

Modelagem matemática do comportamento elétrico de módulos fotovoltaicos: Uma revisão

Marcos Eduardo Treter (IFC) - marcos.treter@ifc.edu.br

Marcello Mezaroba (UDESC) - marcello.mezaroba@udesc.br

Leandro Michels (UFSM) - michels@gepoc.ufsm.br

Resumo:

A obtenção de modelos que descrevem o comportamento elétrico de módulos fotovoltaico é de grande relevância para diversos usos, tais como representar o comportamento equivalente em simulações elétricas, prever a geração de energia, entre outros. A modelagem do comportamento elétrico dos módulos pode ser realizada de diferentes formas, destacando-se os modelos baseados em circuitos elétricos equivalentes e os modelos baseados em redes neurais artificiais (RNAs). Em geral, os modelos diferem entre si na relação de compromisso entre a precisão e a complexidade de implementação. Neste trabalho são revisados os seguintes modelos: i) único diodo com três, quatro e cinco parâmetros; ii) duplo diodo com sete parâmetros; e iii) modelos baseados em RNAs. Um estudo de caso de aplicação do modelo de diodo único de cinco parâmetros é apresentado, para os quais foram obtidos resultados de simulação que demonstram boa conformidade com a realidade.

Palavras-chave: *Sistemas fotovoltaicos, Curva I-V, Modelagem.*

Área temática: *Conversão Fotovoltaica*

Subárea temática: *Tecnologias e ensaios de módulos fotovoltaicos*

MODELAGEM MATEMÁTICA DO COMPORTAMENTO ELÉTRICO DE MÓDULOS FOTOVOLTAICOS: UMA REVISÃO

Marcos Eduardo Treter – marcos.treter@ifc.edu.br

Instituto Federal Catarinense, campus São Bento do Sul

Marcello Mezaroba – marcello.mezaroba@udesc.br

Universidade do Estado de Santa Catarina, Departamento de Engenharia Elétrica

Leandro Michels – michels@gepoc.ufsm.br

Universidade Federal de Santa Maria, Instituto de Redes Inteligentes

Resumo. A obtenção de modelos que descrevem o comportamento elétrico de módulos fotovoltaico é de grande relevância para diversos usos, tais como representar o comportamento equivalente em simulações elétricas, prever a geração de energia, entre outros. A modelagem do comportamento elétrico dos módulos pode ser realizada de diferentes formas, destacando-se os modelos baseados em circuitos elétricos equivalentes e os modelos baseados em redes neurais artificiais (RNAs). Em geral, os modelos diferem entre si na relação de compromisso entre a precisão e a complexidade de implementação. Neste trabalho são revisados os seguintes modelos: i) único diodo com três, quatro e cinco parâmetros; ii) duplo diodo com sete parâmetros; e iii) modelos baseados em RNAs. Um estudo de caso de aplicação do modelo de diodo único de cinco parâmetros é apresentado, para os quais foram obtidos resultados de simulação que demonstram boa conformidade com a realidade.

Palavras-chave: Sistemas fotovoltaicos, Curva I-V, Modelagem.

1. INTRODUÇÃO

A instalação de sistemas fotovoltaicos ao redor do mundo continua em acentuada expansão. Durante o ano de 2018 foram adicionados 100 GW na matriz energética global. Totalizando 505 GW de potência instalada em sistemas fotovoltaicos. Essa expansão fica ainda mais clara ao comparar a potência atual com a potência instalada ao final de 2008 que era de apenas 15 GW (Murdock, 2019).

Em 2018 a implantação de sistemas fotovoltaicos foi superior a implantação de todos os sistemas de energia do tipo fóssil e nuclear somados. Ainda no mesmo ano, apenas a energia fotovoltaica foi responsável por 36% de toda a energia adicionada na matriz energética global. Apesar do predomínio da energia fotovoltaica, apenas 2,2% de toda a produção de eletricidade no mundo teve como origem os sistemas fotovoltaicos. Isso deixa claro o enorme potencial ainda inexplorado e a necessidade do avanço da tecnologia aplicada aos sistemas fotovoltaicos (Europe, 2015).

Este trabalho tem por objetivo apresentar uma revisão bibliográfica dos principais métodos de modelagem do comportamento elétrico de módulos fotovoltaicos. Conforme Pranith e Bhatti (2015) o modelo elétrico de um módulo pode ser útil para os seguintes propósitos: estudar as características dos sistemas fotovoltaicos; analisar os algoritmos de rastreamento do ponto de máxima potência; analisar a dinâmica dos conversores de energia; projetar os sistemas fotovoltaicos; detectar falhas; etc.

Uma das principais dificuldades encontradas na modelagem elétrica dos módulos fotovoltaicos está na influência das condições meteorológicas. O aumento na radiação solar gera um acréscimo na tensão de circuito aberto e na corrente elétrica gerada pelo módulo. Enquanto que o aumento da temperatura reduz a tensão gerada pelo dispositivo (Souza, 2012). A influência da radiação solar e da temperatura na curva I-V são apresentadas na Fig. 1a e na Fig. 1b, respectivamente.




Figura 1 – Influência das condições meteorológicas na curva I-V.

Fonte: Adaptado de (Kyocera, 2019).

Na literatura destacam-se os modelos elétricos de modos fotovoltaicos baseados em circuitos elétricos equivalentes e os modelos baseados em redes neurais artificiais (RNAs). Neste trabalho serão revisados os seguintes modelos: único diodo com três, quatro e cinco parâmetros, duplo diodo com sete parâmetros e os modelos baseados em RNAs. Os métodos analíticos, de otimização e que utilizam inteligência artificial para determinar os parâmetros desconhecidos dos modelos baseados em circuitos elétricos também serão discutidos.

O trabalho está organizado em cinco seções. A seção 2 apresenta a revisão bibliográfica sobre os modelos baseados em circuitos elétricos equivalentes. A seção 3 apresenta a revisão bibliográfica sobre os modelos baseados em redes neurais artificiais. A seção 4 apresenta um estudo de caso de aplicação do modelo de diodo único com cinco parâmetros. Por fim, a seção 5 traz as considerações finais do autor.

2. REVISÃO DOS MODELOS BASEADOS EM CIRCUITOS ELÉTRICOS EQUIVALENTES

A literatura apresenta uma grande quantidade de modelos fotovoltaicos que são baseados em circuitos elétricos equivalentes. Entre os principais modelos estão: diodo único com três, quatro e cinco parâmetros, diodo duplo com sete parâmetros. Os modelos são denominados de acordo com o número de parâmetros que representam as propriedades dos módulos fotovoltaicos.

A determinação dos parâmetros desconhecidos de um modelo não é uma tarefa trivial, pois esses parâmetros não são fornecidos diretamente no catálogo dos módulos fotovoltaicos. Além disso, esses parâmetros tem suas grandezas modificadas de acordo com as condições meteorológicas.

Normalmente a escolha do modelo envolve a ponderação entre a precisão desejada, a complexidade e o custo computacional de implementação. O modelo com sete parâmetros pode resultar em um modelo com maior precisão que o modelo com três parâmetros, entretanto também possui complexidade e custo computacional muito maiores.

2.1 Circuito com único diodo

Modelo com três parâmetros a determinar. O modelo de único diodo com três parâmetros é apresentado na Fig. 2. Este modelo consiste em um diodo conectado em antiparalelo com uma fonte de corrente. A intensidade da corrente fotogerada (I_{ph}) é diretamente proporcional à radiação solar (Mittal, 2018). O modelo de circuito com único diodo com três parâmetros representa a operação ideal de um módulo fotovoltaico. Entretanto, este modelo não considera as perdas de energia que estão presentes em um dispositivo real.

Conforme Mahmoud, Xiao e Zeineldin (2011), a equação que relaciona a corrente (I) e a tensão (V) de saída do módulo fotovoltaico para o modelo ideal é dada por:

$$I = I_{ph} - I_o \left[\exp\left(\frac{V}{aV_T} - 1\right) \right] \quad (1)$$

onde I_o é a corrente de saturação reversa do diodo e a é o fator de idealidade do diodo. A tensão térmica do diodo (V_T) é definida por:

$$V_T = \frac{N_s k T}{q} \quad (2)$$

onde q é a carga elétrica de um elétron, k é a constante de Boltzmann, N_s é o número de células fotovoltaicas conectadas em série dentro do módulo e T é a temperatura de operação do módulo fotovoltaico.

Os três parâmetros desconhecidos deste modelo são: a corrente fotogerada (I_{ph}), a corrente de saturação reversa do diodo (I_o) e o fator de idealidade do diodo (a).




Figura 2 – Modelo de diodo único com três parâmetros.

Fonte: Adaptado de (Mittal, 2018).

Modelo com quatro parâmetros a determinar. O modelo de único diodo com quatro parâmetros a determinar é apresentado na Fig. 3. As perdas de um módulo fotovoltaico real são modeladas ao inserir uma resistência em série (R_s) no modelo anterior. A inclusão de R_s possibilita modelar a soma de várias resistências internas do módulo fotovoltaico, como a resistência existente no contato entre a superfície de silício e os eletrodos (Khan, 2019).




Figura 3 – Modelo de diodo único com quatro parâmetros.
Fonte: Adaptado de (Mittal, 2018).

A equação que relaciona a corrente e a tensão de saída do modelo com quatro parâmetros é definida por:

$$I = I_{ph} - I_o \left[\exp \left(\frac{V + IR_s}{aV_T} - 1 \right) \right] \quad (3)$$

Os quatro parâmetros desconhecidos deste modelo são: I_{ph} , I_o , a e R_s . Destaca-se que o modelo com quatro parâmetros não considera a corrente de fuga da junção PN das células do módulo fotovoltaico. Isso resulta em imprecisão, principalmente quando o módulo é submetido a variações nas condições ambientais (Mittal, 2018).

Modelo com cinco parâmetros a determinar. Uma modificação para aumentar a precisão do modelo com quatro parâmetros considera a inserção de uma resistência em paralelo (R_p), como mostrado na Fig. 4. Dessa forma, os parâmetros desconhecidos deste modelo são: I_{ph} , I_o , a , R_s e R_p .




Figura 4 – Modelo de diodo único com cinco parâmetros.
Fonte: Adaptado de (Mittal, 2018).

A equação que relaciona a corrente e a tensão de saída no modelo é dada por:

$$I = I_{ph} - I_o \left[\exp \left(\frac{V + IR_s}{aV_T} - 1 \right) \right] - \frac{V + IR_s}{R_p} \quad (4)$$

O modelo com cinco parâmetros é um dos mais empregados devido ao seu custo-benefício, ou seja, a relação entre a precisão e a complexidade de implementação (Jordehi, 2016). Esse modelo se mostra deficiente para situações em que os níveis de radiação solar são baixos, onde apresenta baixa convergência.

2.2 Circuito com duplo diodo

Modelo com sete parâmetros a determinar. O modelo de duplo diodo com sete parâmetros é o que mais se aproxima da resposta de um módulo fotovoltaico real se comparado aos demais modelos já expostos. O modelo com sete parâmetros, apresentado na Fig. 5, possui a adição de um segundo diodo que permite modelar as perdas devido às correntes de recombinação na região de depleção das células do módulo fotovoltaico (Jordehi, 2016).




Figura 5 – Modelo de diodo duplo com sete parâmetros.
Fonte: Adaptado de (Mittal, 2018).

O modelo com sete parâmetros é mais complexo que os anteriores e possui os seguintes parâmetros desconhecidos: I_{ph} , I_{o1} , I_{o2} , R_s , R_p , a_1 e a_2 . A equação que relaciona a corrente e a tensão de saída no modelo é definida pela Eq. (5).

$$I = I_{ph} - I_{o1} \left[\exp \left(\frac{V + IR_s}{a_1 V_{T1}} - 1 \right) \right] - I_{o2} \left[\exp \left(\frac{V + IR_s}{a_2 V_{T2}} - 1 \right) \right] - \frac{V + IR_s}{R_p} \quad (5)$$

2.3 Outros modelos

Além dos modelos mencionados, existem alguns outros modelos que foram propostos na literatura (Jordehi, 2016). Como o modelo de único diodo com capacitância, modelo de três diodos, modelo de dois diodos modificados, etc. No entanto, devido à complexidade desses modelos, sua aplicação fica restrita a casos específicos.

2.4 Métodos para determinação dos parâmetros

Os fabricantes de módulos fotovoltaicos, em geral, fornecem em seus catálogos apenas parâmetros como: a corrente de curto-circuito (I_{sc}), a tensão de circuito aberto (V_{oc}), a potência máxima (P_{max}), a corrente no ponto de máxima potência (I_{mp}) e a tensão no ponto de máxima potência (V_{mp}). Esses dados são apresentados para a condição de testes denominada STC, ou seja, irradiância de 1000 W/m², massa de ar AM1,5 e temperatura de operação do módulo fotovoltaico de 25 °C.

Os parâmetros que representam as propriedades dos módulos fotovoltaicos e são necessários para os modelos fotovoltaicos vistos anteriormente, como I_{ph} , I_o , R_s , R_p e a não são fornecidos nos catálogos e precisam ser calculados. A literatura apresenta alguns métodos que podem ser empregados na determinação destes parâmetros, entre os principais estão: i) solução analítica; ii) solução baseada em problema de otimização; iii) determinação por métodos de inteligência artificial.

Solução analítica. Os métodos analíticos podem ser considerados como a forma mais simples de determinar os parâmetros de um modelo fotovoltaico. Ayodele, Ogunjuyigbe e Ekoh (2016) apresentaram uma comparação entre três algoritmos que frequentemente são empregados na solução analítica do modelo de único diodo com cinco parâmetros. Os autores investigaram a precisão, a robustez, o tempo computacional e a facilidade de implementação. Os resultados mostraram que todos os algoritmos apresentam bons resultados, entretanto o modelo não se mostrou eficiente em condições de baixa radiação solar e temperatura elevada.

Os métodos analíticos normalmente apresentam equações transcendentais que são difíceis de serem resolvidas. Portanto, torna-se comum a utilização de algumas simplificações, como a estimativa inicial de alguns parâmetros, ou então assume-se que pelo menos um dos parâmetros desconhecidos possui um valor constante. Frequentemente o fator de idealidade do diodo (a) é considerado um valor constante e considera-se que $1 \leq a \leq 2$. Evidentemente essas premissas simplificadoras acabam reduzindo a precisão do modelo fotovoltaico (Jordehi, 2016).

Problema de otimização. Os métodos baseados em problema de otimização são ferramentas eficientes no cálculo dos parâmetros desconhecidos dos modelos fotovoltaicos. Dentre esses métodos destacam-se aqueles que são baseados nas técnicas de algoritmo evolutivo como: algoritmos genéticos; otimização por exame de partículas; evolução diferencial. Os métodos de otimização possuem a capacidade de solucionar funções não-lineares com base na minimização ou maximização de uma função objetivo (Ishaque, 2011).

Uma revisão bibliográfica sobre as principais técnicas de otimização aplicadas na modelagem fotovoltaica é apresentada por Jordehi (2016). Ishaque e Salam (2011) utilizaram o método de otimização do tipo evolução diferencial para determinar os parâmetros de um modelo de único diodo com cinco parâmetros. Bradaschia et al. (2019) empregaram o método de otimização por enxame de partículas no cálculo dos parâmetros de um modelo de duplo diodo com sete parâmetros.

Métodos de inteligência artificial. Os parâmetros desconhecidos dos modelos fotovoltaicos podem ser estimados através de métodos que utilizam inteligência artificial (IA). Nos últimos anos cresceu o número de trabalhos que propõem o uso de IA, principalmente de redes neurais artificiais (RNAs) no cálculo dos parâmetros desconhecidos.

O uso de uma RNA para estimar os parâmetros do modelo de diodo único com cinco parâmetros é proposto por Gastli, Ben-Brahim e Rhouma (2015). A RNA com 7 neurônios na camada de entrada, 15 na camada oculta e 3 na camada de saída possibilitou determinar os parâmetros desejados de forma precisa. Os parâmetros determinados na saída da RNA foram: a resistência série, a corrente de saturação reversa do diodo e o fator de idealidade do diodo. Os dados utilizados no treinamento da RNA foram gerados através de simulações no software Matlab.

Um sistema de inferência neuro-fuzzy (ANFIS) foi proposto por Kulaksız (2011) para determinar os parâmetros do modelo de único diodo com cinco parâmetros. O modelo ANFIS que combina as vantagens da lógica Fuzzy e das RNAs permitiu determinar os parâmetros de diferentes tipos de módulos (monocristalinos, policristalinos e filmes finos). O sistema utiliza como entrada: o tipo de material, a tensão de circuito aberto, a corrente de curto-circuito e um parâmetro que pode ser obtido a partir da curva I-V do módulo fotovoltaico. Os parâmetros de saída são: a resistência série, a resistência paralela e o fator de idealidade do diodo.

Independentemente do método escolhido, se analítico, de otimização ou que utiliza inteligência artificial, o método deve apresentar características como: fornecer parâmetros precisos do modelo; ser robusto, ou seja, quando aplicado a um mesmo conjunto de dados deve apresentar resultados semelhantes; fornecer parâmetros precisos para diferentes conjuntos de dados e ter baixo tempo computacional (Jordehi, 2016).

2.5 Conversão dos parâmetros para o ponto de operação

As condições meteorológicas influenciam diretamente na operação dos módulos fotovoltaicos, conforme já foi apresentado neste trabalho. Como os módulos fotovoltaicos ficam sujeitos a variações meteorológicas ao longo do dia, os modelos precisam considerar essas variáveis no cálculo de seus parâmetros.

Normalmente os parâmetros dos modelos fotovoltaicos são calculados para a condição STC e, posteriormente são convertidos para um estado distinto do STC. Entretanto, alguns métodos como o abordado por Villalva, Gazoli e Ruppert (2009), permite obter os parâmetros do modelo fotovoltaico diretamente para uma condição distinta do STC, logo não há necessidade de realizar a conversão.

Usualmente são utilizadas equações analíticas que permitem converter cada um dos parâmetros desconhecidos para a condição meteorológica desejável. Essas equações são apresentadas por Jordehi (2016), Ayodele, Ogunjuyigbe e Ekoh (2016) e Drouiche, Harrouni e Arab (2018).

3. REVISÃO DOS MODELOS BASEADOS EM REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso dos seres vivos e foram desenvolvidas a partir de modelos conhecidos do próprio cérebro humano. As RNAs podem ser empregadas em diversas aplicações relacionadas às engenharias como: agrupamento de dados; aproximador universal de funções; controle de processos; classificação de padrões; sistemas de previsão; etc. (Silva, 2010).

Recentemente cresceu o número de trabalhos que propõem o uso das RNAs na modelagem de módulos fotovoltaicos. Os principais conceitos que envolvem o funcionamento das RNAs e alguns exemplos de aplicações na modelagem fotovoltaica serão apresentados a seguir.

3.1 Introdução às RNAs

O processamento de informações no cérebro humano é realizado por processadores biológicos. A célula elementar do sistema nervoso cerebral é o neurônio e seu papel se resume a conduzir impulsos sob determinadas condições de operação. Os neurônios artificiais utilizados nos modelos de redes neurais artificiais realizam funções simples, como coletar sinais existentes em suas entradas, agregá-los de acordo com sua função operacional e produzir uma resposta, levando em conta sua função de ativação (Silva, 2010).

Cada neurônio de uma RNA pode ser implementado conforme a Fig. 6. Os sinais de entrada são formados pelo conjunto (X_1, X_2, \dots, X_n) que são análogos aos impulsos externos captados pelos dendritos no neurônio biológico. As ponderações exercidas pelas junções sinápticas são representadas no neurônio artificial pelo conjunto de pesos (W_1, W_2, \dots, W_n) . A saída do neurônio, denotado por u , é a soma ponderada de suas entradas. A função de ativação $g(\cdot)$ tem o objetivo de limitar a saída do neurônio dentro de um intervalo de valores razoáveis. Por fim, y consiste no valor final produzido pelo neurônio em relação a um determinado conjunto de entradas (Silva, 2010).




Figura 6 – Neurônio de uma rede neural artificial.

Fonte: Adaptado de (Silva, 2010).

A arquitetura de uma RNA define a forma como os seus diversos neurônios estão arranjados, uns em relação aos outros. Basicamente, uma RNA pode ser dividida em três partes denominadas de camadas. A camada de entrada é responsável pelo recebimento de informações advindas do meio externo. As camadas ocultas realizam quase todo o processamento interno da rede. Por fim, a camada de saída é responsável pela apresentação dos resultados finais da rede (Silva, 2010).

As principais arquitetura de RNAs são: *feedforward*, redes recorrentes e redes reticuladas. As redes *feedforward* são as RNAs mais comuns, inclusive na modelagem de sistemas fotovoltaicos as redes *perceptron* multicamadas, que fazem parte da arquitetura *feedforward*, são as mais utilizadas. As redes *perceptron* multicamadas são caracterizadas pela presença de pelo menos uma camada oculta de neurônios, situada entre a camada de entrada e a camada de saída. A Fig. 7 apresenta uma rede *perceptron* multicamadas.

O treinamento de uma RNA consiste na aplicação de um algoritmo com o objetivo de ajustar os pesos e os limiares de seus neurônios para que as suas respostas estejam próximas de valores desejados. As RNAs com arquitetura *feedforward* utilizam o treinamento supervisionado. Essa estratégia consiste em se ter disponível amostras de treinamento, sendo estas constituídas pelos sinais de entradas e suas correspondentes saídas (Silva, 2010).




Figura 7 – Rede *perceptron* multicamadas.

Fonte: Adaptado de (Jiang, 2015).

O algoritmo de treinamento aplicado no processo de treinamento das RNAs com arquitetura *feedforward* de múltiplas camadas é denominado *backpropagation*. Diversas variações têm sido propostas com o objetivo de tornar o processo de convergência mais eficiente. Mekki, Mellit e Salhi (2016) analisaram 14 algoritmos de treinamento, sendo que o algoritmo *resilient-propagation* apresentou os melhores resultados. O algoritmo *Levenberg-Marquardt* frequentemente tem sido empregado na modelagem de módulos fotovoltaicos, como nos trabalhos desenvolvidos por Baptista et al. (2017), Almadhor (2018) e Lopez-Guede et al. (2016).

3.2 Aplicação das RNAs na modelagem fotovoltaica

Uma RNA *perceptron* com três camadas é proposta por Baptista et al. (2017) para determinar a potência gerada por um sistema fotovoltaico. A rede utiliza apenas o nível de irradiação solar como parâmetro de entrada. A topologia da RNA é 1-3-1, ou seja, possui um neurônio na camada de entrada, três na camada oculta e um na camada de saída. O algoritmo utilizado no treinamento da rede foi o *Levenberg-Marquardt*.

A RNA proposta por Almadhor (2018) é semelhante a anterior, ou seja, arquitetura *perceptron* com três camadas e treinada com o algoritmo *Levenberg-Marquardt*. Entretanto, esta RNA permite estimar a tensão e a corrente gerada pelo sistema fotovoltaico. Os parâmetros de entrada da RNA são: irradiação, temperatura ambiente e do módulo fotovoltaico, umidade e velocidade do vento. A RNA possui topologia 5-9-2.

Uma RNA *perceptron* com quatro camadas é proposta por Jiang e Maskell (2015). Esta RNA utiliza a irradiação e a temperatura como entrada e obtém a potência gerada pelo sistema fotovoltaico na saída. Esta RNA também foi treinada pelo algoritmo *Levenberg-Marquardt*. A topologia da rede é do tipo 2-15-15-1.

Mekki, Mellit e Salhi (2016) também propuseram uma RNA *perceptron* com quatro camadas. Novamente a irradiação e a temperatura são os parâmetros de entrada. Neste caso, a rede permite estimar a corrente e a tensão do arranjo fotovoltaico. O treinamento ocorreu através do algoritmo *resilient-propagation*. A topologia da rede é do tipo 2x7x12x2.

Devido à falta de um procedimento sistemático para obter os modelos fotovoltaicos baseados em redes neurais foi desenvolvido por Lopez-Guede et al. (2016) um passo-a-passo que permite auxiliar nessa tarefa. Em geral, o número de camadas ocultas e o número de neurônios que compõem essas camadas são determinados através de simulações, ou seja, testando a rede para diferentes topologias até encontrar aquela que apresenta os melhores resultados.

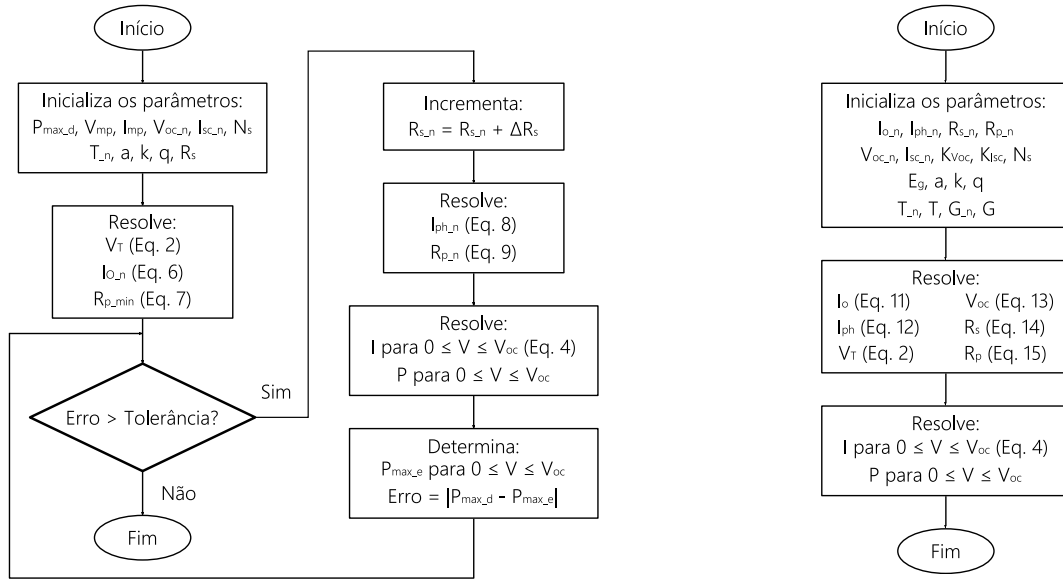
4. ESTUDO DE CASO DE APLICAÇÃO DO MODELO DE ÚNICO DIODO COM CINCO PARÂMETROS

O modelo de único diodo com cinco parâmetros é o mais utilizado para a modelagem de módulos fotovoltaicos devido a sua relação entre a precisão e a complexidade de implementação. A análise realizada por Ayodele, Ogunjuyigbe e Ekoh (2016) mostrou que o método analítico proposto por Villalva, Gazoli e Ruppert (2009) para encontrar os parâmetros do modelo de diodo único com cinco parâmetros apresenta bons resultados. Este método foi proposto em 2009 e continua até o momento como referência de comparação para os novos métodos que estão sendo propostos na literatura.

A seguir é apresentada de forma detalhada a metodologia proposta por Villalva, Gazoli e Ruppert (2009). Posteriormente, é descrito como se realiza a conversão dos parâmetros do modelo para condições meteorológicas distintas do STC através de equações analíticas. Por fim, é apresentada a comparação entre os resultados do modelo com a curva I-V de catálogo do módulo fotovoltaico KC200GT.

4.1 Metodologia

O algoritmo proposto por Villalva, Gazoli e Ruppert (2009), cujo fluxograma é apresentado na Fig. 8a, utiliza apenas os dados fornecidos no catálogo do módulo fotovoltaico para estimar quatro parâmetros do modelo de diodo único de cinco parâmetros. O fator de idealidade do diodo (a) é considerado constante.



(a) Cálculo dos parâmetros do modelo.
Fonte: Adaptado de (Villalva, 2009).

(b) Conversão dos parâmetros do modelo.
Fonte: Autor.

Figura 8 – Algoritmo para determinar os parâmetros do modelo de diodo único com cinco parâmetros e o algoritmo para converter os parâmetros para a condição meteorológica desejada.

A resistência série (R_s) é inicializada com valor nulo e a cada iteração do algoritmo a sua grandeza é incrementada em pequenos passos. A potência do modelo fotovoltaico é calculada para cada valor de R_s e comparada com a potência fornecida no catálogo do módulo. O aumento de R_s leva o algoritmo a convergir e este é encerrado quando a diferença entre a potência do modelo e a potência de catálogo for tolerável.

O algoritmo é inicializado com os seguintes dados de catálogo do módulo: potência máxima ($P_{max,d}$); tensão no ponto de máxima potência (V_{mp}); corrente no ponto de máxima potência (I_{mp}); tensão de circuito aberto ($V_{oc,n}$); corrente de curto-circuito ($I_{sc,n}$); número de células conectadas em série (N_s). As seguintes constantes também são inicializadas: temperatura de operação no STC ($T_n = 25$ °C); fator de idealidade do diodo ($a = 1,3$); constante de Boltzmann ($k = 1,38064852 \cdot 10^{-23}$); carga de um elétron ($q = 1,60217663 \cdot 10^{-19}$); resistência série ($R_{s,n} = 0$).

A tensão térmica (V_T) é determinada pela Eq. (2). A corrente de saturação reversa do diodo ($I_{o,n}$) é calculada pela Eq. (6). A resistência paralela inicial ($R_{p,min}$) é determinada pela Eq. (7).

$$I_{o,n} = \frac{I_{sc,n}}{\exp\left(\frac{V_{oc,n}}{aV_T}\right) - 1} \quad (6)$$

$$R_{p,min} = \frac{V_{mp}}{I_{sc,n} - I_{mp}} - \frac{V_{oc,n} - V_{mp}}{I_{mp}} \quad (7)$$

O algoritmo utiliza um laço que permite estimar o valor da resistência série ($R_{s,n}$) de forma iterativa. Logo, para cada iteração do laço a resistência série é incrementada por um fator ΔR_s , definido como 0,02. A corrente fotogerada ($I_{ph,n}$) também é recalculada para cada iteração do laço pela Eq. (8) assim como a resistência paralela ($R_{p,n}$) pela Eq. (9).

$$I_{ph,n} = \frac{R_{p,n} + R_{s,n}}{R_{p,n}} I_{sc,n} \quad (8)$$

$$R_{p,n} = \frac{V_{mp}(V_{mp} + I_{mp}R_{s,n})}{V_{mp}I_{ph,n} - V_{mp}I_{o,n} \exp\left(\frac{V_{mp} + I_{mp}R_{s,n}}{N_s a} \frac{q}{kT_n}\right)} \frac{1}{V_{mp}I_{o,n} - P_{max,d}} \quad (9)$$

A corrente na saída do módulo (I) é calculada pela Eq. (4) e armazenada em um vetor para cada ponto de tensão entre $0 \leq V \leq V_{oc}$. A Eq. (4) é não linear, logo deve ser utilizado um método numérico para encontrar uma solução aproximada. Uma possibilidade é utilizar o Método de Newton-Raphson o qual é definido pela seguinte equação recursiva:

$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)} \quad (10)$$

onde x_0 é uma aproximação inicial da raiz, n indica a n -ésima iteração do algoritmo e $f'(x_n)$ é a derivada da função $f(x_n)$ no ponto x_n .

O vetor de potências (P) é determinado pelo produto da corrente (I) e da tensão (V) para cada ponto entre $0 \leq V \leq V_{oc}$. O maior valor armazenado em P é definido como o ponto de máxima potência ($P_{max,e}$). O valor da máxima potência do modelo ($P_{max,e}$) é comparado com o valor da máxima potência do catálogo ($P_{max,d}$). Caso a diferença seja superior a um erro tolerável, uma nova iteração do laço é iniciada. Caso contrário, o laço é encerrado e os cinco parâmetros do modelo estão determinados. Os parâmetros do modelo fotovoltaico são determinados para a condição de STC. O algoritmo, cujo fluxograma é apresentado na Fig. 8b, permite converter estes parâmetros para uma condição meteorológica diferente do STC.

O algoritmo de conversão é inicializado com seguintes parâmetros que foram determinados anteriormente: corrente de saturação reversa do diodo ($I_{o,n}$); corrente fotogerada ($I_{ph,n}$); resistência série ($R_{s,n}$); resistência paralela ($R_{p,n}$). Além dos seguintes dados de catálogo do módulo: tensão de circuito aberto ($V_{oc,n}$); corrente de curto-circuito ($I_{sc,n}$); coeficiente de temperatura de I_{sc} (K_{Isc}); coeficiente de temperatura de V_{oc} (K_{Voc}); número de células conectadas em série (N_s). As seguintes constantes também são inicializadas: banda proibida ($E_g = 1,21$); fator de idealidade do diodo (a); constante de Boltzmann (k); carga de um elétron (q). Por fim, são inicializadas as condições meteorológicas no STC e na nova condição desejável: temperatura do módulo no STC (T_n); temperatura do módulo na condição desejada (T); irradiação solar no STC (G_n); irradiação solar na condição desejada (G).

O algoritmo permite atualizar os parâmetros do modelo fotovoltaico para uma nova condição meteorológica. A corrente de saturação reversa é calculada pela Eq. (11). A corrente fotogerada pela Eq. (12). A tensão térmica pela Eq. (2). A tensão de circuito aberto pela Eq. (13). A resistência série pela Eq. (14). A resistência paralela pela Eq. (15). Com a definição desses parâmetros para uma nova condição meteorológica é possível calcular a corrente gerada pelo módulo (I) utilizando a Eq. (4) para cada ponto de tensão entre $0 \leq V \leq V_{oc}$.

$$I_o = I_{o,n} \left(\frac{T}{T_n} \right)^3 \exp \left[\frac{qE_g}{ak} \left(\frac{1}{T_n} - \frac{1}{T} \right) \right] \quad (11)$$

$$I_{ph} = [I_{ph,n} + K_{Isc}(T - T_n)] \frac{G}{G_n} \quad (12)$$

$$V_{oc} = V_{oc,n} - K_{Voc}(T_n - T) + a \log \left(\frac{G}{G_n} \right) \quad (13)$$

$$R_s = R_{s,n} - \frac{a}{I_o} \exp \left(-\frac{V_{oc}}{a} \right) \quad (14)$$

$$R_p = R_{p,n} \left(\frac{G_n}{G} \right) \quad (15)$$

4.2 Exemplo de aplicação

As curvas I-V que são apresentadas por alguns fabricantes de módulos fotovoltaicos em seus respectivos catálogos, podem ser utilizadas na validação dos modelos fotovoltaicos. Normalmente essas curvas são apresentadas para grandezas distintas de irradiação e temperatura. O catálogo dos módulos normalmente apresenta as curvas I-V no formato PDF, um software como o *Engauge Digitizer* pode auxiliar na extração dos pontos da curva I-V com relativa precisão.

Nesta seção do trabalho será realizada a comparação do modelo fotovoltaico de diodo único com cinco parâmetros que foi exposto na seção anterior com as curvas I-V de catálogo do módulo fotovoltaico KC200GT. Este módulo é fabricado pela Kyocera e apresenta em seu catálogo as curvas I-V para cinco níveis de irradiação e três de temperatura.

O módulo KC200GT frequentemente é escolhido na literatura para validar os modelos fotovoltaicos, inclusive foi utilizado na validação do modelo proposto por Villalva, Gazoli e Ruppert (2009). O algoritmo apresentado na Fig. 8a foi utilizado para obter os parâmetros do modelo fotovoltaico na condição STC. Estes parâmetros são apresentados na Tab. 1.

Tabela 1 - Parâmetros do modelo fotovoltaico no STC.

Fonte: Autor.


CARACTERÍSTICA	VALOR
Corrente de saturação reversa ($I_{o,n}$)	$9,825 \cdot 10^{-8}$ A
Corrente fotogerada ($I_{ph,n}$)	8,219 A
Resistência série ($R_{s,n}$)	0,2 Ω
Resistência paralela ($R_{p,n}$)	225,1 Ω
Fator de idealidade (a)	1,3

Posteriormente os parâmetros do modelo fotovoltaico foram convertidos para condições meteorológicas distintas do STC utilizando o algoritmo apresentado na Fig. 8b. Com a conversão dos parâmetros foi possível gerar a curva I-V utilizando a Eq. (4) para variações na irradiância e na temperatura de operação dos módulos.

As curvas I-V do modelo fotovoltaico foram comparadas com as curvas de catálogo do módulo KC200GT para variações na irradiação conforme a Fig. 9a. A comparação para variações na temperatura é apresentada na Fig. 9b.

As comparações entre as curvas do modelo com as curvas do catálogo apresentaram pequenas diferenças. A maior divergência entre as curvas ocorreu no ponto de tensão de circuito aberto para irradiação de 200 W/m².

O ponto de maior divergência já era esperado devido o modelo de único diodo com cinco parâmetros apresentar menor precisão em condições de baixa irradiação. Além disso, é preciso considerar que a curva I-V foi extraída do catálogo com o uso do software *Engauge Digitizer*, logo podem existir alguns desvios em relação a curva original.



(a) Comparação para variações na irradiação .

(b) Comparação para variações na temperatura.

Figura 9 – Comparação entre as curvas I-V do catálogo e do modelo.

Fonte: Autor.

5. Conclusões

A revisão bibliográfica dos principais métodos para modelagem matemática para caracterização de módulos e séries fotovoltaicas demonstrou que a precisão dos resultados está diretamente relacionada ao nível de complexidade dos modelos. Observa-se que existe um grande compromisso entre a complexidade e a precisão, e por isso a escolha do uso de um ou outro modelo para uma dada aplicação deve sempre considerar esse compromisso.

Os modelos baseados em circuitos elétricos se mostram adequados para a representação do comportamento dos módulos em simuladores de circuito, uma vez que seu modelo é formado por elementos já existentes nos simuladores do tipo SPICE. Contudo, a grande questão nesses modelos está na correta determinação dos parâmetros de simulação, que demandam métodos específicos para módulos fotovoltaicos. Um exemplo de caso de obtenção dos parâmetros para o modelo de único diodo com cinco parâmetros foi apresentado de forma detalhada, demonstrando que a sua utilização é complexa.

Por outro lado, os modelos baseados em redes neurais artificiais não possuem correspondência com um circuito elétrico equivalente. Esses modelos tem a vantagem de demandar um menor esforço para obtenção dos parâmetros, uma vez que rotinas genéricas para treinamento das redes neurais podem ser diretamente aplicadas. Contudo, para obter resultados precisos, esses modelos necessitam de um grande conjunto de dados para treinamento, o que muitas vezes limita a sua aplicação.

Agradecimentos

Os autores agradecem ao INCTGD, CAPES, CNPq e FAPERGS pelo apoio financeiro recebido para o desenvolvimento desse trabalho. O presente trabalho foi realizado com apoio do INCT e suas agências financiadoras (CNPq processo 465640/2014-1, CAPES processo No. 23038.000776/2017-54 e FAPERGS 17/2551-0000517-1).

REFERÊNCIAS

- Almadhor, Ahmad. "Performance prediction of distributed PV generation systems using Artificial Neural Networks (ANN) and Mesh Networks." 2018 International Conference on Smart Grid (icSmartGrid). IEEE, 2018.
- Ayodele, T. R., A. S. O. Ogunjuyigbe, and E. E. Ekoh. "Evaluation of numerical algorithms used in extracting the parameters of a single-diode photovoltaic model." *Sustainable Energy Technologies and Assessments* 13 (2016): 51-59.
- Baptista, Dario, et al. "Hardware implementation of an artificial neural network model to predict the energy production of a photovoltaic system." *Microprocessors and Microsystems* 49 (2017): 77-86.
- Bradaschia, Fabricio, et al. "Parameter Identification for PV Modules Based on an Environment-Dependent Double-Diode Model." *IEEE Journal of Photovoltaics* 9.5 (2019): 1388-1397.
- Drouiche, Imane, Samia Harrouni, and Amar Hadj Arab. "A new approach for modelling the aging PV module upon experimental I-V curves by combining translation method and five-parameters model." *Electric Power Systems Research* 163 (2018): 231-241.
- Europe, Solar Power. "Global market outlook for solar power 2015–2019." European Photovoltaic Industry Association, Bruxelles, Tech. Rep (2015).
- Gastli, A., L. Ben-Brahim, and M. B. H. Rhouma. "ANN-based extraction approach of PV cell equivalent circuit parameters." 2015 17th European Conference on Power Electronics and Applications (EPE'15 ECCE-Europe). IEEE, 2015.
- Ishaque, Kashif, and Zainal Salam. "An improved modeling method to determine the model parameters of photovoltaic (PV) modules using differential evolution (DE)." *Solar energy* 85.9 (2011): 2349-2359.
- Jiang, Lian Lian, and Douglas L. Maskell. "Automatic fault detection and diagnosis for photovoltaic systems using combined artificial neural network and analytical based methods." 2015 International Joint Conference on Neural Networks (IJCNN). IEEE, 2015.
- Jordehi, A. Rezaee. "Parameter estimation of solar photovoltaic (PV) cells: A review." *Renewable and Sustainable Energy Reviews* 61 (2016): 354-371.
- Khan, Muhammad Faisal Nadeem, Ghulam Ali, and Ahmed Khalil Khan. "A Review of Estimating Solar Photovoltaic Cell Parameters." 2019 2nd International Conference on Computing, Mathematics and Engineering Technologies (iCoMET). IEEE, 2019.
- Kulaksız, A. A. "ANFIS-based parameter estimation of one-diode equivalent circuit model of PV modules." 2011 IEEE 12th International Symposium on Computational Intelligence and Informatics (CINTI). IEEE, 2011.
- Kyocera, "KC200GT high efficiency multicrystal photovoltaic module." datasheet, Nov. 2019.
- Lopez-Guede, Jose Manuel, et al. "Systematic modeling of photovoltaic modules based on artificial neural networks." *International Journal of Hydrogen Energy* 41.29 (2016): 12672-12687.
- Mahmoud, Yousef, W. Xiao, and H. H. Zeineldin. "A simple approach to modeling and simulation of photovoltaic modules." *IEEE transactions on Sustainable Energy* 3.1 (2011): 185-186.
- Mekki, H., Adel Mellit, and H. Salhi. "Artificial neural network-based modelling and fault detection of partial shaded photovoltaic modules." *Simulation Modelling Practice and Theory* 67 (2016): 1-13.
- Mittal, Manan, et al. "Performance prediction of PV module using electrical equivalent model and artificial neural network." *Solar Energy* 176 (2018): 104-117.
- Murdock, Hannah E., et al. "Renewables 2019 Global Status Report." (2019).
- Pranith, Sai, and T. S. Bhatti. "Modeling and parameter extraction methods of PV modules." 2015 International Conference on Recent Developments in Control, Automation and Power Engineering (RDCAPE). IEEE, 2015.
- Silva, IN da, Danilo Hernane Spatti, and Rogério Andrade Flauzino. "Redes neurais artificiais para engenharia e ciências aplicadas." São Paulo: Artliber 23.5 (2010): 33-111.
- Souza, Ronilson Di. "Os sistemas de energia solar fotovoltaica: Livro digital de introdução aos sistemas solares." (2012).
- Villalva, Marcelo Gradella, Jonas Rafael Gazoli, and Ernesto Ruppert Filho. "Comprehensive approach to modeling and simulation of photovoltaic arrays." *IEEE Transactions on power electronics* 24.5 (2009): 1198-1208.

PHOTOVOLTAIC MODULES MODELING: A REVIEW

Abstract. *Photovoltaic models are very important for many applications, such as representing the module behavior in electrical simulations, predicting power generation, among others. Photovoltaic modeling can be performed by equivalent electrical circuits models and by artificial neural networks (RNAs) models. Photovoltaic models have differences between precision and complexity of implementation. In this work the models will be reviewed: i) single diode with three, four and five parameters; ii) double diode with seven parameters; and iii) RNA models. A case study with the five-parameter single-diode model is developed, simulations have been performed and the results demonstrate good compliance with reality.*

Key words: *Photovoltaic systems, I-V curve, PV Model.*