

**UNIVERSIDADE FEDERAL DO PAMPA**

**AMANDA COSTA MAIA**

**ESTRATÉGIA PARA CLASSIFICAÇÃO DE DEFEITOS EM  
ARRANJOS FOTOVOLTAICOS ATRAVÉS DE REDES NEURAIAS  
ARTIFICIAIS**

**Alegrete  
2020**

**AMANDA COSTA MAIA**

**ESTRATÉGIA PARA CLASSIFICAÇÃO DE DEFEITOS EM  
ARRANJOS FOTOVOLTAICOS ATRAVÉS DE REDES NEURAIIS  
ARTIFICIAIS**

Trabalho de Conclusão de Curso  
apresentado ao Curso de Engenharia  
Elétrica da Universidade Federal do  
Pampa, como requisito parcial para  
obtenção do Título de Bacharel em  
Engenharia Elétrica.

Orientador: Guilherme Sebastião da Silva

**Alegrete  
2020**

Ficha catalográfica elaborada automaticamente com os dados fornecidos pelo(a) autor(a) através do Módulo de Biblioteca do Sistema GURI (Gestão Unificada de Recursos Institucionais).

M217e Maia, Amanda Costa

Estratégia para classificação de defeitos em arranjos fotovoltaicos através de redes neurais artificiais / Amanda Costa Maia.

72 p.

Trabalho de Conclusão de Curso (Graduação) -- Universidade Federal do Pampa, ENGENHARIA ELÉTRICA, 2020.

“Orientação: Guilherme Sebastião Silva”.

1. Defeitos. 2. Curva I-V. 3. Classificação. 4. Arranjos Fotovoltaicos. 5. Perceptron Multicamadas. I. Título.



SERVIÇO PÚBLICO FEDERAL  
MINISTÉRIO DA EDUCAÇÃO  
Universidade Federal do Pampa

**AMANDA COSTA MAIA**

**ESTRATÉGIA PARA CLASSIFICAÇÃO DE DEFEITOS EM ARRANJOS FOTOVOLTAICOS  
ATRAVÉS DE REDES NEURAIAS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica.

Trabalho de Conclusão de Curso defendido e aprovado em: 27 de Novembro de 2020.

Banca examinadora:

---

Prof. Dr. Guilherme Sebastião da Silva  
Orientador  
UNIPAMPA

---

Prof. Dr. Giovanni Guarienti Pozzebon  
UNIPAMPA

---

Eng. Jonathan Behrens

Esco GD



Documento assinado eletronicamente por **GUILHERME SEBASTIAO DA SILVA, PROFESSOR DO MAGISTERIO SUPERIOR**, em 27/11/2020, às 17:17, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **GIOVANI GUARIENTI POZZEBON, PROFESSOR DO MAGISTERIO SUPERIOR**, em 27/11/2020, às 17:20, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Assinado eletronicamente por **JONATHAN BEHRENS, Usuário Externo**, em 07/12/2020, às 11:37, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



A autenticidade deste documento pode ser conferida no site [https://sei.unipampa.edu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.unipampa.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0413160** e o código CRC **E230A7D9**.

---

Universidade Federal do Pampa, Campus Alegrete  
Av. Tiarajú, 810 – Bairro: Ibirapuitã – Alegrete – RS CEP: 97.546-550

Telefone: (55) 3422-8400



## AGRADECIMENTO

Primeiramente queria agradecer a Deus, que dirigiu cada passo meu até este instante e que nos momentos de adversidades me sustentou e deu forças para continuar.

Queria agradecer à minha família, meus pais (Araci e Atenágoras) e meus irmãos (Magno e Bianca) pelo amor, suporte, confiança, paciência, e por sempre estarem ao meu lado.

Ao meu namorado, Elias, que mesmo à distância sempre me apoiou durante minha formação, por estar ao meu lado nas horas boas e ruins e dividir essa caminhada comigo.

Aos meus amigos que adquiri no decorrer desse curso, Ana Paula, Larissa, Leonardo e Richard, aos momentos infundáveis de estudos, mas também, aos momentos de alegria. Obrigada por fazerem parte da minha vida.

Ao meu orientador professor Guilherme S. da Silva que me concedeu todo apoio durante minha graduação e também na realização desta monografia.

Queria agradecer também à todos os professores e professoras da Unipampa pelos conhecimentos adquiridos na graduação.

Queria dizer que cada um de vocês fazem parte da minha história e da minha formação acadêmica, sem vocês não teria chegado até aqui.

“Alegrai-vos na esperança, sede pacientes na tribulação, perseverai em oração”.

Romanos 12:12

## RESUMO

A curva característica de um módulo fotovoltaico é um importante critério para verificar as condições de operação de qualquer sistema fotovoltaico. Sendo que, para cada característica de tensão e corrente, há um molde da curva I-V. Essa curva modifica-se com a mudança de parâmetros externos como temperatura e irradiância. Além disso, há parâmetros intrínsecos dos módulos fotovoltaicos que alteram a forma da curva I-V, como a resistência série e a resistência paralela. E para cada defeito que possa ocorrer em um arranjo fotovoltaico a curva I-V tem um padrão alterando os parâmetros da curva característica. Estes defeitos em um sistema reduzem a potência gerada do arranjo, causam a diminuição na vida útil e ocasionam danos irreversíveis nas células fotovoltaicas. Portanto, há a necessidade de identificar os defeitos de um arranjo fotovoltaico, os defeitos são escolhidos de acordo com a norma NBR 16274. A identificação dos defeitos é baseada na curva I-V, na irradiância incidente no arranjo e nos dados disponibilizados pelo fabricantes do arranjo, além disso, uma rede neural artificial do tipo *perceptron* multicamadas com uma camada escondida é utilizada para classificação das condições escolhidas. Os resultados do sistema proposto mostraram que a rede neural foi capaz de classificar os defeitos com uma acurácia de 99,3%, além do mais o sistema possui uma estrutura compacta.

Palavras-Chave: Classificação, Curva I-V, Defeitos, Fotovoltaico, Módulo, *Perceptron* Multicamadas, Redes Neurais Artificiais.

## ABSTRACT

The characteristic curve of a photovoltaic module is an important parameter to verify the operational condition of any photovoltaic system. In addition, to each voltage and current characteristic, there is a mold of the I-V curve. This curve modifies with the parameters change, such, temperature and irradiance. Besides, there are intrinsic parameters of the photovoltaic modules, such, the series resistance and the shunt resistance, which change the shape of the I-V curve. For which defect that may happens in a photovoltaic array, the I-V curve has a pattern, changing the I-V curve parameters. These defects in a system reduce the array generate power, cause the decrease on useful life and cause irreversible damages on the photovoltaic cells. Therefore, there is a need to identify the photovoltaic array defects, the defects are chosen according with the standard NBR 16274. The defects identification is based on the I-V curve, the array irradiance and the array datasheet, therefore, an artificial neural network, such, multilayer perceptron with one hidden layer is used for classification of the chosen conditions. The proposed system results shown that the neural network was able to classify the defects with an accuracy of 99,3%, and moreover the system has a compact structure.

Keywords: Classification, I-V curve, Defects, Photovoltaic, Module, Multilayer *Perceptron*, Neural Network.

## LISTA DE FIGURAS

Figura 1 - Curva I-V de uma célula fotovoltaica. ....	22
Figura 2 - Curva P-V de uma célula fotovoltaica. ....	22
Figura 3 - Modelo equivalente de um diodo. ....	23
Figura 4 - Interferência da irradiância da curva I-V e curva P-V. ....	25
Figura 5 - Efeito da temperatura na curva I-V e na curva P-V. ....	26
Figura 6 - Efeito da resistência série na curva I-V. ....	26
Figura 7 - Efeito da resistência paralela na curva I-V. ....	27
Figura 8 - Curva I-V com sombreamento suave. ....	27
Figura 9 - Sombreamento total. ....	28
Figura 10 - Curva I-V com sombreamento total. ....	29
Figura 11 - Sombreamento parcial. ....	29
Figura 12 - Curva I-V para sombreamento parcial. ....	30
Figura 13 - Rede Neural Artificial. ....	30
Figura 14 - Aprendizado Supervisionado. ....	31
Figura 15 - Aprendizado não-supervisionado. ....	32
Figura 16 - Rede de única camada. ....	32
Figura 17 - Rede direta de múltiplas camadas. ....	33
Figura 18 - Rede com realimentação. ....	33
Figura 19 - Rede <i>perceptron</i> de uma única camada. ....	34
Figura 20 - Neurônio Adaline. ....	34
Figura 21 - Rede PMC com duas camadas ocultas. ....	35
Figura 22 - Defeitos característicos da curva I-V. ....	36
Figura 23 - Sistema de detecção de defeitos. ....	37
Figura 24 - Banco de dados para treinamento da RNA. ....	38
Figura 25 - Fluxograma do banco de dados. ....	39
Figura 26 - Fluxograma do método do Newton-Raphson. ....	41
Figura 27 - Cálculo da curva I-V. ....	43
Figura 28 - Tensão de inflexão em um arranjo FV. ....	44
Figura 29 - Cálculo da curva I-V com sombreamento parcial. ....	45
Figura 30 - Constituição da Rede Neural Artificial. ....	47
Figura 31 - Etapa de tratamento dos dados. ....	50
Figura 32 - Topologia RNA <i>perceptron</i> multicamadas utilizada. ....	54
Figura 33 - Performance do erro durante o treinamento da RNA. ....	54
Figura 34 - Matriz de confusão. ....	55
Figura 35 - Rede <i>Perceptron</i> de Multicamadas criada e treinada no Matlab. ....	56
Figura 36 - Curva I-V para condições normais de operação. ....	57
Figura 37 - Resultado da RNA para “1 0 0 0 0 0”. ....	58
Figura 38 - Relatório impresso para condições normais de operação. ....	58

Figura 39 - Curva I-V para diminuição da resistência em paralelo.....	59
Figura 40 - Resultado da RNA para “0 1 0 0 0 0”.....	59
Figura 41 - Relatório impresso para diminuição da resistência em paralelo.....	60
Figura 42 - Curva I-V para pontos de inflexões.....	61
Figura 43 - Resultado da RNA para “0 0 1 0 0 0”.....	61
Figura 44 - Relatório impresso para pontos de inflexão.....	62
Figura 45 - Curva I-V para diminuição da corrente de curto-circuito. ....	63
Figura 46 - Resultado da RNA para “0 0 0 1 0 0”.....	63
Figura 47 - Relatório impresso para diminuição da corrente de curto-circuito. ....	64
Figura 48 - Curva I-V para diminuição da tensão de circuito aberto. ....	65
Figura 49 - Resultado da RNA para “0 0 0 0 1 0”.....	65
Figura 50 - Relatório impresso para diminuição da tensão de circuito aberto. ....	66
Figura 51 - Curva I-V para aumento da resistência em série.....	66
Figura 52 - Resultado da RNA para “0 0 0 0 0 1”.....	67
Figura 53 - Relatório impresso para aumento da resistência em série. ....	67

## LISTA DE TABELAS

Tabela 1 - Tipos de defeitos. ....	40
Tabela 2 - Intervalo dos valores atribuídos aleatoriamente. ....	40
Tabela 3 - Elementos da matriz X. ....	46
Tabela 4 - Possibilidades de saída da rede neural. ....	47
Tabela 5 - Funções de ativação. ....	48
Tabela 6 - Algoritmos de aprendizagem. ....	48
Tabela 7 - Parâmetros para treinamento. ....	49
Tabela 8 - Parâmetros do módulo KD210GX-LP. ....	52
Tabela 9 - Parâmetros de treinamento da RNA. ....	53
Tabela 10 - EQM e taxas de acertos para diferentes topologias. ....	53
Tabela 11 - Dados do módulo KC40T. ....	56
Tabela 12 - Dados do arranjo para condições normais de operação. ....	57
Tabela 13 - Dados do arranjo para diminuição de $R_{sh}$ . ....	58
Tabela 14 - Dados do arranjo para pontos de inflexão. ....	60
Tabela 15 - Dados do arranjo para diminuição de $I_{sc}$ . ....	62
Tabela 16 - Dados do arranjo para diminuição de $V_{oc}$ . ....	64
Tabela 17 - Dados do arranjo para aumento de $R_s$ . ....	66

## LISTA DE ABREVIATURAS E SIGLAS

FV – Fotovoltaico

I – Corrente

V – Tensão

$I_{sc}$  – Corrente de curto-circuito

$I_{sc}^{stc}$  – Corrente de curto circuito em condição padrão de teste

$I_{pv}$  – Corrente de saída

$V_{pv}$  – Tensão de saída

$I_{ph}$  – corrente fotogerada pela célula

$I_0$  – Corrente de saturação reversa

$V_{oc}$  – Tensão de circuito aberto

$V_{oc}^{stc}$  – Tensão de circuito aberto para condição padrão de teste

$V_T$  – Tensão térmica

$I_{mpp}$  – Corrente de máxima potência

$V_{mpp}$  – Tensão de máxima potência

$R_s$  – Resistência série

$R_s^{stc}$  – Resistência série para  $1000 \text{ W/m}^2$  e  $25 \text{ }^\circ\text{C}$

$R_{sh}$  – Resistência paralela

$R_{sh}^{stc}$  – Resistência paralela para  $1000 \text{ W/m}^2$  e  $25 \text{ }^\circ\text{C}$

G – Irradiância incidente na célula fotovoltaica

$\beta$  – coeficiente de temperatura de  $V_{oc}$

$\Delta T$  – Variação de temperatura

$\alpha$  – Coeficiente de temperatura de  $I_{sc}$

q – Carga do elétron

a – Fator de idealidade

k – Constante de Boltzmann

D – Diodo antiparalelo

T – Temperatura da célula

$N_s$  – Número de células conectadas em série

$N_p$  – Número de células conectadas em paralelo

n – Número de módulos em série de um arranjo

m – Número de módulos em paralelo de um arranjo

$V_{inf}$  – Tensão de inflexão

RNA – Rede neural artificial

$x_n$  – N-ésima entrada da rede neural

w – Peso sináptico das conexões

b – Função bias

f(u) – Função de ativação da rede

y – Saída da rede neural

X – Matriz de entrada da rede neural artificial

Y – Matriz de saída da rede neural artificial

PMC – *Perceptron* de múltiplas camadas

r – Valor normalizado;

x – Valor a ser normalizado;

$x_{min}$  – Menor valor do intervalo que irá ser normalizado;

$x_{max}$  – Maior valor do intervalo a ser normalizado

EQM – Erro quadrático médio

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>16</b>
1.1 Motivação.....	17
1.2 Objetivos.....	18
1.2.1 Objetivo Geral.....	18
1.2.2 Objetivos Específicos.....	18
1.3 Organização do trabalho.....	18
<b>2 REVISÃO BIBLIOGRÁFICA.....</b>	<b>20</b>
2.1 Células Fotovoltaicas.....	20
2.1.1 Associação de células fotovoltaicas.....	21
2.1.2 Características da células fotovoltaicas.....	21
2.1.3 Modelo equivalente da célula fotovoltaica.....	23
2.2 Fatores que modificam a curva característica de um arranjo fotovoltaico.....	24
2.2.1 Impacto da irradiância e da temperatura na curva I-V.....	24
2.2.2 Impacto do $R_s$ e do $R_{sh}$ na curva I-V.....	26
2.2.3 Efeito do sombreamento em sistemas fotovoltaicos.....	27
2.3 Redes Neurais Artificiais.....	30
2.3.1 Treinamento da rede neural artificial.....	31
2.3.2 Arquitetura de Rede.....	32
2.3.3 Principais topologias de redes neurais artificiais.....	33
<b>3 METODOLOGIA.....</b>	<b>36</b>
3.1 Defeitos característicos da curva I-V.....	36
3.2 Sistema para detecção de defeitos em arranjos fotovoltaicos.....	37
3.3 Banco de Dados.....	38
3.3.1 Cálculo das Resistências em série e em paralelo.....	40
3.3.2 Curva I-V para condições de irradiância regular.....	42
3.3.3 Curva I-V para condições de sombreamento parcial.....	43
3.3.4 Matrizes de Saída do Banco de Dados.....	45
3.4 Constituição da Rede Neural Artificial.....	47
3.5 Tratamento dos dados.....	49
<b>4 RESULTADOS E DISCUSSÕES.....</b>	<b>52</b>
4.1 Treinamento da rede neural do tipo <i>perceptron</i> de múltiplas camadas.....	52

<b>4.2 Algoritmo de tratamento de dados .....</b>	<b>55</b>
4.2.1 Condições normais de operação .....	57
4.2.2 Variação da resistência em paralelo.....	58
4.2.3 Pontos de inflexão na curva I-V .....	60
4.2.4 Variação da corrente de curto-circuito.....	62
4.2.5 Variação da tensão de circuito aberto .....	64
4.2.6 Variação da resistência em série .....	66
<b>5 CONSIDERAÇÕES FINAIS .....</b>	<b>68</b>
5.1 Trabalhos publicados .....	68
5.2 Proposta de trabalhos futuros .....	69
<b>REFERÊNCIAS .....</b>	<b>70</b>

## 1 INTRODUÇÃO

Atualmente as principais fontes primárias de energia são carvão e gás natural, sendo que 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 combustíveis principalmente no setor energético, no ano de 2018 houve um aumento na utilização de petróleo para produção de energia elétrica, de acordo com (INTERNATIONAL ENERGY AGENCY, 2018). Entretanto, a redução do preço de fontes renováveis acarretará em um aumento de 50% em escala mundial entre os anos de 2019 e 2024 na utilização da energia fotovoltaica (INTERNATIONAL ENERGY AGENCY, 2017).

O Brasil possui um grande potencial energético em relação à radiação solar em todo seu território devido a maior parte do país estar localizado nas proximidades da linha do Equador, porém esse potencial ainda é pouco aproveitado (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL), 2005).

No Brasil, o crescimento da utilização de energia fotovoltaica deu-se após os incentivos governamentais em 2012 e resoluções de normativas. Os incentivos reduzem o tempo de retorno do investimento e incentiva a instalação de sistemas fotovoltaicos no país (NASCIMENTO, 2017).

A energia fotovoltaica, por definição, é a transformação direta da energia proveniente da luz solar em energia elétrica (MARQUES, 2015). A conversão de energia é realizada através de um dispositivo denominado célula fotovoltaica.

O módulo fotovoltaico é definido como o conjunto de células ligadas em série ou em paralelo (DEMONTI, 2003). Para assegurar a máxima geração de potência nesses dispositivos deve-se garantir que estejam posicionados corretamente em direção ao sol, esse posicionamento é diretamente ligado à localidade da instalação. Além

disso, deve-se garantir o adequado rastreamento do ponto de máxima potência e que os módulos estejam em condições adequadas para operação.

### 1.1 Motivação

O dispositivos fotovoltaicos estão sujeitos a variações climáticas, como irradiância e a temperatura, cada módulo fotovoltaico deve estar operando corretamente para garantir um contínuo fornecimento de potência (SYAFARUDDIN; KARATEPE; HIYAMA, 2011). Ao longo do tempo, os módulos fotovoltaicos podem degradar e diminuir sua eficiência devido aos fatores externos. Portanto, para garantir a máxima produção de energia em sistemas fotovoltaicos é necessário assegurar que os dispositivos que compõem o sistema estejam em condições apropriadas para operação do conjunto (JIANG; MASKELL, 2015).

Os geradores fotovoltaicos operam em corrente contínua, por isso falhas ou defeitos em módulos ou arranjos são mais difíceis de serem detectados (CARVALHO et al., 2018), e aparelhos para este tipo de aplicação são quase inexistentes.

Existem três principais tipos de defeitos que ocorrem no lado de corrente contínua: perda de energia constante (degradação e defeitos no arranjo), perda de energia variável (sombreamentos) e obstruções (CHINE et al., 2014). Cada defeito pode gerar danos irreversíveis ao arranjo fotovoltaico e perda de potência.

Os principais métodos para detectar falhas em arranjos fotovoltaicos de acordo com (CHINE et al., 2014) são:

- Métodos que utilizam dados climáticos;
- Métodos baseados na análise da corrente, tensão (curva I-V) e a derivada da corrente (curva  $-dI/dV-V$ );
- Métodos que usam o rastreamento do ponto de máxima potência;
- Métodos baseados em inteligência artificial (redes neurais artificiais).

O método baseado em redes neurais artificiais apresenta boa acurácia, rápido processamento, simples implementação e fácil localização dos defeitos, de acordo com (JIANG; MASKELL, 2015).

O método a ser implementado nesta pesquisa utilizará a curva I-V de um arranjo fotovoltaico juntamente com redes neurais artificiais para a detecção dos defeitos: variação de resistência em paralelo, pontos de inflexão na curva I-V, variação da corrente de curto-circuito, variação da tensão de circuito aberto e variação da resistência em série.

## **1.2 Objetivos**

### **1.2.1 Objetivo Geral**

O objetivo geral desta pesquisa é verificar e classificar possíveis defeitos de um arranjo fotovoltaico a partir da curva I-V utilizando redes neurais artificiais.

### **1.2.2 Objetivos Específicos**

- Propor um modelo de rede neural artificial que tenha a capacidade de classificação.
- Fazer um algoritmo capaz de simular matematicamente os defeitos gerados na curva I-V e armazená-los em um banco de dados.
- Realizar o treinamento da rede neural proposta.
- Fazer um algoritmo que colete os principais pontos da curva I-V e através da rede neural já treinada detectar os possíveis defeitos de um arranjo fotovoltaico e as causas prováveis.

## **1.3 Organização do trabalho**

Este trabalho está dividido em cinco capítulos. Primeiramente apresenta-se uma breve contextualização do cenário energético mundial e a importância das condições ótimas de operação de um sistema fotovoltaico.

No capítulo 2 apresenta-se uma breve revisão bibliográfica sobre módulos fotovoltaicos e as possíveis condições de operação. Também nesse capítulo apresenta-se o conceito geral de redes neurais artificiais.

Logo após, no capítulo 3 é apresentada a metodologia de pesquisa realizada neste trabalho, destacando o passo a passo realizado.

E por fim, no capítulo 4 são apresentados os resultados alcançados nessa pesquisa e o capítulo 5 contém as considerações finais referentes ao trabalho.

## 2 REVISÃO BIBLIOGRÁFICA

Nesta seção é apresentada uma revisão bibliográfica sobre o conceito, funcionamento e a representação matemática de arranjos fotovoltaicos. É abordado também, a forma que elementos internos e externos modificam a curva característica dos arranjos e o padrão dessas mudanças. Além disso, é realizado uma revisão sobre redes neurais artificiais especificando as suas diferentes funções, arquiteturas de rede, tipos de aprendizado e os principais tipos de RNA utilizadas na literatura, considerando redes para classificação de padrões.

### 2.1 Células Fotovoltaicas

O efeito fotovoltaico (FV) ocorre quando uma estrutura constituída por materiais semicondutores é submetida a radiação solar resultando em uma diferença de potencial em seus terminais (CEPEL; CRESESB, 2014). A célula fotovoltaica utiliza esse efeito para converter a energia contida nos fótons em energia elétrica.

As células fotovoltaicas são fabricadas através de materiais semicondutores, geralmente silício devido a sua abundância na superfície terrestre. O silício passa por um processo de purificação, e após, é adicionado impurezas selecionadas.

No processo de adicionar impurezas ao material são utilizados dois tipos átomos, um com cinco elétrons em sua camada de valência formando um material do tipo  $n$  (MEIRELLES; MARQUES, 2011), e outro átomo com três elétrons em sua camada de valência que constitui um material do tipo  $p$  (GASPARIN, 2009). Na célula FV dá-se a junção desses dois materiais, dita junção  $pn$ .

A energia dos fótons provenientes da radiação solar é transferida para os elétrons livres presentes na camada do tipo  $n$  fazendo com que esses elétrons fluam para a camada com falta de elétrons (tipo  $p$ ). O campo elétrico gerado pela junção  $pn$  faz os elétrons fluírem ordenadamente gerando corrente elétrica contínua (BRITO, 2014).

A eficiência da célula FV depende da tecnologia empregada, as principais são monocristalino, policristalino e silício amorfo. Na tecnologia monocristalina, o silício passa por uma etapa de rígida purificação que aumenta o custo de fabricação, esse tipo de célula pode chegar a uma eficiência de 25% (CEPEL; CRESESB, 2014). Em contrapartida, nas células policristalinas a etapa de purificação não é tão rígida, diminuindo a eficiência (cerca de 20%) e o custo de fabricação. Por outro lado, as células de silício amorfo possuem estruturas desorganizadas (ocasionando em uma eficiência de cerca de 10%), facilitando sua fabricação, e conseqüentemente possuem um baixo custo.

### **2.1.1 Associação de células fotovoltaicas**

Uma célula fotovoltaica produz tensão de aproximadamente 0,7 V e corrente entre 3 e 5 A (CEPEL; CRESESB, 2014). Dessa forma, as células FV são associadas em série ou em paralelo para o aumento de corrente ou tensão, e como resultado de potência.

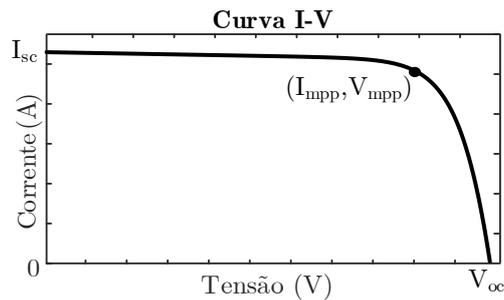
Para o aumento de tensão, deve-se associar células em série. A corrente permanece a mesma, e deve-se utilizar células com o mesmo valor de corrente para evitar perdas. Em contrapartida, para o aumento de corrente deve-se associar células em paralelo, onde a tensão mantém-se constante, e conseqüentemente deve-se utilizar células com o mesmo valor de tensão.

A associação de células, em série ou paralelo, constitui um módulo fotovoltaico. Assim como, a associação de módulos denomina-se um arranjo fotovoltaico.

### **2.1.2 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). A forma geral da curva característica é mostrada na Figura 1.

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



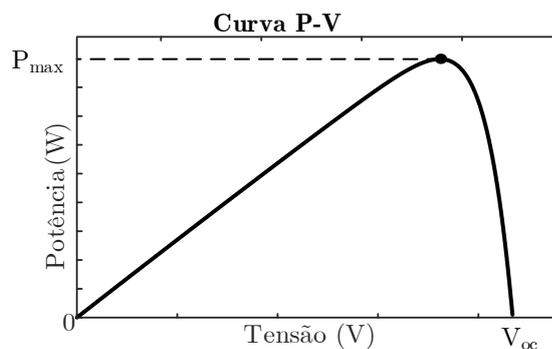
Fonte: Autora.

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, ou seja, possui resistência e tensão zero (CEPEL; CRESESB, 2014).
- Tensão de circuito aberto ( $V_{oc}$ ): medida quando não há nenhuma carga conectada nos terminais da célula, ou seja, a resistência é infinita.
- Corrente de máxima potência ( $I_{mpp}$ ): é a corrente no ponto onde é possível extrair a máxima potência da célula FV.
- Tensão de máxima potência ( $V_{mpp}$ ): é a tensão onde drena-se a máxima potência da célula fotovoltaica.

A partir dos valores de tensão e de corrente é possível calcular a potência da célula FV e traçar a curva de potência por tensão (curva P-V). Nesta curva é possível analisar com mais clareza o ponto de máxima potência, conforme a Figura 2.

Figura 2 - Curva P-V de uma célula fotovoltaica.



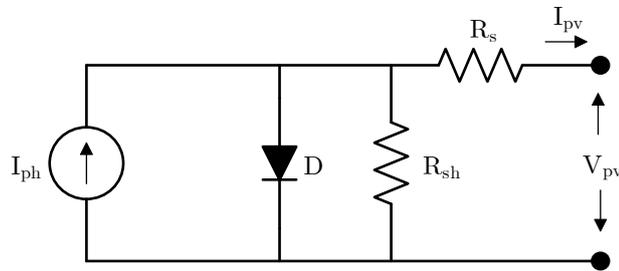
Fonte: Autora.

### 2.1.3 Modelo equivalente da célula fotovoltaica

A célula fotovoltaica pode ser representada por um circuito equivalente e equações matemáticas que permitem estudar seu comportamento.

A Figura 3 apresenta o modelo de um diodo da célula fotovoltaica, onde a fonte de corrente representa a corrente fotogerada pela célula fotovoltaica e o diodo em antiparalelo representa a junção *pn* da célula FV (LUNA, 2013). Esse modelo é o mais utilizado na literatura por ser simples e representar as características da célula fotovoltaica.

Figura 3 - Modelo equivalente de um diodo.



Fonte: Autora.

Aplicando a lei das correntes de Kirchhoff no circuito elétrico da Figura 3 tem-se a Equação 2.1.

$$I_{pv} = I_{ph} - I_0 \cdot \left[ \exp \left( q \cdot \frac{V_{pv} + I_{pv} \cdot R_s}{a \cdot k \cdot T} \right) - 1 \right] - \frac{V_{pv} + I_{pv} \cdot R_s}{R_{sh}} \quad (2.1)$$

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 ( $1,381 \times 10^{-23}$  m<sup>2</sup>kg/s<sup>2</sup>K);

$T$ : temperatura da célula (K).

Para associações de células fotovoltaicas em série ou em paralelo a Equação 2.1 modifica-se para a Equação 2.2. Dessa forma, faz-se necessário utilizar o número de

células que estão conectadas em série ( $N_s$ ), e também o número de células conectadas em paralelo ( $N_p$ ) (ALDWANE, 2014).

$$I_{pv} = N_p \cdot I_{ph} - N_p \cdot I_0 \cdot \left[ \exp \left( q \cdot \frac{V_{pv} + I_{pv} \cdot R_s}{N_s \cdot a \cdot k \cdot T} \right) - 1 \right] - \frac{1}{N_p} \cdot \frac{V_{pv} + I_{pv} \cdot R_s}{R_{sh}} \quad (2.2)$$

## 2.2 Fatores que modificam a curva característica de um arranjo fotovoltaico

A curva característica de um arranjo fotovoltaico não é fixa, sendo que fatores internos do arranjo como: a conexões dos módulos, as condições físicas das células e dos módulos alteram a curva I-V. Além disso, condições climáticas como irradiância e a temperatura também são capazes de alterar a curva.

### 2.2.1 Impacto da irradiância e da temperatura na curva I-V

Fatores intrínsecos da célula FV influenciam na curva I-V, por exemplo, a tecnologia empregada. Além disso, existem parâmetros externos que tem efeito direto na curva I-V, como a irradiância e a temperatura da célula.

A corrente de curto-circuito depende diretamente da irradiância solar, conforme a Equação 2.3. No entanto, a tensão de circuito aberto altera-se em escala logarítmica devido a corrente e a tensão terem uma relação exponencial (CEPEL; CRESESB, 2014), essa análise deve ser realizada considerando a temperatura constante.

$$I_{sc} = I_{sc}^{stc} \cdot \frac{G}{1000} \quad (2.3)$$

Onde:

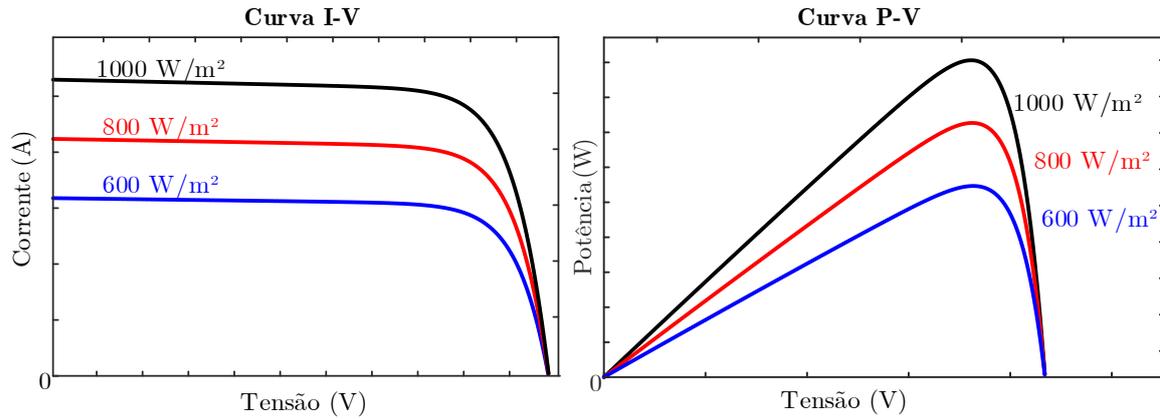
G: irradiância incidente na célula fotovoltaica ( $\text{W}/\text{m}^2$ );

$I_{sc}$ : corrente de curto-circuito para uma irradiância G (A);

$I_{sc}^{stc}$ : corrente de curto-circuito em condição padrão de teste (A).

O efeito da diminuição da irradiância na curva I-V e na curva P-V pode ser observado na Figura 4. Nota-se que há um decréscimo no ponto de máxima potência.

Figura 4 - Interferência da irradiância da curva I-V e curva P-V.



Fonte: Autora.

Em contrapartida, com o aumento da temperatura da célula fotovoltaica há uma diminuição da tensão de circuito aberto devido ao aumento da agitação das moléculas da célula (CEPEL; CRESESB, 2014). Esse efeito é representado pela Equação 2.4.

$$V_{oc} = V_{oc}^{stc} \cdot (1 - \beta \cdot \Delta T) \quad (2.4)$$

Onde:

$V_{oc}^{stc}$ : tensão de circuito aberto para condição padrão de teste (V);

$\beta$ : coeficiente de temperatura de  $V_{oc}$  (V/°C);

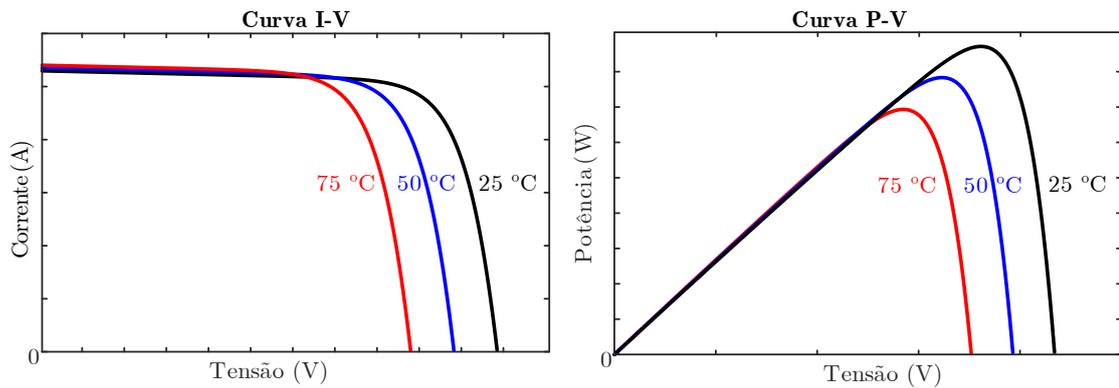
$\Delta T$ : variação de temperatura (°C).

Todavia, a corrente de curto-circuito possui um pequeno aumento, expresso pela Equação 2.5.

$$I_{sc} = I_{sc}^{stc} \cdot (1 + \alpha \cdot \Delta T) \quad (2.5)$$

Onde,  $\alpha$  representa o coeficiente de temperatura de  $I_{sc}$  (A/°C). O efeito da temperatura na curva I-V e na curva P-V podem ser vistos na Figura 5.

Figura 5 - Efeito da temperatura na curva I-V e na curva P-V.



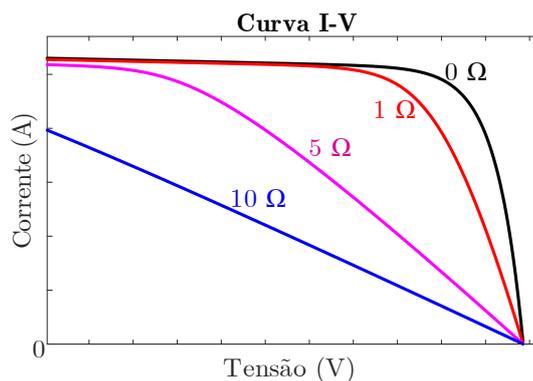
Fonte: Autora.

### 2.2.2 Impacto do $R_s$ e do $R_{sh}$ na curva I-V

A curva I-V também relaciona outros parâmetros, como a resistência série e a paralela da célula fotovoltaica.

A resistência série ( $R_s$ ) representa as perdas devido à resistência do material semicondutor que constitui a célula e aos contatos metálicos, seu valor ideal é de  $0 \Omega$  (CARVALHO, 2014). O aumento de temperatura e a diminuição irradiância em relação aos valores padrões de teste geram o aumento da resistência em série. A Figura 6 mostra a influência do aumento desse parâmetro.

Figura 6 - Efeito da resistência série na curva I-V.

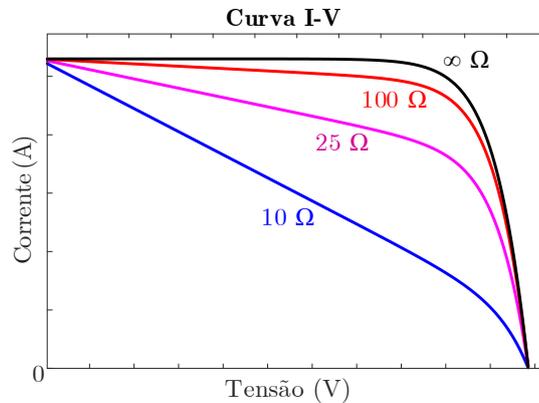


Fonte: Autora.

Além disso, a resistência paralela ( $R_{sh}$ ) representa as correntes de fugas, impurezas do material semicondutor e imperfeições da célula fotovoltaica, seu valor ideal é  $\infty \Omega$ . A diminuição da irradiância acarreta uma redução no valor da

resistência em paralelo (em relação ao valor padrão de teste). A Figura 7 representa o impacto da diminuição desse parâmetro na curva I-V.

Figura 7 - Efeito da resistência paralela na curva I-V.



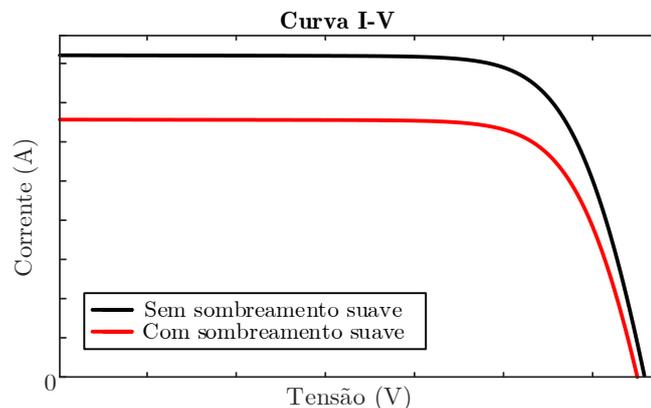
Fonte: Autora.

### 2.2.3 Efeito do sombreamento em sistemas fotovoltaicos

Sombreamentos reduzem a corrente ou a tensão em um sistema fotovoltaico e acarretam diminuição da potência produzida pelo arranjo FV. Os sombreamentos são causados por árvores, prédios, poeira, poluição, nuvens, neblinas, entre outros (SEYEDMAHMOUDIAN et al., 2013), e são classificados em três tipos: suave, severo e parcial.

Sombreamentos suaves são geralmente causados pelo acúmulo de sedimento na superfície do módulo FV. Como consequência, a irradiância que chega na célula diminui, reduzindo a corrente gerada pelo conjunto (PEDRO, 2016). A Figura 8 mostra o efeito do sombreamento suave na curva I-V.

Figura 8 - Curva I-V com sombreamento suave.

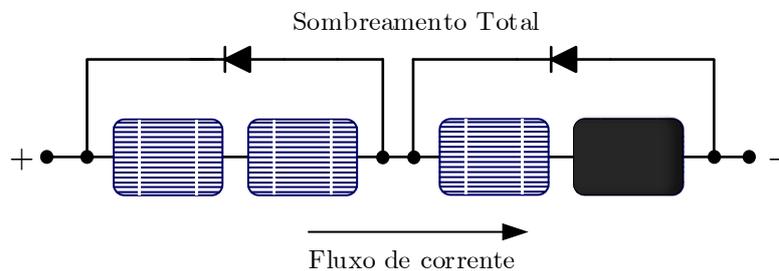


Fonte: Autora.

O sombreamento total é causado por algum obstáculo, onde toda a superfície da célula obstruída, nesse caso a célula não produz mais corrente tornando-se uma carga. A célula passa a dissipar potência criando pontos quentes (do inglês *hotspots*) que geram danos irreversíveis. Por esse motivo, módulos fotovoltaicos possuem diodos de *bypass* que formam um caminho alternativo para a corrente, protegendo a célula fotovoltaica sombreada (COUTINHO, 2017).

O diodo de *bypass* é conectado a um conjunto de células do módulo FV em antiparalelo, a Figura 9 mostra como os diodos são dispostos em um módulo fotovoltaico. Os diodos devem ser projetados para suportar a corrente de operação do módulo e a tensão das células conectadas a eles. Na operação sem sombreamento total da célula FV diodo está inversamente polarizado não interferindo na operação do módulo FV.

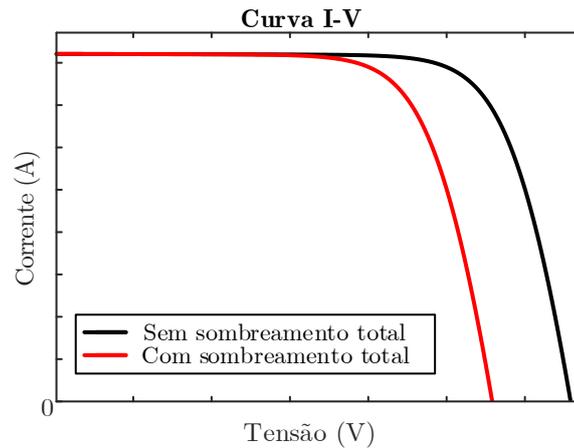
Figura 9 - Sombreamento total.



Fonte: Autora.

Em um sombreamento total de uma célula, o diodo conectado ao conjunto de células em que ocorre o sombreamento é polarizado diretamente, devido a diferença de potencial que surge entre as células FV. Conseqüentemente, este conjunto de células é desabilitado diminuindo a tensão fornecida pelo módulo. A curva I-V mostra a mudança, conforme a Figura 10.

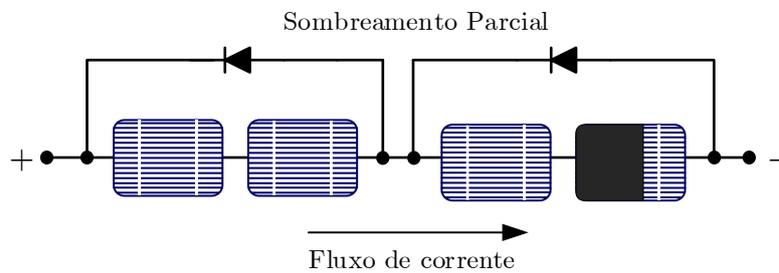
Figura 10 - Curva I-V com sombreamento total.



Fonte: Autora.

O caso de sombreamento parcial é o mais crítico entre eles. A célula parcialmente obstruída recebe apenas uma parcela da irradiância total. E como resultado, a corrente fornecida por essa célula será menor que a corrente do conjunto, conforme a Figura 11.

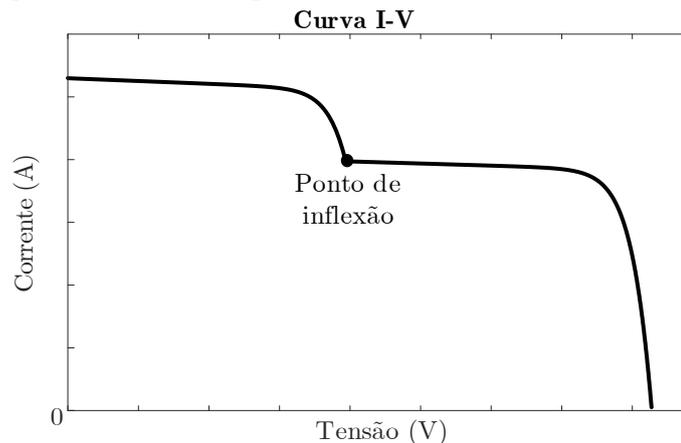
Figura 11 - Sombreamento parcial.



Fonte: Autora.

Como as células do módulo FV são ligadas em série, a corrente do módulo será limitada pela célula sombreada criando um ponto de inflexão na curva I-V, como pode ser observado na Figura 12.

Figura 12 - Curva I-V para sombreamento parcial.



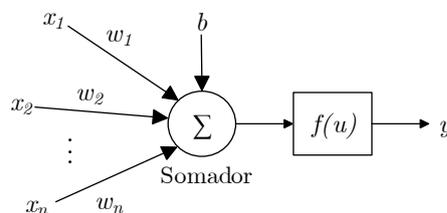
Fonte: Autora.

Para baixas tensões o diodo de *bypass* está diretamente polarizado e a corrente não é limitada pela célula que está sombreada parcialmente. Em contrapartida, para tensões acima do ponto de inflexão, o diodo está inativo e a corrente é limitada pela célula parcialmente sombreada. Um arranjo FV possui um número de pontos de inflexão proporcional ao número de sombreamento existentes (BASTIDAS RODRÍGUEZ; RAMOS PAJA; FRANCO MEJÍA, 2012).

### 2.3 Redes Neurais Artificiais

Redes neurais artificiais (RNA) são sistemas de processamento baseado no neurônio biológico e contêm a capacidade de aprendizado através de exemplos e de generalização. O primeiro modelo de neurônio artificial foi proposto por McCulloch e Pitts, suas principais partes são descritas na Figura 13 (CASTRO; ZUBEN, 2003).

Figura 13 - Rede Neural Artificial.



Fonte: Adaptado de (CASTRO; ZUBEN, 2003).

Onde  $x_n$  é a  $n$ -ésima entrada 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; JUNIOR, 2007). Redes neurais artificiais podem ser utilizadas para resolução de

vários tipos de problemas, como: classificação, categorização, aproximação, previsão e otimização (BRAGA; CARVALHO; LUDERMIR, 2007).

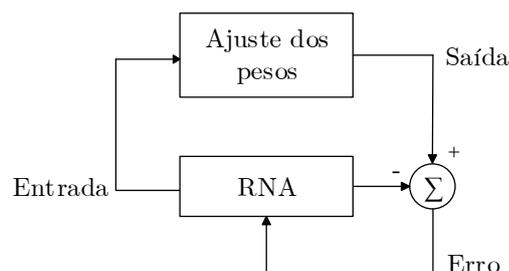
- Classificação: Atribui classes anteriormente conhecidas a um conjunto de entrada qualquer.
- Categorização: Agrupa dados de entrada em categorias ou classes equivalentes onde as categorias não são conhecidas anteriormente.
- Aproximação: O objetivo principal é assemelhar-se às funções contínuas de acordo com a entrada.
- Previsão: Com base nos valores disponíveis à rede neural, esta é capaz de estimar dados futuros.
- Otimização: Tem o objetivo de minimizar ou maximizar funções.

### 2.3.1 Treinamento da rede neural artificial

Para que uma rede neural artificial seja capaz de solucionar os problemas mencionados anteriormente esta necessita de alterar seus pesos sinápticos. O processo de alteração desses pesos denomina-se treinamento. As principais formas de treinar um rede neural são através da aprendizagem supervisionada e aprendizagem não-supervisionada.

Para o aprendizado supervisionado deve-se possuir valores de entrada e os valores de saída para determinada classe. A condição de parada é dada pela diferença entre a saída esperada e o valor real. A Figura 14 mostra o modelo deste tipo de aprendizagem.

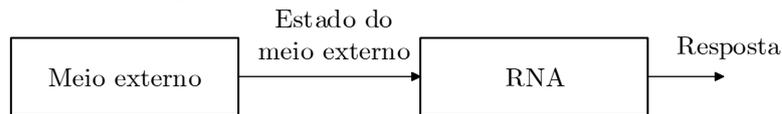
Figura 14 - Aprendizado Supervisionado.



Fonte: Adaptado de (BRAGA; CARVALHO; LUDERMIR, 2007).

No aprendizado não-supervisionado as informações de saída não são fornecidas à rede durante o treinamento e o aprendizado ocorre de forma a reconhecer e organizar padrões dos dados de entrada. O treinamento da rede neural ocorre segundo o diagrama da Figura 15.

Figura 15 - Aprendizado não-supervisionado.



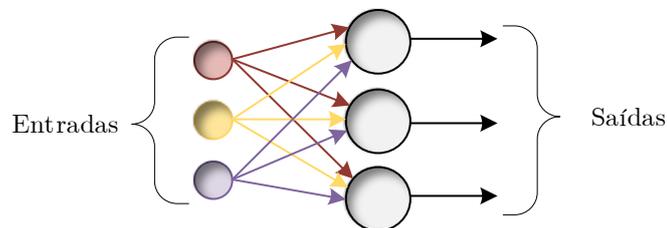
Fonte: Adaptado de (BRAGA; CARVALHO; LUDERMIR, 2007).

### 2.3.2 Arquitetura de Rede

A arquitetura da rede neural é definida de acordo com as conexões que são realizadas entre a entrada e a saída. A forma que os neurônios estão conectados difere a arquitetura dessa rede, e também o tipo de aprendizagem implementado na RNA (MONTGOMER; JUNIOR, 2007). Existem três tipos básicos de estruturas: rede direta de única camada, redes diretas de múltiplas camadas e redes com realimentação (OLIVEIRA, 2005).

A rede direta de única camada é a arquitetura de RNA mais simples, pois possui uma única camada de entrada e uma de saída. E, a propagação do sinal acontece no sentido da entrada para saída (TATIBANA; KAETSU, 2002). O exemplo dessa arquitetura é visto na Figura 16.

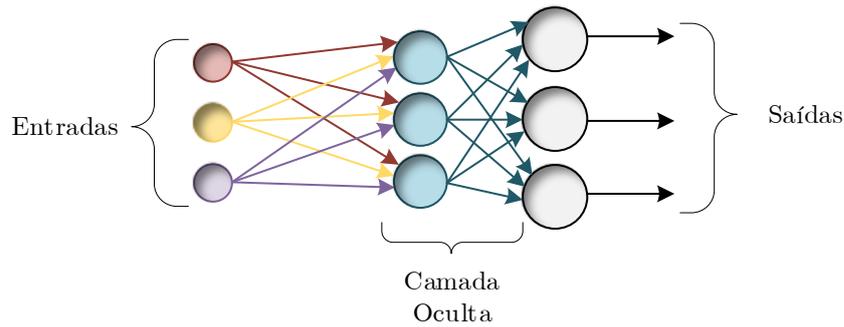
Figura 16 - Rede de única camada.



Fonte: Adaptado de (OLIVEIRA, 2005).

A rede direta de múltiplas camadas também possui o fluxo em direção à saída, entretanto, essa arquitetura possui camadas ocultas entre a entrada e a saída. Estas camadas são constituídas por neurônios e são totalmente ligadas entre si (FLECK et al., 2016). A Figura 17 mostra a arquitetura.

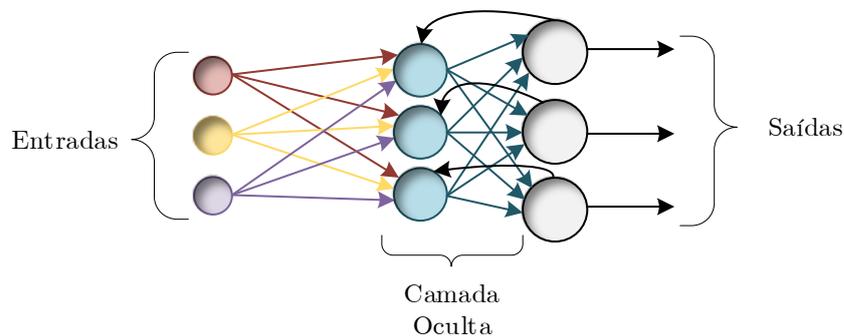
Figura 17 - Rede direta de múltiplas camadas.



Fonte: Adaptado de (OLIVEIRA, 2005).

Uma arquitetura possui uma rede com realimentação quando um sinal de saída de um neurônio alimentar um outro neurônio de uma camada anterior a ele. Este tipo de rede possui uma característica não-linear permitindo que a entrada da rede possa ser não-linear (RAUBER, 2014). A Figura 18 mostra uma rede neural artificial com realimentação.

Figura 18 - Rede com realimentação.



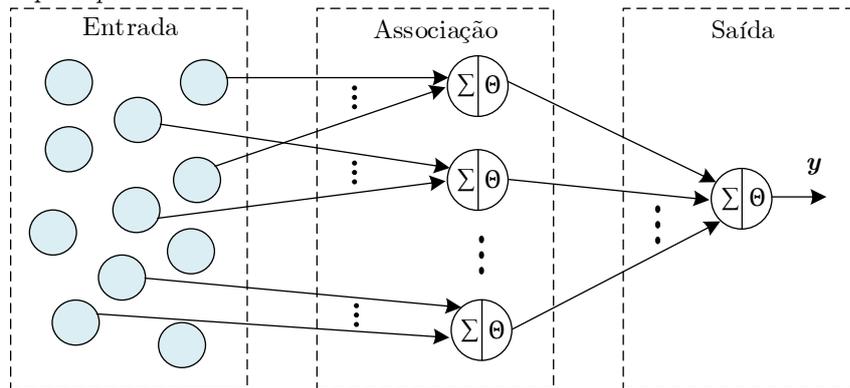
Fonte: Adaptado de (OLIVEIRA, 2005).

### 2.3.3 Principais topologias de redes neurais artificiais

As principais topologias de RNAs surgiram após a década de 80 e são baseadas no neurônio de McCulloch. As primeiras redes diretas que surgiram foram *perceptron*, *adaline* e *perceptron* de múltiplas camadas (BRAGA; CARVALHO; LUDERMIR, 2007).

A rede *perceptron* é composta por uma entrada, uma camada escondida e uma saída, como mostra a Figura 19. Este tipo de rede consegue classificar classes linearmente separáveis e sempre chega a uma solução em um tempo finito. O treinamento ocorre através de exemplos e de forma supervisionada.

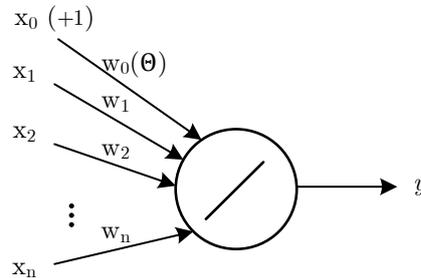
Figura 19 - Rede *perceptron* de uma única camada.



Fonte: Adaptado de (MORAIS, 2010).

Enquanto que a rede *perceptron* é utilizada como separador linear, a rede adaline é usada como aproximador linear de funções. A Figura 20 mostra um exemplo de um neurônio adaline, além disso a rede adaline utiliza funções de ativação lineares. As redes *perceptron* e adaline resolvem problemas somente com características lineares (RAUBER, 2014).

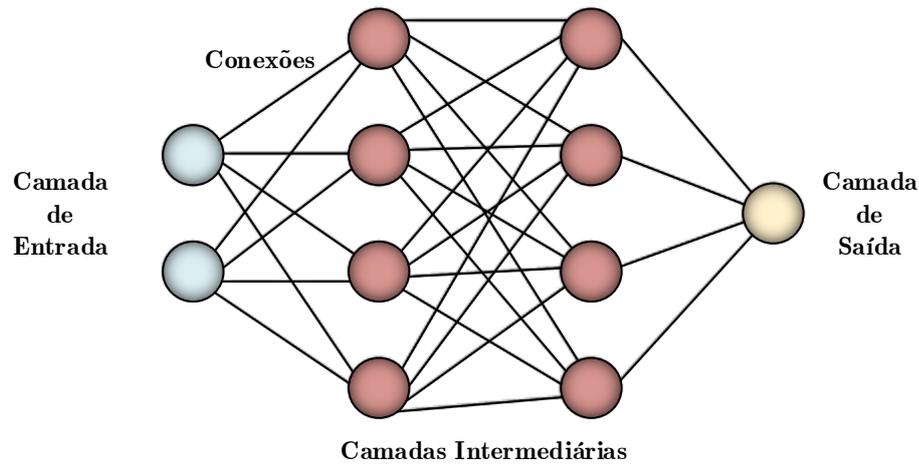
Figura 20 - Neurônio Adaline



Fonte: Adaptado de (BRAGA; CARVALHO; LUDERMIR, 2007).

A rede *perceptron* de múltiplas camadas (PMC) é formada pela entrada, uma ou duas camadas intermediárias e a saída, a Figura 21 mostra uma rede PMC com duas camadas ocultas. Além disso, os neurônios devem possuir funções de ativação sigmoidais (BRAGA; CARVALHO; LUDERMIR, 2007).

Figura 21 - Rede PMC com duas camadas ocultas.



Fonte: Adaptado de (MORAIS, 2010).

A PMC que possui uma camada oculta consegue aproximar qualquer função contínua. Todavia, se uma rede PMC possuir duas camadas intermediárias pode-se aproximar qualquer função (FLECK et al., 2016).

O aprendizado supervisionado é aplicado em rede *perceptron* de múltiplas camadas. A literatura aponta dois tipos principais de algoritmos de treinamento: o algoritmo *back-propagation* e o algoritmo *levenberg-marquardt* (FLECK et al., 2016).

O algoritmo *back-propagation* é capaz de calcular o erro das camadas escondidas através da observação que os pesos sinápticos dessas camadas causam na saída. Entretanto, o algoritmo *levenberg-marquardt* utiliza a otimização numérica para estimar o ajuste dos pesos sinápticos (BRAGA; CARVALHO; LUDERMIR, 2007).

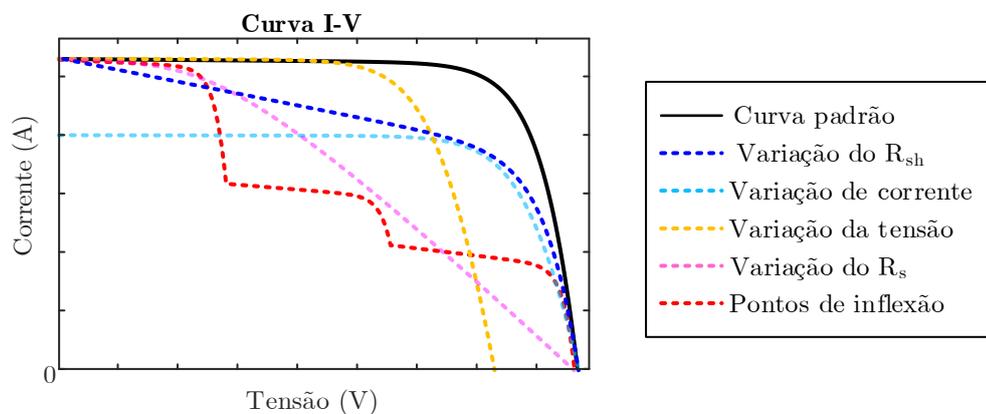
### 3 METODOLOGIA

Nesta seção é apresentada a metodologia de pesquisa utilizada neste trabalho. Apresenta-se os principais defeitos que podem ocorrer em um sistema fotovoltaico no lado de corrente contínua. Além disso, é exposto um método para detectar os padrões da curva característica de um arranjo FV através de uma rede neural artificial do tipo *perceptron* de múltiplas camadas.

#### 3.1 Defeitos característicos da curva I-V

A curva I-V de arranjos fotovoltaicos pode ser utilizada como um instrumento de verificação e avaliação dos defeitos que células ou módulos podem apresentar. A Figura 22 mostra os principais pontos associados a cada defeito em relação à condição normal de operação (TRETER, 2018).

Figura 22 - Defeitos característicos da curva I-V.



Fonte: Adaptado de (NBR 16274, 2014).

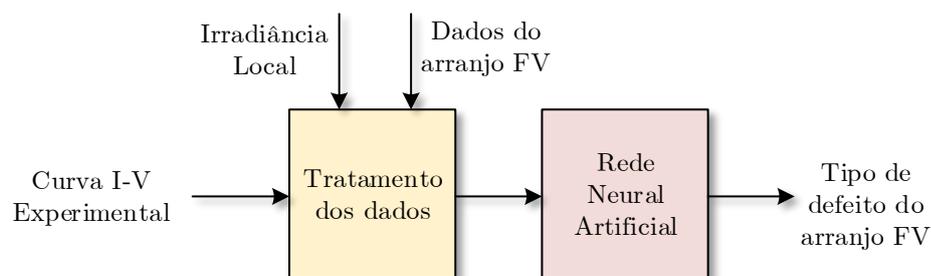
- **Varição do  $R_{sh}$** : diminuição da resistência paralela é causado por danos na célula FV ou sombreamentos parciais. Isso causa um aumento na corrente de fuga do módulo (NBR 16274, 2014).
- **Varição de corrente**: diminuição da corrente de curto-circuito de um módulo fotovoltaico é causado por acúmulos de sedimentos na superfície do mesmo, degradação das células FV ou problemas de calibração dos sensor de corrente.

- Variação de tensão: redução da tensão de circuito aberto é ocasionado por sombreamentos totais das células FV, curto-circuito no diodo de *bypass* ou aumento da temperatura, sendo que o último também acarretará em um pequeno aumento na corrente de curto-circuito.
- Variação do  $R_s$ : aumento da resistência série do arranjo é ocasionado por danos na fiação que compõe o sistema, degradação do módulo FV ou problemas da fabricação da célula (NBR 16274, 2014).
- Pontos de inflexão: o surgimento de tensões de inflexão na curva I-V é causado por sombreamentos parciais, danos nas células FV ou a operação indevida do diodo de *bypass*.

### 3.2 Sistema para detecção de defeitos em arranjos fotovoltaicos

O sistema proposto é capaz de identificar imperfeições em um módulo FV através de redes neurais artificiais. Este sistema é composto por uma rede neural do tipo classificação (responsável por detectar os tipos de defeitos) e por um algoritmo de tratamento dos dados de entrada. O sistema é representado pela Figura 23.

Figura 23 - Sistema de detecção de defeitos.



Fonte: Autora.

A entrada do sistema é composta pela irradiância submetida ao arranjo, a curva I-V e os parâmetros do arranjo FV, composto pelos dados provenientes da folha do fabricante e a quantidade de módulos em série e em paralelo.

Na etapa de tratamentos dos dados coleta-se os principais pontos da curva I-V. Os dados tratados são transferidos para a RNA, observando-se que a rede neural já deve estar treinada, e a saída do sistema é o defeitos 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. Considera-se também as condições normais de operação do arranjo fotovoltaico.

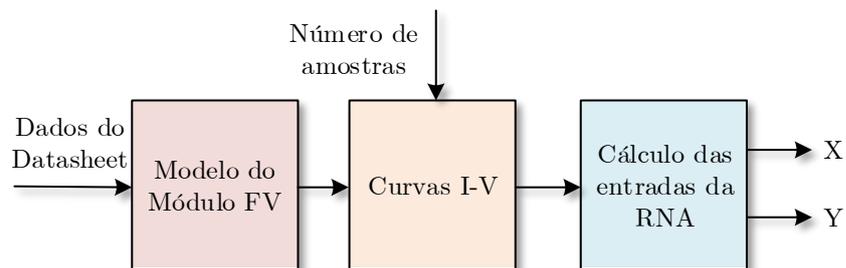
Para o funcionamento completo do sistema necessita-se de três etapas: criação da rede neural, banco de dados e tratamento dos dados.

Deve-se criar uma rede neural do tipo *perceptron* de múltiplas camadas e treiná-la. Além disso, para o treinamento correto da RNA deve-se criar um banco de dados capaz de simular as condições de defeitos e em que o arranjo opera normalmente. E por último, com a rede neural já treinada, é realizada a etapa de tratamento de dados.

### 3.3 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, o número de módulos em série e em paralelo, o número de amostras desejado para o treinamento e as condições de defeitos a serem simuladas. A Figura 24 mostra o esquema de funcionamento geral do banco de dados.

Figura 24 - Banco de dados para treinamento da RNA.

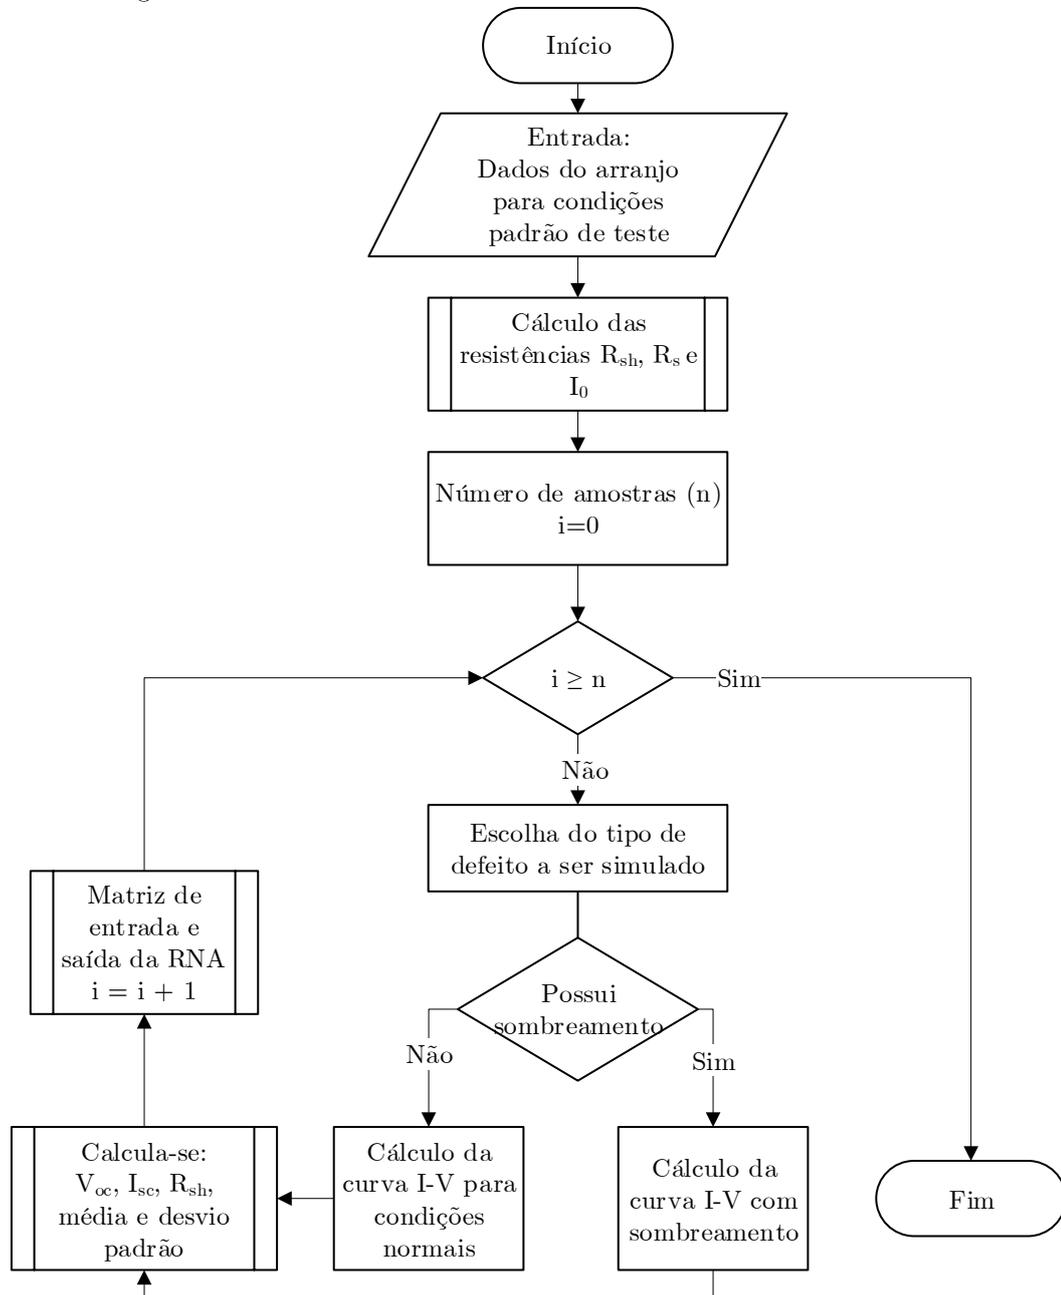


Fonte: Autora.

Para o treinamento da RNA necessita-se simular as condições próximas às condições reais dos defeitos. Para isso, foi gerado um algoritmo capaz de simular um arranjo fotovoltaico para uma condição desejada, traçando a curva I-V, e após

selecionando os principais pontos para o treinamento da RNA. A Figura 25 mostra o fluxograma com a lógica do algoritmo para gerar o banco de dados.

Figura 25 - Fluxograma do banco de dados.



Fonte: Autora.

Inicialmente, escolhe-se o módulo fotovoltaico a ser utilizado, os parâmetros utilizados como entrada  $P_{max}$ ,  $V_{mpp}$ ,  $I_{mpp}$ ,  $V_{oc}$ ,  $I_{sc}$ ,  $\alpha$  e  $\beta$  que estão disponíveis no *datasheet* do módulo fotovoltaico para condição de  $1000 \text{ W/m}^2$  e  $25^\circ\text{C}$ .

Escolhe-se também o número de amostras e o tipo de imperfeição do arranjo a ser simulado. A Tabela 1 mostra os defeitos simulados.

Tabela 1 - Tipos de defeitos.

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

Fonte: Autora.

Os valores designados às variáveis de irradiância, de temperatura, do número de módulos em série, e do número de módulos em paralelo são dados de acordo com a Tabela 2.

Tabela 2 - Intervalo dos valores atribuídos aleatoriamente.

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

Fonte: Autora.

Para a simulação da curva I-V necessita-se de calcular as resistências  $R_{sh}$  e  $R_s$ . Além disso, utilizam-se dois métodos para calcular a curva I-V: condições de irradiância uniforme no módulo FV e condições de sombreamento parcial.

Em seguida, constroem-se as matrizes X e Y que são utilizadas para o treinamento da rede neural. As etapas do cálculo das resistências, curva I-V e das matrizes de saída serão descritos a seguir.

### 3.3.1 Cálculo das Resistências em série e em paralelo

As resistências  $R_{sh}$  e  $R_s$  para as condições padrões de teste e a corrente  $I_0$  são estimadas através do método do Newton-Raphson, dado pela Equação 3.1 (FARIVAR; ASAEI, 2010).

$$I_{k+1} = I_k - \frac{G(I)}{G'(I)} \quad (3.1)$$

A função  $G(I)$  é representada pela Equação 3.2 e  $G'(I)$  é a derivada de  $G(I)$ .

$$G(I) = I_{ph} - I_0 \cdot \left[ \exp\left(q \cdot \frac{V_{pv} + I_{pv} \cdot R_s}{a \cdot k \cdot T}\right) - 1 \right] - \frac{V_{pv} + I_{pv} \cdot R_s}{R_{sh}} - I_{pv} \quad (3.2)$$

Inicialmente, define-se  $R_s = 0$ , onde  $R_{sh}$  é dado pela Equação 3.3 e  $I_0$  é dada pela Equação 3.4.

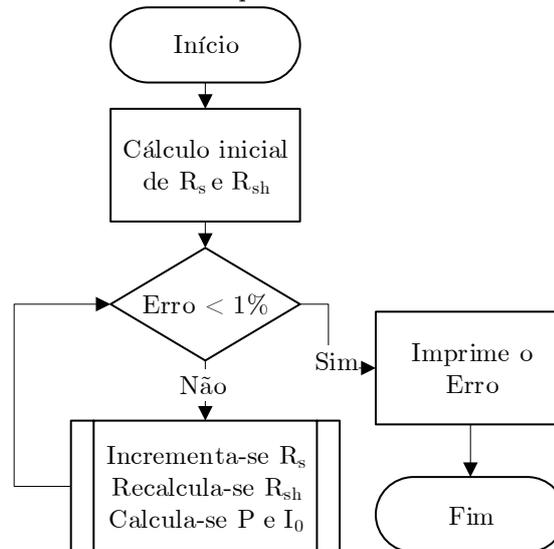
$$R_{sh} = \frac{V_{mpp} + I_{mpp} \cdot R_s}{I_{sc} - I_{mpp} - I_0 \cdot \left[ \exp\left(q \cdot \frac{V_{pv} + I_{pv} \cdot R_s}{a \cdot N \cdot k \cdot T}\right) - 1 \right]} \quad (3.3)$$

$$I_0 = \frac{I_{sc} - \frac{V_{oc}}{R_{sh}}}{\exp\left(q \cdot \frac{V_{pv} + I_{pv} \cdot R_s}{a \cdot N \cdot k \cdot T}\right) - 1} \quad (3.4)$$

O fluxograma da Figura 26 mostra o método utilizado para o cálculo das resistências e da corrente de saturação reversa (CORNELIUS et al., 2018). A potência de saída é calculada pela Equação 3.5.

$$P = I_{pv} \cdot V_{pv} \quad (3.5)$$

Figura 26 - Fluxograma do método do Newton-Raphson.



Fonte: Autora.

### 3.3.2 Curva I-V para condições de irradiância regular

A Equação 2.5 permite obter a curva I-V para diferentes circunstâncias de temperatura e irradiância, e também, para diversas quantidades de módulos em série ou em paralelo.

O fluxograma a Figura 26 mostra o cálculo das resistências para condições padrão de teste. Porém, esses parâmetros modificam-se com a variação de temperatura e irradiância. De acordo com (SOTO, 2004), a resistência paralela varia inversamente com a irradiância, conforme a Equação 3.6.

$$R_{sh} = R_{sh}^{stc} \cdot \frac{1000}{G} \quad (3.6)$$

Onde  $R_{sh}^{stc}$  é a resistência paralela para 1000 W/m<sup>2</sup> e 25 °C e G a irradiância que a célula está submetida. Todavia, a resistência série possui uma variação com a irradiância e a temperatura (IBRAHIM; ANANI, 2017), conforme a Equação 3.7.

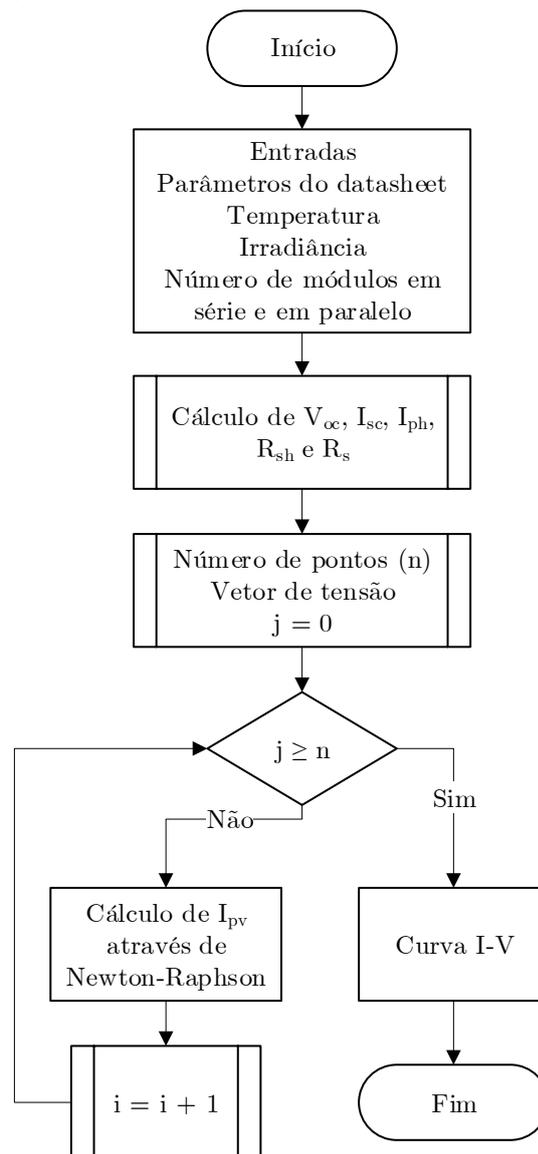
$$R_s = \frac{T}{298} \cdot \left[ 1 - 0,217 \cdot \ln \left( \frac{G}{1000} \right) \right] \cdot R_s^{stc} \quad (3.7)$$

$R_s^{stc}$  representa resistência série para 1000 W/m<sup>2</sup> e 25 °C. Além disso, como consequência da alteração das resistências a corrente fotogerada do módulo FV altera-se de acordo com a Equação 3.8.

$$I_{ph} = \left( 1 + \frac{R_s}{R_{sh}} \right) \cdot I_{sc} \quad (3.8)$$

Portanto, através o fluxograma da Figura 27 é possível traçar a curva I-V matematicamente.

Figura 27 - Cálculo da curva I-V.

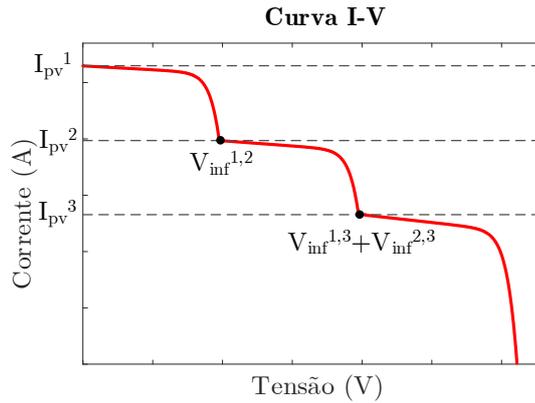


Fonte: Autora.

### 3.3.3 Curva I-V para condições de sombreamento parcial

A modelagem matemática para a curva I-V em condições de sombreamento parcial é baseada nas tensões de inflexão. Em que, a corrente de um módulo parcialmente sombreado gera uma tensão de inflexão ( $V_{inf}$ ) na curva I-V do arranjo FV, como visto na Figura 28.

Figura 28 - Tensão de inflexão em um arranjo FV.



Fonte: Autora.

A tensão de inflexão para uma um arranjo com n módulos em série é dada pela Equação 3.9, de acordo com (BASTIDAS RODRÍGUEZ; RAMOS PAJA; FRANCO MEJÍA, 2012).

$$V_{inf}^{n,n+1} = -a \cdot N \cdot V_t \cdot \text{lambert}_W \left[ 0, I_0^n \cdot A^n \cdot \exp(B^n) \right] \dots \quad (3.9)$$

$$\dots - I_{ph}^n \cdot (R_s^n + R_{sh}^n) + R_{sh}^n \cdot (I_{ph}^n + I_0^n)$$

A função Lambert é utilizada para tornar a relação de tensão e corrente explícita, segundo (BASTIDAS RODRÍGUEZ; RAMOS PAJA; FRANCO MEJÍA, 2012). As variáveis A e B são dadas pelas Equações 3.10 a 3.15.

$$A^n = \frac{R_{sh}^n}{a \cdot N \cdot V_t} \quad (3.10)$$

$$B^n = A^n \cdot (I_{pv}^n + I_0^n - I_{ph}^n) \quad (3.11)$$

$$I_{pv}^n = \left( 1 + \frac{R_s^n}{R_{sh}^n} \right) \cdot I_{sc}^n \quad (3.12)$$

$$R_s^n = \frac{T}{298} \cdot \left[ 1 - 0,217 \cdot \ln \left( \frac{G}{1000} \right)^n \right] \cdot R_s^{stc} \quad (3.13)$$

$$R_{sh}^n = R_{sh} \cdot \frac{1000}{G^n} \quad (3.14)$$

$$I_0^n = \frac{I_{ph}^n - V_{pv}^n / R_{sh}^n}{\exp(V_{pv}^n / a \cdot N \cdot V_T) - 1} \quad (3.15)$$

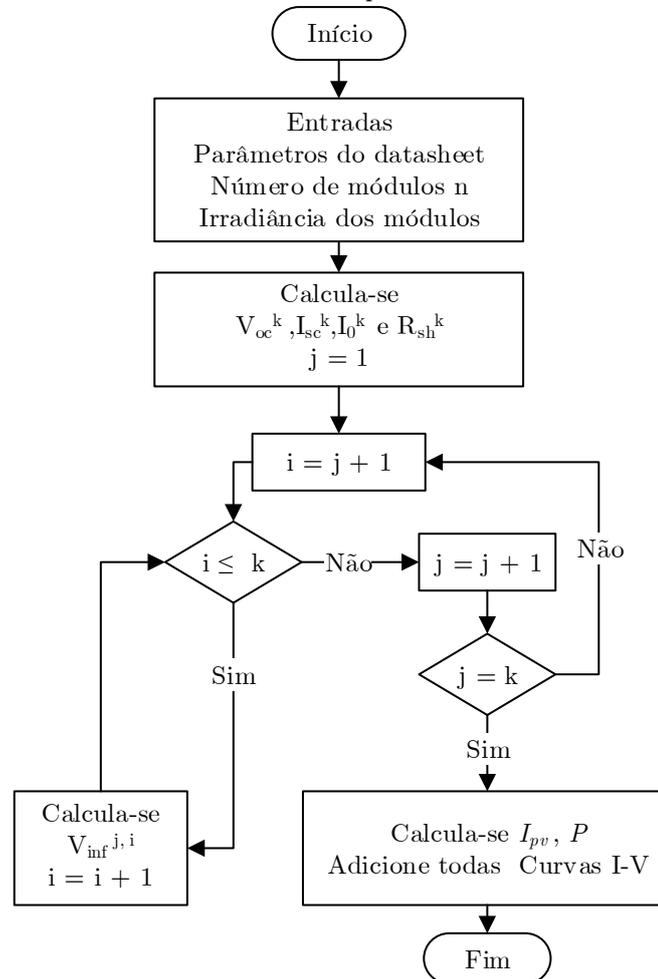
A tensão térmica  $V_T$  é dada pela Equação 3.16, e a corrente de saída é descrita pela Equação 3.17.

$$V_T = \frac{k \cdot T}{q} \quad (3.16)$$

$$I_{ph}^n = \frac{1000}{G^n} \cdot [I_{ph}^{n-1} + n(T - 298)] \quad (3.17)$$

A curva I-V para situações de sombreamento parcial pode ser traçada pelo fluxograma da Figura 29, segundo (MAIA et al., 2019).

Figura 29 - Cálculo da curva I-V com sombreamento parcial.



Fonte: Autora.

### 3.3.4 Matrizes de Saída do Banco de Dados

Para o treinamento da RNA é necessário separar os principais pontos da curva I-V e colocá-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 possui seis colunas e a quantidade de linhas da matriz depende da quantidade de amostras geradas. O formato da matriz e seus elementos que a compõem podem ser observados na Equação 3.18.

$$X = \begin{pmatrix} G_1 & V_{oc,1} & I_{sc,1} & R_{sh,1} & M_1 & D_1 \\ \cdot & \cdot & & & & \cdot \\ \cdot & & \cdot & & & \cdot \\ \cdot & & & \cdot & & \cdot \\ G_m & V_{oc,m} & I_{sc,m} & R_{sh,m} & M_m & D_m \end{pmatrix}^T \quad (3.18)$$

Cada elemento da matriz X é descrito na Tabela 3.

Tabela 3 - Elementos da matriz X.

Símbolo	Descrição
G	Irradiância que incide no arranjo FV
V <sub>oc</sub>	Tensão de circuito aberto do arranjo
I <sub>sc</sub>	Corrente de curto-circuito do arranjo
R <sub>sh</sub>	Resistência em paralelo do arranjo
M	Média da corrente de saída
D	Desvio padrão da corrente de saída

Fonte: Autora.

Para que a RNA aprenda de forma mais rápida e não se confunda é preciso realizar a normalização dos dados da matriz de entrada. Através da Equação 3.19 normalizam-se os dados no intervalo de 0 a 1 (EDMAR, 1999).

$$r = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3.19)$$

Em que:

r: Valor normalizado;

x: Valor a ser normalizado;

x<sub>min</sub>: menor valor do intervalo que irá ser normalizado;

x<sub>max</sub>: maior valor do intervalo a ser normalizado.

De forma análoga, a quantidade de linhas da matriz de saída é igual ao número de amostras, porém a matriz  $Y$  possui seis colunas, conforme mostrado na Equação 3.20. Os valores de saída assumidos nessa matriz são dados pela Tabela 4.

$$Y = \begin{pmatrix} y_{11} & y_{12} & y_{13} & y_{14} & y_{15} & y_{16} \\ \bullet & & & & & \bullet \\ \bullet & & \bullet & & & \bullet \\ \bullet & & & & & \bullet \\ y_{m1} & y_{m2} & y_{m3} & y_{m4} & y_{m5} & y_{m6} \end{pmatrix}^T \quad (3.20)$$

Tabela 4 - Possibilidades de saída da rede neural.

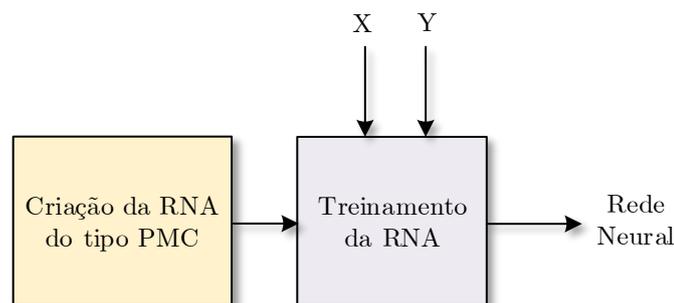
Tipo de defeito	Saída prevista da RNA (Y)
Condições normais de operação	1 0 0 0 0
Variação do $R_{sh}$	0 1 0 0 0
Pontos de inflexão	0 0 1 0 0
Variação do $I_{sc}$	0 0 0 1 0
Variação do $V_{oc}$	0 0 0 0 1
Variação do $R_s$	0 0 0 0 1

Fonte: Autora.

### 3.4 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. No treinamento da RNA utilizam-se as matrizes  $X$  e  $Y$  provenientes do banco de dados. A Figura 30 demonstra esse processo.

Figura 30 - Constituição da Rede Neural Artificial.



Fonte: Autora.

Para a criação da rede neural utilizou-se o software Matlab<sup>®</sup> com objetivo de resolver problemas de classificação (MATSUNAGA, 2012).

O primeiro passo é carregar as variáveis de entrada e saída desejadas da rede neural. Para isso, utilizou-se a função `load(nome_do_arquivo.mat)`.

A rede neural criada é do tipo *perceptron* multicamadas, e tem como característica camadas totalmente conectadas do tipo alimentação direta e um número variável de camadas ocultas.

Para criação desse tipo de rede utilizou-se o comando *feedforwardnet*, definiu-se o número de camadas ocultas desejado para a rede neural, o número de neurônios em cada camada, a função de ativação, o algoritmo de aprendizagem e os parâmetros para treinamento.

A Tabela 5 mostra as funções de ativação disponíveis (MATSUNAGA, 2012).

Tabela 5 - Funções de ativação.

Função	Descrição
<i>purelin</i>	Linear
<i>tansig</i>	Tangente hiperbólica
<i>logsig</i>	Sigmoide
<i>satlin</i>	Linear com saturação

Fonte: Autora.

Já a Tabela 6 apresenta as possibilidades de algoritmos de aprendizados que podem ser utilizados.

Tabela 6 - Algoritmos de aprendizagem.

Algoritmo	Descrição
<i>trainlm</i>	<i>Levenberg-marquardt</i>
<i>traingd</i>	Gradiente decrescente
<i>traingdm</i>	Gradiente decrescente com momento
<i>traingda</i>	Gradiente decrescente com taxa adaptativa
<i>traingdx</i>	Gradiente decrescente com momento e taxa adaptativa

Fonte: Autora.

E a Tabela 7 mostra os parâmetros para o treinamento disponíveis.

Tabela 7 - Parâmetros para treinamento.

Parâmetro	Descrição
<i>net.trainParam.epochs</i>	Número máximo de épocas
<i>net.trainParam.goal</i>	Erro
<i>net.trainParam.lr</i>	Taxa de aprendizado
<i>net.trainParam.time</i>	Tempo máximo de treinamento
<i>net.divideParam.trainRatio</i>	Porcentagem de amostras para treinamento
<i>net.divideParam.valRatio</i>	Porcentagem de amostras para validação
<i>net.divideParam.testRatio</i>	Porcentagem de amostras para teste

Fonte: Autora.

A função *train* é utilizada para treinar a rede neural criada. O treinamento é realizado através das entradas disponíveis e da saída desejada, das condições de paradas são o erro, do número máximo de épocas ou do tempo máximo de treinamento. Além disso, a rede treinada é salva na função *net* e pode ser visualizada pelo comando *view*.

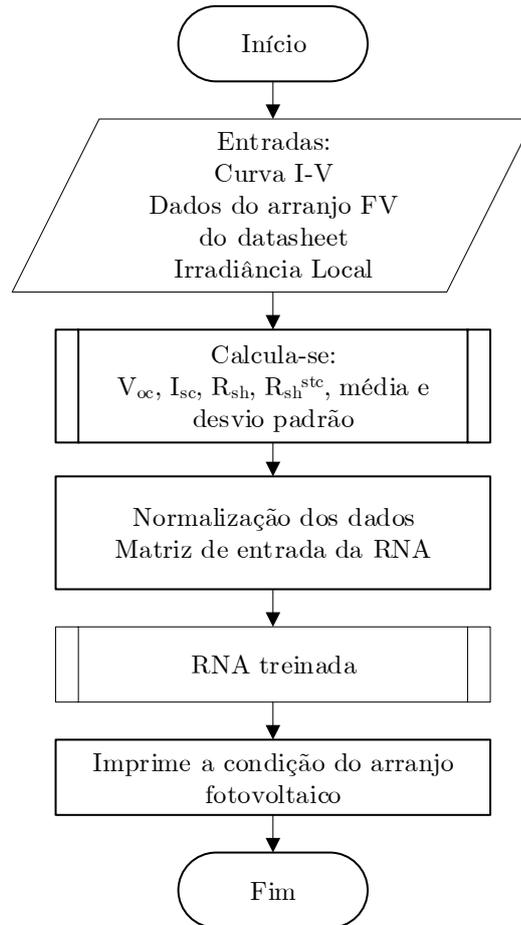
### 3.5 Tratamento dos dados

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

Este 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 Equação 3.18, contudo possui somente uma linha. O fluxograma da Figura 31 representa a lógica do algoritmo utilizado para tratar os dados da curva I-V.

Figura 31 - Etapa de tratamento dos dados.



Fonte: Autora.

Para cada condição da Tabela 4 que o arranjo fotovoltaico possa apresentar é impresso um relatório final dos possíveis defeitos ou falhas de acordo com (NBR 16274, 2014).

Se a saída da RNA for “1 0 0 0 0 0” o arranjo FV não apresenta nenhum defeitos e é impresso a mensagem: “*O arranjo está em condições normais de operação.*”.

Em contrapartida, para a saída “0 1 0 0 0 0” é impresso a mensagem:

“Defeito detectado: Diminuição da resistência paralela

----- Causas prováveis -----

- Defeito nas células fotovoltaicas ou em suas interconexões;
- Divergência entre as correntes de curto-circuito dos módulos.”

Para a saída da RNA “0 0 1 0 0 0” é impresso a mensagem:

“Defeito detectado: Pontos de inflexão na curva

----- Causas prováveis -----

- Sombreamento parcial de célula(s) ou módulo(s);
- Células ou módulos danificados;
- Diodo de *bypass* em curto-circuito.”

Para a saída da RNA “0 0 0 1 0 0” é impresso a mensagem:

“Defeito detectado: Diminuição da corrente de curto-circuito

----- Causas prováveis -----

- O arranjo está sujo ou obstruído;
- Os módulos estão degradados;
- Dados dos módulos estão incorretos;
- Número de módulos em paralelo está incorreto;
- Problemas de calibração ou de medição da corrente.”

Para a saída da RNA “0 0 0 0 1 0” é impresso a mensagem:

“Defeito detectado: Diminuição da tensão de circuito aberto

----- Causas prováveis -----

- Sombreamento total de célula(s) ou módulo(s);
- Diodo de *bypass* invertido ou operando incorretamente.”

Para a saída da RNA “0 0 0 0 0 1” é impresso a mensagem:

“Defeito detectado: Aumento da resistência em série

----- Causas prováveis -----

- Danos ou falhas na fiação;
- Falha nas conexões dos módulos fotovoltaicos.

\*\*\*Recomenda-se verificar a qualidade dos cabos utilizados nas fiações ou conexões do arranjo fotovoltaicos\*\*\*”

## 4 RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados de simulação obtidos de acordo com a metodologia exposta utilizando o software Matlab®. Os resultados são decorrentes do treinamento da rede neural artificial do tipo *perceptron* multicamadas e do algoritmo de tratamento de dados.

### 4.1 Treinamento da rede neural do tipo *perceptron* de múltiplas camadas

O treinamento da RNA realiza-se a partir do banco de dados criado para simular as condições reais de funcionamento dos módulos fotovoltaicos. O módulo *Kyocera* KD210GX-LP compõe o arranjo utilizado para gerar as amostras. Os parâmetros do módulo são apresentados na Tabela 8.

Tabela 8 - Parâmetros do módulo KD210GX-LP.

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

Fonte: Autora.

Para o banco de dados foram geradas 750 amostras com valores de irradiância, de temperatura, do número de módulos em série, e do número de módulos em paralelo aleatórios determinados pelos intervalos da Tabela 2. E, foram geradas 125 amostras para cada uma das seis condições apresentadas na Tabela 1. As amostras foram armazenadas nas matrizes X e Y.

A rede neural do tipo *perceptron* multicamadas foi configurada utilizando os critérios da Tabela 9. Também, foram utilizados setenta por cento das amostras (525 amostras) para o treinamento da RNA e vinte por cento das amostras (150 amostras)

para os testes e dez por cento das amostras (75 amostras) para validação. Além disso, entre as funções de ativação descritas na Tabela 5, a função utilizada na RNA foi a tangente hiperbólica, por melhor se adaptar as características da rede.

Tabela 9 - Parâmetros de treinamento da RNA.

Descrição	Valor
Taxa de aprendizado	0,01
Momentum	0,9
Critério de parada	$1 \times 10^{-6}$
Limite de épocas	3000

Fonte: Autora

O número de camadas escondidas e o número de neurônios são definidos empiricamente. Todavia, para avaliar a melhor configuração de RNA utilizou-se os critérios do erro quadrático médio (EQM), da taxa de acertos no treinamento e no teste. Os resultados apresentados são apresentados na Tabela 10.

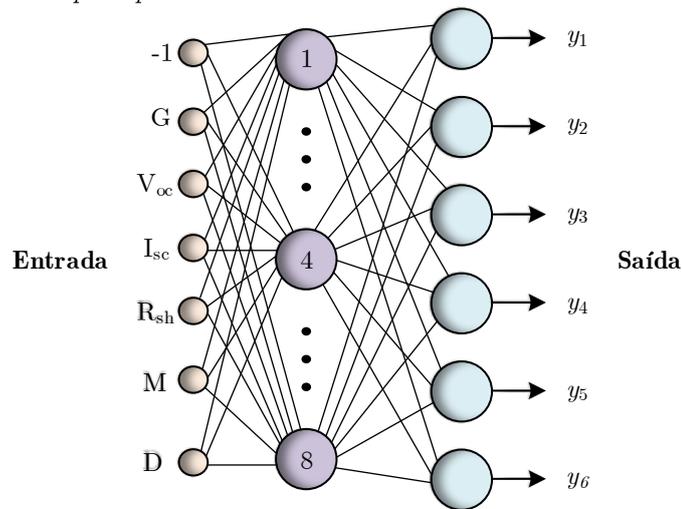
Tabela 10 - EQM e taxas de acertos para diferentes topologias.

Nº de neurônios	Erro Quadrático Médio (EQM)	Taxa de acertos treinamento (%)	Taxa de acertos teste (%)
5	$5,1 \times 10^{-4}$	99,73	98,67
6	$2,7 \times 10^{-4}$	99,82	98,6
7	$2,3 \times 10^{-4}$	99,86	98,99
8	$1,9 \times 10^{-4}$	99,87	98,74
9	$2,22 \times 10^{-4}$	99,89	98,79
10	$4,44 \times 10^{-4}$	99,76	98,93

Fonte: Autora.

De acordo com os resultados apresentados na Tabela 10, conclui-se que a rede que possui um melhor desempenho é a que possui oito neurônios em sua camada oculta. Então, a topologia completa da rede PMC a ser utilizada é apresentada na Figura 32.

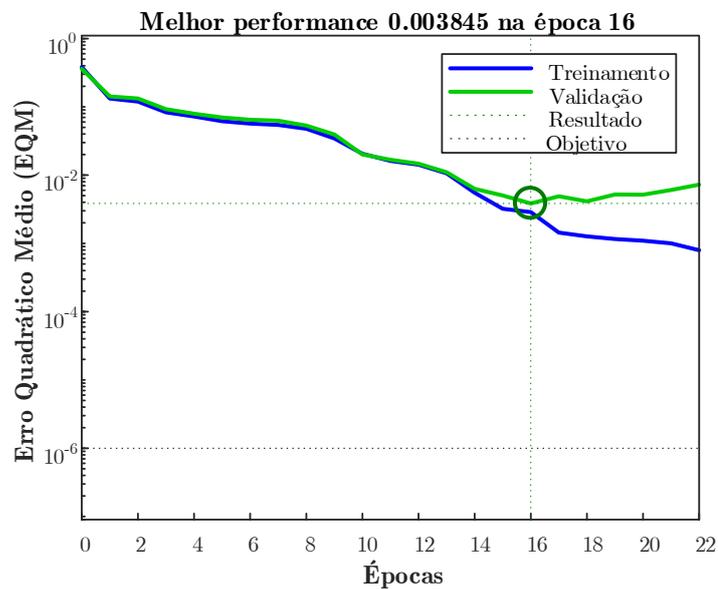
Figura 32 - Topologia RNA *perceptron* multicamadas utilizada.



Fonte: Autora.

Para a etapa do treinamento da RNA utilizou-se os dados da Tabela 9 e o algoritmo de treinamento *levenberg-marquardt*. A performance do erro durante o treinamento é vista na Figura 33.

Figura 33 - Performance do erro durante o treinamento da RNA.



Fonte: Autora.

Além disso, na etapa de teste da RNA utilizou-se 150 amostras para gerar a matriz de confusão, dada pela Figura 34. A matriz de confusão é utilizada para mostrar resultados de redes neurais do tipo classificação, onde as colunas representam as saídas da RNA.

Figura 34 - Matriz de confusão.

**Matriz de Confusão**

Classe de Saída	1	25 16.7%	0 0.0%	0 0.0%	0 0.0%	1 0.7%	0 0.0%	96.2% 3.8%
	2	0 0.0%	25 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	25 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	25 16.7%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	24 16.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	25 16.7%	100% 0.0%
			100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	96.0% 4.0%	100% 0.0%
		1	2	3	4	5	6	
		Classe Alvo						

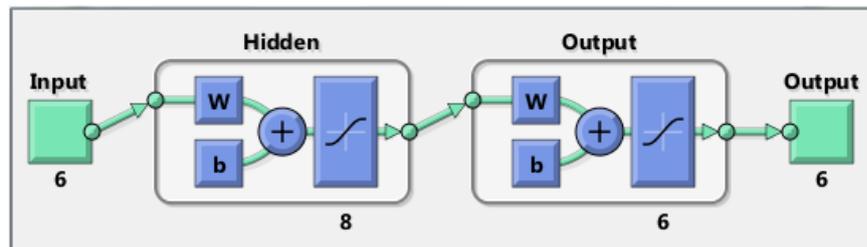
Fonte: Autora.

A matriz de confusão expõe quantas amostras foram classificadas corretamente pela rede neural após o seu treinamento. Também, observa-se que apenas na quinta coluna (que representa o defeito “Variação do  $V_{oc}$ ”) a RNA classificou um defeito incorretamente. Além disso, a matriz de confusão mostra a acurácia da rede neural treinada, que nesse caso foi de 99,3%.

## 4.2 Algoritmo de tratamento de dados

O algoritmo de tratamento de dados utiliza a RNA anteriormente treinada, conforme a Figura 35, para identificar se há algum defeito no arranjo FV a partir da curva I-V.

Figura 35 - Rede *Perceptron* de Multicamadas criada e treinada no Matlab.



Fonte: Autora.

A entrada do algoritmo de tratamento de dados é a curva I-V, os dados do módulo FV para condições padrões de teste, número de módulos em série, e número de módulos em paralelo.

Para verificar a capacidade de generalização da RNA treinada usou-se um módulo diferente para compor o arranjo. O módulo utilizado para adquirir os resultados foi o *Kyocera* KC40T, e seus parâmetros retirados da folha de dados fornecida pelo fabricante são disponibilizados na Tabela 11.

Tabela 11 - Dados do módulo KC40T.

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

Fonte: Autora.

Os defeitos testados são: condições normais de operação, variação da resistência em paralelo, pontos de inflexão na curva, variação da corrente de curto-circuito, variação da tensão de circuito aberto, e variação da resistência em série. Para cada condição verificada é emitido um relatório sobre os possíveis defeitos do arranjo FV de acordo com (NBR 16274, 2014).

Além disso, para cada defeito são simulados diferentes configurações do arranjo FV com o intuito de verificar se a RNA consegue tornar-se genérica. Os valores de irradiância ( $G$ ), número de módulos em série ( $n$ ) e número de módulos em paralelo ( $m$ ) são dispostos de forma aleatória.

#### 4.2.1 Condições normais de operação

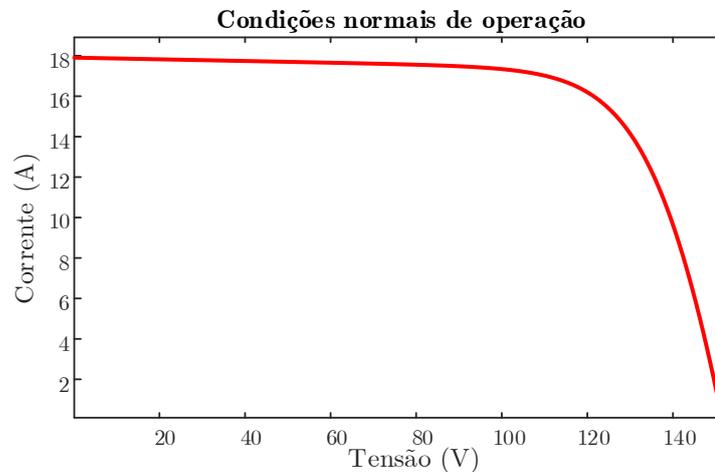
Para verificar se a RNA consegue rastrear condições normais de operação inseriram-se como entrada do algoritmo: as condições disponibilizadas na Tabela 12 e a curva I-V mostrada pela Figura 36.

Tabela 12 - Dados do arranjo para condições normais de operação.

Descrição	Valor
Irradiância	$G = 846 \text{ W/m}^2$
Número de módulos em série	$n = 8$
Número de módulos em paralelo	$m = 7$

Fonte: Autora.

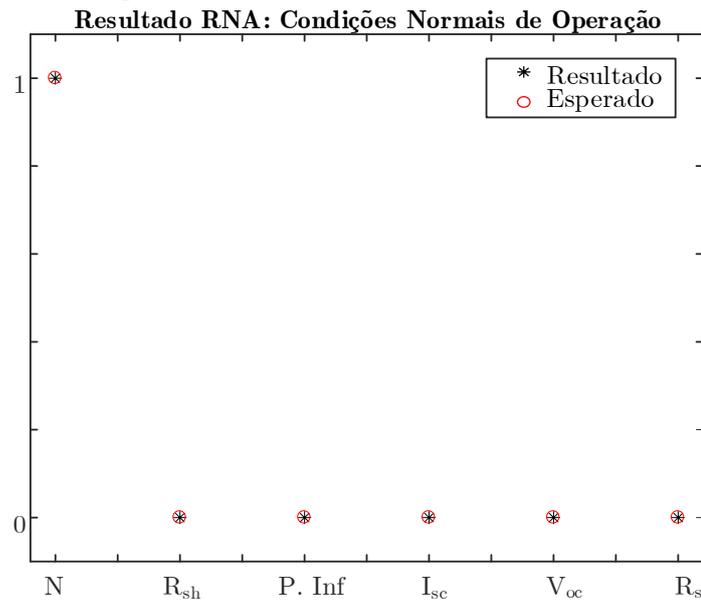
Figura 36 - Curva I-V para condições normais de operação.



Fonte: Autora

A rede neural obteve com saída os resultados da Figura 37, onde “o” indica a saída esperada e “\*” indica a saída da RNA.

Figura 37 - Resultado da RNA para "1 0 0 0 0".



Fonte: Autora.

O algoritmo de tratamento de dados não reproduz o resultado da RNA, porém ele verifica suas saídas e imprime um relatório da condição do arranjo, conforme a Figura 38.

Figura 38 - Relatório impresso para condições normais de operação.

```
O arranjo está em condições normais de operação.
```

Fonte: Autora.

#### 4.2.2 Variação da resistência em paralelo

Em seguida, deseja-se verificar se a rede neural é capaz de detectar a variação da resistência em paralelo em relação às condições sem defeitos. Para isso, inseriram-se os dados dispostos na Tabela 13 e a curva I-V em vermelho da Figura 39.

Tabela 13 - Dados do arranjo para diminuição de R<sub>sh</sub>.

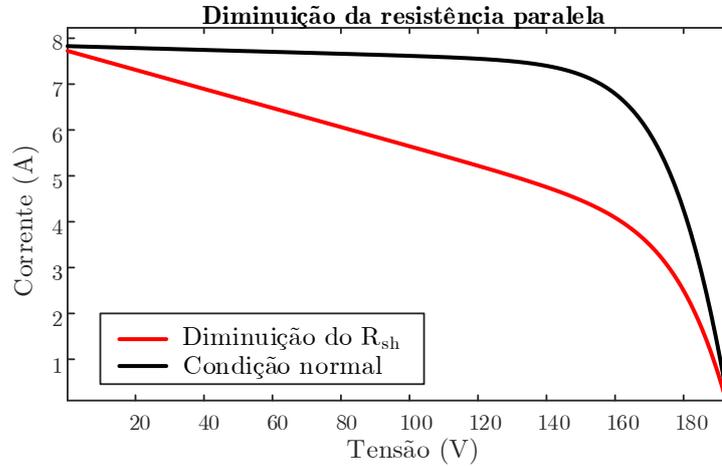
Descrição	Valor
Irradiância	G = 422 W/m <sup>2</sup>
Número de módulos em série	n = 7
Número de módulos em paralelo	m = 9

Fonte: Autora.

Na Figura 39 pode-se observar como a curva I-V (em preto) se comportaria se o arranjo não apresenta-se nenhum defeito. Em contrapartida, a curva I-V em vermelho expõe o efeito da diminuição de R<sub>sh</sub>. Observa-se que há uma diminuição do

ponto de máxima potência que acarreta em uma redução na potência de saída do arranjo FV.

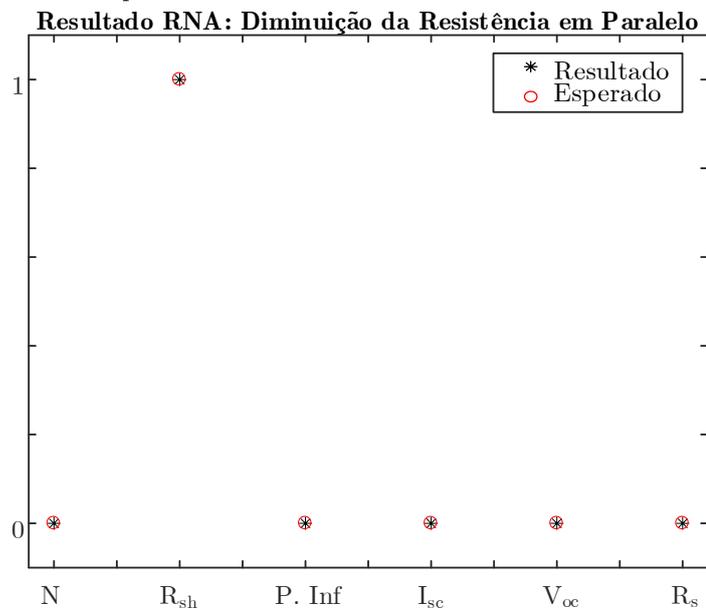
Figura 39 - Curva I-V para diminuição da resistência em paralelo.



Fonte: Autora.

O resultado da rede neural é visto na Figura 40, sendo que “o” indica o resultado esperado da RNA, enquanto que “\*” mostra a saída da rede. Como somente o segundo neurônio de saída da rede foi ativo, então, conclui-se que houve variação da resistência em paralelo em relação à condição padrão.

Figura 40 - Resultado da RNA para “0 1 0 0 0 0”.



Fonte: Autora.

O algoritmo verifica a ativação de cada neurônio de saída, e como ocorreu somente a ativação do segundo neurônio é impresso o relatório da Figura 41. No relatório são indicados os principais causas da diminuição da resistência paralela.

Figura 41 - Relatório impresso para diminuição da resistência em paralelo.

```

Defeito detectado: Diminuição da resistência paralela.
----- Causas prováveis -----
--> Defeito nas células fotovoltaicas ou em suas interconexões;
--> Divergência entre as correntes de curto-circuito dos módulos.

```

Fonte: Autora.

### 4.2.3 Pontos de inflexão na curva I-V

Para averiguar se a RNA tem a capacidade de detectar pontos de inflexão na curva I-V, inseriu-se como entrada do algoritmo de tratamento de dados os parâmetros da Tabela 14 e a curva I-V em vermelho da Figura 42.

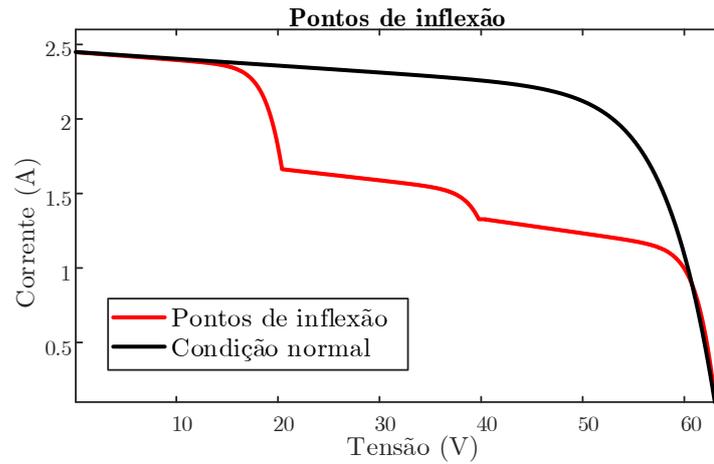
Tabela 14 - Dados do arranjo para pontos de inflexão.

Descrição	Valor
Irradiância	$G = 931 \text{ W/m}^2$
Número de módulos em série	$n = 3$
Número de módulos em paralelo	$m = 1$

Fonte: Autora.

A curva I-V em preto, conforme a Figura 42, representa a condição onde não há defeitos no arranjo FV, enquanto que a curva em vermelho apresenta a curva com pontos de inflexão. Apesar que a corrente de curto-circuito e a tensão de circuito aberto permanecem as mesmas, esse tipo de defeito tem como consequência a geração de inúmeros pontos de máxima potência, ocasionando diminuição da potência gerada.

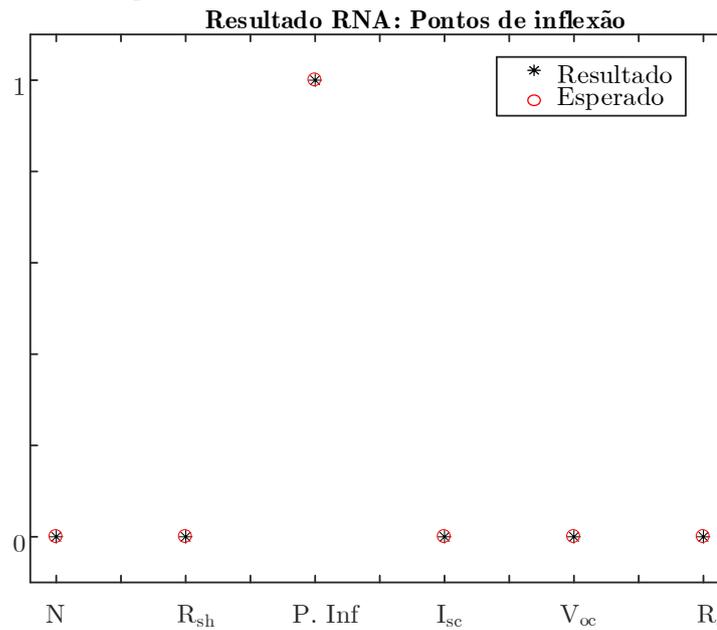
Figura 42 - Curva I-V para pontos de inflexões.



Fonte: Autora.

A Figura 43 mostra a saída da rede neural treinada para esse defeito, observa-se que a saída esperada e o real são muito próximas.

Figura 43 - Resultado da RNA para “0 0 1 0 0 0”.



Fonte: Autora.

Como o terceiro neurônio dessa rede está ativo, define-se que o defeito “pontos de inflexão” foi detectado. E, o algoritmo imprime as possíveis causas mostradas na Figura 44.

Figura 44 - Relatório impresso para pontos de inflexão.

```

Defeito detectado: Pontos de inflexão na curva.
----- Causas prováveis -----
--> Sombreamento parcial de célula(s) ou módulo(s);
--> Células ou módulos danificados;
--> Diodo de bypass em curto-circuito.

```

Fonte: Autora.

É importante destacar que o sombreamento parcial pode causar danos irreversíveis às células fotovoltaicas. Portanto, deve-se verificar as causas do sombreamento e solucioná-las.

#### 4.2.4 Variação da corrente de curto-circuito

Para o caso da variação da corrente de curto-circuito foram inseridos os dados da Tabela 15 e a curva I-V em vermelho, mostrada na Figura 45.

Tabela 15 - Dados do arranjo para diminuição de  $I_{sc}$ .

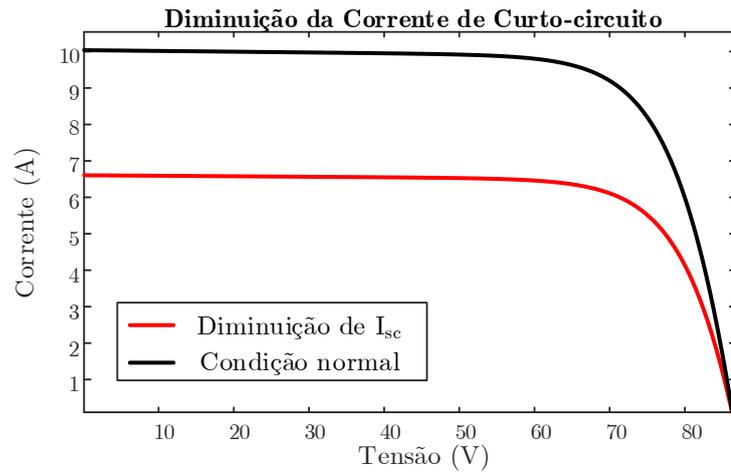
Descrição	Valor
Irradiância	$G = 420 \text{ W/m}^2$
Número de módulos em série	$n = 9$
Número de módulos em paralelo	$m = 8$

Fonte: Autora.

Destaca-se que a variação de corrente é proporcional a mudança da irradiância. E, o defeito intitulado como “Variação da corrente de curto-circuito” não considera a diminuição de irradiância em relação aos valores padrões de teste. Este defeito leva em consideração a diminuição de irradiância que chega à célula fotovoltaica em relação a irradiância que incide na superfície do arranjo fotovoltaico.

A Figura 45 mostra curva I-V em preto como a condição onde não ocorre o defeito, e a curva I-V em vermelho apresenta diminuição de  $I_{sc}$ . Este defeito também ocasiona diminuição na potência gerada pelo arranjo fotovoltaico.

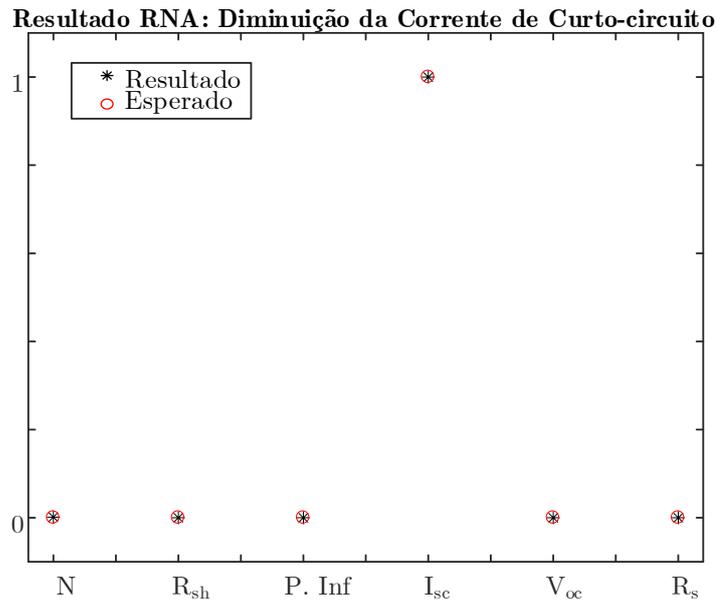
Figura 45 - Curva I-V para diminuição da corrente de curto-circuito.



Fonte: Autora.

A Figura 46 mostra saída da RNA, onde somente o quarto neurônio de saída da rede foi ativa. Então o defeito variação de  $I_{sc}$  foi detectado pela rede neural artificial.

Figura 46 - Resultado da RNA para “0 0 0 1 0 0”.



Fonte: Autora.

O algoritmo constata qual neurônio foi ativo e imprime o relatório da Figura 47 com as principais causas para a diminuição da corrente de curto-circuito, de acordo com a norma NBR 16274 (2014).

Figura 47 - Relatório impresso para diminuição da corrente de curto-circuito.

```

Defeito detectado: Diminuição da corrente de curto-circuito.
----- Causas prováveis -----
--> O arranjo está sujo ou obstruído;
--> Os módulos estão degradados;
--> Dados do módulos estão incorretos;
--> Número de módulos em paralelo está incorreto;
--> Problemas de calibração ou de medição da corrente.

```

Fonte: Autora.

#### 4.2.5 Variação da tensão de circuito aberto

Para testar a aptidão da rede neural de identificar o defeito “Variação da tensão de circuito aberto” adicionou-se como entrada do algoritmo os dados da Tabela 16 e a curva I-V em vermelho da Figura 48.

Tabela 16 - Dados do arranjo para diminuição de  $V_{oc}$ .

Descrição	Valor
Irradiância	$G = 512 \text{ W/m}^2$
Número de módulos em série	$n = 8$
Número de módulos em paralelo	$m = 8$

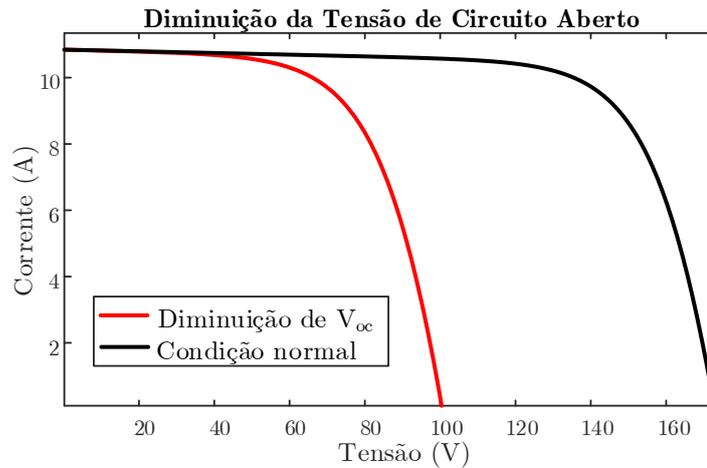
Fonte: Autora.

A curva I-V em preto mostra a curva I-V do arranjo sem defeito, conforme a Figura 48. Em contrapartida, a curva em vermelho mostra como a curva I-V se comporta quando apresenta o defeito da variação de  $V_{oc}$ . Verifica-se também que esse defeito tem como consequência a diminuição do ponto de máxima potência.

É imprescindível destacar que, apesar do aumento de temperatura causar uma diminuição da tensão de circuito aberto, esse fenômeno não deve ser considerado um defeito tendo em consideração que a temperatura varia ao longo do dia.

Além do mais, apesar de não ter sido considerado como entrada do algoritmo de tratamento de dados, cada curva I-V apresentada na seção 4.2 foram geradas com temperaturas diferentes e aleatórias em um intervalo de 10 a 60 °C.

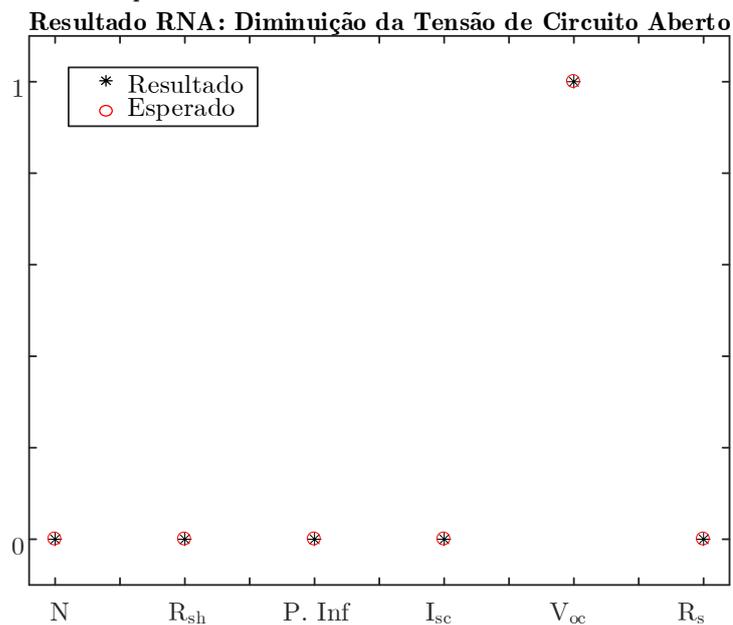
Figura 48 - Curva I-V para diminuição da tensão de circuito aberto.



Fonte: Autora.

A Figura 49 expõe o resultado da rede neural para a condição de diminuição da tensão de circuito aberto. Observa-se que a diferença entre o resultado esperado e a saída real da RNA é ínfima.

Figura 49 - Resultado da RNA para “0 0 0 0 1 0”.



Fonte: Autora.

O algoritmo verificou que somente o quinto neurônio de saída da rede está ativo, logo, define-se que foi detectado o defeito da diminuição de  $V_{oc}$  e é impresso o relatório da Figura 50 indicando as fontes prováveis desse defeito.

Figura 50 - Relatório impresso para diminuição da tensão de circuito aberto.

```

Defeito detectado: Diminuição da tensão de circuito aberto.
----- Causas prováveis -----
--> Número de módulos em série incorreto;
--> Sombreamento total de célula(s) ou módulo(s);
--> Diodo de bypass invertido ou operando incorretamente.

```

Fonte: Autora.

#### 4.2.6 Variação da resistência em série

As condições do arranjo são apresentados na Tabela 17 e na curva I-V em vermelho na Figura 51. Esses parâmetros são a entrada do algoritmo de tratamento de dados para a averiguar se a RNA é capaz de detectar a variação da resistência em série.

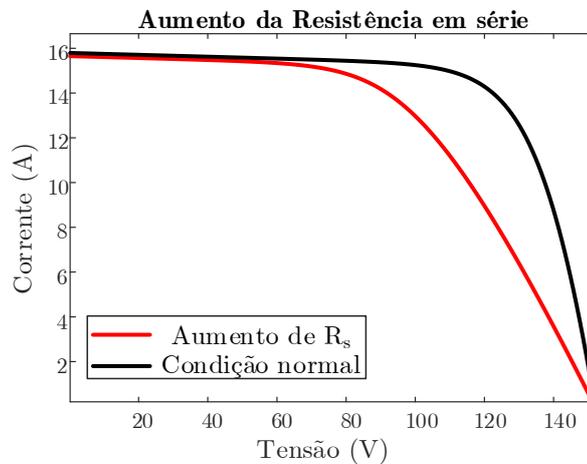
Tabela 17 - Dados do arranjo para aumento de  $R_s$ .

Descrição	Valor
Irradiância	$G = 853 \text{ W/m}^2$
Número de módulos em série	$n = 7$
Número de módulos em paralelo	$m = 7$

Fonte: Autora.

A curva em preto da Figura 51 representa o arranjo que não há nenhum defeito. A medida que na curva I-V em vermelho há um aumento da resistência em série do arranjo fotovoltaico.

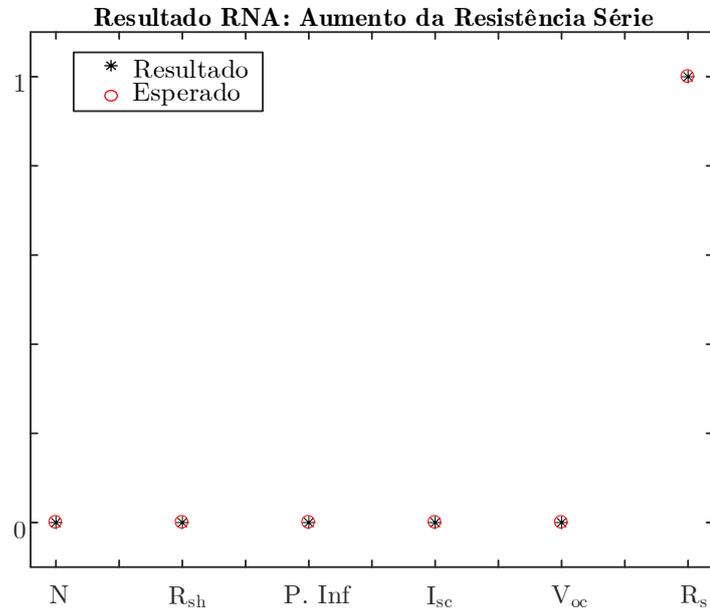
Figura 51 - Curva I-V para aumento da resistência em série.



Fonte: Autora.

A Figura 52 representa a saída da RNA, observa-se que a condição do aumento da resistência em série foi identificada pela rede.

Figura 52 - Resultado da RNA para “0 0 0 0 1”.



Fonte: Autora.

O algoritmo de tratamento de dados constata que somente o último neurônio da rede foi ativado, e como resultado imprime o relatório da Figura 53 apontando os fatores elementares que poderiam causar o defeito.

Figura 53 - Relatório impresso para aumento da resistência em série.

```

Defeito detectado: Aumento da resistência em série.
----- Causas prováveis -----
--> Danos ou falhas na fiação;
--> Falha nas conexões dos módulos fotovoltaicos.
*** Recomenda-se verificar a qualidade dos cabos utilizados
    nas fiações ou conexões do arranjo fotovoltaico ***

```

Fonte: Autora.

## 5 CONSIDERAÇÕES FINAIS

Esse trabalho apresentou um sistema que através de uma rede neural do tipo *perceptron* multicamadas foi capaz de detectar possíveis defeitos em arranjos fotovoltaicos, tendo como entrada a curva I-V do arranjo fotovoltaico e os dados disponíveis no *datasheet*.

O sistema apresentado teve o objetivo de avaliar a curva I-V de um arranjo FV e como saída detectar a condição do arranjo, indicada pela norma brasileira NBR 16274 (2014). A principal vantagem do sistema é que não necessita-se de conhecimentos técnicos da curva I-V para a classificação de possíveis defeitos. A desvantagem do sistema proposto é a modelagem matemática do módulo fotovoltaico que deve ser realizada para o treinamento da rede neural artificial.

Os resultados apresentados na seção 4 demonstram que o sistema proposto cumpriu os objetivos propostos, onde a rede neural artificial *perceptron* multicamadas foi capaz de classificar os seguintes defeitos: condições normais de operação, variação da resistência paralela, pontos de inflexão na curva, variação da corrente de curto-circuito, variação da tensão de circuito aberto, e variação da resistência em série. Além disso a rede neural artificial apresentou uma acurácia de 99,3%.

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 do mais, podem gerar danos irreversíveis as células FV chegando a condições extremas de queima das células. Por esse motivo, tem-se a necessidade da utilização de um sistema para auxiliar a manutenção dos arranjo fotovoltaicos com o intuito de minimizar perdas.

### 5.1 Trabalhos publicados

O desenvolvimento desse trabalho gerou as seguintes publicações:

- CORNELIUS, R. G.; MAIA, A. C.; MELLO, A. P. C.; KAEHLER, J. W.; SILVA, G. S. Desenvolvimento de um dispositivo eletrônico para

caracterização de painéis fotovoltaicos. Em: **Seminar on Power Electronics and Control**, 2018. Santa Maria, RS, Brasil.

- MAIA, A. C.; CORNELIUS, R. G.; MELLO, A. P. C.; SILVA, G. S. Method to trace the photovoltaic characteristic curves under partial shading conditions. Em: **IEEE PES Innovative Smart Grid Technologies Latin America**, 2019. Gramado, RS, Brasil.
- MAIA, A. C.; MELLO, A. P. C.; SILVA, G. S. Estratégia para Classificação de Defeitos em Arranjos Fotovoltaicos através de Redes Neurais Artificiais. Em: **VIII Simpósio Brasileiro de Sistemas Elétricos**, 2020. Santo André, SP, Brasil.

## 5.2 Proposta de trabalhos futuros

Apresentam-se as seguintes propostas para trabalhos futuros:

- Realizar o treinamento da RNA com amostras a partir de arranjos fotovoltaicos com defeitos reais;
- Implementação prática do sistema proposto.

## REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **Energia Solar**. Disponível em: <[http://www.aneel.gov.br/aplicacoes/atlas/pdf/03-Energia\\_Solar\(3\).pdf](http://www.aneel.gov.br/aplicacoes/atlas/pdf/03-Energia_Solar(3).pdf)>.

ALDWANE, B. Modeling, simulation and parameters estimation for Photovoltaic module. **2014, 1st International Conference on Green Energy, ICGE 2014**, p. 101–106, 2014.

BASTIDAS RODRÍGUEZ, J. D.; RAMOS PAJA, C. A.; FRANCO MEJÍA, E. Modeling and parameter calculation of photovoltaic fields in irregular weather conditions. **Ingeniería**, v. 17, n. 1, p. 37–48, 2012.

BRAGA, A. DE P.; CARVALHO, A. P. DE L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. [s.l: s.n.].

BRITO, E. M. D. S. B. **Construção de um Caracterizador Solar Baseado em Carga Capacitiva**, 2014.

CARVALHO, D. P. et al. **Métodos de diagnóstico de falhas para arranjos fotovoltaicos. VII Congresso Brasileiro de Energia Solar**, 2018.

CARVALHO, A. L. C. DE. **Metodologia para análise , caracterização e simulação de células fotovoltaicas. Universidade Federal de Minas Gerais**, 2014.

CASTRO, L. N.; ZUBEN, F. J. VON. **Redes neurais artificiais**. [s.l: s.n.].

CEPEL; CRESESB. **Manual de Engenharia para Sistemas Fotovoltaicos.**, 2014.

CHINE, W. et al. Fault detection method for grid-connected photovoltaic plants. **Renewable Energy**, v. 66, p. 99–110, 2014.

CORNELIUS, R. G. et al. **Desenvolvimento de um dispositivo eletrônico para caracterização de painéis fotovoltaicos. SEPOC**, 2018.

COUTINHO, C. R. **O Efeito do Sombreamento e Diodos de Bypass em Módulos Fotovoltaicos**. 2017.

DEMONTI, R. **Processamento da energia elétrica proveniente de módulos fotovoltaicos**. [s.l: s.n.].

EDMAR, M. **Extração de conhecimento de redes neurais artificiais**, 1999.

FARIVAR, G.; ASAEI, B. **Photovoltaic Module Single Diode Model Parameters Extraction Based on Manufacturer Datasheet Parameters**, 2010.

FLECK, L. et al. **Redes Neurais Artificiais: Princípios Básicos**. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47–57, 2016.

GASPARIN, F. **Desenvolvimento de um Traçador de Curvas Características de Módulos Fotovoltaicos**, 2009.

IBRAHIM, H.; ANANI, N. Variations of PV module parameters with irradiance and temperature. **Energy Procedia**, 2017.

INTERNATIONAL ENERGY AGENCY, I. **World Energy Balances**. Disponível em: <<https://www.iea.org/statistics/balances/>>.

INTERNATIONAL ENERGY AGENCY, I. **World Energy Outlook 2018**. Disponível em: <[www.iea.org/t&c/](http://www.iea.org/t&c/)>.

JIANG, L. L.; MASKELL, D. L. **Automatic Fault Detection and Diagnosis for Photovoltaic Systems using Combined Artificial Neural Network and Analytical Based Methods**, **International Joint Conference on Neural Networks**, IEEE, 2015.

LUNA, M. L. M. **Comparação e Validação de Modelos Elétricos de um Diodo e Dois Diodos de um Módulo Fotovoltaico**, 2013.

MAIA, A. C. et al. **Method to trace the photovoltaic characteristic curves under partial shading conditions**, **ISGT**, 2019.

MARQUES, R. DA S. **Energia Solar no Brasil: dos incentivos aos desafios**. p. 53, 2015.

MATSUNAGA, V. Y. **Curso de redes reurais utilizando o MATLAB**, 2012.

MEIRELLES, B.; MARQUES, F. **Fabricação de Células Solares**, 2011.

MONTGOMER, E.; JUNIOR, O. L. **Redes Neurais: Fundamentos e aplicações com programas em C.** [s.l: s.n.].

MORAIS, E. C. **Reconhecimento De Padrões E Redes Neurais Artificiais Em Predição De Estruturas Secundárias De Proteínas**, 2010.

NASCIMENTO, R. L. Energia solar no Brasil: situação e perspectivas. **Estudo Técnico**, p. 1–46, 2017.

NBR 16274, A. **Sistemas fotovoltaicos conectados à rede — Requisitos mínimos para documentação, ensaios de comissionamento, inspeção e avaliação de desempenho.** Associação Brasileira de Normas Técnicas, 2014.

OLIVEIRA, Â. R. **Redes Neurais Artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão.** [s.l: s.n.].

PEDRO, M. C. M. **Modelling of Shading Effects in Photovoltaic Optimization**, 2016.

RAUBER, T. W. **Redes neurais artificiais**, 2014. Disponível em: <<http://scholar.google.com/scholar?cluster=>>.

SEYEDMAHMOUDIAN, M. et al. Analytical modeling of partially shaded photovoltaic systems. **Energies**, v. 6, n. 1, p. 128–144, 2013.

SOTO, W. DE. **Improvement and Validation of a Model for Photovoltaic Array Performance.** [s.l: s.n.].

SYAFARUDDIN; KARATEPE, E.; HIYAMA, T. **Controlling of Artificial Neural Network for Fault Diagnosis of Photovoltaic Array.** 6th International Conference on Intelligent System Applications to Power Systems. Anais IEEE, 2011.

TATIBANA, C. Y.; KAETSU, D. Y. **Introdução as redes neurais artificiais**, 2002.

TRETER, M. E. **Métodos De Aquisição Experimental De Curvas I-V De Arranjos Fovoltáicos : Uma Revisão**, 2018.