%), TB (98,7 a 100%), GC (96,8 a 100%) e GD (96,7 a 100%)

## V. CONCLUSÃO

Os resultados apresentados permitem concluir que o uso das redes neurais artificiais para a previsão da geração solar mostra-se como uma boa alternativa para o tratamento deste problema, não necessitando dos complexos modelos matemáticos aplicados para tal finalidade. Todas as modelagens das redes consideradas, com os diferentes algoritmos de treinamento, apresentaram resultados muito próximos e satisfatórios.

Um fator fundamental na análise dos resultados da rede neural está na definição do conjunto de dados de entrada apresentados à rede neural. Conforme mostrado nos casos I e II, a utilização de um segundo parâmetro na entrada reduz os valores dos diferentes tipos de erros, como o relativo, o EMP e o ESM, melhorando o desempenho da rede neural e, conseqüentemente, a previsão da geração de energia. Os resultados mostraram para o caso I, que trabalhar com apenas um único parâmetro de entrada para estimar a produção de energia elétrica, no caso a radiação solar incidente no plano do

arranjo fotovoltaico, pode não ser a melhor escolha para a modelagem da rede neural.

Para estender o modelo proposto a um cenário em tempo real é preciso retreinar a rede neural para o sistema fotovoltaico que se deseja analisar, uma vez que as previsões ficam relacionadas às características físicas e elétricas do sistema. A grande vantagem é que o modelo pode ser aplicado a outros sistemas com inversores diferentes instalados em regiões diferentes, sem que seja necessário definir os parâmetros do sistema.

## REFERÊNCIAS

- [1] M. K. Fuentes, "A Simplified Thermal Model," Sandia National Laboratories, Albuquerque, 1987.
- [2] D.L.King, "Photovoltaic Module and Array Performance Characterization Methods for All System Operating Conditions," Sandia National Laboratories, 1996.
- [3] D. L. K. J. A. & B. W. E. King, "Field Experience with a New Performance Characterization Procedure for Photovoltaic Arrays," em *2nd World Conf. and Ex. on PV Solar Energy Conversion*, Vienna, 1998.
- [4] H. C. Tissot, L. C. Camargo e A. T. R. Pozo, "Treinamento de Redes Neurais Feedforward: comparativo dos algoritmos Backpropagation e Differential Evolution," 16 10 2012. [Online]. Available: [http://www.ppgia.pucpr.br/~enia/anaais/enia/artigos/1052\\_43\\_2.pdf](http://www.ppgia.pucpr.br/~enia/anaais/enia/artigos/1052_43_2.pdf). [Acesso em 23 12 2015].
- [5] E. Martin, *Edifícios Fotovoltaicos Conectados a la Red Eléctrica: Caratcterización y Análisis*, Universidade Politécnica de Madri, 1998.
- [6] F. P.-H. P. J. F. E. F. H. L. Almonacid, "A methodology based on dynamic artificial neural network for short-term forecasting of the power output of a PV generator," *Energy Conv. and Manag.*, vol. 85, pp. 389-398, 2014.
- [7] C. P. B. Chupong, "Forecasting power output of PV grid connected system in Thailand without using solar radiation measurement," *Energy Procedia*, vol. 9, pp. 230-237, 2011.
- [8] S. Haykin, *Redes neurais: princípios e prática*, Porto Alegre: Bookman, 2001, p. 900.
- [9] Universidade de Genebra, "PVsyst Photovoltaic Software version 5.73," Universidade de Genebra, 30 01 2014. [Online]. Available: <http://www.pvsyst.com/en/software/download>. [Acesso em 10 07 2015].
- [10] B. Wittmer, A. Mermoud e T. Schott, "Analysis of PV grid installations performance, comparing measured data to simulation results to identify problems in operation and monitoring," em *European Photovoltaic Solar Energy Conference*, Hamburg, Germany, 2015.
- [11] D. M. F. S. N. P. E. Fiorin, "Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares," *Revista Brasileira de Ensino de Física*, vol. 33, n. 1, p. 1309, 2011.