APLICAÇÃO DO MÉTODO METAHEURÍSTICO EVOLUÇÃO DIFERENCIAL PARA ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FOTOVOLTAICOS

RAFAELA D. SILVEIRA, SÉRGIO A. O. DA SILVA, FÁBIO R. DURAND, LEONARDO P. SAMPAIO

LEPQER - Laboratório de Eletrônica de Potência, Qualidade de Energia e Energias Renováveis Universidade Tecnológica Federal do Paraná – UTFPR Av. Alberto Carazzai, 1640, CEP. 86300-000, Cornélio Procópio – PR, Brasil E-mails: rafaeladsilveira@hotmail.com, augus@utfpr.edu.br, fabiodurand@utfpr.edu.br, sampaio@utfpr.edu.br

Abstract— This work presents the study and application of an evolutionary algorithm based on Differential Evolution (DE) metaheuristic method that is employed for estimation of some parameters needed to represent the equivalent model of the photovoltaic (PV) cell. The DE algorithm can be used in search of global optimal points with fast convergence time, configuration of few control variables and accuracy. Since the parameters, such as parallel and series resistances, diode reverse saturation current and diode ideality factor, are not usually provided by the PV module manufactures, the knowledge of them allows that the photovoltaic cell and, hence, the photovoltaic modules being represented with more accuracy. The identification of the referred parameters is performed by means of the data, as well as the current-voltage (I-V) characteristic curve provided by the PV module manufactures, which will be used as input of the ED algorithm. The problem formulation has as main objective to minimize the error between the reference I-V curve and the I-V curve achieved from the ED algorithm. Simulation results show that, by using the DE algorithm, the desired parameters are effectively estimated in a small number of iterations and fast convergence time.

Keywords— Differential evolution metaheuristic method, evolutionary algorithms, photovoltaic modules, parameter estimation.

Resumo— Este trabalho apresenta o estudo e aplicação de um algoritmo evolutivo (AE) baseado no método metaheurístico Evolução Diferencial (ED) empregado na estimação de parâmetros necessários para representar o modelo equivalente de uma célula fotovoltaica (FV). O algoritmo ED pode ser utilizado na busca de pontos ótimos globais apresentando rápida convergência, configuração de poucas variáveis de controle e precisão. Uma vez que os parâmetros, representados pelas resistências série e paralela, corrente de saturação reversa e fator de idealidade do diodo, não são fornecidos pelos fabricantes de módulos fotovoltaicos, o conhecimento dos mesmos permite que a célula fotovoltaica e consequentemente o módulo FV, sejam representados com maior exatidão. A identificação dos referidos parâmetros é realizada a partir de dados e da curva característica corrente-tensão (I-V) de referência fornecidos pelos fabricantes de módulos FV, os quais servirão de entrada do algoritmo ED. A formulação do problema tem como objetivo minimizar o erro entre a curva I-V de referência e a curva I-V obtida a partir do algoritmo ED. Resultados de simulação mostram que, com a utilização do algoritmo ED, os parâmetros desejados são efetivamente estimados em um pequeno número de iterações e rápida convergência.

Palavras-chave— Método metaheurístico evolução diferencial, algoritmos evolutivos, módulos fotovoltaicos, estimação de parâmetros.

1 Introdução

A busca por fontes de energia alternativas e renováveis tem crescido substancialmente nos últimos anos em decorrência do aumento da demanda de energia elétrica, de possível esgotamento das reservas energéticas disponíveis e também pela preocupação com o meio ambiente (Adefarati & Bansal, 2016).

Diante desse cenário, a energia solar fotovoltaica tem se consolidado como um potencial investimento sustentável para a geração de energia elétrica, por ser considerada uma energia limpa, com baixa degradação ecológica e tecnicamente viável (Prada-Gil et al., 2017; Bhattacharya & Mishra, 2016). Isto justifica a crescente ampliação da participação da energia solar nas matrizes energéticas de vários países.

A produção direta de energia elétrica através da energia proveniente do sol é realizada a partir de painéis ou módulos fotovoltaicos (FV). Por sua vez, um módulo fotovoltaico, é constituído por várias células fotovoltaicas, as quais são dispositivos de material semicondutor que convertem a energia incidente do sol em energia elétrica (Schonardie & Martins, 2008; Goetzberger & Hoffmann, 2005). O tipo de material da célula fotovoltaica está diretamente relacionado à sua eficiência e, além disso, fatores climáticos como irradiação solar e temperatura podem influenciar as características elétricas de corrente e tensão de saída da célula.

Sendo assim, técnicas e métodos de rastreamento do ponto de máxima potência (MPPT – *Maximum Power Point Tracking*) são frequentemente empregados nas estruturas de sistemas fotovoltaicos, como forma de garantir que o sistema esteja sempre operando em sua máxima eficiência (Kivimäki et al., 2018; Oliveira et al., 2016; Lyden & Haque, 2015).

Todavia, para se desenvolver um sistema de geração de energia fotovoltaica e possibilitar as implementações de sistemas de controle e técnicas de MPPT, é primordial o uso de programas computacionais de simulação para as devidas análises dinâmicas do sistema (Gow & Manning, 1996).

Desse modo, torna-se necessária a obtenção de um modelo matemático capaz de reproduzir o comportamento de uma célula fotovoltaica de maneira precisa.

Na literatura, são mostrados alguns modelos que representam as características elétricas das células fotovoltaicas através de circuitos elétricos equivalentes, utilizando parâmetros que influenciam em seu desempenho (Huang, et al., 2016; Guo et al., 2012; Xiao, Dunford & Capel, 2004). Dentre tais parâmetros, podem ser citadas as resistências série e paralela, a corrente de saturação reversa do diodo e o fator de idealidade da junção p-n, os quais geralmente não são fornecidos pelos fabricantes, dificultando assim a caracterização da célula fotovoltaica. Além disso, as análises matemáticas dos circuitos equivalentes apresentam equações analíticas não-lineares complexas, e para serem usadas, muitas vezes requerem o uso de métodos iterativos (Villalva, Gazoli & Filho, 2009).

Algoritmos Evolutivos (AE), como os Algoritmos Genéticos (AG) têm sido propostos para a solução e determinação dos parâmetros de módulos fotovoltaicos (Zhang & Haque, 2016; Maherchandani, Agarwal & Sahi, 2012; Jervase, Bourdoucen & Al-Lawati, 2011; Moldovan, Picos & Garcia-Moreno, 2009). No caso do AG, apesar de ser amplamente utilizado na busca de soluções em problemas de otimização, o mesmo apresenta convergência prematura e baixa velocidade de execução (Ishaque et al., 2011).

Outra técnica de AE, o método metaheurístico Evolução Diferencial (ED), introduzida por (Storn & Price, 1995), também tem sido empregada na busca de melhores resultados e já foi utilizada em diversas aplicações (Costa et al., 2017; Tang, Dong & Liu, 2015; Yahia, Liouane & Dhifaoui, 2014). O método ED utiliza uma abordagem diferente das aplicadas aos algoritmos genéticos e quando comparados entre si, o método ED se destaca apresentando menor tempo de convergência, configuração de poucas variáveis de controle e melhor precisão (Ishaque et al., 2011). Além disso, o método ED apresenta um esquema de mutação, operador genético, baseado na diferença vetorial de um número substancial de vetores; isso reduz a probabilidade do algoritmo se prender em pontos ótimos locais, sendo a técnica robusta e eficiente para funções não-lineares no espaco contínuo (Zhou et al., 2017; Storn & Price, 1995).

Neste trabalho, é apresentado a aplicação de um algoritmo baseado no método metaheurístico Evolução Diferencial para estimação de parâmetros de um módulo fotovoltaico (Sunmodule Plus SW 245 da SolarWorld). O algoritmo ED, utiliza como referência de entrada os dados e a curva corrente-tensão (I-V) fornecidos no datasheet do fabricante. Em seguida, a partir da execução do algoritmo, uma função de análise fornece a corrente gerada pelo módulo fotovoltaico resultando na curva corrente-tensão (I-V) com os parâmetros estimados, sem a necessidade de manipulações das equações matemáticas do modelo. O algoritmo ED se comporta como um aproximador de função, cujo objetivo é minimizar o erro entre as curvas I-V estimada e a de referência. Resultados de simulação são apresentados com intuito de validar a aplicação do algoritmo e avaliar os desempenhos englobando aspectos relacionados com a precisão, tempo de convergência e número de iterações necessárias.

2 Modelo matemático da célula fotovoltaica

O funcionamento de uma célula fotovoltaica pode ser determinado através do seu circuito elétrico equivalente, representado pelo modelo de um diodo, como ilustrado na Figura 1. Este modelo apresenta um desempenho satisfatório e tem sido o mais utilizado em estudos e aplicações que envolvem sistemas fotovoltaicos (Sampaio & Silva, 2017; Oliveira et al., 2016; Benda, 2014; Guo et al., 2012).



Figura 1. Circuito elétrico de uma célula fotovoltaica.

A corrente gerada pela célula fotovoltaica, pode ser obtida através da equação (1) onde, $V \in I$ são respectivamente tensão e corrente nos terminais de saída da célula; I_{ph} é a fotocorrente; I_r a corrente de saturação reversa da célula; $R_s \in R_p$ são respectivamente as resistências série e paralela do circuito equivalente; q é a carga do elétron 1,6.10⁻¹⁹, k é a constante de Boltzmann 1,38.10⁻²³, T é a temperatura em K e n é o fator de idealidade da junção p-n.

$$I = I_{ph} - I_r \left[e^{q \left(\frac{V + IR_s}{nKT} \right)} - 1 \right] - \frac{V + IR_s}{R_p}$$
(1)

A Figura 1 caracteriza a representação de uma única célula fotovoltaica. Contudo, os módulos fotovoltaicos comerciais são constituídos pela conexão de várias células. Sendo assim, a equação (1) é adequada à estrutura do módulo fotovoltaico por meio de (2), onde N_s é o número de células configuradas em série.

$$I = I_{ph} - I_r \left[e^{q \left(\frac{VN_s + IR_s}{nKT} \right)} - 1 \right] - \frac{VN_s + IR_s}{R_p}$$
(2)

Neste trabalho, a equação (2) é utilizada como função de análise do método ED e, sua solução resulta na curva característica corrente-tensão (I-V), a qual é considerada como um dado de comparação na função objetivo do problema. A solução do problema fornece assim, os parâmetros desejados do modelo do módulo fotovoltaico.

3 Formulação do Problema

Os parâmetros a serem estimados pelo algoritmo ED podem ser descritos por um vetor conforme mostrado em (3).

$$\rho = [R_s \quad R_p \quad I_r \quad n] \tag{3}$$

Durante a execução do algoritmo, é realizada uma avaliação da aptidão dos vetores, através de uma função objetivo, para a solução do problema. A função objetivo utilizada neste estudo está mostrada em (4), e representa o erro quadrático médio (J) calculado a partir da diferença entre a corrente I_e obtida com os parâmetros estimados por simulação, e a corrente I_t obtida por meio do *datasheet* do fabricante.

$$J = \sum_{n=1}^{N} (I_{t} - I_{e})^{2}$$
(4)

Um valor pequeno de J implica em um desvio pequeno entre a corrente estimada a partir do modelo e a corrente do módulo fotovoltaico. Idealmente, é desejado que J seja nulo.

4 Método Metaheurístico Evolução Diferencial

No método metaheurístico Evolução Diferencial, as populações de indivíduos são criadas e submetidas aos operadores genéticos: mutação, cruzamento e seleção. Estes operadores utilizam uma indicação da qualidade de cada indivíduo como solução do problema (avaliação) e geram um processo de evolução natural destes indivíduos, que possivelmente deverá gerar um indivíduo que caracterizará uma boa solução, ou a melhor solução possível, para um determinado problema (Coelho & Mariani, 2006).

4.1 Inicialização

Seja uma população inicial, gerada aleatoriamente na geração G, com NP vetores, cobrindo todo o espaço de busca:

$$x_{i,G}, i = 1, 2, \dots NP$$
 (5)

Onde, $x_{i,G}$ são denominados vetores *targets* e o número de elementos de tais vetores, é equivalente ao número de parâmetros a serem estimados pelo algoritmo.

4.2 Mutação

No processo de mutação, novos vetores de parâmetros são gerados através da adição da diferença vetorial ponderada entre dois vetores da população a um terceiro vetor.

A equação (6) é utilizada para a obtenção do vetor mutado $v_{i,G+1}$, onde três vetores distintos $(x_{r_1,G}, x_{r_2,G}, x_{r_3,G})$ são selecionados aleatoriamente no intervalo [1, *NP*]. O vetor $x_{r_1,G}$ é chamado vetor base e os índices i, r_1, r_2, r_3 são inteiros e distintos entre si; *F* é uma variável de controle do algoritmo, tipicamente definida no intervalo [0,2] e determina a ponderação da diferença vetorial $(x_{r_2,G} - x_{r_3,G})$.

$$v_{i,G+1} = x_{r_1,G} + F(x_{r_2,G} - x_{r_3,G})$$
(6)

A Figura 2 apresenta a representação gráfica do processo de mutação no algoritmo ED.



Figura 2. Representação gráfica do processo de mutação do método Evolução Diferencial.

4.3 Cruzamento

O cruzamento é introduzido no método ED para aumentar a diversidade dos indivíduos que passaram pelo processo de mutação. Sendo assim, os elementos dos vetores mutados $V_{i,G+1}$, são combinados com os elementos de outros vetores, $X_{i,G}$, gerados anteriormente de forma aleatória. Essa combinação irá resultar nos vetores tentativas $U_{i,G+1}$, de acordo com a equação (7), onde C_r é denominada taxa de cruzamento e é definida no intervalo [0,1].

A obtenção do vetor tentativa pode ser representada de acordo com a ilustração da Figura 3.

4.4 Avaliação e seleção

Caso o vetor tentativa $u_{i,G+1}$ apresente melhor aptidão que o vetor *target* $x_{i,G}$ no processo de solução do problema, o vetor tentativa será o primeiro vetor *target* da geração seguinte. Essa é a etapa de seleção dos indivíduos, e pode ser descrita por (8), onde J é a função objetivo a ser minimizada no algoritmo.

$$x_{i,G+1} = \begin{cases} u_{i,G+1}, & J(u_{i,G+1}) < J(x_{i,G}) \\ x_{i,G}, & caso \ contrário \end{cases}$$
(8)



Figura 3.Ilustração do processo de cruzamento no método Evolução Diferencial, considerando vetores com 4 parâmetros.

4.5 Pseudocódigo

Os algoritmos evolutivos podem ser descritos como um procedimento contínuo dos ciclos de evolução até que o critério de parada estabelecido no algoritmo seja atingido.

Neste caso, o pseudocódigo para implementação do algoritmo Evolução Diferencial, é descrito como segue:

- **1.** Definir as variáveis NP, C_r , $F \in G$;
- 2. Gerar aleatoriamente a população inicial;
- Avaliar a aptidão de cada indivíduo na funcão objetivo;
- Prosseguir com o processo de iteração até o critério de parada, onde:

Para cada indivíduo:

a) Escolher vetor *target* e vetor base;

b) Escolher dois indivíduos da população de forma aleatória;

c) Computar o vetor de diferença ponderada;

d) Adicionar ao vetor base e ao de cruzamento com o vetor *target* para obter o vetor tentativa;

 e) Selecionar o vetor tentativa com melhor solução para o problema;

Fim para cada indivíduo

5. Fim.

5 Resultados

Neste trabalho, a estimação dos parâmetros do módulo fotovoltaico é realizada considerando as condições padronizadas de teste, denominada STC (*Standard Test Conditions*), com radiação solar igual a 1000 W/m² e temperatura de 25°C.

O módulo fotovoltaico em estudo, pertence à fabricante SolarWorld[®] cuja especificação é SW 245 Mono. A curva característica I-V do módulo PV foi considerada como parâmetro de entrada do algoritmo ED, o qual foi implementado utilizando o *software* MATLAB[®].

A Figura 4 apresenta a curva de entrada do algoritmo, enquanto que as especificações do módulo fotovoltaico se encontram na Tabela 1.



Figura 4. Curva I-V do módulo fotovoltaico, sinal de entrada no algoritmo Evolução Diferencial.

Tabela 1. Parâmetros do módulo fotovoltaico SW 245 Mono SolarWorld.

Parâmetros do módulo fotovoltaico SW 245 Mono SolarWorld		
Potência máxima	245 Wp	
Tensão de circuito aberto	37,7 V	
Corrente de curto-circuito	8,25 A	
Número de células em série	60	

As variáveis de controle definidas no algoritmo ED estão apresentadas na Tabela 2. Não há uma regra para estabelecer os valores de tais variáveis, porém, na maioria dos casos, o fator de mutação é escolhido como sendo F > 0,4 (Storn & Price, 1995). Já para a taxa de cruzamento, um valor alto intensifica a diversidade da população, melhorando a convergência. Além disso, é desejável que C_r seja alto pois os parâmetros a serem estimados estão altamente relacionados entre si (Ishaque et al., 2012). A definição de NP e G depende das características e complexidade do problema e podem ser selecionados de forma empírica, entretanto, quanto maior o valor NP, maior o tempo de convergência do algoritmo.

Tabela 2. Variáveis de controle definidas no algoritmo ED.

Variáveis de controle do algoritmo ED	Valor
Tamanho da população (NP)	20
Fator de ponderação (F)	0,8
Taxa de cruzamento (C_r)	0,9
Número máximo de gerações (G)	100

No algoritmo ED, também foi estabelecido um critério de parada atribuindo um valor inferior a 0,01 para a função objetivo. Isso significa que o algoritmo é executado por consecutivas repetições até que um erro menor que 1% entre as curvas I-V simulada e a de referência, seja atingido.

Os parâmetros estimados através da execução do algoritmo estão apresentados na Tabela 3. Já a Figura 5 mostra o gráfico da comparação das curvas características I-V simulada adotando os parâmetros estimados, e a de referência. Além disso, as curvas características de potência-tensão (P-V) também foram obtidas e estão mostradas na Figura 6.

De acordo com o gráfico mostrado na Figura 5, é possível observar que o algoritmo ED converge para uma solução factível que aproxima a curva I-V de referência da curva I-V simulada.

Parâmetros estimados pelo algoritmo ED	Valor
Resistência série (R_s)	0,00245223 Ω
Resistência paralela (R_p)	17,4014456 Ω
Corrente de saturação reversa (I_r)	1,19734e-08 A
Fator de idealidade (<i>n</i>)	1,1104331

Tabela 3. Parâmetros estimados pelo algoritmo ED.



Figura 5. Curva I-V simulada com os parâmetros estimados pelo algoritmo ED e curva I-V de referência do módulo fotovoltaico.



Figura 6. Curva P-V simulada com os parâmetros estimados pelo algoritmo ED e curva P-V de referência do módulo fotovoltaico.

O desempenho do algoritmo pode ser avaliado em aspectos de precisão, tempo de convergência e número de iterações. A precisão está relacionada ao erro, ou seja, ao valor final obtido na função objetivo utilizada no algoritmo. Esse erro representa a quantificação da diferença entre as curvas analisadas na Figura 5. Já o tempo de convergência está relacionado ao tempo que o algoritmo leva para detectar a melhor solução do problema, enquanto o número de interações indica a quantidade de repetições consecutivas da execução do algoritmo para se chegar ao resultado do problema. A Tabela 4 apresenta os aspectos de desempenhos analisados neste trabalho.

Tabela 4. Parâmetros de desempenho do algoritmo ED.

Parâmetros de desempenho do ED	Valor
Erro quadrático médio (J)	0,00158757292
Tempo de convergência (t_c)	0,058511 s
Número de iterações (N_{it})	2

Analisando o valor da função objetivo, o erro quadrático médio J foi 0,00158757292, o que indica um resultado próximo entre a curva I-V simulada com os parâmetros estimados e a curva I-V de referência. Neste caso, a solução foi identificada pelo algoritmo ED em um tempo de convergência de 0,058511 segundos em apenas 2 iterações executadas.

O tempo de convergência e o número de iterações do algoritmo, os quais variam de acordo com o número da população inicial *NP*, são considerados satisfatórios para esta aplicação

6 Conclusão

Este trabalho apresentou o estudo e aplicação de um algoritmo evolutivo baseado no método metaheurístico Evolução Diferencial empregado na estimação de parâmetros do modelo de um módulo fotovoltaico, representado por um circuito elétrico equivalente. Tais parâmetros, como as resistências série e paralela, a corrente de saturação reversa do diodo e o fator de idealidade da junção p-n, geralmente não são fornecidos pelos fabricantes, dessa forma, a obtenção dos mesmos é fundamental para a caracterização de uma célula fotovoltaica bem como do módulo fotovoltaico.

Para a identificação dos referidos parâmetros, o algoritmo ED utilizou como referência de entrada os dados e a curva corrente-tensão (I-V) de referência fornecida pelo *datasheet* do fabricante do módulo fotovoltaico.

Com base nos resultados obtidos, é possível observar que a curva característica I-V simulada com os parâmetros estimados é muito próxima à curva I-V de referência fornecida pelo fabricante. Isso significa que o algoritmo ED é capaz de estimar os parâmetros citados. O mesmo é observado para as curvas P-V.

O algoritmo baseado no método ED apresentou bom desempenho e a técnica se mostrou viável para tal aplicação, pois dispensa a necessidade de manipulações das equações matemáticas do modelo do módulo fotovoltaico. Além disso, o algoritmo converge para uma solução factível apresentando um tempo de convergência satisfatório e pequeno número de iterações.

Agradecimentos

Os autores agradecem as contribuições da Universidade Tecnológica Federal do Paraná e à CAPES pelo auxílio financeiro para o desenvolvimento deste estudo.

Referências Bibliográficas

- Adefarati, T. and Bansal, R. C. (2016). Integration of renewable distributed generators into the distribution system: a review. *IET Renewable Power Generation*, Vol. 10, No.7, pp. 873-884.
- Bhattacharya, S. and Mishra, S. (2016). Efficient power sharing approach for photovoltaic generation based microgrids. *IET Renewable Power Generation*, Vol. 10, No. 7, pp. 973-987.
- Benda, V. (2015). Photovoltaics towards terawattsprogress in photovoltaic cells and modules. *IET Power Electronics*, Vol. 8, No. 12, pp. 2343-2351.
- Coelho, L. D. S., and Mariani, V. C. (2006). Evolução diferencial híbrida com programação quadrática aplicada ao problema de despacho econômico de energia elétrica. Sba: Controle & Automação Sociedade Brasileira de Automatica, Vol. 17, No.4, pp. 409-423.
- Costa, B. L. G., Bacon, V. D., da Silva, S. A. O. and Angélico, B. A. (2017). Tuning of a PI-MR Controller Based on Differential Evolution Metaheuristic Applied to the Current Control Loop of a Shunt-APF. *IEEE Transactions on Industrial Electronics*, Vol. 64, No. 6, pp. 4751-4761.
- Goetzberger, A. and Hoffmann, V. U., (2005). Photovoltaic solar energy generation. Springer Science & Business Media, Vol.112.
- Gow, J. A. and Manning, C. D. (1996). Development of a model for photovoltaic arrays suitable for use in simulation studies of solar energy conversion systems.
- Guo, S., Ma, F. J., Hoex, B., Aberle, A. G. and Peters, M. (2012). Analysing solar cells by circuit modelling. *Energy Procedia*, Vol. 25, pp. 28-33.
- Huang, P. H., Xiao, W., Peng, J. C. H., and Kirtley, J. L. (2016). Comprehensive parameterization of solar cell: Improved accuracy with simulation efficiency. *IEEE Transactions on Industrial Electronics*, Vol. 63, No. 3, pp. 1549-1560.
- Ishaque, K., Salam, Z., Taheri, H. and Shamsudin, A. (2011). Parameter extraction of photovoltaic cell using differential evolution method. In *Applied*

Power Electronics Colloquium (IAPEC), IEEE, pp. 10-15.

- Ishaque, K., Salam, Z., Mekhilef, S., and Shamsudin, A., (2012). Parameter extraction of solar photovoltaic modules using penalty-based differential evolution. *Applied Energy*, Vol. 99, pp. 297-308.
- Jervase, J. A., Bourdoucen, H. and Al-Lawati, A. (2001). Solar cell parameter extraction using genetic algorithms. *Measurement Science and Technology*, Vol. 12, No.11, p. 1922.
- Kivimäki, J., Kolesnik, S., Sitbon, M., Suntio, T., and Kuperman, A. (2018). Design Guidelines for Multiloop Perturbative Maximum Power Point Tracking Algorithms. *IEEE Transactions on Power Electronics*, Vol. 33, No. 2, pp. 1284-1293.
- Lyden, S. and Haque, M. E. (2015). Maximum Power Point Tracking techniques for photovoltaic systems: A comprehensive review and comparative analysis. *Renewable and* sustainable energy reviews, Vol. 52, pp. 1504-1518.
- Maherchandani, J. K., Agarwal, C. and Sahi, M. (2012). Estimation of solar cell model parameter by hybrid genetic algorithm using matlab. International Journal of Advanced Research in Computer Engineering & Technology (IJARCET), Vol. 1, No.6, pp. 78.
- Moldovan, N., Picos, R. and Garcia-Moreno, E. (2009). Parameter extraction of a solar cell compact model usign genetic algorithms. In *Electron Devices CDE, Spanish Conference*, pp. 379-382.
- Oliveira, F. M., Silva, S. A. O., Durand, F. R., Sampaio, L. P., Bacon, V. D. and Campanhol, L.
 B. (2016). Grid-tied photovoltaic system based on PSO MPPT technique with active power line conditioning. *IET Power Electronics*, Vol. 9, No. 6, pp. 1180-1191
- Prada-Gil, M., Domínguez-García, J. L., Trilla, L. and Gomis-Bellmunt, O. (2016). Technical and economic comparison of various electrical collection grid configurations for large photovoltaic power plants. *IET Renewable Power Generation*, Vol. 11, No. 3, pp. 226-236.
- Sampaio, L. P. and Silva, S. A. O. (2017). Graphic computational platform integrated with an electronic emulator dedicated to photovoltaic systems teaching. *IET Power Electronics*, Vol. 10, No. 14, pp. 1982-1992.
- Schonardie, M. F. and Martins, D. C. (2008) Threephase grid-connected photovoltaic system with active and reactive power control using dq0 transformation. In *Power Electronics Specialists Conference, PESC, IEEE*, pp. 1202-1207.
- SolarWorld, Data Sheet. (2012). Sunmodule Plus SW 245 Mono, SW-02-5002US.
- Storn, R. and Price, K. (1995). Differential evolution: A simple and efficient adaptive scheme for

global optimization over continuous spaces, Int. Comput. Sci. Instit., Berkeley, CA, USA, Tech. Rep. TR-95-012, 1995.

- Tang, L., Dong, Y. and Liu, J. (2015). Differential evolution with an individual-dependent mechanism. *IEEE Transactions on Evolutionary Computation*, Vol. 19, No. 4, pp. 560-574.
- Villalva, M. G., Gazoli, J. R. and Ruppert Filho, E. (2009). Comprehensive approach to modeling and simulation of photovoltaic arrays. *IEEE Transactions on power electronics*, Vol. 24, No. 5, pp. 1198-1208.
- Xiao, W., Dunford, W. G., & Capel, A. (2004). A novel modeling method for photovoltaic cells. In *Power Electronics Specialists Conference*, 2004. PESC 04. 2004 IEEE 35th Annual, Vol. 3, pp. 1950-1956.

- Zhang, Y., Lyden, S., de la Barra, B. L. and Haque, M. E. (2016). A genetic algorithm approach to parameter estimation for PV modules. *Power* and Energy Society General Meeting (PESGM), pp. 1-5.
- Zhou, Y. Z., Yi, W. C., Gao, L. and Li, X. Y. (2017). Adaptive differential evolution with sorting crossover rate for continuous optimization problems. *IEEE transactions on cybernetics*, Vol. 47, No. 9, pp. 2742-2753.
- Yahia, H., Liouane, N. and Dhifaoui, R. (2014). Differential evolution method-based output power optimisation of switched reluctance generator for wind turbine applications. *IET Renewable Power Generation*, Vol. 8, No. 7, pp. 795-806.