



Avaliação de algoritmos de treinamento para redes neurais artificiais para previsão temporal de geração fotovoltaica

Evaluación de algoritmos de entrenamiento para redes neuronales artificiales para la previsión temporal de generación fotovoltaica

Training algorithms evaluation for artificial neural network to temporal prediction of photovoltaic generation

Raul Vitor – Arantes Monteiro
Madeleine - Rocio Castillo
Geraldo – Caixeta Guimarães

Fabício Augusto Matheus- Moura
Márcio Augusto - Tamashiro

Recibido: febrero de 2016

Aprobado: abril de 2016

Resumen/Abstract

Políticas energética atuais vêm encorajando a conexão de geradores de energia baseados em tecnologias de baixa poluição, principalmente aqueles que utilizam fontes renováveis, em redes de distribuição. Consequentemente, se torna muito importante o entendimento dos desafios técnicos, tendo em vista alta penetração fotovoltaica de sistemas fotovoltaicos na rede, especialmente considerando-se os efeitos intermitentes dessa fonte na qualidade da energia, confiabilidade e estabilidade do sistema elétrico de distribuição. Esse fato pode afetar às redes de distribuição em que estão conectados, causando sobretensões, subtensões e oscilações de frequência. De maneira a prever esses distúrbios, utilizam-se as redes neurais artificiais. Esse artigo tem como objetivo analisar 3 algoritmos de treinamento utilizados em redes neurais artificiais para a previsão temporal de potência ativa gerada por placas fotovoltaicas. Como resultado, conclui-se que o algoritmo com melhor desempenho em relação aos 3 analisados foi o Levenberg-Marquardt.

Palavras-chave: algoritmos de treinamento, redes neurais artificiais, penetração fotovoltaica, microgeração, qualidade da energia.

Políticas energéticas actuales han animado a la conexión de los generadores de energía basados en tecnologías poco contaminantes, especialmente los que utilizan fuentes renovables en redes de distribución. En consecuencia, se hace muy importante entender los desafíos técnicos en vista de la alta penetración de PV de los sistemas fotovoltaicos en la red, especialmente teniendo en cuenta los efectos intermitentes de esta fuente en la calidad de la energía, la fiabilidad y la estabilidad del sistema de distribución eléctrica. Esto puede afectar a las redes de distribución que están conectados, causando fluctuaciones de tensión, baja tensión y frecuencia. Con el fin de proporcionar estos trastornos, se hace uso de redes neuronales artificiales. Este artículo tiene como objetivo analizar 3 algoritmos de entrenamiento utilizados en las redes neuronales artificiales para la predicción temporal de la potencia activa generada por las placas fotovoltaicas. Como resultado, se concluye que el algoritmo con un rendimiento mejorado en comparación con los 3 se analizó Levenberg-Marquardt.

Palabras clave: algoritmos de entrenamiento, redes neuronales artificiales, penetración fotovoltaica, microgeneración, la calidad de la energía.

Current energy policies are encouraging the connection of power generation based on low-polluting technologies, mainly those using renewable sources, to distribution networks. Hence, it becomes increasingly important to understand technical challenges, facing high penetration of PV systems at the grid, especially considering the effects of intermittence of this source on the power quality, reliability and stability of the electric distribution system. This fact can affect the distribution networks on which they are attached causing overvoltage, undervoltage and frequency oscillations. In order to predict these disturbs, artificial neural networks are used. This article aims to analyze 3 training algorithms used in artificial neural networks for temporal prediction of the generated active power thru photovoltaic panels. As a result it was concluded that the algorithm with the best performance among the 3 analyzed was the Levenberg-Marquardt.

Keywords: training algorithm; artificial neural networks; photovoltaic penetration; microgeneration; power quality.

INTRODUÇÃO

As redes de distribuição, tradicionalmente passivas, ou seja, projetadas para um fluxo de potência unidirecional, desde a subestação até os consumidores finais, não foram concebidas para suportar a inserção de unidades de geração, ou Geração Distribuída (GD). Assim, vários estudos têm indicado que esta integração pode acarretar em problemas técnicos e operacionais para a rede. Tal fato aponta para a necessidade de se entender como se daria esta interconexão, atentando-se para a escolha da melhor barra de conexão, além de ser determinado o modo de operação dos geradores a fim de minimizar os possíveis impactos para a qualidade da energia elétrica e estabilidade do sistema. Adicionalmente, maior atenção deve ser dispensada à natureza intermitente da geração de energia pelos sistemas fotovoltaicos, pois estes dependem da irradiação solar, que condiciona a fiabilidade no fornecimento de energia.

A conexão desta nova fonte de energia, PV, ao sistema de potência existente consiste num importante desafio para a engenharia. Um gerador baseado na energia solar não responde às variações das condições do sistema elétrico da mesma forma que um gerador síncrono tradicional. Mesmo na ausência de transitórios eletromagnéticos, a fonte solar tem características exclusivas, tais como resposta de alta velocidade (baixa inércia) e taxas elevadas da rampa de potência. A instalação em larga escala das fontes fotovoltaicas ("Photovoltaic" – PV) requer meios mais confiáveis para interconexão com a rede de energia elétrica principal.

O Brasil é um país de clima predominantemente tropical com um grande potencial energético para a geração de energia elétrica através da energia solar. Avaliando somente as regiões Centro – Oeste e Sudeste em média o período de insolação diária é de 7 a 8 horas diárias com uma irradiação solar anual em uma média de 16 a 18 (MJ/m².dia) [1].

A geração de energia elétrica através de placas fotovoltaicas em determinados casos se torna uma alternativa viável quando se analisa comunidades distantes e com difícil acesso a linhas e redes de distribuição de energia elétrica [2].

Em 2012 a ANEEL – Agência Nacional de Energia elétrica, aprovou a Resolução Normativa – REN 482/2012 que estabelece as condições gerais para o acesso a micro e minigeração aos sistemas de distribuição de energia elétrica em baixa tensão, alimentados por fontes renováveis de energia [3]. Prevê – se, dessa maneira, um grande aumento na geração de energia elétrica através de placas fotovoltaicas e também o aumento na procura dessa tecnologia. Dessa forma, o setor elétrico nacional vislumbra uma expressiva elevação futura de geração de energia elétrica através de placas fotovoltaicas.

Contudo, os efeitos desse tipo de fornecimento de energia necessitam ser melhor esclarecidos e muitos deles somente se apresentarão quando do aumento da conexão de painéis fotovoltaicos nas redes elétricas.

Em determinadas épocas do ano, como por exemplo, período seco no Brasil, há uma elevação na demanda de energia elétrica. Isto se deve a intensa utilização de refrigeradores de ar. Uma alternativa técnica para restabelecer o equilíbrio carga-geração, para as concessionárias e permissionárias de energia elétrica, seria utilizar a energia fornecida pela micro e minigeração. Contudo, o perfil de carga dos consumidores residenciais se comporta de uma maneira bastante específica. Durante o dia, período em que a geração de

energia elétrica por PV é maior, devido a insolação, os consumidores estão fora de suas residências. Assim, toda a energia elétrica produzida é injeta na rede. Com isso há um aumento considerável de potência ativa disponível na rede de distribuição originando assim uma variação no nível de tensão da rede, neste caso um aumento de tensão [4]. O mesmo fenômeno ocorre de forma inversa ao anoitecer, ou seja, com a redução da produção, e conseqüentemente da injeção de potência ativa na rede, pode se ter um afundamento de tensão em pontos específicos do alimentador.

Assim, uma sobretensão ou uma subtensão ocasionada por micro e minigeradoras inseridos na rede de distribuição de energia elétrica, podem acabar danificando e comprometendo o funcionamento de motores, equipamentos eletrônicos, eletrodomésticos e acabar comprometendo a própria estrutura da rede no que tange às capacidades de distribuição dos condutores elétricos presentes. Neste sentido, estudos vêm sendo feitos para caracterizar, modelar, simular e planejar o comportamento e a operação de sistemas de distribuição com geração distribuída [5-8].

Neste artigo, é apresentada uma análise de desempenho de algoritmos de treinamento utilizados em redes neurais artificiais (RNA), que considera a avaliação de impactos técnicos tais como: o desempenho, o tempo de processamento e respostas desses algoritmos quando utilizados para previsão temporal utilizando-se grande quantidade de entrada de dados; utilizando dados de temperatura na placa fotovoltaica e irradiação solar variáveis no tempo ao longo de um horizonte determinado. O objetivo consiste em encontrar uma ferramenta que leve ao melhor desempenho da rede, minimizando ou maximizando cada aspecto técnico segundo o interesse de se obterem respostas de processamento mais rápidas e com menores erros, conduzindo a soluções mais reais e diversificadas para a tomada de decisões, conhecidas como soluções ótimas. Dada a natureza combinatória deste problema, que requer uma ferramenta de otimização capaz de manipular múltiplos objetivos, os impactos técnicos serão avaliados simultaneamente utilizando uma metodologia baseada no conceito do NARX (*Nonlinear Autoregressive with External Input*). Foram comparados os algoritmos de treinamento disponibilizados na toolbox do MATLAB®, que disponibiliza para o usuário 3 algoritmos de treinamento: Levenberg-Marquardt (LM); *Bayesian Regularization* (BS); e *Scaled Conjugate Gradient* (SCG).

O EFEITO DA IRRADIAÇÃO NA FOTOCÉLULA

A corrente emitida por uma fotocélula é diretamente relacionada à irradiação solar em sua superfície. A corrente de curto-circuito é linearmente proporcional a esta irradiação. Já a tensão de circuito aberto se refere à tensão através do diodo interno da junção p-n quando a fotocorrente gerada passa por ele. A dependência da tensão de circuito aberto à irradiação corresponde à dependência que a tensão da junção p-n tem com a fotocorrente, de forma que quando a irradiação é baixa – sendo também a fotocorrente gerada – a tensão de circuito aberto é baixa. A figura 1, demonstra como é o formato da curva de corrente por tensão para diversas irradiações.




Fig. 1. Curva corrente por tensão de uma fotocélula com diferentes irradiações.

O EFEITO DA TEMPERATURA NA FOTOCÉLULA

Em semicondutores a largura de banda de energia diminui com o aumento da temperatura. Em uma fotocélula, com a temperatura mais alta, mais fótons têm energia suficiente para criar pares p-n. Como consequência da crescente difusão dos portadores minoritários, na corrente de curto-circuito, é observado um ligeiro aumento, porém o efeito é muito pequeno, sendo de apenas 0,07% de aumento por Kelvin [9]. A tensão de circuito aberto é fortemente dependente da temperatura, caindo 0,4% por Kelvin e a potência caindo de 0,4 a 0,5% por Kelvin [9]. A temperatura deve ser considerada em projeto, já que a instalação de módulos em locais exteriores pode levar a um aumento de 40 Kelvin acima da temperatura ambiente. A figura 2, demonstra o efeito da temperatura em uma fotocélula.




Fig. 2. Curva de corrente por tensão de uma fotocélula com diferentes temperaturas.

REDES NEURAIS ARTIFICIAIS

Heurísticas

Em problemas de reconfiguração, em que a complexidade da solução é uma função do número de variáveis e, o elevado número dessas pode levar a uma explosão combinatória, dificultando a utilização de programação matemática para a resolução desses problemas.

Neste cenário, surgem as técnicas heurísticas - conjuntos de regras e métodos que conduzem à solução relativamente rápida de problemas, mas não asseguram que esta seja a melhor. Com isso, obtêm-se ganhos em termos de eficiência computacional em detrimento da precisão das respostas encontradas.

O funcionamento de uma rede neural artificial

O funcionamento do cérebro humano vem sendo alvo de estudos científicos durante muitos anos e ainda fascina pesquisadores pelo fato de ser um órgão extremamente complexo na maneira do seu funcionamento. A forma como o cérebro reconhece e identifica uma fisionomia ou um som é extremamente complexa. Porém, a compreensão do funcionamento do cérebro pode ser de grande valia para estudos computacionais quando esses são traduzidos em linguagens de programação.

SIMON (1999) define uma rede neural como um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso [10]. Ela se assemelha ao cérebro humano em dois aspectos:

O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;

Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O processo de aprendizagem é realizado através de um algoritmo de aprendizagem cujo o objetivo é mudar os pesos sinápticos de forma que a rede neural artificial se adapte e alcance o objetivo desejado [10].

Devido à sua disseminação, e desempenho para a resolução de problemas com o auxílio da computação, as redes neurais artificiais têm sido amplamente utilizadas como uma rede neural para identificar uma pessoa através de sua voz[11]. No que tange ao setor elétrico, as redes neurais artificiais foram aplicadas a previsão de carga em curto prazo em redes de distribuição, bem como para a previsão de eficiência de geração de energia elétrica através de placas fotovoltaicas, e como ferramenta auxiliar para a quantificação de variações de tensão de curta duração[12-14].

Arquitetura de redes

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. A maneira como estes algoritmos estão estruturados são chamadas de "arquitetura de redes". Em geral, pode-se citar três classes de arquiteturas de rede fundamentalmente diferentes[10]:

- Redes alimentadas adiante com camada única,
- Redes alimentadas diretamente com múltiplas camadas;
- Redes recorrentes.

Inteligência artificial e redes neurais

SIMON (1999) diz que "o objetivo da inteligência artificial (IA) é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas cognitivas, para as quais os humanos são atualmente melhores" [10]. Um sistema de IA deve ser capaz de fazer três coisas: (1) armazenar conhecimento; (2) aplicar o conhecimento armazenado para resolver problemas e (3) adquirir novo conhecimento através da experiência.

Um sistema de IA tem três componentes fundamentais: representação, raciocínio e aprendizagem.

MATERIAIS E MÉTODOS

Para este trabalho, foram coletados dados climáticos de irradiância (W/m^2), temperatura ambiental ($^{\circ}C$), potência medida (W), temperatura da placa solar ($^{\circ}C$) e as horas dos dias (hs) para o mês de outubro de 2015 na cidade de Uberlândia - MG (Brasil). Esses dados serviram como dados de entrada para a preparação da rede. A figura 3, mostra a potência gerada por uma placa fotovoltaica de acordo com os dados coletados em um período de 29 dias. Os dados de potência ativa gerada, de acordo com os dados de entrada citados anteriormente, serviram como dados de objetivo para a preparação da rede neural artificial. As características das placassão fornecidas na tabela 1.




Fig. 3. Irradiância, temperatura da célula e potência gerada.

TABELA 1. CARACTERÍSTICAS ELÉTRICAS DA PLACA SOLAR	
Desempenho elétrico nas condições padrões de irradiância de 1.000 W/m ² , AM=1,5 e temperatura da célula de 25 °C (STC)	
Potência Máxima: P _{máx} (W)	235 W (0/+5%)
Tensão de Potência Máxima: V _{mpp} (V)	30,5 V
Corrente de Potência Máxima: I _{mpp} (A)	7,71 A
Tensão de Circuito Aberto: V _{oc} (V)	37 V
Corrente de Curto Circuito: I _{cc} (A)	8,4 A
Tensão Máxima (V)	1000 V
Coefficiente de Temperatura de V _{oc}	- 0,4049 %/°C
Coefficiente de Temperatura de I _{cc}	0,0825 %/°C
Desempenho elétrico a 800 W/m ² , NOCT 20 °C, AM=1,5, Velocidade do Vento 1 m/s	
Potência Máxima: P _{máx} (W)	172 W
Tensão de Potência Máxima: V _{mpp} (V)	27,7 V
Corrente de Potência Máxima: I _{mpp} (A)	6,2 A
Tensão de Circuito Aberto: V _{oc} (V)	33,9 V
Corrente de Curto Circuito: I _{cc} (A)	6,8 A

Para a preparação da rede neural artificial, foi utilizado o software MATLAB®. Esse software disponibiliza em sua toolbox modelos de redes neurais artificiais, das quais podemos citar: Fitting tools; Pattern-Recognition tool; Clustering tool; Time series Tool.

Para esta pesquisa foi utilizada a ferramenta para a previsão temporal de dados **time series tool**.

A ferramenta escolhida ainda dá a opção de 3 tipos de soluções para problemas, a NARX (Non-linear Auto-Regressive eXogenous); a NAR (Non-linear Auto-regressive); e a Non-Linear Input-Output. Foi escolhida a solução NARX.

A rede neural NARX pode ser expressa por equação (1):

$$y_{t+1} = f(x_t, x_{t-1}, \dots, x_{t-n}, y_t, y_{t-1}, \dots, y_{t-n},) \quad (1)$$

onde o próximo valor do sinal de saída, y_{t+1} , é regredida utilizando os valores anteriores medidos y_t, y_{t-1} , e sinais de entradas u_t, u_{t-1} , (isto é, temperatura ambiental, temperatura da célula, tempo e potência medida). A função f representa a rede neural, onde os pesos de cada conexão na rede são treinados pelos algoritmos de treinamentos.

A estrutura da rede neural NARX é ilustrada na figura 4.




Fig. 4. Estrutura da rede NARX.

Para cada sinal de entrada, p , está associado um peso, w , para fortalecer ou empobrecer o sinal de entrada. A RNA calcula o sinal de entrada de rede, e usa um ativador de função (função de transferência) para calcular o sinal de saída, "o", dada a entrada da rede. A força do sinal de saída é ainda influenciada por um valor limiar, b , também referida como *bias* [15-16]. Essa relação pode ser expressada por na equação (2), [17]:

$$y_j = \sum_{i=1}^n w_{ij} u_i + b_j \quad (2)$$

Neste trabalho foram comparados os algoritmos de treinamento disponibilizados na toolbox do MATLAB®. Este disponibiliza para 3 algoritmos de treinamento mais comumente utilizados: Levenberg-Marquardt (LM); *Bayesian Regularization*(BS); e *Scaled Conjugate Gradient* (SCG).

O algoritmo para treinamento Scaled Conjugate Gradient é apresentado na figura 5, [16].

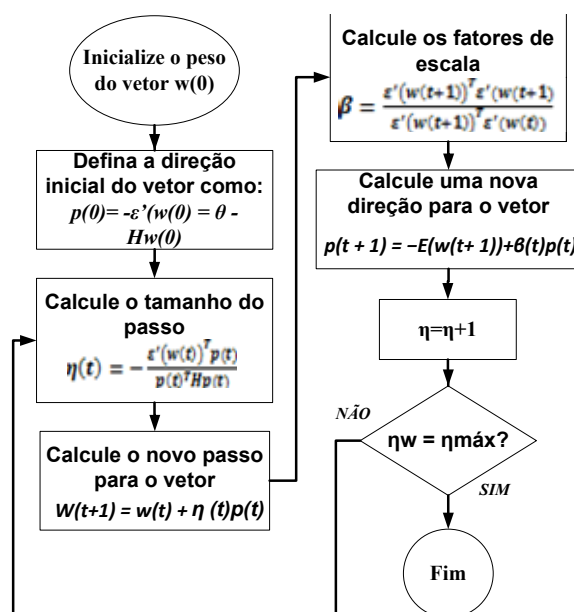


Fig. 5. Algoritmo de treinamento para *Scaled Conjugat Gradient*.

Para o método de Levenberg-Marquardt, a mudança nos pesos (v_i) podem ser obtidas resolvendo-se equação (3), [18]:

$$\sum_{j=1}^n \alpha_{ij} v_{ij} = -\frac{1}{2} \frac{\partial E}{\partial v_i} \quad (3)$$

Em que "n" é o número de pesos adaptáveis da rede, "E" o erro médio quadrático da rede e "α" uma matriz cujos elementos são dados por equação (4), [18]:

$$\alpha_{ij} = (1 + \lambda \delta_{ij}) \sum_{k=1}^N \left[\frac{\partial y(x_k)}{\partial w_i} \frac{\partial y(x_k)}{\partial w_j} \right] \quad (4)$$

O método BayesianRegularization altera a função de desempenho de erro anexando desvio padrão dos pesos e os limiares [19]. Ou seja equação (5):

$$F = \beta E_D + \alpha E_w \quad (5)$$

Em que α e β são parâmetros de regularização.

Usando(4) para minimizar a performance de erro, habilita a rede a ter menores pesos e limites. Isso equivale a reduzir o tamanho da rede de forma que a mesma responda suavemente reduzindo o *overfitting*. Redes Bayesianas são ferramentas que descrevem distribuições de probabilidade através de uma representação gráfica [20].

RESULTADOS

Tratados os dados de entrada e de saída da rede neural escolhida, foi feito o treinamento dessa rede através dos 3 algoritmos citados anteriormente. A capacidade da rede utilizada para o treinamento foi 75%. Para a validação e teste, ambos, 15%. Ao todo, entre dados de entrada e de objetivo, foram utilizados 2820 dados para a preparação e treinamento da rede. Os testes foram feitos em um PC com 3.40GHz Intel Core i7A Pentium® e 8 GB de memória RAM. Com relação ao treinamento da rede neural, uma das alternativas para resolver o problema da parada do treinamento é a técnica da validação cruzada. Ao invés de definir o número exato de iterações de ajuste de pesos no treinamento divide-se aleatoriamente o conjunto de dados em 3 subconjuntos: treinamento, validação e testes. Com isso, a cada iteração a rede é treinada, já com os pesos ajustados, é testada com o subconjunto de validação e o erro da predição é calculado ao final da iteração. A motivação é ajustar os pesos com os dados do subconjunto de treinamento e calcular o erro com os dados do subconjunto de validação, fornecendo assim, dados diferentes à rede. Assim, o erro da validação cruzada começa alto, decresce até certo ponto e depois aumenta. Enquanto o erro da validação está diminuindo a rede está generalizando, quando o erro começa a aumentar, ao mesmo tempo em que o erro do treinamento continua a diminuir, a rede começa a decorar as entradas, perdendo a capacidade de generalização. Nesse momento a rede deve parar o treinamento. As figuras 6 e 7, ilustram a validação e o teste de erros da RNA de acordo com os algoritmos BS, LM e SCG, respectivamente.

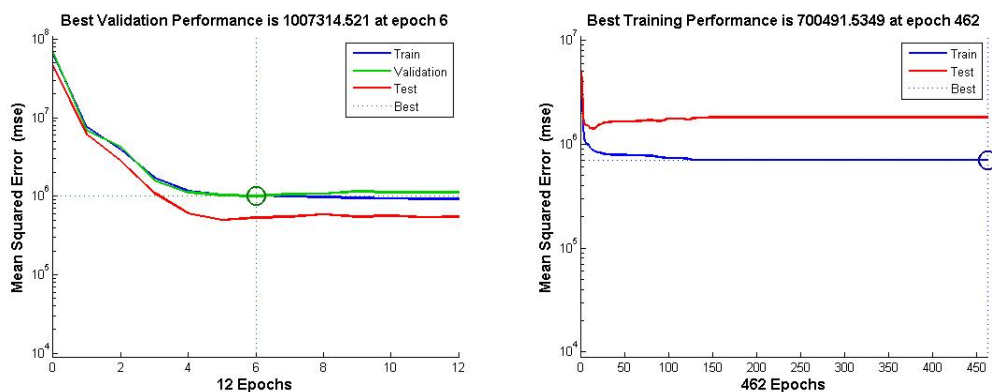


Fig. 6. Mean Square Error (mse) para o algoritmo de treinamento BS e para o LM.




Fig.7. Mean Square Error (mse) para o algoritmo de treinamento SCG.

As figuras. 8 e 9, ilustram a regressão linear da RNA de acordo com os algoritmos BS, LM e SCG, respectivamente.




Fig. 8. Regressão linear para o algoritmo de treinamento BS e LM.




Fig. 9. Regressão linear para o algoritmo de treinamento SCG.

CONCLUSÕES

Comparando-se os MSE observa-se que o algoritmo LM teve um melhor desempenho, uma vez que a validação e os testes de erros decresceram em menos iterações que os demais (12 Epochs). Para a regressão linear o algoritmo SCG obteve o melhor desempenho para o treinamento ($R = 0,92062$) e validação ($R = 0,9055$), resultando em uma melhor regressão no geral ($R = 0,9003$). Por tanto, conclui-se que apesar da diferença de resultados, entre os 3 tipos de algoritmos de treinamento, ser pequena torna-se conveniente adotar o algoritmo Levenberg-Marquardt, uma vez que este necessitou de menos iterações do que os demais algoritmos para treinar e preparar a rede neural.

REFERÊNCIAS

- [1] Agência Nacional de Energia Elétrica – ANEEL. Atlas de energia elétrica do Brasil. 2ª Ed. Brasília - DF. 2005.[Consulta: 6 de julho de 2015].
- [2] Ce. Shang, D. Srinivasan, T. Reindl, An improved particle swarm optimization algorithm applied to battery sizing for stand-alone hybrid power systems, *Int J Electr Power Energy Syst*, Elsevier, vol. 74, pp 104-117, 2016.[Consulta: 20 de setembro de 2015].
- [3] M. K. Junior, A. V Soares, P. F. Barbosa, and M. E. M. Udaeta, Distributed Generation in Brazil : Advances and gaps in regulation, *IEEE Latin America Transactions*, vol. 13, no. 8, pp. 2594–2601, 2015.[Consulta: 19 de setembro de 2015].
- [4] J.Descheemaeker, V. J.Ryckeghem, C. V.Steenberge, C.Debruyne, J.Desmet. Incentives and technical considerations related to increased voltage tolerance in low voltage distribution grids. ICHQP. Romênia. Mai. 2014.[Consulta: 27 dezembro de 2015].
- [5] G. Salazar and D. Carrión, Characterization and Modeling of the Efficiency of Photovoltaic Systems, *IEEE Latin America Transactions*, vol. 13, no. 8, pp. 2580–2586, 2015. [Consulta: 25 de setembro de 2015].
- [6] E. N. Conceição and K. M. Silva, Modeling and Simulation of the Protection of Distribution Feeders in ATP, *IEEE Latin America Transactions*, vol. 13, no. 5, pp. 1392–1397, 2015. [Consulta: 07 de outubro de 2015].
- [7] A. V. Netto, Planning of Network System for the Distribution and Transmission Areas of Electric Energy, *IEEE Latin America Transactions*, vol. 13, no. 1, pp. 345–352, 2015. [Consulta: 05 de outubro de 2015].
- [8] A. Barin, L. Canha, A. Abaide, and R. Machado, Methodology for placement of Dispersed Generation Systems by analyzing its Impacts in Distribution Networks, *IEEE Latin America Transactions*, vol. 10, no. 2, pp. 1544–1549, 2012. [Consulta: 10 de outubro de 2015].
- [9] E. Skoplaki, A. G. Boudouvis, and J. A. Palyvos, “A simple correlation for the operating temperature of photovoltaic modules of arbitrary mounting,” *Sol. Energy Mater. Sol. Cells*, vol. 92, no. 11, pp. 1393–1402, 2008.[Consulta: 19 de outubro de 2015].
- [10] H. Simon. *Neurals Networks: a comprehensive foundation*. 1999. Prentice Hall, Inc.
- [11] F. L. Alegre, Aplicación de RNA y HMM a la verificación automática de locutor, *IEEE Latin America Transactions*, vol. 5, no. 5, pp. 329–337, 2007.[Consulta: 23 de outubro de 2015].
- [12] F. Ferro, R. Wazlawick, R. Bastos, and C. Oliveira, Improvement of the Short Term Load Forecasting Through the Similarity Among Consumption Profiles, *IEEE Latin America Transactions*, vol. 7, no. 5, pp. 527–532, 2009. [Consulta: 25 de outubro de 2015].
- [13] G. A. Rampinelli, M. A. A. Teyra, A. Krenzinger, and C. W. M. Prieb, Artificial Intelligence Techniques Applied to Energetic Analysis of Photovoltaic Systems, *IEEE Latin America Transactions*, vol. 8, no. 5, pp. 512–518, 2010. [Consulta: 27 de outubro de 2015].
- [14] R. N. D. M. Machado, U. H. Bezerra, E. G. Pellaes, R. C. L. De Oliveira, and M. E. D. L. Tostes, Use of wavelet transform and Generalized Regression Neural Network (GRNN) to the characterization of short-duration voltage variation in electric power system, *IEEE Latin America Transactions*, vol. 7, no. 2, pp. 217–222, 2009. [Consulta: 4 de novembro de 2015]
- [15] P. E. Andries. *Computational Intelligence An Introduction*. Second Edition. Wiley, 2007. [Consulta: 22 de novembro de 2015].
- [16] H. Shayeghi, H. A. Shayanfar, and O. P. Malik, “Robust decentralized neural networks based LFC in a deregulated power system,” *Electr. Power Syst. Res.*, vol. 77, no. 3–4, pp. 241–251, 2007. [Consulta: 17 de novembro de 2015].
- [17] R. Tapakis, S. Michaelides, and A. G. Charalambides, “Science Direct Computations of diffuse fraction of global irradiance : Part 2 – Neural Networks,” *Sol. ENERGY*, 2016. [Consulta: 14 de novembro de 2015].

- [18] G. Lera, M. Pinzolas, A quasi-local levenberg-marquardt algorithm for neural network training, *Neural Networks Proceedings*, 1998. *IEEE World Congr. Comput. Intell. 1998 IEEE Int. Jt. Conf.*, vol. 3, pp. 2242–2246 vol.3, 1998. [Consulta: 15 de novembro de 2015].
- [19] X. Li, D. Wang., A Sensor Registration Method Using Improved Bayesian Regularization Algorithm, *Int. Jt. Conf. Comput. Sci. Optim.*, no. 4, pp. 195–199, 2009. [Consulta: 5 de dezembro de 2015].
- [20] A.C. Pifer; L.A. Guedes, Aprendizagem Estrutural de Redes Bayesianas Utilizando Métrica MDL Modificada, *IEEE Latin America Transactions*, vol. 5, no. 8, pp. 644–651, 2007. [Consulta: 10 de dezembro de 2015].

AUTORES

Raul Vitor Arantes Monteiro

Engenheiro Eletricista pela Universidade Federal de Mato Grosso (UFMT) em 2010. Mestre em Engenharia de Edificações e Ambiental pela UFMT em 2015. Atualmente está inserido no Programa de Pós Graduação em Engenharia Elétrica pela Universidade Federal de Uberlândia (UFU) como aluno de doutorado.

e-mail: raulvdm@terra.com.br

Geraldo Caixeta Guimarães

Engenheiro Eletricista pela Universidade Federal de Uberlândia (UFU) em 1977. Mestre em Engenharia Elétrica pela Universidade Federal de Santa Catarina (1984) e (PhD) pela University of Aberdeen (1990). Desde 1992 é professor titular na Universidade Federal de Uberlândia.

e-mail: raulvdm@terra.com.br

Madeleine Rocio Castillo

Mestre e doutora em Engenharia Elétrica pela Universidade de São Paulo - Escola de Engenharia de São Carlos. Atualmente trabalha na Universidade Federal do Triângulo Mineiro.

e-mail: rociodel pilar_21@hotmail.com

Fabrcio Augusto Matheus Moura

Engenheiro eletricista, mestre e doutro em ciências pela Universidade Federal de Uberlândia (UFU) respectivamente em 2005, 2008 e 2010. Professor e pesquisador do Departamento de Engenharia Elétrica, Universidade Federal do Triângulo Mineiro (UFTM).

e-mail: fabrcio@eletrica.ufm.edu.br

Márcio Augusto Tamashiro

Engenheiro Eletricista pela Universidade Federal de Uberlândia (UFU) em 1998. Mestre em Engenharia Elétrica pela UFU em 2004. Desde 2005 é professor do Instituto Federal de Educação, Ciência e Tecnologia do Tocantins (IFTO) – Campus Palmas.

e-mail: marcio.tamashiro@gmail.com