

Estratégia para Classificação de Defeitos em Arranjos Fotovoltaicos através de Redes Neurais Artificiais

Amanda C. Maia, Guilherme S. da Silva, Ana Paula C. Mello

Universidade Federal do Pampa, Alegrete, Brasil

e-mail: amanda_maia15@hotmail.com, guilhermesds@gmail.com, anamello@unipampa.edu.br.

Abstract: The characteristic curve of a photovoltaic module is an important parameter to verify the operational condition of any photovoltaic system. For which defect that may happens in a photovoltaic array the I-V curve has a pattern, changing its parameters. Those defects in a system reduces the array generate power, cause the decrease in useful life and cause irreversible damages on the photovoltaic cells. In this context, this work presents a system to verify and classify the defects of a photovoltaic array through artificial neural networks.

Resumo: A curva característica de um módulo fotovoltaico é um importante critério para verificar as condições de operação de qualquer sistema fotovoltaico. E, para cada defeito que possa ocorrer em um arranjo fotovoltaico, a curva I-V tem um padrão alterando os parâmetros da curva característica. Este defeitos em um sistema reduzem a potência gerada do arranjo, causam a diminuição na vida útil e ocasionam em danos irreversíveis nas células fotovoltaicas. Nesse contexto, este trabalho apresenta um sistema para verificar e classificar os defeitos de um arranjo fotovoltaico com a utilização de redes neurais artificiais.

Keywords: Classification, I-V curve, Defects, Photovoltaic, Artificial Neural Network.

Palavras-chaves: Classificação, Curva I-V, Defeitos, Fotovoltaico, Redes Neurais Artificiais.

1. INTRODUÇÃO

Atualmente as principais fontes primárias de energia são carvão e gás natural, e, os combustíveis fósseis no ano de 2017 eram responsáveis por 81,2% da produção mundial de energia (International Energy Agency, 2017).

Devido à preocupação ambiental tenta-se diminuir o consumo desses tipos de combustíveis, principalmente no setor energético. E, apesar da redução do preço de fontes renováveis, como eólica e fotovoltaica, no ano de 2018 houve um aumento na utilização de petróleo para produção de energia elétrica, de acordo com (International Energy Agency, 2018). Em contra partida, estima-se um aumento de 50% em escala mundial entre os anos de 2019 e 2024 na utilização da energia fotovoltaica (International Energy Agency, n.d.).

O Brasil possui um grande potencial energético em relação à radiação solar em todo seu território, devido a maior parte do país está localizado nas proximidades da linha do Equador. (Agência Nacional de Energia Elétrica (ANEEL), 2005).

Os módulos fotovoltaicos estão sujeitos a variações climáticas, como, irradiância e temperatura. E ao longo do tempo, estes podem degradar e diminuir sua eficiência devido a fatores externos. Portanto, para garantir a máxima produção de energia em sistemas fotovoltaicos é necessário garantir que os dispositivos que compõem este sistema estejam em condições apropriadas para operação do conjunto.

A curva I-V de um módulo fotovoltaico varia em relação a diversos parâmetros externos (irradiância e temperatura), internos (resistência série e paralela) e condições de sombre-

amento. A variação de cada parâmetro dá-se de acordo com padrões.

Em (CEPEL; CRESESB, [s.d.]) mostra como a curva I-V modifica-se com a variação da irradiância e temperatura, onde a corrente gerada varia linearmente com a irradiância, em contra partida, a tensão diminui com o aumento da temperatura. Em (Carvalho, 2014) mostra o efeito das resistências na curva I-V. Além disso, (Pedro, 2016), (SEYEDMAHMOUDIAN et al., 2013) e (Coutinho, 2017) expõem o efeito do sombreamento na curva I-V.

Este artigo apresenta o desenvolvimento de uma topologia para verificar e classificar possíveis defeitos de um arranjo fotovoltaico. Além de identificar padrões na curva I-V de um módulo fotovoltaico utilizando redes neurais artificiais.

2. CÉLULAS FOTOVOLTAICAS

O efeito fotovoltaico (FV) ocorre quando uma estrutura é submetida a radiação solar resultando em uma diferença de potencial em seus terminais (CEPEL; CRESESB, [s.d.]). A célula fotovoltaica utiliza esse efeito para converter a energia contida nos fótons em energia elétrica.

2.1 Características da células fotovoltaicas

A célula fotovoltaica possui um comportamento não-linear entre a corrente e a tensão gerada. Cada conjunto de pontos da corrente e tensão da curva característica da célula (curva I-V) representa o ponto de operação (LUNA, 2013), Fig. 1.

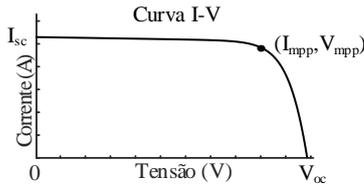


Fig. 1 Curva I-V de uma célula fotovoltaica.

A curva I-V de uma célula fotovoltaica possui quatro parâmetros principais, descritos a seguir:

Corrente de curto-circuito (I_{sc}): ocorre quando os terminais da células são curto-circuitados (CEPEL; CRESESB, [s.d.]).

Tensão de circuito aberto (V_{oc}): medida quando não há carga conectada nos terminais da célula.

Corrente de máxima potência (I_{mpp}): corrente no ponto onde é possível drenar a máxima potência da célula FV.

Tensão de máxima potência (V_{mpp}): denomina-se a tensão onde drena-se a máxima potência da célula fotovoltaica.

2.2 Modelo equivalente da célula fotovoltaica

A Fig. 2 apresenta o modelo de um diodo de uma célula fotovoltaica. Esse modelo é o mais utilizado na literatura por ser o mais simples e representar satisfatoriamente as características da célula fotovoltaica.

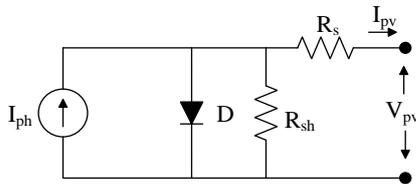


Fig. 2 Circuito equivalente da célula FV.

Aplicando a lei das correntes de Kirchoff no circuito elétrico da Fig. 2, obtém-se (1).

$$I_{pv} = I_{ph} - I_0 \cdot \left[\exp\left(q \cdot \frac{V_{pv} + I_{pv} \cdot R_s}{a \cdot k \cdot T}\right) - 1 \right] - \frac{V_{pv} + I_{pv} \cdot R_s}{R_{sh}} \quad (1)$$

Onde: I_{pv} : corrente de saída (A); I_{ph} : corrente fotogerada pela célula (A); I_0 : Corrente de saturação reversa (A); q : carga do elétron ($1,62 \times 10^{-19}$ C); a : fator de idealidade; k : constante de Boltzmann ($1,381 \times 10^{-23}$ m²kg/s²K); T : temperatura da célula (K).

3. REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais (RNA) são sistemas de processamento baseado no neurônio biológico, que contém a capacidade de aprendizado através de exemplos e de generalização. O primeiro modelo de neurônio artificial foi proposto por McCulloch e Pitts, e suas principais partes é descrito na Fig. 3 (Castro and Zuben, 2003).

Onde x são as entradas da rede neural, w é o peso sináptico das conexões, b é a função bias, $f(u)$ é a função de ativação da rede e y é a saída (Montgomer and Junior, 2007).

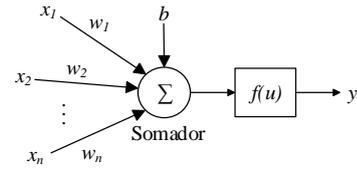


Fig. 3 Rede Neural Artificial.

Uma rede neural artificial é a combinação de neurônios e possuem uma ou mais camadas. Utiliza-se redes neurais artificiais para resolução de vários tipos de problemas, como classificação, categorização, aproximação, previsão e otimização (Braga et al., 2007).

4. METODOLOGIA

Nesta seção apresenta-se os principais defeitos que podem ocorrer em um sistema fotovoltaico no lado de corrente contínua, assim como, suas consequências na curva I-V. Além da metodologia aplicada para criar e treinar uma RNA do tipo perceptron multicamadas.

4.1 Defeitos característicos da curva I-V

A curva I-V de um arranjo fotovoltaico pode ser utilizada como um instrumento de verificação e avaliação dos defeitos que células ou módulos podem apresentar. A Fig. 4 mostra os principais pontos na curva característica de arranjo FV para averiguação desses defeitos (Treter, n.d.).

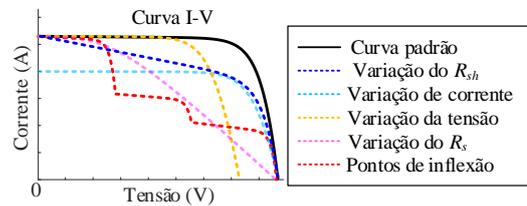


Fig. 4 Padrões da curva I-V.

Variação do R_{sh} : causada por danos na célula FV e sombreamentos parciais. (NBR 16274, 2011).

Variação de corrente: causada por acúmulos de sedimentos na superfície do módulo, degradação das células FV ou problemas de calibração do sensor de corrente.

Variação de tensão: ocasionada por sombreamentos total de células FV ou curto-circuito nos diodos de bypass.

Variação do R_s : ocasionada por danos na fiação que compõe o sistema, degradação do módulo FV ou problemas da fabricação da célula (NBR 16274, 2011).

Pontos de inflexão: causados por sombreamento parcial, danos nas células FV ou a operação indevida do diodo de bypass.

4.2 Sistema para detecção de defeitos em sistemas FV

O sistema capaz de identificar imperfeições em um arranjo FV através de redes neurais artificiais é representado pela Fig. 5. Este sistema contém uma rede neural do tipo classifi-

cação responsável por detectar os tipos de defeitos mencionados na seção 4.1.

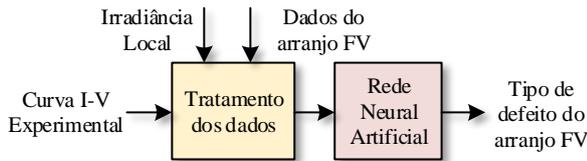


Fig. 5 Sistema proposto.

A curva I-V do arranjo fotovoltaico a ser analisado é a entrada do sistema, na etapa de tratamentos dos dados coleta-se os principais pontos da curva, a irradiância local e os dados do arranjo.

Os dados tratados são transferidos para a RNA e a saída do sistema é o defeito do arranjo, caso houver. Os defeitos analisados são: variação da resistência paralela/pontos de inflexão, variação da corrente de curto-circuito, variação da tensão de circuito aberto e variação da resistência série. Cada etapa do sistema é apresentada nas próximas seções.

4.3 Constituição da Rede Neural Artificial

A constituição de uma rede neural artificial é realizada em duas etapas: a criação da rede e o seu treinamento. A Fig. 6 demonstra esse processo.

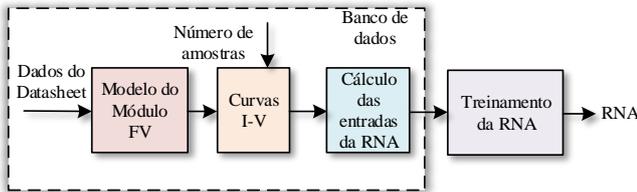


Fig. 6 Constituição da rede neural artificial.

4.4 Banco de dados

O banco de dados é criado para o treinamento da RNA, onde o usuário pode escolher o módulo fotovoltaico a ser utilizado, assim como, o número de módulos em série ou em paralelo e o número de amostra desejado para o treinamento.

A Fig. 7 mostra o fluxograma com a lógica do algoritmo para gerar o banco de dados. E inicialmente, escolhe-se o módulo fotovoltaico disponível no algoritmo, onde é utilizado os dados disponíveis no *datasheet* do módulo fotovoltaico para condição de 1000 W/m^2 e 25°C . Os parâmetros utilizados como entrada são P_{max} , V_{mpp} , I_{mpp} , V_{oc} , I_{sc} , α e β .

Através do método do Newton-Raphson estima-se as resistências R_{sh} e R_s para as condições padrões de teste e a corrente I_0 , (Cornelius et al., 2018). Após esse cálculo, deve-se escolher o tipo de imperfeição do arranjo e o número de amostras.

A Tabela 1 mostra os defeitos simulados. Utilizou-se dois métodos para calcular a curva I-V, para condições de irradiância uniforme no módulo FV (Cornelius et al., 2018) e para condições de sombreamento parcial (Maia et al., 2019).

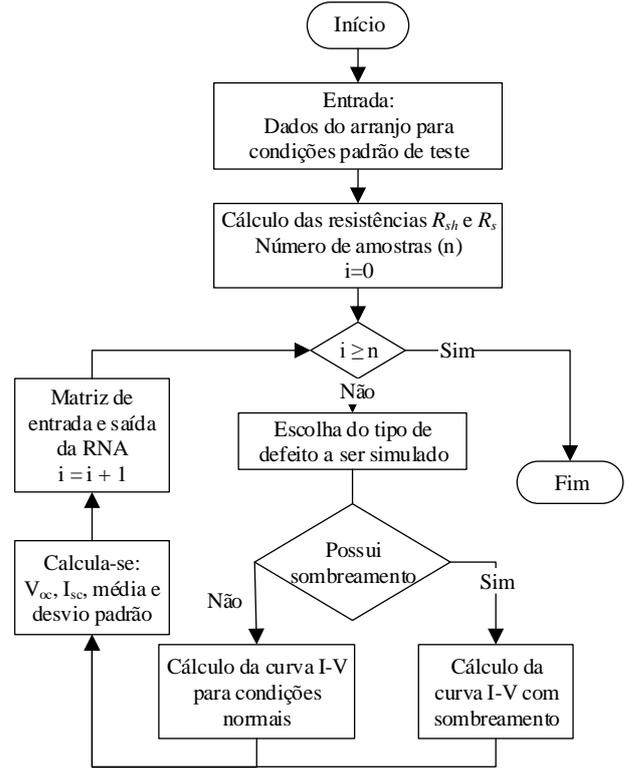


Fig. 7 Banco de dados.

Tabela 1 Tipos de defeitos a serem simulados.

Código	Tipo de defeito
0	Condições normais de operação
1	Variação do R_{sh} / Pontos de inflexão
2	Variação do I_{sc}
3	Variação do V_{oc}
4	Variação do R_s

4.4.1 Matriz de saída do banco de dados

Para o treinamento da RNA é necessário separar os principais pontos da curva I-V e coloca-los na forma matricial. Portanto, após o cálculo da curva I-V do arranjo FV montam-se as matrizes de entrada (X) e de saída (Y) da RNA.

A matriz de entrada (2) possui sete colunas e a quantidade de linhas da matriz depende da quantidade de amostras a ser gerada.

$$X = \begin{pmatrix} G_1 & V_{oc,1} & V_{oc,1}^{stc} & I_{sc,1} & I_{sc,1}^{stc} & M_1 & D_1 \\ \cdot & & \cdot & & & & \cdot \\ \cdot & & & \cdot & & & \cdot \\ \cdot & & & & \cdot & & \cdot \\ G_m & V_{oc,m} & V_{oc,m}^{stc} & I_{sc,m} & I_{sc,m}^{stc} & M_m & D_m \end{pmatrix} \quad (2)$$

M é a média da corrente de saída e D representa o desvio padrão da corrente de saída.

De forma análoga, a quantidade de linhas da matriz de saída é igual ao número de amostras, porém, a matriz Y possui uma três colunas, mostrado em (3). Os valores de saída assumidos nessa matriz são dados pela Tabela 2.

$$Y = \begin{pmatrix} y_{11} & y_{12} & y_{13} \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ y_{m1} & y_{m2} & y_{m3} \end{pmatrix} \quad (3)$$

Tabela 2 - Possibilidades de saída da rede neural.

Tipo de defeito	Saída prevista (Y)
Condições normais de operação	000
Varição do R_{sh} / Pontos de inflexão	001
Varição do I_{sc}	010
Varição do V_{oc}	011
Varição do R_s	100

A concepção da RNA utilizada, do tipo classificação, deu-se através do software Matlab[®]. Além disso, criou-se uma rede do tipo perceptron multicamadas capaz de solucionar problemas não-lineares (Matsunaga, 2012).

4.5 Tratamento dos dados da curva I-V experimental

A entrada do sistema completo para detecção de defeitos é a curva I-V experimental de um arranjo FV, previamente conhecida. Entretanto, a entrada da rede neural efetua-se na forma de matriz. Deste modo, necessita-se de um algoritmo capaz de coletar os principais pontos da curva I-V experimental.

O algoritmo é análogo ao banco de dados, porém, essa etapa requer somente a matriz de entrada da RNA (X), e não é necessário gerar a curva característica do arranjo.

A matriz de entrada é equivalente à (2), contudo, possui somente uma linha. O fluxograma da Fig. 8 representa a lógica do algoritmo utilizado para tratar os dados da curva I-V experimental.

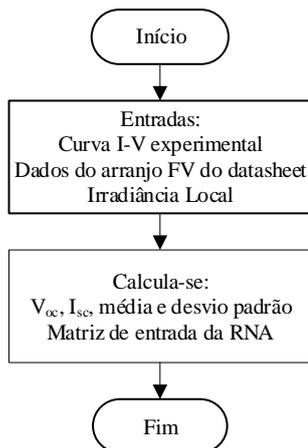


Fig. 8 Tratamento dos dados da curva I-V experimental.

5. RESULTADOS

O módulo fotovoltaico *Kyocera* KC40T foi utilizado para criar as amostras do banco de dados. Este módulo possui os parâmetros indicados na Tabela 3.

Tabela 3 Parâmetros do módulo KC40T.

Descrição	Valor
Máxima Potência	$P_{max} = 43W$
Tensão de Máxima Potência	$V_{mpp} = 17,4V$
Corrente de Máxima Potência	$I_{mpp} = 2,48A$
Tensão de Circuito Aberto	$V_{oc} = 21,7V$
Corrente de Curto-Circuito	$I_{sc} = 2,65A$
Número de Células	$N = 36$
Fator de Idealidade	$a = 1,3$
Coefficiente de temperatura de I_{sc}	$\alpha = 1,06 \times 10^{-3} A/^{\circ}C$
Coefficiente de temperatura de V_{oc}	$\beta = -8,21 \times 10^{-2} V/^{\circ}C$

Para elaboração das amostras foram utilizados valores aleatórios de irradiância, temperatura, número de módulos em série, número de módulos em paralelo, os intervalos estão de acordo com a Tabela 4.

Tabela 4 Intervalo dos valores atribuídos.

Descrição	Intervalo atribuído
Irradiância	400 – 1000 W/m ²
Temperatura	10 – 60 °C
Número de módulos em série	1 – 10
Número de módulos em paralelo	1 – 10

Em seguida foi criada uma rede neural artificial do tipo perceptron multicamadas e a definição do número de neurônios é realizada de forma empírica.

Para determinar o número de neurônios a ser utilizado realizou-se diversos testes com diferentes números de neurônios em cada camada escondida, e, calculou-se o erro quadrático médio. O resultado é indicado na Tabela 5.

Tabela 5 Resultado da variação do número de neurônios em cada camada escondida.

Rede Neural	Erro Quadrático Médio (EQM)
2 camadas (10,10)	0,004
2 camadas (20,10)	0,0001
2 camadas (15,5)	0,00192
3 camadas (15,15,15)	$8,7 \times 10^{-7}$
3 camadas (10,10,10)	$8,26 \times 10^{-7}$

Observa-se que a RNA com 3 camadas escondidas e 10 neurônios em cada camada possui o menor erro, portanto, esta configuração será utilizada para validação dos resultados.

Para o treinamento da rede neural foi utilizado as 400 amostras do banco de dados, em que 80% das amostras foram dispostas para o treinamento e o restante para teste. Além disso, o erro esperado é de 1×10^{-6} e o pode-se alcançar no máximo 5000 épocas. A RNA criada é mostrada na Fig. 9.

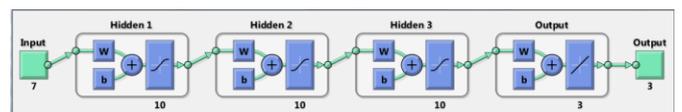


Fig. 9 Rede Neural Artificial.

A evolução do treinamento e teste da RNA criada é demonstrada na Fig. 10.

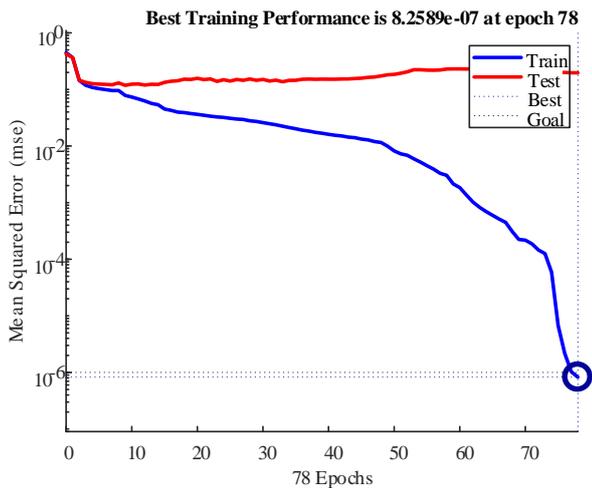


Fig. 10 Evolução do treinamento em cada época.

Para o verificar o funcionamento do algoritmo de tratamento de dados utilizou-se a RNA previamente treinada. Além disso, para gerar as amostras foi usado o módulo da *Kyocera* KD210GX-LP, cujo os dados estão disponibilizados na Tabela 6.

Tabela 6 Parâmetros do modulo KD210GX-LP

Descrição	Valor
Máxima Potência	$P_{max} = 210W$
Tensão de Máxima Potência	$V_{mpp} = 26,6V$
Corrente de Máxima Potência	$I_{mpp} = 7,9A$
Tensão de Circuito Aberto	$V_{oc} = 33,2V$
Corrente de Curto-Circuito	$I_{sc} = 8,58A$
Número de Células	$N = 54$
Fator de Idealidade	$a = 1,3$
Coefficiente de temperatura de I_{sc}	$\alpha = 5,15 \times 10^{-3} A/^{\circ}C$
Coefficiente de temperatura de V_{oc}	$\beta = -1,2 \times 10^{-1} V/^{\circ}C$

A Fig. 11 mostra a comparação do resultado esperado e a resposta da rede para uma saída 000, ou seja, em condições normais de operação. Considerando uma irradiância de 215 W/m², 8 módulos em série e 9 em paralelo.

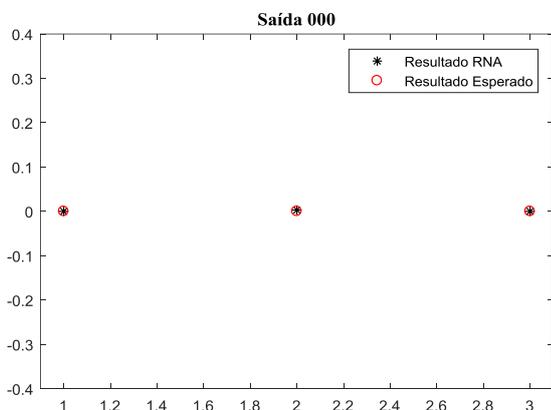


Fig. 11 Saída RNA para condições normais de operação.

A Fig. 12 representa a saída da RNA para variação de resistência em paralelo ou existências de pontos de inflexão. E, a

irradiância utilizada para gerar a amostra foi de 926 W/m², 3 módulos em série e 1 em paralelo.

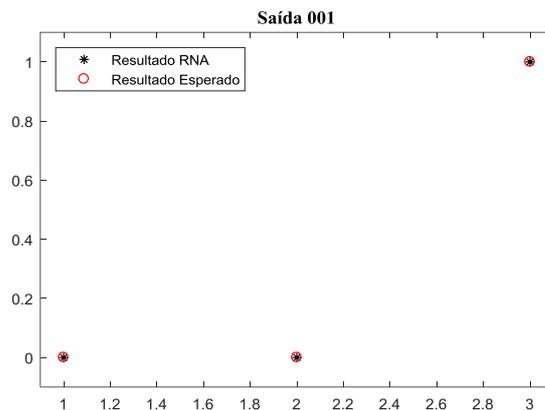


Fig. 12 Saída da RNA para variação do R_{sh} ou pontos de inflexão.

A saída 010, Fig. 13, representa a variação da corrente de curto circuito. O arranjo foi submetido a uma irradiância de 228 W/m², sendo utilizados 5 módulos em série e 8 em paralelo.

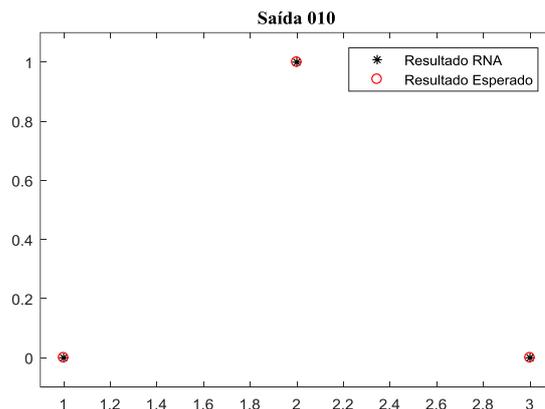


Fig. 13 Saída da RNA para variação de I_{sc} .

A Fig. 14 mostra a saída da RNA para a variação da tensão de circuito aberto. Considerou-se a irradiância de 690 W/m², 8 módulos em série e 9 em paralelo.

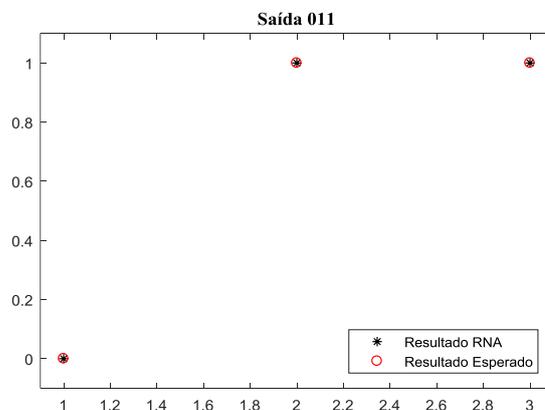


Fig. 14 Saída da RNA para variação de V_{oc} .

A Fig. 15 representa da variação da resistência série. E os dados do arranjo são: irradiância de 769 W/m^2 , 7 módulos em série e 8 em paralelo.

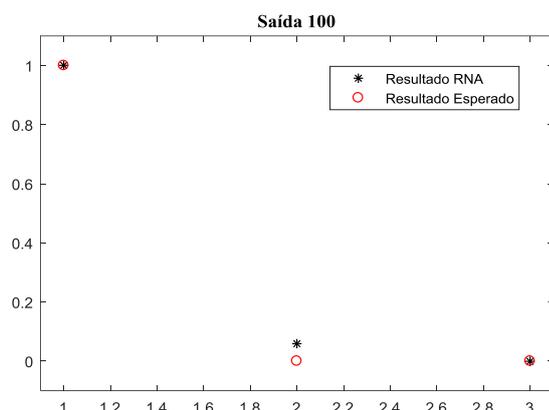


Fig. 15 Saída da RNA para variação de R_s .

6. CONCLUSÕES

Os defeitos nos arranjos FV têm como consequência a redução de potência gerada em relação a potência máxima gerada para condições nominais de operação. Além disso, podem gerar danos irreversíveis às células FV, chegando à condições extremas de queima das células. Esse artigo apresentou uma rede neural artificial capaz de classificar possíveis defeitos em módulos fotovoltaicos, de acordo com cada padrão na curva I-V. Os próximos passos do projeto é a otimização da rede neural artificial.

REFERÊNCIAS

- Agência Nacional de Energia Elétrica (ANEEL), 2005. Energia Solar. Atlas da Energ. Elétrica do Bras. 14.
- Braga, A. de P., Carvalho, A.P. de L.F., Ludermir, T.B., 2007. Redes Neurais Artificiais: Teoria e Aplicações.
- Carvalho, A.L.C. de, 2014. Metodologia para análise, caracterização e simulação de células fotovoltaicas. Diss. apresentada para obtenção do Grau Mestre em Eng. Elétrica pela Universidade Fed. Minas Gerais 97.
- Castro, L.N., Zuben, F.J. Von, 2003. Redes neurais artificiais.
- Cornelius, R.G., Maia, A.C., Mello, A.P.C. De, Kaehler, J.W.M., Silva, G.S., 2018. Desenvolvimento de um dispositivo eletrônico para caracterização de painéis fotovoltaicos.
- Coutinho, C.R., 2017. O Efeito do Sombreamento e Diodos de Bypass em Módulos Fotovoltaicos.
- International Energy Agency, I., 2018. World Energy Outlook 2018.
- International Energy Agency, I., 2017. World Energy Balances [WWW Document]. URL <https://www.iea.org/statistics/balances/>
- International Energy Agency, I., n.d. Global solar PV market set for spectacular growth over next 5 years [WWW Document]. 2019. URL <https://www.iea.org/newsroom/news/2019/october/global-solar-pv-market-set-for-spectacular-growth-over-next-5-years.html>
- Maia, A.C., Cornelius, R.G., Mello, A.P.C. De, Silva, G.S., 2019. Method to trace the photovoltaic characteristic curves under partial shading conditions.
- Matsunaga, V.Y., 2012. Curso de redes neurais utilizando o MATLAB.
- Montgomer, E., Junior, O.L., 2007. Redes Neurais: Fundamentos e aplicações com programas em C.
- NBR 16274, A., 2011. Abnt Nbr. Assoc. Bras. Normas Técnicas 8. <https://doi.org/01.080.10; 13.220.99>
- Pedro, M.C.M., 2016. Modelling of Shading Effects in Photovoltaic Optimization.
- Seyedmahmoudian, M., Mekhilef, S., Rahmani, R., Yusof, R., Renani, E.T., 2013. Analytical modeling of partially shaded photovoltaic systems. Energies. <https://doi.org/10.3390/en6010128>
- Treter, M.E., n.d. Métodos De Aquisição Experimental De Curvas I-V De Arranjos Fotovoltaicos : Uma Revisão.