

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO UNIVERSITÁRIO NORTE DO ESPÍRITO SANTO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENERGIA

ANDRÉ SILVA

**IDENTIFICAÇÃO DE FUNCIONAMENTO ATÍPICO DE
PAINEL FOTOVOLTAICO**

SÃO MATEUS
2020

ANDRÉ SILVA

IDENTIFICAÇÃO DE FUNCIONAMENTO ATÍPICO DE PAINEL FOTOVOLTAICO

Dissertação apresentada ao Programa de Pós-Graduação em Energia do Centro Universitário Norte do Espírito Santo da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Energia.

Orientador: Prof. Dr. Wanderley Cardoso Celeste.

Coorientador: Prof. Dr. Daniel José Custódio Coura.

SÃO MATEUS

2020

Ficha catalográfica disponibilizada pelo Sistema Integrado de
Bibliotecas - SIBI/UFES e elaborada pelo autor

S586i Silva, André, 1975-
Identificação de funcionamento atípico de painel fotovoltaico /
André Silva. - 2020.
195 f. : il.

Orientador: Wanderley Cardoso Celeste.

Coorientador: Daniel José Custódio Coura.

Dissertação (Mestrado em Energia) - Universidade Federal do
Espírito Santo, Centro Universitário Norte do Espírito Santo.

1. Geração de energia fotovoltaica. 2. Localização de falhas
(Engenharia). 3. Redes neurais (Computação). 4. Inteligência
artificial. I. Celeste, Wanderley Cardoso. II. Coura, Daniel José
Custódio. III. Universidade Federal do Espírito Santo. Centro
Universitário Norte do Espírito Santo. IV. Título.

CDU: 620.9

ANDRÉ SILVA

**IDENTIFICAÇÃO DE FUNCIONAMENTO ATÍPICO DE PAINEL
FOTOVOLTAICO**

Dissertação apresentada ao Programa de Pós-Graduação em Energia da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Energia.

Aprovada em 26 de maio de 2020.

COMISSÃO EXAMINADORA

Prof. Dr. Wanderley Cardoso Celeste
Universidade Federal do Espírito Santo
Orientador

Prof. Dr. Daniel José Custódio Coura
Universidade Federal do Espírito Santo

Prof. Dr. Leonardo José Silvestre
Universidade Federal do Espírito Santo

Prof. Dr. Hélder Roberto de Oliveira
Rocha
Universidade Federal do Espírito Santo

Prof. Dr. Daniel Cruz Cavalieri
Instituto Federal do Espírito Santo



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO

PROTOCOLO DE ASSINATURA



O documento acima foi assinado digitalmente com senha eletrônica através do Protocolo Web, conforme Portaria UFES nº 1.269 de 30/08/2018, por
WANDERLEY CARDOSO CELESTE - SIAPE 1723581
Departamento de Computação e Eletrônica - DCE/CEUNES
Em 26/05/2020 às 18:39

Para verificar as assinaturas e visualizar o documento original acesse o link:
<https://api.lepisma.ufes.br/arquivos-assinados/25626?tipoArquivo=O>



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO

PROTOCOLO DE ASSINATURA



O documento acima foi assinado digitalmente com senha eletrônica através do Protocolo Web, conforme Portaria UFES nº 1.269 de 30/08/2018, por DANIEL JOSE CUSTODIO COURA - SIAPE 1870073 Departamento de Computação e Eletrônica - DCE/CEUNES Em 26/05/2020 às 18:50

Para verificar as assinaturas e visualizar o documento original acesse o link:
<https://api.lepisma.ufes.br/arquivos-assinados/25633?tipoArquivo=O>



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO

PROTOCOLO DE ASSINATURA



O documento acima foi assinado digitalmente com senha eletrônica através do Protocolo Web, conforme Portaria UFES nº 1.269 de 30/08/2018, por
HELDER ROBERTO DE OLIVEIRA ROCHA - SIAPE 1860639
Departamento de Engenharia Elétrica - DEE/CT
Em 27/05/2020 às 12:50

Para verificar as assinaturas e visualizar o documento original acesse o link:
<https://api.lepisma.ufes.br/arquivos-assinados/25783?tipoArquivo=O>



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO

PROTOCOLO DE ASSINATURA



O documento acima foi assinado digitalmente com senha eletrônica através do Protocolo Web, conforme Portaria UFES nº 1.269 de 30/08/2018, por
LEONARDO JOSE SILVESTRE - SIAPE 1504334
Departamento de Computação e Eletrônica - DCE/CEUNES
Em 27/05/2020 às 15:02

Para verificar as assinaturas e visualizar o documento original acesse o link:
<https://api.lepisma.ufes.br/arquivos-assinados/25830?tipoArquivo=O>

*Dedico à minha família em especial
aos meus pais João e Suzani, minha
esposa Monaliza e minha filha
Melissa.*

AGRADECIMENTOS

À Deus, fonte de todo o conhecimento, pelas muitas bênçãos e por ter me dado condição de concluir mais esta importante etapa em minha vida.

À minha família, em especial aos meus avós Januário, Elvira, Virgílio e Jovelina pelo carinho e apoio proporcionado na infância e juventude. Aos meus pais João e Suzani pelo amor, cuidado e esforço que fizeram para me proporcionar educação e valores. Aos meus irmãos Marcelo e Filipe, pelo apoio e bons momentos vividos juntos. À minha esposa Monaliza e minha filha Melissa pelo amor, força, paciência e compreensão durante os momentos difíceis.

Aos Professores Dr. Wanderley Cardoso Celeste e Dr. Daniel José Custódio Coura, pela orientação e paciência. Aos professores membros da banca Dr. Hélder Roberto de Oliveira Rocha, Dr. Leonardo José Silvestre e Dr. Daniel Cruz Cavalieri pelas importantes contribuições dadas ao trabalho.

Aos todos professores do programa pelo conhecimento adquirido e aos colegas da turma pelos bons momentos de convivência e pela troca de conhecimento.

Ao IFES São Mateus pelo afastamento parcial para participação neste curso e a todos os colegas de trabalho pelo apoio e compreensão.

À UFES pela disponibilização da infraestrutura, do corpo docente e da oferta do curso de mestrado.

À CAPES, FAPES e Petrobrás pelo apoio financeiro e técnico ao programa de Mestrado em Energia.

“O que sabemos é uma gota; o que ignoramos é um oceano”.

(Isaac Newton)

RESUMO

A energia solar é uma fonte barata e limpa, sendo uma boa opção para substituir combustíveis fósseis, diminuindo a geração de gases do efeito estufa.

Para alcançar este objetivo, o custo da energia deve se mostrar competitivo em relação a outras fontes. Os módulos solares têm longa vida útil, mas são necessárias ações de manutenção para que se alcance esse tempo. Devido à exposição a condições ambientais adversas, os equipamentos estão sujeitos a falhas, que normalmente são difíceis detectar e localizar. A presente dissertação tem por objetivo identificar funcionamento atípico em uma *string* fotovoltaica utilizando apenas a tensão e a corrente em seus terminais, sem a utilização de dados ambientais de irradiação solar e temperatura. A metodologia utilizada é a coleta de dados de tensão e de corrente da *string* em condição de funcionamento normal e em 4 tipos de condição de falha: sombreamento de um painel inteiro, sombreamento de um setor de um painel, curto-circuito de um painel inteiro e arco elétrico. As falhas de sombreamento de painel, sombreamento de setor, e de curto-circuito são subdivididas em 6, uma para cada painel, gerando no total, 20 condições diferentes de funcionamento, visando a identificação do painel anormal. Para cada uma das 20 condições, são coletados dados em condições climáticas diversas. Os dados coletados são utilizados para treinar, validar e testar uma rede neural convolucional. Esta rede consegue aprender as características que permitem a identificação de cada uma das 20 condições de funcionamento com acurácia de 94,03%.

Palavras chave: Monitoramento Não Intrusivo, Detecção de falhas, Localização de Falhas, Energia Solar Fotovoltaica, Redes Neurais Convolucionais.

ABSTRACT

Solar energy is a cheap and clean source, being an excellent option to replace fossil fuels, reducing the generation of greenhouse gases. To achieve this goal, the cost of energy must be competitive with other sources. The solar modules have a long service life, but maintenance actions are necessary to reach this time. Due to exposure to adverse environmental conditions, equipment is subject to failures, which are usually difficult to detect and locate. This dissertation aims to identify atypical functioning in a photovoltaic string using only the voltage and current at its terminals, without using environmental data of solar irradiation and temperature. The methodology used in the collection of voltage and current data from the string in normal operating conditions and four types of failure conditions: shading of an entire panel, shading of a panel sector, and short-circuit of a whole module, and electric arc. The panel shading, sector shading, and short-circuit failures have subdivided into 6, one for each panel generating 20 different operating conditions, to identify the abnormal module. For each of the 20 states, data have collected under diverse climatic conditions. The collected data has used to train, validate, and test a convolutional neural network, which can learn the characteristics that allow the identification of each of the 20 operating conditions with an accuracy of 94,03%.

Keywords: Non-Intrusive Load Monitoring, Fault Detection, Fault Location, Photovoltaic Solar Energy, Convolutional Neural Network, Deep Learning, Machine Learning.

LISTA DE FIGURAS

Figura 1.1: Evolução do custo da célula solar	19
Figura 1.2: Evolução do custo do módulo solar.....	20
Figura 2.1: Esquema das condições do espectro de referência AM1.5	24
Figura 2.2: Distribuição espectral da radiação de um corpo negro, do sol no espaço extraterrestre (AM0) e do sol no padrão AM1.5.....	25
Figura 2.3: Modelo de circuito equivalente de uma célula solar.....	26
Figura 2.4: Característica I-V de uma célula solar.....	27
Figura 2.5: Exemplo de interligação interna das células em um módulo solar .	30
Figura 2.6: Componentes do sistema fotovoltaico.....	30
Figura 2.7: Quebra do vidro frontal.....	33
Figura 2.8: Delaminação	33
Figura 2.9: Corrosão do barramento e conexões por penetração de umidade	34
Figura 2.10: Célula com rachadura	35
Figura 2.11: Célula escurecida.....	36
Figura 2.12: Falha linha a linha em várias localizações no arranjo fotovoltaico	38
Figura 2.13: Caixa de junção destruída por falha de arco.....	39
Figura 2.14: Sombreamento parcial	40
Figura 2.15: Acúmulo de poeira sobre os módulos solares.....	41
Figura 2.16: Imagem termográfica mostrando as células sobreaquecidas em vermelho.....	42
Figura 2.17: Diodos de by-pass defeituosos	43
Figura 3.1: a) eletroluminescência (0,8 A) b) eletroluminescência (8 A) c) fotoluminescência d) infravermelho.....	47
Figura 3.2: Sistemas fotovoltaicos a) aterrados b) não aterrados	49
Figura 3.3: Diagrama esquemático do princípio de funcionamento do RCD	50
Figura 3.4: Princípio do TDR (DsT: dispositivo sob teste).....	51
Figura 3.5: Princípio da medida da capacitância para o terra.	53
Figura 3.6: Relação entre tensão e corrente de um arranjo para cinco condições de funcionamento.....	55
Figura 3.7: Classificação dos dados do arranjo fotovoltaico em condição normal e com falha linha a linha 1.....	56
Figura 3.8: Classificação dos dados do arranjo fotovoltaico em condição normal e com falha circuito aberto 1.	57
Figura 3.9: Características I-V e $(-dI/dV)$ -V: (a) em um arranjo normal;(b) em uma string com uma célula sombreada.....	58
Figura 3.10: Processo de obtenção da rede CNN de diagnóstico de arco série.	63
Figura 4.1: Estrutura de uma rede neural artificial.....	66
Figura 4.2: Estrutura do neurônio artificial.....	66
Figura 4.3: Hiperplano de separação de classes no perceptron	69
Figura 4.4: Problema dos mínimos locais	78

Figura 4.5: Treinamento com parada antecipada (Early Stopping)	83
Figura 4.6: Método de normalização MinMax_Scaler	85
Figura 4.7: Método de normalização <i>Standard_Scaler</i>	85
Figura 4.8: Estrutura da rede neural convolucional LeNet-5	87
Figura 4.9: um mapa de características em uma camada convolucional	88
Figura 4.10: Exemplo da operação de convolução (stride = 1, sem padding)..	89
Figura 4.11: Camada pooling	90
Figura 5.1: Estrutura da planta fotovoltaica experimental	92
Figura 5.2: String fotovoltaica.....	93
Figura 5.3: Posicionamento da string e do LER 1	94
Figura 5.4: Inversor	94
Figura 5.5: Módulo de sensores	96
Figura 5.6: Conexões do módulo de sensores a) alimentação b) sinais de saída c) circuito de potência	97
Figura 5.7: Módulo de digitalização	98
Figura 5.8: Módulo de simulação de curto-circuito e arco elétrico.....	99
Figura 5.9: Sombreamento de um módulo fotovoltaico inteiro	100
Figura 5.10: Sombreamento de um setor de um módulo fotovoltaico	100
Figura 5.11: Módulo de monitoramento ambiental	101
Figura 5.12: Componentes internos do módulo de monitoramento ambiental.	102
Figura 5.13: Minimódulo solar que compõe o sensor de irradiação	102
Figura 5.14: Sensor de temperatura AM2320	103
Figura 5.15: Montagem do sensor de temperatura	104
Figura 5.16: Transmissor de rádio frequência STX882-433.....	105
Figura 5.17: Módulo receptor de dados ambientais	106
Figura 5.18: Receptor de rádio frequência	106
Figura 5.19: Calibração do sensor de corrente	107
Figura 5.20: Calibração do sensor de tensão.....	108
Figura 5.21: Localização geográfica das instituições de ensino envolvidas no estudo	109
Figura 5.22: Estação meteorológica e sensor de irradiação	110
Figura 5.23: Módulo receptor com relógio e cartão SD utilizado na calibração	110
Figura 5.24: Dados de irradiação solar coletados do sensor em calibração e da estação meteorológica entre os dias 14 a 21/11/2019.....	111
Figura 5.25: Detalhamento do filtro de média deslizante	112
Figura 5.26: Aplicação em cascata do filtro.....	112
Figura 5.27: Dados de irradiação coletados via sensor sob calibração e via estação meteorológica no dia 19/11/2019.....	113
Figura 5.28: Dados de irradiação do sensor e da estação meteorológica após filtragem.....	114
Figura 5.29: Dados de irradiação filtrados do sensor e da estação meteorológica após calibração.	115

Figura 5.30: Interface do Usuário	116
Figura 5.31: Detalhamento de aquisição de dados	118
Figura 5.32: Resposta em frequência do filtro passa altas.....	121
Figura 5.33: Estrutura das redes neurais: a) redes 1 e 2; b) rede 3 e 10; c) rede 4.	122
Figura 5.34: Estrutura das redes neurais; a) rede 5; b) redes 6, 7, 8 e 9	123
Figura 5.35: Fluxograma do treinamento dividido em etapas.....	138
Figura 5.36: Fluxograma do processo para obtenção do tempo total de treinamento das redes para comparação	141
Figura 5.37: Mensagens de log com indicação das informações utilizadas (tempo da época com 1 algarismo significativo).....	142
Figura 5.38: Mensagens de log com indicação das informações utilizadas (tempo da época com 2 algarismo significativos)	142
Figura 6.1: Amostras de tensão e corrente para uma coleta em condições climáticas aproximadamente constantes (ciclo de coleta 225).....	145
Figura 6.2: Gráfico Corrente versus Tensão por tipo de defeito (módulo 1)...	146
Figura 6.3: Evolução da acurácia e perda durante o treinamento e a validação da rede 0.	148
Figura 6.4:Matriz de confusão entre as condições de funcionamento da rede 0 (normalizada)	150
Figura 6.5: Evolução da acurácia e da perda durante o treinamento e a validação da rede 3	151
Figura 6.6: Matriz de confusão entre as condições de funcionamento para a rede 3 (normalizada)	152
Figura 6.7: Evolução da acurácia e perda durante o treinamento e a validação da rede 4.	153
Figura 6.8: Matriz de confusão das condições de funcionamento da rede 4 (normalizada)	154
Figura 6.9: Evolução da acurácia e perda durante o treinamento e a validação da rede 5.	155
Figura 6.10: Matriz de confusão entre as condições de funcionamento para a rede 5 (normalizada).	156
Figura 6.11: Evolução da acurácia e perda durante o treinamento e a validação da rede 6.	157
Figura 6.12: Matriz de confusão entre condições de funcionamento para a rede 6 (normalizada).	158
Figura 6.13: Evolução da acurácia e perda durante o treinamento e validação da rede 7.	159
Figura 6.14: Matriz de confusão entre as condições de funcionamento para a rede 7 (normalizada).	160
Figura 6.15: Evolução da acurácia e da perda durante o treinamento e a validação da rede 8.	161
Figura 6.16: Matriz de confusão entre condições de funcionamento para a rede 8 (normalizada).	162

Figura 6.17: Evolução da acurácia e da perda durante o treinamento e a validação da rede 9	163
Figura 6.18: Matriz de confusão entre condições de funcionamento para a rede 9 (normalizada)	164
Figura 6.19: Evolução da acurácia e da perda da rede 10 durante o treinamento e a validação	165
Figura 6.20: Matriz de confusão entre condições de funcionamento para a rede 10 (normalizada)	166

LISTA DE TABELAS

Tabela 3.1: Formas de onda de resposta em TDR (Z_0 : impedância característica da linha de transmissão)	52
Tabela 4.1: Principais funções de ativação.	68
Tabela 5.1: Características do inversor	95
Tabela 5.2: Constantes de calibração dos sensores	108
Tabela 5.3: Codificação das condições de funcionamento da string fotovoltaica.	117
Tabela 5.4: Estrutura básica das redes neurais utilizadas.	124
Tabela 5.5: Estrutura da rede neural 0	125
Tabela 5.6: Estrutura das redes neurais 1 e 2	125
Tabela 5.7: Estrutura da rede neural 3	126
Tabela 5.8: Estrutura da rede neural 4	127
Tabela 5.9: Estrutura da rede neural 5	128
Tabela 5.10: Estrutura da rede neural 6	129
Tabela 5.11: Estrutura da rede neural 7	130
Tabela 5.12: Estrutura da rede neural 8	131
Tabela 5.13: Estrutura da rede neural 9	132
Tabela 5.14: Estrutura da rede neural 10	134
Tabela 6.1: Número de amostras adquiridas para cada condição de funcionamento	144
Tabela 6.2: Grupos de condições de funcionamento da string fotovoltaica. ..	146
Tabela 6.3: Desempenho das redes neurais na identificação de condições de funcionamento da string fotovoltaica.	148

LISTA DE ABREVIATURAS E SIGLAS

No caso de algumas abreviaturas internacionalmente conhecidas, optou-se por mantê-las em sua língua original.

CC	Corrente Contínua
CA	Corrente Alternada
MPP	<i>Maximum Power Point</i>
MPPT	<i>Maximum Power Point Tracker</i>
I_{sc}	<i>Short circuit current</i>
V_{oc}	<i>Open circuit voltage</i>
I_{mp}	<i>Maximum power current</i>
V_{mp}	<i>Maximum power voltage</i>
STC	<i>Standard Test Conditions</i>
GFDI	<i>Ground Fault Detection and Interrupt</i>
GFPD	<i>Ground Fault Protection Device</i>
RCD	<i>Residual Current Device</i>
IMD	<i>Insulation Monitoring Device</i>
PID	<i>Potential Induced Degradation</i>
LID	<i>Light Induced Degradation</i>
CNN	<i>Convolutional Neural Network</i>

SUMÁRIO

1	INTRODUÇÃO	19
1.1	DEFINIÇÃO DO PROBLEMA	21
1.2	OBJETIVO GERAL	22
1.3	OBJETIVOS ESPECÍFICOS	22
1.4	ESTRUTURA CAPITULAR.....	22
2	SISTEMA FOTOVOLTAICO	23
2.1	ESPECTRO DA RADIAÇÃO SOLAR.....	23
2.2	MODELO DA CÉLULA SOLAR	25
2.3	ESTRUTURA DE UM SISTEMA FOTOVOLTAICO	28
2.4	DEFEITOS EM SISTEMAS FOTOVOLTAICOS	31
2.5	DEFEITOS NOS MÓDULOS FOTOVOLTAICOS.....	32
2.5.1	Falhas de encapsulamento	32
2.5.2	Perda de aderência da folha traseira	34
2.5.3	Quebra de interconexão.....	34
2.5.4	Corrosão.....	34
2.5.5	Rachaduras nas células.....	35
2.5.6	Falha de degradação	35
2.5.1	Falha na caixa de junção	36
2.6	DEFEITOS NO CABEAMENTO	37
2.6.1	Falha de circuito aberto	37
2.6.2	Falha linha a linha.....	37
2.6.3	Falha para a terra.....	38
2.6.4	Falha de arco.....	38
2.7	DEFEITOS DE INCOMPATIBILIDADE	39
2.7.1	Falha de sombreamento parcial	40
2.7.2	Falha de pontos quentes (hot spots)	41
2.8	FALHA EM EQUIPAMENTOS ELETRÔNICOS.....	42
2.8.1	Falha nos diodos (by-pass e bloqueio)	42
2.8.2	Falha no MPPT	43
2.8.3	Falha no inversor.....	43
3	DIAGNÓSTICO DE FALHAS	44

3.1	INSPEÇÃO VISUAL	44
3.2	TÉCNICAS DE IMAGEM.....	45
3.3	TÉCNICAS BASEADAS EM DISPOSITIVOS DE PROTEÇÃO	47
3.4	TÉCNICAS INDEPENDENTES DE DADOS CLIMÁTICOS.....	50
3.5	TÉCNICAS DE ANÁLISE DA CURVA I-V	53
3.6	TÉCNICA DE COMPARAÇÃO ENTRE AS SAÍDAS REAL E MODELADA DO SISTEMA FOTOVOLTAICO	59
3.7	TÉCNICAS ESTATÍSTICAS	60
3.8	TÉCNICAS DE APRENDIZADO DE MÁQUINA.....	61
3.9	TÉCNICAS DE DETECÇÃO DE ARCO ELÉTRICO.....	63
3.10	TÉCNICAS DE DETECÇÃO DE <i>HOT SPOTTING</i>	64
4	REDES NEURAIS	65
4.1	ESTRUTURA.....	65
4.1.1	Neurônio artificial	66
4.1.2	Funções de ativação	67
4.1.3	Perceptron.....	68
4.1.4	Perceptron de Múltiplas Camadas (Multilayer Perceptron - MLP) 71	
4.1.5	Backpropagation	71
4.1.6	Algoritmo de retropropagação	79
4.1.7	Validação	82
4.2	PRÉ-PROCESSAMENTO DOS DADOS.....	84
4.3	REDES NEURAIS CONVOLUCIONAIS.....	86
4.3.1	Camada convolucional.....	87
4.3.2	Camada de agrupamento (Pooling)	89
4.3.3	Camada totalmente conectada	89
4.3.4	Camada de saída com Softmax	90
5	METODOLOGIA.....	91
5.1	PLANTA FOTOVOLTAICA	91
5.1.1	String fotovoltaica	92
5.1.1	Inversor	93
5.1.2	Módulo de sensores	95
5.1.3	Módulo de digitalização de dados.....	97
5.1.4	Módulo de simulação de curto-circuito e arco elétrico.....	98

5.1.5	Simuladores de sombreamento	99
5.1.6	Módulo de monitoramento ambiental	100
5.1.7	Módulo receptor de dados ambientais	105
5.1.8	Calibração dos sensores de tensão e corrente	106
5.1.9	Calibração do Sensor de Irradiação.....	108
5.1.10	Sistema Computacional	115
5.2	AQUISIÇÃO DE DADOS	116
5.3	ESTRUTURA DA REDE NEURAL CONVOLUCIONAL	119
5.4	TREINAMENTO DA REDE NEURAL	135
5.5	MÉTRICAS PARA ANÁLISE	139
6	RESULTADOS E DISCUSSÕES.....	143
6.1	DADOS ADQUIRIDOS	143
6.2	IDENTIFICAÇÃO DE CONDIÇÕES DE FUNCIONAMENTO DA STRING 147	
7	CONCLUSÃO E CONSIDERAÇÕES FINAIS	167
8	REFERÊNCIAS	170
	APÊNDICE 1: HORÁRIOS E CONDIÇÕES CLIMÁTICAS MÉDIAS DOS CICLOS DE COLETA	177
	APÊNDICE 2: DADOS CLIMÁTICOS	186
	APÊNDICE 3: TAXAS DE APRENDIZAGEM DURANTE TREINAMENTO DAS REDES NEURAS.....	189
	ANEXO A	191
	ANEXO B	192
	ANEXO C	194

1 INTRODUÇÃO

O uso de energia proveniente de fontes renováveis tem crescido devido à necessidade de obtenção de energia limpa, para evitar o uso de combustíveis fósseis e diminuir os danos ao meio ambiente e à saúde pública (ABDULMAWJOOD; REFAAT; MORSI, 2018; JÄGER-WALDAU, 2017; MELLIT; TINA; KALOGIROU, 2018). Dentre algumas fontes de energias renováveis, cita-se a hidráulica, a eólica, a solar e a biomassa como sendo as de maior importância no cenário mundial (KABIR et al., 2018).

A energia solar em particular tem apresentado um rápido crescimento na última década devido a avanços tecnológicos que têm permitido o aumento da eficiência das células fotovoltaicas que constituem os painéis fotovoltaicos (GREEN, 2009; GREEN et al., 2017), bem como a redução dos custos de fabricação (KANNAN; VAKEESAN, 2016; WOODHOUSE et al., 2019) com consequente redução do investimento necessário para a implantação de sistemas fotovoltaicos.

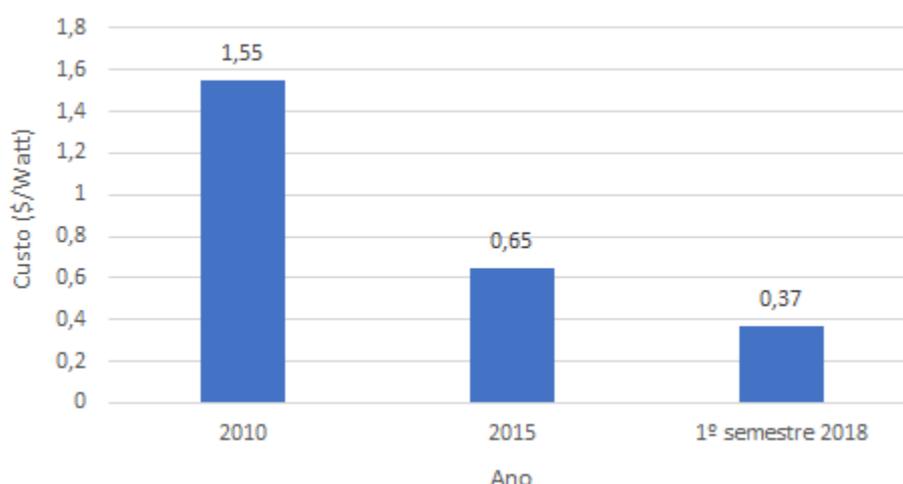
A Figura 1.1 mostra um histórico do preço por potência produzida das células solares, partindo de US\$76,67 em 1977 e atingindo US\$ 0,36 em 2014 (KANNAN; VAKEESAN, 2016). O preço do módulo fotovoltaico também teve redução partindo de US\$1,55 por Watt em 2010 e atingindo US\$ 0,37 no primeiro semestre de 2018, conforme ilustrado na Figura 1.2 (WOODHOUSE et al., 2019).



Fonte:(KANNAN; VAKEESAN, 2016)

Nota: Adaptado pelo autor

Figura 1.2: Evolução do custo do módulo solar



Fonte: (WOODHOUSE et al., 2019)

Nota: Adaptado pelo autor

Além disso, devido à sua natureza modular, os painéis fotovoltaicos são flexíveis, permitindo desde a criação de um grande sistema de geração de energia elétrica (modelo tradicional) a sistemas de geração de médio e pequeno porte, como por exemplo, em residências, em unidades comerciais, em unidades de ensino, em setores de uso comum como aeroportos, rodoviárias e estádios de futebol, e em indústrias, os quais se enquadram no conceito de geração distribuída, que é realizada através da conexão de tais sistemas à rede da concessionária (sistemas *grid-connected*) (TANNOUS et al., 2018). Esse tipo de geração pode aumentar a confiabilidade e a qualidade do sistema elétrico, desde que feita criteriosamente (KAKRAN; CHANANA, 2018; SINGH, 2013; TOLEDO; OLIVEIRA FILHO; DINIZ, 2010).

Devido aos equipamentos da usina ficarem em campo, expostos às intempéries da natureza, existe a necessidade de manutenção periódica e a possibilidade da ocorrência de defeitos (ou falhas). Falhas na planta provocam a diminuição (ou interrupção) da geração de energia, a diminuição do tempo de vida útil (ou inutilização) de equipamentos e o aumento dos custos de manutenção. Além disso, falhas não corrigidas levam a problemas de segurança como sobreaquecimento e riscos de incêndio (DHERE; SHIRADKAR, 2012).

A detecção das falhas em sistemas fotovoltaicos tem um grau de dificuldade maior do que em instalações elétricas convencionais. Isso se deve à variação da potência gerada, tensão e corrente dos painéis fotovoltaicos devido às condições

climáticas (irradiação solar e temperatura). Soma-se a isso o fato de os painéis fotovoltaicos terem uma característica natural de limitação da corrente e não linearidade da curva corrente *versus* tensão (curva I-V). Desta forma, torna-se difícil a detecção de falhas por dispositivos convencionais de proteção (SABBAGHPUR ARANI; HEJAZI, 2016; SINGH, 2013), que se baseiam em limiares de grandezas elétricas individuais (como corrente elétrica no caso de fusíveis e disjuntores).

Em uma instalação elétrica convencional, quando ocorre um curto-circuito, esse problema pode ser detectado e isolado rapidamente por fusíveis ou disjuntores devido à característica de corrente muito superior à corrente de projeto. Isso pode não ocorrer com os painéis solares devido a corrente de curto circuito de um painel fotovoltaico ser apenas um pouco maior do que a corrente em condição normal, insuficiente, portanto, para acionar um fusível ou disjuntor.

Outro problema é a localização das falhas. Em usinas geradoras fotovoltaicas o número de módulos solares pode ser grande, dependendo do porte da usina, de modo que a localização de falhas pode demandar muito tempo de trabalho de medição em campo (SABBAGHPUR ARANI; HEJAZI, 2016).

Portanto, sistemas que monitorem, detectem, classifiquem e localizem as falhas rapidamente são bem-vindos, pois reduzem a quantidade de energia perdida, os danos aos equipamentos e os custos de manutenção, através da redução no tempo de reparo.

1.1 DEFINIÇÃO DO PROBLEMA

A disponibilidade de produção de energia, o tempo de vida útil e os custos de manutenção de uma planta fotovoltaica influenciam diretamente na viabilidade econômica do investimento e no preço final da energia gerada, independente do porte (pequeno, médio ou grande) do empreendimento. Portanto, qualquer fator que possa causar a diminuição da produção de energia e do tempo de vida útil do empreendimento deve ser eficientemente minimizado.

Uma forma de atuar na minimização de tais causas é a partir da aplicação de manobras de manutenção tanto corretivas como preventivas (PERDUE; GOTTSCHALG, 2015; VILLARINI et al., 2017). Entretanto, para entender o papel

de tais manobras, é fundamental conhecer o aspecto modular de um sistema solar fotovoltaico, isto é, sua constituição desde uma célula solar individual até o sistema fotovoltaico propriamente dito, criado a partir de arranjos de painéis.

Os comportamentos atípicos e as falhas devem ser identificados rapidamente para minimizar seus efeitos negativos que são, dentre eles, perda de energia, danos aos equipamentos e diminuição de sua vida útil.

1.2 OBJETIVO GERAL

A presente dissertação tem como objetivo principal identificar comportamentos atípicos em uma *string* fotovoltaica apenas a partir de informações extraídas da tensão e da corrente geradas pela *string*.

1.3 OBJETIVOS ESPECÍFICOS

Identificar 20 condições de funcionamento diferentes em uma *string* fotovoltaica, com acurácia superior a 80% utilizando apenas os sinais de tensão e de corrente obtidos em seus terminais e uma rede neural convolucional. As 20 condições de funcionamento são compostas de funcionamento normal, sombreamento, curto-circuito e arco elétrico. São utilizados dois tipos de sombreamento: sombreamento de um painel inteiro e sombreamento de um setor de 20 células (1/3 do total) de um painel. Nos dois casos, o sombreamento consiste no bloqueio de 50% da radiação incidente. O curto-circuito é realizado entre os terminais positivo e negativo de um mesmo painel. Os dois tipos de sombreamento e o curto-circuito são realizados em cada um dos 6 painéis individualmente, enquanto o arco elétrico é gerado em apenas uma localização na *string*. Os dados ambientais de irradiação solar e temperatura ambiente são coletados e armazenados para possível análise posterior, não sendo utilizados pela rede neural.

1.4 ESTRUTURA CAPITULAR

O trabalho divide-se em 7 capítulos: no Capítulo 2 trata-se dos sistemas fotovoltaicos; no Capítulo 3 faz-se uma revisão de literatura; no Capítulo 4 são apresentadas as redes neurais como ferramentas para a resolução do problema aqui tratado; no Capítulo 5 é apresentada a metodologia utilizada; no Capítulo 6 são mostrados os resultados obtidos; por fim, a conclusão é apresentada no Capítulo 7.

2 SISTEMA FOTOVOLTAICO

2.1 ESPECTRO DA RADIAÇÃO SOLAR

A radiação solar é composta de vários comprimentos de onda, e é semelhante à radiação emitida por um corpo negro na temperatura de 6000K (VILLALVA; GAZOLI; FILHO, 2009). Ao atravessar a atmosfera o espectro dessa radiação é alterado devido à absorção desigual entre os comprimentos de onda. Portanto o espectro da radiação que atinge as células solares é diferente daquela que é emitida pelo sol. Além da radiação solar direta, as células solares são atingidas pela radiação difusa, que provém da atmosfera (luz azulada), e da radiação refletida na superfície terrestre.

O espectro da radiação incidente nas células solares depende, dentre muitos fatores, da distância percorrida no interior da atmosfera e da quantidade de vapor de água presente na atmosfera. Para avaliar o desempenho dos módulos solares é necessário utilizar uma distribuição espectral padrão, pois as células solares são sensíveis aos comprimentos de onda. A *ASTM (American Society for Testing and Materials)* define duas distribuições espectrais terrestres padronizadas: a AM1.5 normal-direta e a AM1.5 global (ou total).

A distribuição AM1.5 normal-direta é composta apenas da radiação vinda diretamente do sol e incidente perpendicularmente no módulo fotovoltaico, enquanto a AM1.5 global é composta da radiação direta, da radiação difusa e da radiação refletida na superfície da terra.

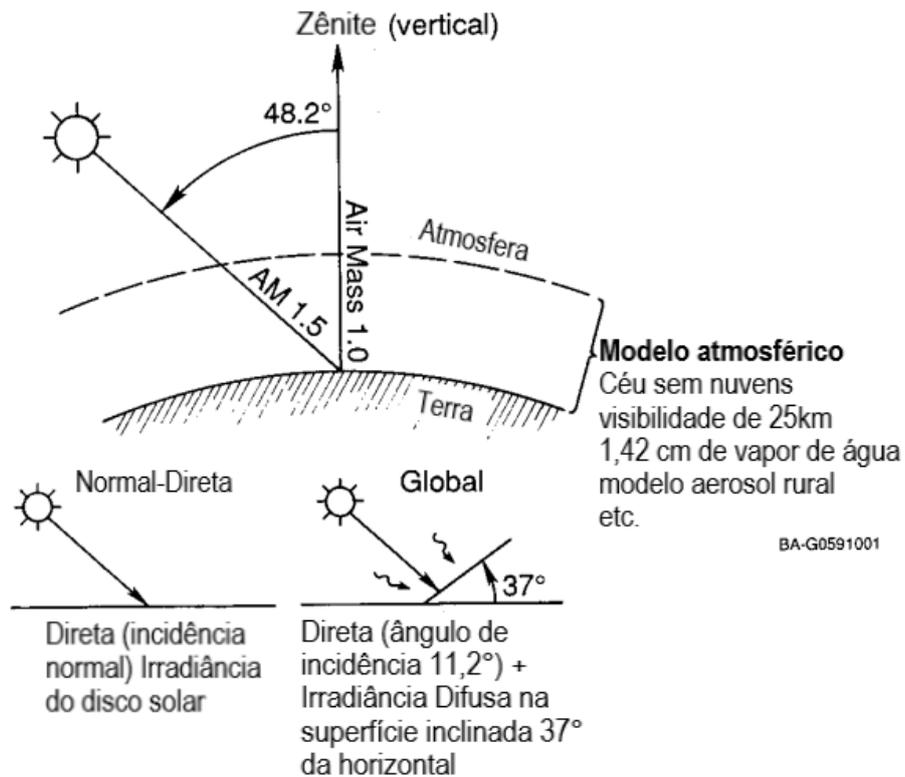
A distribuição AM1.5 normal-direta é apropriada para uso em módulos fotovoltaicos que utilizam concentradores, enquanto a AM1.5 global é apropriada para uso em coletores planos, como os módulos fotovoltaicos convencionais (RIORDAN; HULSTRON, 1990).

A sigla AM significa *Air Mass*, e o número que a segue (1.5) significa a distância relativa de atmosfera atravessada pelos raios solares (uma atmosfera e meia, nesse caso), que depende da inclinação com que a radiação incide na atmosfera. A radiação no espaço extraterrestre é referenciada como AM0.

Os padrões espectrais AM1.5 são definidos em um posicionamento do sol em ângulo de 48,19° (aproximadamente 48,2°) em relação ao Zênite (vertical) e o

painel solar inclinado 37° em relação à horizontal na direção do sol, conforme ilustrado na Figura 2.1.

Figura 2.1: Esquema das condições do espectro de referência AM1.5

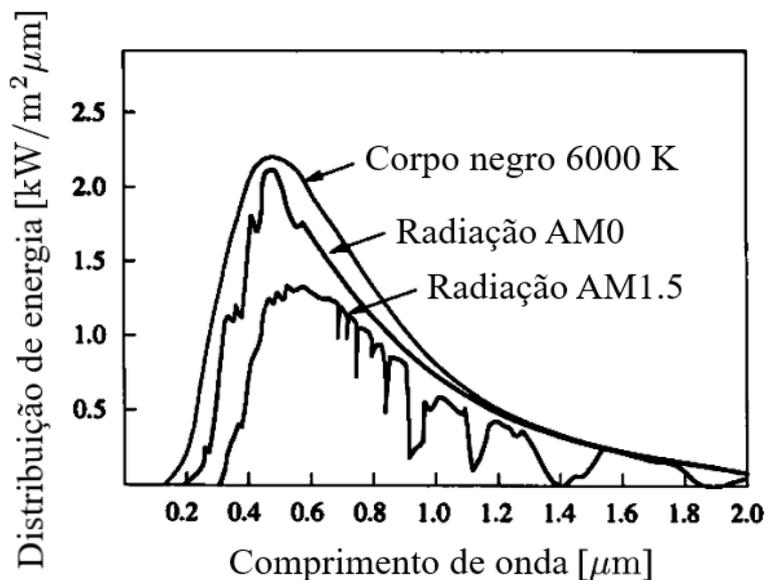


Fonte: (RIORDAN; HULSTRON, 1990).

Nota: Adaptado pelo autor.

Podemos ver na Figura 2.2 as distribuições espectrais da radiação de um corpo negro a 6000 K, da radiação solar no espaço extraterrestre e da radiação solar na superfície terrestre no padrão AM1.5.

Figura 2.2: Distribuição espectral da radiação de um corpo negro, do sol no espaço extraterrestre (AM0) e do sol no padrão AM1.5.



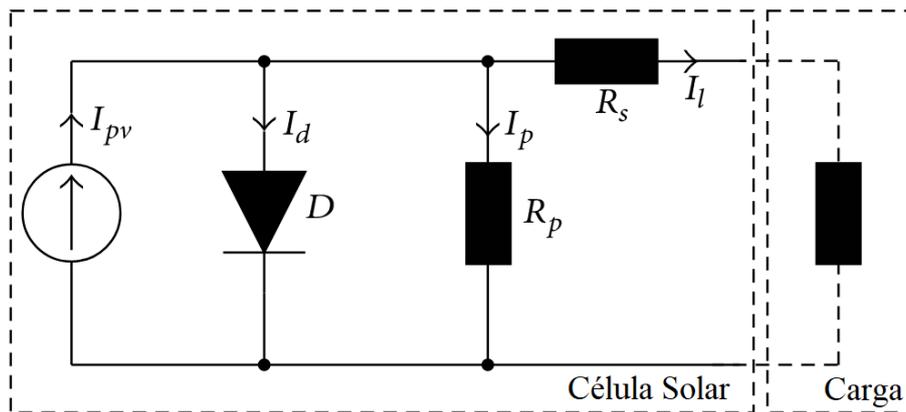
Fonte: (VILLALVA; GAZOLI; FILHO, 2009)

Nota: Adaptado pelo autor.

2.2 MODELO DA CÉLULA SOLAR

A Figura 2.3 ilustra o modelo típico de uma célula solar. Como pode ser visto na figura, a célula solar pode ser modelada por um circuito equivalente formado por uma fonte de corrente I_{pv} , que representa a corrente gerada pela luz incidente na célula solar, um diodo D , que representa a característica não linear entre a tensão e a corrente na junção semicondutora P-N, e duas resistências, R_p e R_s , que representam características de não idealidade da célula. A resistência em paralelo R_p representa um caminho para a corrente de fuga I_p , e a resistência em série R_s representa os efeitos das resistências das camadas semicondutoras P e N, resistências dos contatos de metal e condutores.

Figura 2.3: Modelo de circuito equivalente de uma célula solar



Fonte: (BAL et al., 2015).
Nota: Adaptado pelo autor.

Normalmente um módulo solar é formado por certa quantidade de células conectadas em série. Considerando que todas as células estejam em condições similares de irradiação e temperatura, a característica I-V de um módulo solar baseado no modelo de célula com um diodo é expressa por (BAL et al., 2015)

$$I_l = I_{pv} - \underbrace{I_0 \left[\exp\left(\frac{q(V + I_l R_s N_s)}{N_s A k T} - 1\right) \right]}_{I_d} - \underbrace{\left(\frac{V + I_l R_s N_s}{N_s R_p} \right)}_{I_p} \quad (2.1)$$

Onde:

I_l é a corrente fornecida pelo módulo solar à carga;

V é a tensão fornecida pelo módulo solar à carga;

I_{pv} é a corrente gerada pelo efeito fotovoltaico devido à luz incidente;

I_d é a corrente no diodo;

I_p é a corrente na resistência paralela;

I_0 é a corrente de saturação do diodo;

q é a carga do elétron ($1,60217 \times 10^{-19}$ C);

k é a constante de Boltzmann ($1,3806 \times 10^{-23}$ J/K);

A é o fator de idealidade do diodo ($1 \leq A \leq 2$);

T é a temperatura do módulo;

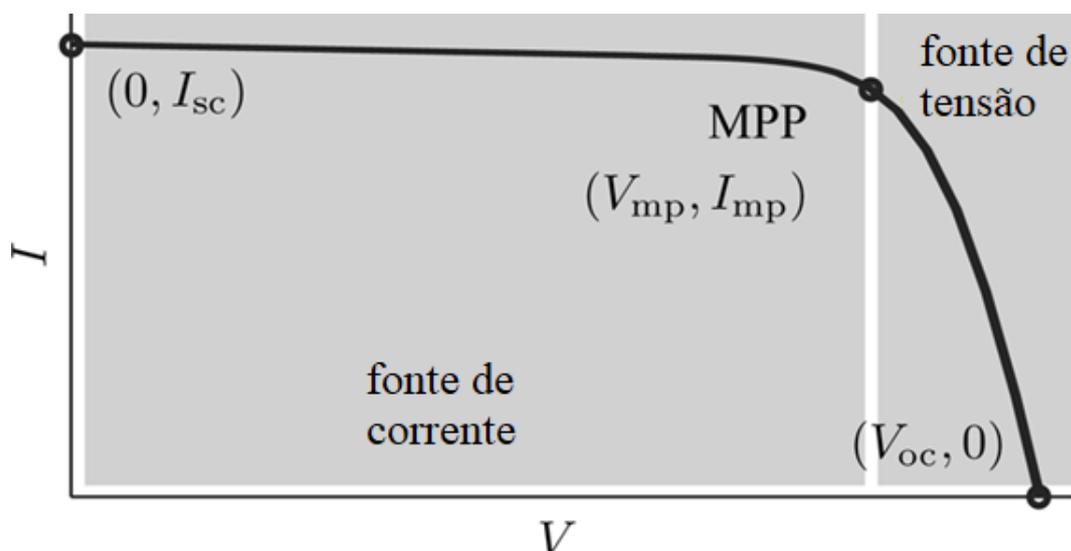
N_s é o número de células conectadas em série;

R_s é a resistência série de uma célula;

R_p é a resistência paralela de uma célula.

Para uma mesma condição de temperatura e irradiância, a característica I-V de uma célula, módulo ou arranjo fotovoltaico é uma curva não linear como mostrada na Figura 2.4, onde se pode observar alguns valores de referência que são a corrente de curto circuito (I_{sc}), a tensão de circuito aberto (V_{oc}), e a corrente e a tensão no ponto de máxima potência (I_{mp} e V_{mp}).

Figura 2.4: Característica I-V de uma célula solar



Fonte: (VILLALVA; GAZOLI; FILHO, 2009).

Nota: Adaptado pelo autor.

A curva característica I-V muda com a irradiação, temperatura das células e o espectro da radiação solar, por isso os valores de referência dos módulos fotovoltaicos são especificados em condições padronizadas de teste (*STC – Standard Test Conditions*), que são irradiância solar de 1000W/m² com espectro AM1.5, e temperatura 25°C (VILLALVA; GAZOLI; FILHO, 2009).

A corrente gerada pela luz incidente no painel (I_{pv}) varia linearmente com a irradiação solar e depende também da temperatura, de acordo com a Equação

(2.2). Geralmente, considera-se que $I_{pv} \approx I_{sc}$, pois em dispositivos reais R_s é baixa e R_p é alta (VILLALVA; GAZOLI; FILHO, 2009).

$$I_{pv} = [I_{pvrr} + K_I(T - T_r)] \frac{G}{G_r} \quad (2.2)$$

Onde:

I_{pvrr} é a corrente do efeito fotovoltaico nas condições de referência;

T_r é a temperatura de referência do módulo solar (em Kelvin);

G_r é a Irradiação de referência (1000 W/m²);

G é a irradiação solar incidente no painel;

K_I é o coeficiente de variação da corrente com a temperatura.

A corrente de saturação do diodo, I_0 , pode ser calculada de acordo com a Equação(2.3) (VILLALVA; GAZOLI; FILHO, 2009).

$$I_0 = \frac{I_{scr} + K_I \Delta T}{\exp[q(V_{ocr} + K_V \Delta T)/AkT] - 1} \quad (2.3)$$

Onde:

I_{scr} é a corrente de curto circuito nas condições de referência;

V_{ocr} é a tensão de circuito aberto nas condições de referência;

$\Delta T = (T - T_r)$ é a diferença de temperatura em relação à temperatura de referência.

2.3 ESTRUTURA DE UM SISTEMA FOTOVOLTAICO

A tensão gerada por uma única célula é pequena, variando de valores de aproximadamente 0,5 V a 0,9 V para células de silício, 1 a 1,1 V para as de Arseneto de Gálio, podendo chegar até próximo de 4,8V para células multijunção de 5 junções.

A capacidade de corrente da célula é proporcional à área, com valores de densidade de corrente entre 16 a 42 mA/cm² para células de silício, dependendo da tecnologia (GREEN et al., 2017), podendo gerar em torno de 9 A para uma célula com densidade de corrente de 40 mA/cm² e dimensões 15x15 cm. Uma célula de silício com estas dimensões é capaz de gerar de 4,5 a 8,1 W de potência.

Visto que a potência gerada por uma única célula solar é pequena frente à maioria dos equipamentos elétricos, para gerar uma quantidade de potência a um nível utilizável, são necessárias várias células.

Para aumentar a tensão gerada, as células são conectadas em série, e para aumentar a corrente são conectadas em paralelo. Variando o número de células em série e em paralelo, é possível ajustar os valores de tensão e corrente de acordo com a necessidade.

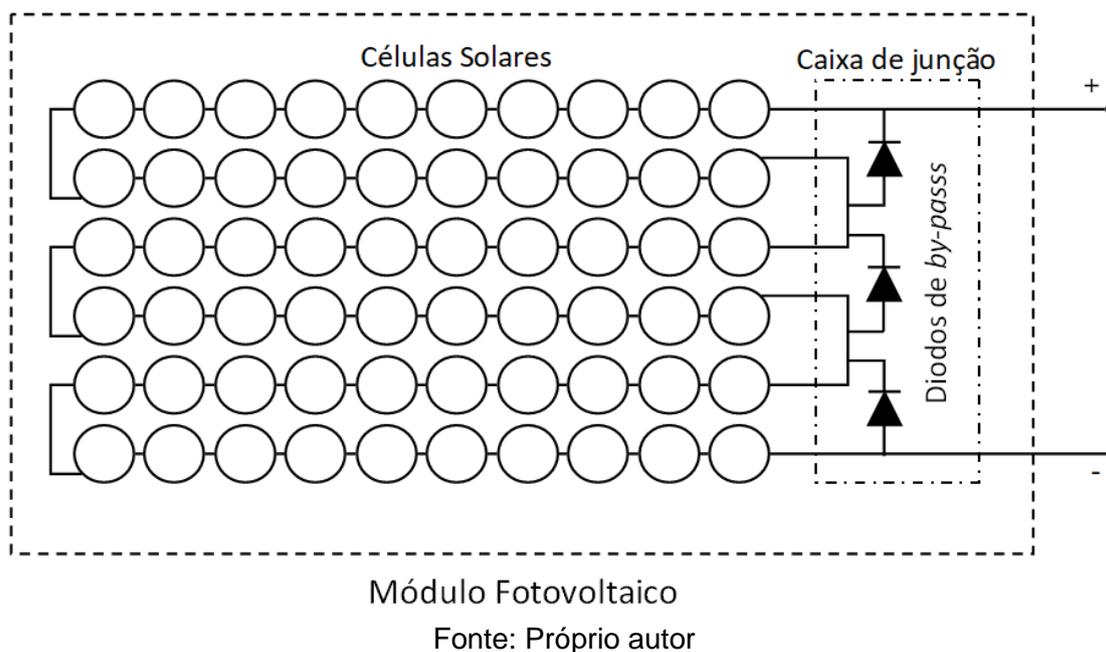
Devido ao baixo valor de tensão da célula, no nível mais baixo de agrupamento, um número da ordem de dezenas de células é conectado em série e encapsulado em unidades chamadas módulos solares (também conhecidos como painéis solares).

A Figura 2.5 mostra um exemplo de interligação das células solares em um módulo solar de 60 células. Os diodos de *by-pass* servem para minimizar possíveis polarizações reversas nas células solares, que podem ocorrer em condições atípicas, como sombreamento. Normalmente é utilizado um diodo de *by-pass* para cada 20 células, aproximadamente.

Em um segundo nível de agrupamento, os módulos solares são interconectados em série, formando o que é chamado de *string*, para obter a tensão final desejada.

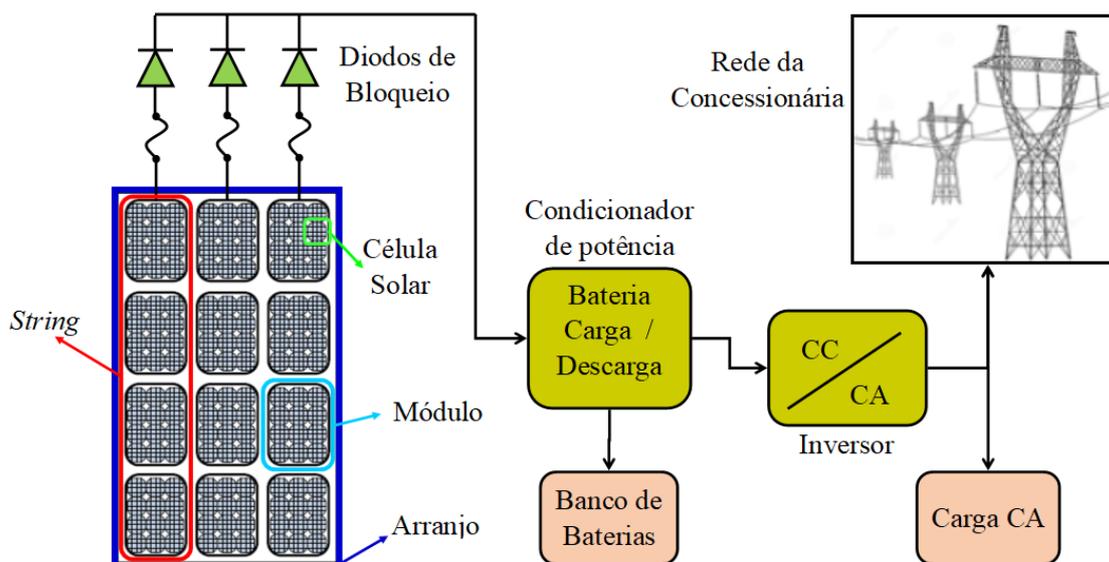
No terceiro nível de agrupamento, as *strings* são conectadas em paralelo para obter o nível de corrente desejado, formando o chamado arranjo fotovoltaico ou gerador solar, com a capacidade de potência requerida (ABDULMAWJOOD; REFAAT; MORSI, 2018; SINGH, 2013).

Figura 2.5: Exemplo de interligação interna das células em um módulo solar



A Figura 2.6 ilustra os componentes de um sistema fotovoltaico típico. É formado por um arranjo de módulos solares, diodos de bloqueio, um condicionador de potência, um sistema de armazenamento e um inversor conectado à rede de energia elétrica da concessionária e à carga (ABDULMAWJOOD; REFAAT; MORSI, 2018; SINGH, 2013).

Figura 2.6: Componentes do sistema fotovoltaico



Fonte: (ABDULMAWJOOD; REFAAT; MORSI, 2018).

Nota: Adaptado pelo autor.

A função do arranjo fotovoltaico é converter a energia solar em energia elétrica. A corrente elétrica no arranjo flui sempre no mesmo sentido. A corrente com este comportamento é chamada de corrente contínua CC (*DC – Direct Current*). O diodo de bloqueio serve para evitar que a corrente flua em sentido contrário em períodos de baixa irradiação solar (o que poderia provocar a descarga da bateria).

O condicionador de potência contém um rastreador de ponto de máxima potência (*MPPT– Maximum Power Point Tracker*), e um controlador de carga e descarga da bateria. A função do *MPPT* é extrair a máxima potência do arranjo em qualquer condição de irradiação, enquanto a do controlador de carga e descarga é evitar sobrecarga ou sobredescarga da bateria, prolongando sua vida útil.

A bateria serve para armazenar energia para períodos sem irradiação solar. Este item é opcional em sistemas conectados à rede de distribuição da concessionária. É normalmente utilizado em sistemas isolados, onde não há rede de distribuição da concessionária de energia disponível, sendo necessário para manter a continuidade do fornecimento de energia em períodos de baixa ou nenhuma insolação.

O inversor de potência converte a corrente contínua do arranjo fotovoltaico em corrente alternada e a injeta na rede da concessionária (SINGH, 2013).

2.4 DEFEITOS EM SISTEMAS FOTOVOLTAICOS

Um defeito ou falha é qualquer efeito que diminua a potência de saída de um sistema fotovoltaico (LIVERA et al., 2019). Os defeitos podem ser classificados quanto à sua localização. Podem estar no lado CC ou no lado CA. A interface entre estas duas partes é o inversor, que converte a corrente contínua em alternada, e que, dependendo da configuração do sistema, pode conter também um *MPPT* (rastreador do ponto de máxima potência).

No lado CA, as principais falhas são no inversor, ou na rede da concessionária de energia elétrica, como falta de energia devido à manutenção, ou atuação de algum dispositivo de proteção, normalmente provocado por raios, sobrecarga,

sobretensão, ou ainda desbalanceamento das tensões (DAVARIFAR; RABHI; HAJJAJI, 2013).

No lado CC os defeitos podem ocorrer nos módulos, ou nas *strings* devido a sombreamento, acúmulo de sujeira ou neve, degradação, corrosão, e problemas no diodo de *by-pass*. Também podem ocorrer defeitos no cabeamento como falhas em conexões (circuito aberto), curto-circuito, ou perda de potência devido à resistência elétrica em conexões ruins (ABDULMAWJOOD; REFAAT; MORSI, 2018).

Quanto à característica temporal, os defeitos podem ser classificados como temporários ou permanentes. Os defeitos temporários podem surgir e desaparecer depois de certo tempo por ação do próprio ambiente, ou por uma ação de limpeza dos painéis. Entre eles, inclui-se o sombreamento (causado por obstáculos entre o sol e o painel) e o acúmulo de materiais diversos sobre os painéis (folhas, excrementos de pássaros, sujeira, neve) que diminuem a radiação incidente nas células.

Os defeitos permanentes causam danos irreversíveis ao painel e, portanto, perduram até uma ação de manutenção, como substituição do componente defeituoso ou do módulo solar.

São classificadas como permanentes: falhas nas conexões entre os módulos, ou entre células de um mesmo módulo (curto-circuito, circuito aberto, e danos parciais nas interconexões), no diodo de *by-pass*, degradação, corrosão, pontos quentes, soldas ruins, dentre outros fatores (ABDULMAWJOOD; REFAAT; MORSI, 2018; DAVARIFAR; RABHI; HAJJAJI, 2013; LIVERA et al., 2019; MADETI; SINGH, 2017).

2.5 DEFEITOS NOS MÓDULOS FOTOVOLTAICOS

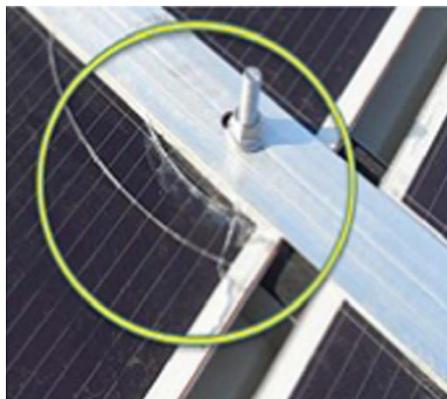
São defeitos que ocorrem dentro dos módulos fotovoltaicos. Nas subseções a seguir são apresentados os principais defeitos dessa natureza.

2.5.1 Falhas de encapsulamento

São três as principais falhas de encapsulamento, isto é, quebra de vidro, descoloração e delaminação. A quebra de vidro (Figura 2.7) é um defeito que pode causar penetração de umidade, podendo provocar corrosão no módulo,

perda de isolamento e adesão, aumento da corrente de fuga, diminuição da resistência para a terra (TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018).

Figura 2.7: Quebra do vidro frontal



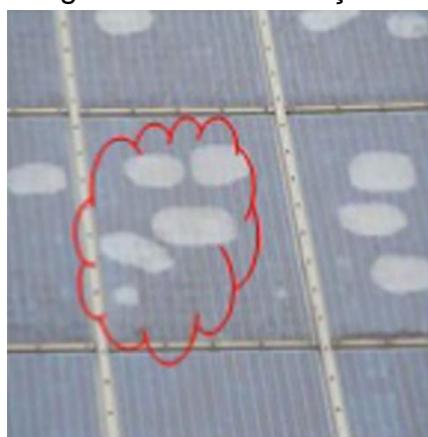
Fonte: (MELLIT; TINA; KALOGIROU, 2018)

Nota: Adaptada pelo autor

A descoloração, amarelamento ou escurecimento pode ser causado por uma baixa qualidade do encapsulamento EVA (*Ethylene Vinyl Acetate*), exposição à radiação ultravioleta ou aquecimento (LIVERA et al., 2019; MADETI; SINGH, 2017).

A delaminação (Figura 2.8) é a perda de aderência entre camadas do encapsulamento formando espaços entre elas. Causa reflexão de parte da radiação solar com conseqüente perda de potência gerada e penetração de umidade (ABDULMAWJOOD; REFAAT; MORSI, 2018).

Figura 2.8: Delaminação



Fonte: (MELLIT; TINA; KALOGIROU, 2018)

Nota: Adaptada pelo autor

2.5.2 Perda de aderência da folha traseira

A folha traseira protege os componentes internos das intempéries e provê segurança contra as altas tensões. Caso ela se solte, provocará a exposição dos componentes, causando problemas de segurança. Pode ser causado pela delaminação ou pela composição de seus materiais (TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018).

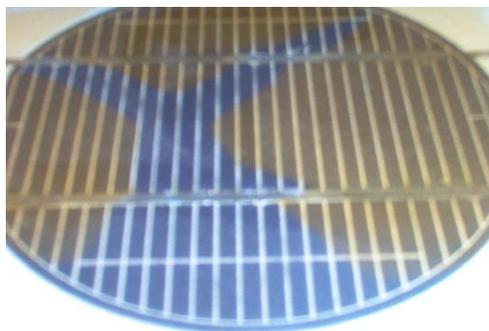
2.5.3 Quebra de interconexão

Desconexão da fita que conecta as células internamente no painel. Pode ser causada por soldagem de baixa qualidade, vibrações ou choques no transporte, *hot spot*, ciclo térmico, forças mecânicas repetitivas, distância pequena entre as células ou corrosão. Pode causar aumento da resistência série, circuito aberto ou curto-circuito (TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018).

2.5.4 Corrosão

Ataca as conexões metálicas e afeta a adesão entre a armação metálica e as células (TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018). Pode causar também arco elétrico do tipo série, caso haja uma desconexão de junção dos condutores (MADETI; SINGH, 2017) ou perda de potência. Pode atingir os contatos da caixa de junção, aumentando sua resistência, podendo causar danos e risco de incêndio (MELLIT; TINA; KALOGIROU, 2018). Pode ser originada pela entrada de umidade no módulo (SABBAGHPUR ARANI; HEJAZI, 2016).

Figura 2.9: Corrosão do barramento e conexões por penetração de umidade

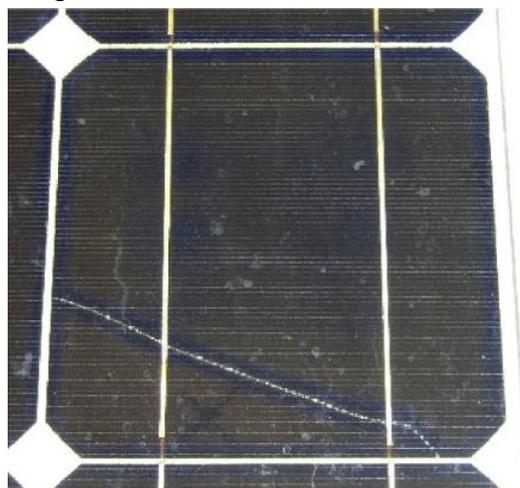


Fonte: (KAPLANIS; KAPLANI, 2011)

2.5.5 Rachaduras nas células

Podem ser causadas por defeitos na fabricação da célula ou módulo, transporte ou instalação. Rachaduras maiores podem ser detectadas por inspeção visual. Micro rachaduras podem ser detectadas pelo método da eletroluminescência, ultrassom ou raios-X (MADETI; SINGH, 2017; TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018). Causam diminuição na potência e na corrente gerada (LIVERA et al., 2019). Na Figura 2.10 podemos ver uma célula com rachadura.

Figura 2.10: Célula com rachadura



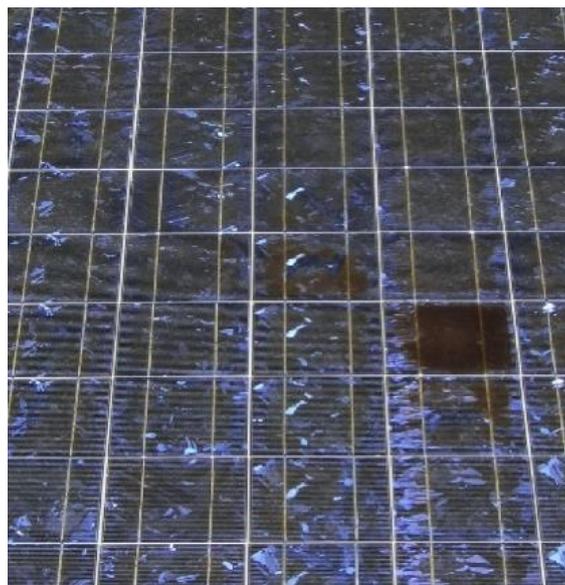
Fonte: (LIVERA et al., 2019)

Nota: Adaptada pelo autor

2.5.6 Falha de degradação

A degradação causa diminuição na potência gerada pelo módulo solar. É causada por vários fatores já citados que podem diminuir a irradiação incidente na célula (degradação ótica), como descoloração (amarelamento ou escurecimento), delaminação, bolhas, ou defeitos na cobertura anti-reflexiva, ou aumentar a resistência série, causando perda de potência por efeito joule (degradação elétrica), como quebra ou corrosão nas interconexões, e rachaduras nas células (DALIENTO et al., 2017; SABBAGHPUR ARANI; HEJAZI, 2016).

Figura 2.11: Célula escurecida



Fonte: (LIVERA et al., 2019)

Nota: Adaptada pelo autor

Existem ainda outros tipos de degradação, como a degradação induzida por potencial (*PID*, do inglês *Potential Induced Degradation*) e a degradação induzida por luz (*LID*, do inglês *Light Induced Degradation*).

A *PID* é causada por correntes de fuga em sistemas não aterrados (que não tem nenhum dos condutores transportadores de corrente aterrados). Módulos fotovoltaicos com diferença de potencial em relação ao quadro metálico aterrado estão sujeitos a degradação, principalmente em potenciais negativos. A degradação é acelerada por altas tensões, temperaturas e umidade (LIVERA et al., 2019; PINGEL et al., 2010; TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018).

A *LID* é causada pela exposição à luz solar devido à ativação de defeitos Boro-Oxigênio e Ferro-Boro. Tem um efeito mais intenso em módulos de Silício monocristalino (tipo p com Boro) e menos intenso em módulos de Silício multicristalino, isso devido à menor concentração de Oxigênio (LIVERA et al., 2019).

2.5.1 Falha na caixa de junção

A caixa de junção é um compartimento fixado na folha traseira do módulo, onde são feitas as conexões da fiação que vem das células no interior do módulo com os diodos de *by-pass* que ficam no interior da caixa de junção, e com os cabos

terminais que serão conectados aos outros módulos da *string*. As causas de falha na caixa de junção são: fixação ruim na folha traseira, penetração de umidade, corrosão das conexões, montagem das conexões ruim ou degradação térmica (TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018).

Segundo (MAOYI CHANG et al., 2015), 85% das falhas em caixas de junção tiveram contribuições do processo de instalação do sistema e 15% dos fabricantes dos módulos e das caixas de junção. Os principais tipos de falha nas caixas de junção são diodos de *by-pass* queimados (60,7%), caixa de junção queimada (21,9%), e potência baixa sem queima aparente (15,1%). As principais causas destes três tipos de falhas nas caixas de junção foram: energia sobre estresse, retrabalho no cabo, cabo não soldado, fita inserida não adequadamente, dobra de cabo, puxamento do cabo, retrabalho no conector e cabo não abraçado.

2.6 DEFEITOS NO CABEAMENTO

São defeitos que ocorrem nos cabos e conexões do sistema fotovoltaico, inclusive nos condutores internos aos módulos. As subseções a seguir trazem os principais defeitos desta natureza.

2.6.1 *Falha de circuito aberto*

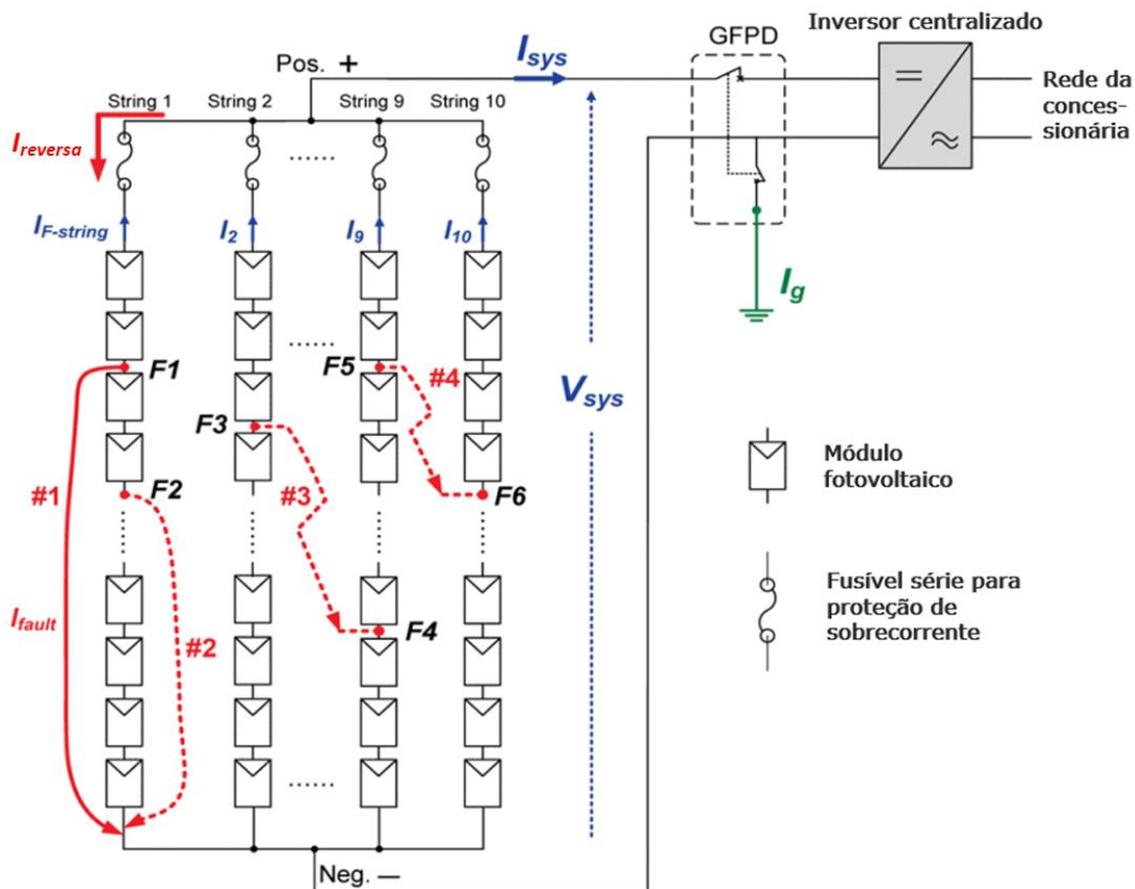
Desconexão causada por falha nas soldagens ou interconexões dentro do módulo fotovoltaico, na caixa de junção ou nos cabos de conexão. Provoca queda na corrente de curto-circuito do arranjo, enquanto a tensão de circuito aberto permanece inalterada (ABDULMAWJOOD; REFAAT; MORSI, 2018; SABBAGHPUR ARANI; HEJAZI, 2016).

2.6.2 *Falha linha a linha*

É um contato acidental de baixa impedância entre dois pontos do arranjo fotovoltaico com potenciais elétricos diferentes, da mesma *string* ou de *strings* diferentes, não envolvendo condutores aterrados. Pode ser causada por problemas de isolamento de condutores e conectores ou danos mecânicos. Esta falha causa redução na tensão de circuito aberto do arranjo, porém a corrente

de curto-circuito é mantida inalterada (ABDULMAWJOOD; REFAAT; MORSI, 2018; MELLIT; TINA; KALOGIROU, 2018).

Figura 2.12: Falha linha a linha em várias localizações no arranjo fotovoltaico



Fonte: (ZHAO et al., 2013)

Nota: Adaptada pelo autor

2.6.3 Falha para a terra

Contato acidental entre um ou mais condutores transportadores de corrente (+ ou -) e o terra. É uma das falhas mais comuns em sistemas fotovoltaicos. Pode causar um grande aumento de corrente nos condutores afetados, gerar arco elétrico e perigo de incêndio. Pode ser causada por falha no isolamento, sobreaquecimento ou envelhecimento dos cabos condutores, ou falha no isolamento dos módulos fotovoltaicos (ABDULMAWJOOD; REFAAT; MORSI, 2018; MELLIT; TINA; KALOGIROU, 2018).

2.6.4 Falha de arco

O arco elétrico é a condução de corrente elétrica através do ar ou outro dielétrico, provocando faíscas e altas temperaturas. É classificado em duas categorias:

série e paralelo. O arco série ocorre quando um condutor transportador de corrente, que interliga as células, os módulos, ou uma conexão que une esses condutores, se rompe dentro ou fora dos módulos e a corrente contínua fluindo pelo ar. Já o arco paralelo ocorre quando o isolamento entre dois condutores próximos de potenciais diferentes falha, provocando um curto-circuito.

Diferentemente de sistemas em CA, em sistemas CC a corrente não passa periodicamente por zero, o que é um agravante, gerando uma ignição mais sustentada.

A falha de arco provoca ruído de alta frequência, podendo provocar queda súbita de tensão no caso do arco paralelo, e é muito perigosa, pois pode provocar incêndio (ABDULMAWJOOD; REFAAT; MORSI, 2018; ALAM et al., 2014; MELLIT; TINA; KALOGIROU, 2018; TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018).

Figura 2.13: Caixa de junção destruída por falha de arco.



Fonte: (DHERE; SHIRADKAR, 2012)

2.7 DEFEITOS DE INCOMPATIBILIDADE

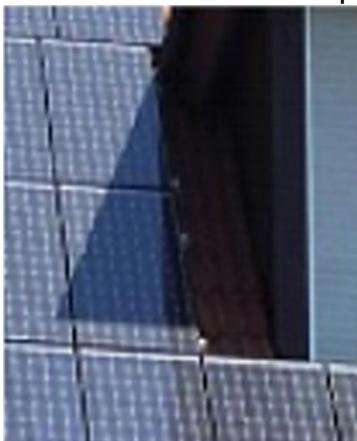
Ocorre quando os parâmetros elétricos de uma ou mais células/módulos são significativamente diferentes. Pode ser causada por interconexão de células/módulos com curva I-V diferentes, tais como módulos fabricados com diferentes tecnologias, ou valores nominais diferentes, ou sujeitos a condições ambientais diferentes como irradiação ou temperatura, ou ainda, que sofreram degradação, como células defeituosas ou circuito aberto. Pode levar a danos

irreversíveis nos módulos, devido a aquecimento excessivo, e gerar grande perda de potência. É difícil de detectar usando dispositivos convencionais de proteção, pois tais falhas não produzem correntes altas (DAVARIFAR; RABHI; HAJJAJI, 2013; LIVERA et al., 2019; MELLIT; TINA; KALOGIROU, 2018; TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018).

2.7.1 Falha de sombreamento parcial

O sombreamento parcial é causado por nuvens, fumaça, obstáculos próximos ao arranjo fotovoltaico, que se interpõe entre o sol e os módulos, como construções, postes, árvores, ou objetos sobre os módulos como folhas de árvores, neve, ou excremento de pássaros, bloqueando a luz em parte das células ou módulos do arranjo. Provoca incompatibilidade, perda de energia e sobreaquecimento nas células (ABDULMAWJOOD; REFAAT; MORSI, 2018; DAVARIFAR; RABHI; HAJJAJI, 2013; LIVERA et al., 2019; MELLIT; TINA; KALOGIROU, 2018).

Figura 2.14: Sombreamento parcial



Fonte:(MELLIT; TINA; KALOGIROU, 2018)

Nota: Adaptado pelo autor

Outra forma de sombreamento é o empoeiramento, isto é, o acúmulo de material sobre a superfície dos módulos como poeira ou sujeira, diminuindo a radiação que deveria incidir sobre as células solares, reduzindo seu rendimento (ABDULMAWJOOD; REFAAT; MORSI, 2018).

Figura 2.15: Acúmulo de poeira sobre os módulos solares



Fonte: (MELLIT; TINA; KALOGIROU, 2018)

Nota: Adaptada pelo autor

2.7.2 Falha de pontos quentes (*hot spots*)

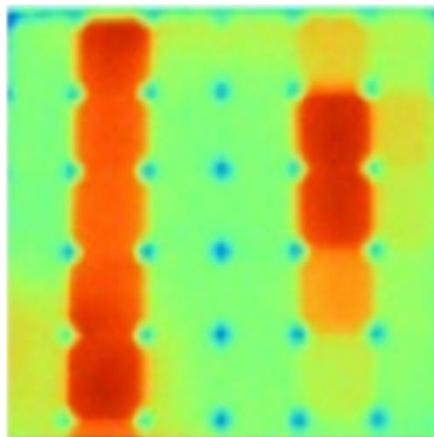
Ocorre por defeitos em conexões, como “solda fria”, causando aumento de resistência elétrica em conexões, ou, quando uma ou mais células solares trabalham reversamente polarizadas, dissipando potência ao invés de produzi-la, que é o comportamento conhecido como *hot spotting* (KIM, K. A. et al., 2016).

Neste caso, sendo causada por sombreamento parcial ou falha de incompatibilidade. O excesso de calor produzido leva ao aumento de temperatura nas células afetadas, causando os pontos quentes (*hot spots*).

A causa do *hotspotting* é que muitas células em série submetidas a uma irradiação solar maior forçam a circulação de corrente em células sujeitas a irradiação menor (que estão gerando menos corrente), ou defeituosas, causando a polarização reversa. Esta falha provoca o sobreaquecimento das células, acelerando a degradação ótica e mecânica (LIVERA et al., 2019; MADETI; SINGH, 2017; MELLIT; TINA; KALOGIROU, 2018; TRIKI-LAHIANI; BENNANI-BEN ABDELGHANI; SLAMA-BELKHODJA, 2018).

Para diminuir os efeitos desta falha, são adicionados diodos de *by-pass* em paralelo com um determinado número de células, evitando a polarização reversa nesse grupo. Em caso de falha nos diodos de *by-pass*, a mitigação dos efeitos de aquecimento não será possível.

Figura 2.16: Imagem termográfica mostrando as células sobreaquecidas em vermelho



Fonte: (MELLIT; TINA; KALOGIROU, 2018)

Nota: Adaptado pelo autor

2.8 FALHA EM EQUIPAMENTOS ELETRÔNICOS

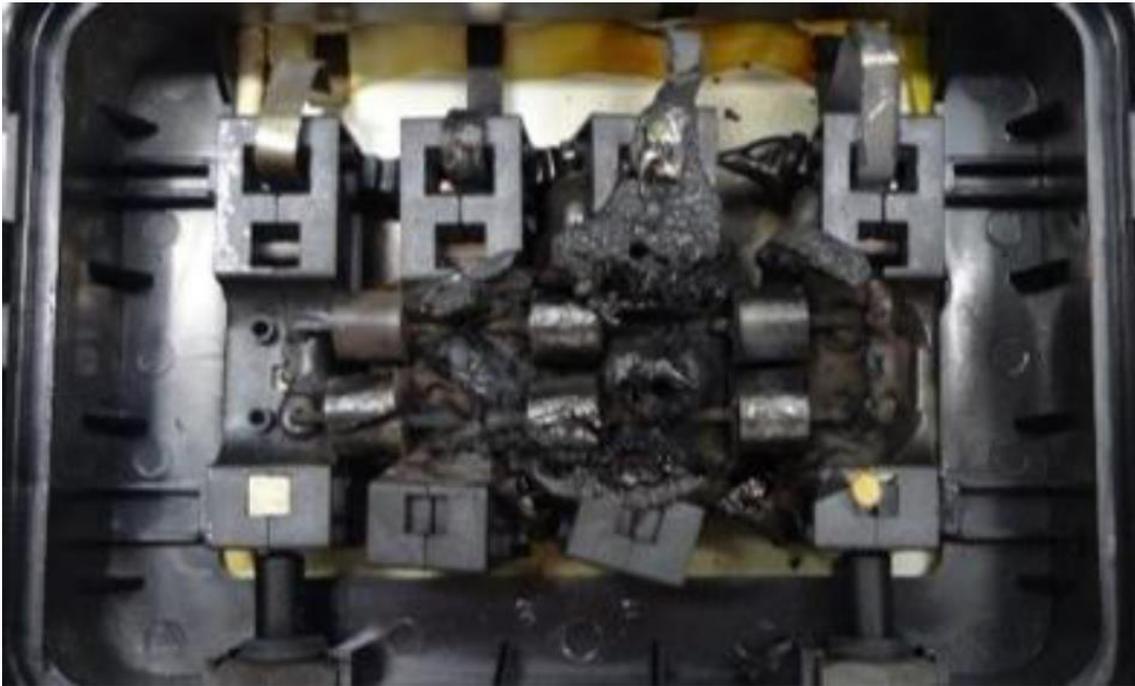
São falhas de dispositivos eletrônicos que controlam o fluxo de energia gerado pelo módulo fotovoltaico. As subseções a seguir descrevem falhas desta natureza.

2.8.1 Falha nos diodos (*by-pass* e *bloqueio*)

Os diodos podem estar nas situações de curto-circuito, circuito aberto ou conectado de forma invertida. A primeira condição pode ser causada por picos de tensão ou corrente induzidos por descargas atmosféricas (raios) próximas ao arranjo fotovoltaico. Neste caso, o diodo se comportará como um resistor.

O diodo de *by-pass* só opera em caso de sombreamento. Caso esteja em curto-circuito, ele poderá sobreaquecer, causando danos à caixa de junção e perigo de incêndio se o sombreamento for prolongado. Se estiver aberto, não desempenhará sua função de mitigar o sobreaquecimento no módulo em caso de ocorrência de sombreamento parcial (ABDULMAWJOOD; REFAAT; MORSI, 2018; MADETI; SINGH, 2017; MELLIT; TINA; KALOGIROU, 2018; OKE et al., 2018). Em caso de conexão invertida por erro de montagem, provocará problemas tanto em funcionamento normal quanto em sombreamento parcial.

O diodo de bloqueio opera em caso de corrente invertida na *string*. Se estiver em curto, não desempenhará sua função e se estiver aberto ou invertido, não haverá corrente na *string*.

Figura 2.17: Diodos de *by-pass* defeituosos

Fonte: (OKE et al., 2018)

2.8.2 Falha no MPPT

Esta falha provoca baixa, ou até nenhuma, produção de energia, devido ao arranjo não trabalhar no ponto de maior potência, ou ficar em circuito aberto. Normalmente tal falha ocorre devido a falha nos dispositivos semicondutores ou nas junções soldadas. Este tipo de falha atinge em torno de 41% dos sistemas conectados à rede (JAMSHIDPOUR; POURE; SAADATE, 2015).

2.8.3 Falha no inversor

Pode ser causada por alto estresse térmico ou mecânico nas chaves eletrônicas ou falha em outros componentes como capacitores ou circuitos de acionamento (MADETI; SINGH, 2017). Os inversores normalmente têm vida útil menor que os módulos solares, sendo, portanto, um tipo de falha relativamente comum.

3 DIAGNÓSTICO DE FALHAS

O diagnóstico de falhas nos sistemas fotovoltaicos compreende a detecção e a classificação dessas falhas em categorias ou causas. Os métodos de diagnóstico de falhas são baseados nas abordagens de inspeção visual, métodos de imagens e técnicas de análise de dados (métodos elétricos).

Os métodos elétricos podem ainda ser classificados em *on-line* e *off-line*. Os métodos *on-line* podem trabalhar concomitantemente com a geração de energia, não sendo necessário o desligamento do sistema. Os métodos *off-line* não podem trabalhar com o sistema energizado, sendo necessário seu desligamento.

Os métodos elétricos *on-line* têm como vantagem a característica de detectar rapidamente as falhas, pois estão em constante operação. A inspeção visual pode levar muito tempo caso a planta seja grande e necessita de mão de obra treinada, mas é necessária para avaliar e controlar as causas externas de possíveis falhas e a verificar a necessidade de uma análise mais profunda. Já os métodos de imagem podem identificar problemas internos bastante específicos, identificando as causas das falhas e fornecendo informações para possíveis melhorias nos processos de fabricação, montagem e operação das plantas. Portanto é desejável a integração de diferentes métodos para detecção e localização de um número maior de falhas, principalmente aquelas que provocam efeitos semelhantes nas características elétricas (LIVERA et al., 2019).

Em (ALAM et al., 2015) é destacado que as falhas à terra, linha a linha, e arco são as principais causas de falhas catastróficas que podem resultar em incêndios, como os ocorridos em Bakersfield em 2009 e em Mount Holly em 2011. Algumas falhas podem permanecer indetectáveis ou demorarem para ser detectadas antes que se inicie um processo de incêndio.

3.1 INSPEÇÃO VISUAL

A avaliação visual é um dos métodos mais simples e práticos para detectar defeitos visíveis e podem identificar várias falhas permanentes como delaminação, descoloração (amarelamento e escurecimento), bolhas, flexão, marcas de queima, quebra de vidro, células quebradas ou trincadas, fiação

exposta, oxidação ou corrosão de interligações, trilhas de caracol e falhas temporárias como poeira, sujeira, folhas, excrementos de pássaros e sombra.

As inspeções visuais normalmente são feitas com frequência e regularidade para encontrar problemas e, caso necessário, realizar outros testes. Entretanto, a inspeção visual depende da habilidade de quem a realiza e pode tornar-se entediante, não ser confiável, ou pode levar muito tempo para detectar as falhas (ABDULMAWJOOD; REFAAT; MORSI, 2018; LIVERA et al., 2019).

3.2 TÉCNICAS DE IMAGEM

As técnicas de imagem utilizam equipamentos específicos para obtenção de imagens, e podem indicar, com precisão, a localização da falha (LIVERA et al., 2019). Os principais métodos que utilizam imagens são eletroluminescência, fotoluminescência, infravermelho (termografia) e ultrassom.

No método de eletroluminescência, a imagem é obtida a partir de fótons emitidos pela recombinação de portadores de carga excitados na célula solar. A intensidade de emissão nas imagens é proporcional à densidade de corrente e ao tempo de vida dos portadores. Este método pode identificar distribuição de corrente não uniforme, conexões ruins e rachaduras (MADETI; SINGH, 2017). Neste caso, a célula funciona como um diodo emissor de luz, de modo que as áreas com defeito aparecem mais escuras, enquanto as sem defeito aparecem mais claras. A excitação é conseguida por meio de uma corrente injetada na célula solar, enquanto a câmera registra a imagem. A corrente injetada deve estar entre 10% e 100% da corrente de curto-circuito da célula. Densidades de correntes baixas (10%) permitem analisar as propriedades do material da célula, enquanto que as altas (100%) permitem analisar as propriedades dos contatos elétricos (EBNER; KUBICEK; UJVARI, 2013).

O custo desta técnica pode ser alto, sendo aplicável apenas a painéis fora de operação (ABDULMAWJOOD; REFAAT; MORSI, 2018). A excitação da célula pode ser feita através de radiação incidindo na célula. Neste caso, o método é chamado de fotoluminescência.

O método termográfico, ou escaneamento térmico, utiliza câmeras sensíveis às radiações infravermelhas para observar o comportamento térmico dos painéis

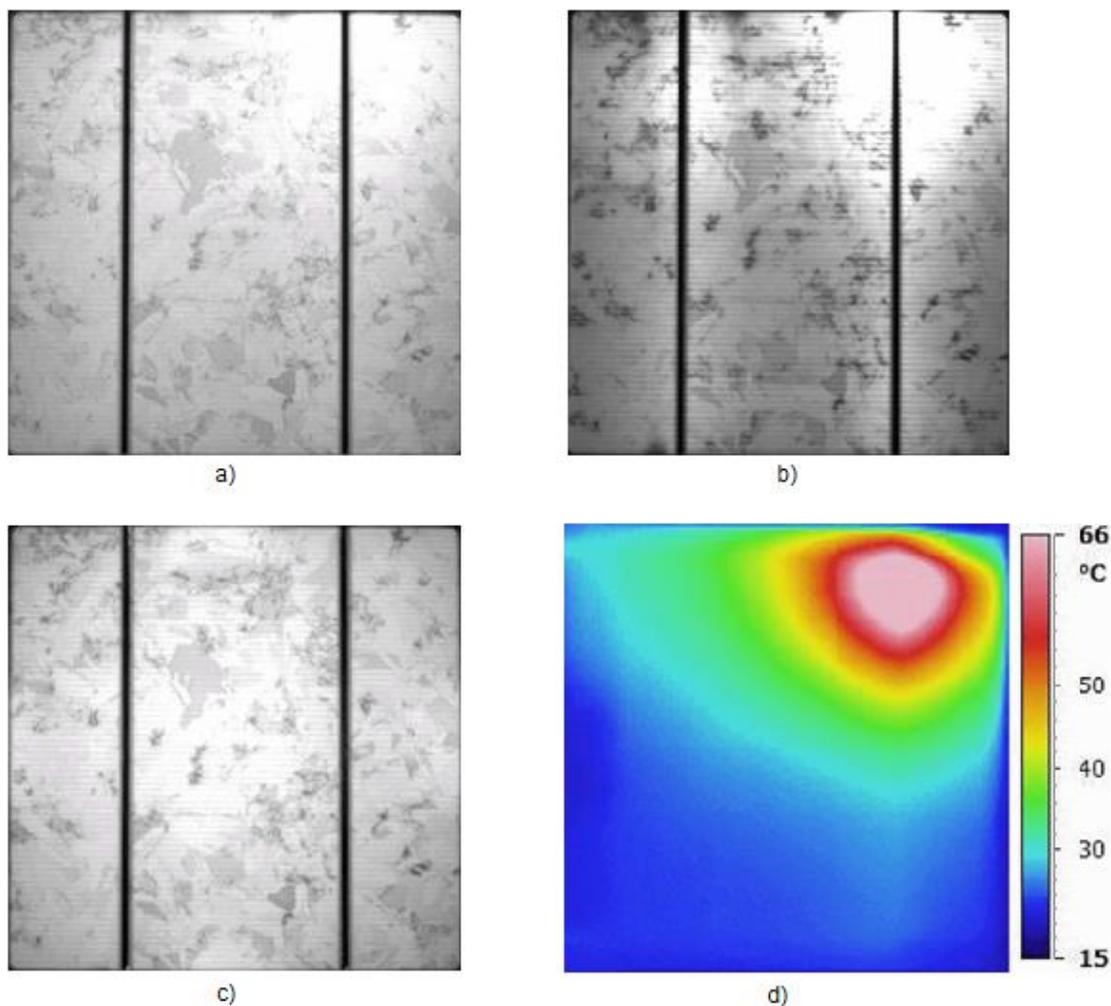
solares. Neste método, é possível detectar as diferenças de temperatura nas células/módulos/arranjo para localizar a posição do defeito via dissipação de calor (efeito joule). As elevações de temperatura são causadas por maus contatos nas interconexões ou na fiação do módulo, curtos-circuitos internos, diodos de derivação defeituosos, elevação da resistência série da célula, incompatibilidade entre células, trilhas de caracol e rachaduras de células.

Células em série gerando menos corrente que outras podem operar reversamente polarizadas e dissiparem calor como um resistor. Módulos com circuito aberto, degradação induzida por potencial (*PID*) e delaminação também podem ser identificados por este método (ABDULMAWJOOD; REFAAT; MORSI, 2018; LIVERA et al., 2019; MADETI; SINGH, 2017).

O método termográfico pode ser feito com o painel iluminado em circuito aberto, curto-circuito, no ponto de máxima potência, ou em condição sem iluminação, aplicando uma corrente no sentido direto ao módulo com uma fonte externa (EBNER; KUBICEK; UJVARI, 2013).

A Figura 3.1 ilustra os vários métodos descritos acima aplicados a uma célula com alta resistência série, fornecendo aproximadamente metade da potência de uma célula sem defeito. Em a) e b) é vista uma área brilhante na borda superior no lado direito e em torno do barramento, onde há uma alta densidade de fluxo de corrente elétrica. Em c) é mostrada a imagem da fotoluminescência, onde não se vê defeitos além dos limites dos grãos. Assim, conclui-se que o defeito é causado por um mau contato. Apenas na parte superior direita há um bom contato elétrico no barramento. Em d) é mostrada a imagem de termografia (infravermelho), onde a temperatura mais alta é justamente onde há a maior densidade de corrente, o que poderia ser confundido com ponto quente ou curto-circuito, se analisada individualmente (EBNER; KUBICEK; UJVARI, 2013).

Figura 3.1: a) eletroluminescência (0,8 A) b) eletroluminescência (8 A) c) fotoluminescência d) infravermelho



Fonte: (EBNER; KUBICEK; UJVARI, 2013)

Nota: Adaptado pelo autor

3.3 TÉCNICAS BASEADAS EM DISPOSITIVOS DE PROTEÇÃO

São técnicas baseadas na utilização de dispositivos que interrompem o circuito elétrico em caso de falha. O tipo de dispositivo utilizado é compatível com a estratégia de aterramento utilizada. Os principais dispositivos utilizados são o fusível *GFDI* (*Ground Fault Detection and Interrupt*), o *RCD* (*Residual Current Device*) e o *IMD* (*Insulation Monitoring Device*).

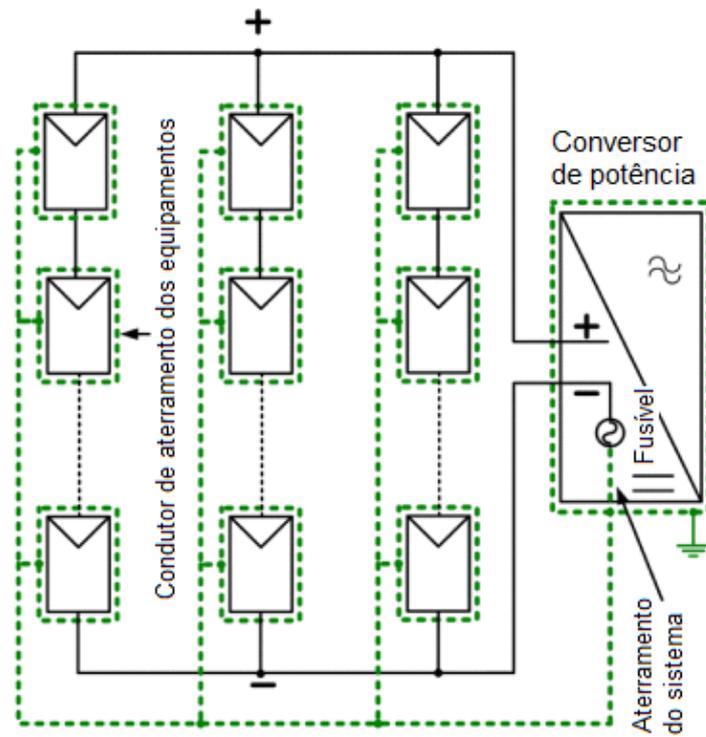
Por questão de segurança, as partes metálicas das instalações elétricas que não são utilizadas para condução de corrente elétrica devem ser aterradas (o quadro metálico dos módulos fotovoltaicos e sua estrutura metálica de sustentação). Os sistemas fotovoltaicos são classificados de duas formas quanto ao aterramento: Sistemas aterrados e não aterrados. Nos sistemas aterrados, um dos condutores

transportadores de corrente (positivo ou negativo) também é conectado ao condutor de aterramento. A Figura 3.2 ilustra o diagrama esquemático dos dois sistemas (ALAM et al., 2015).

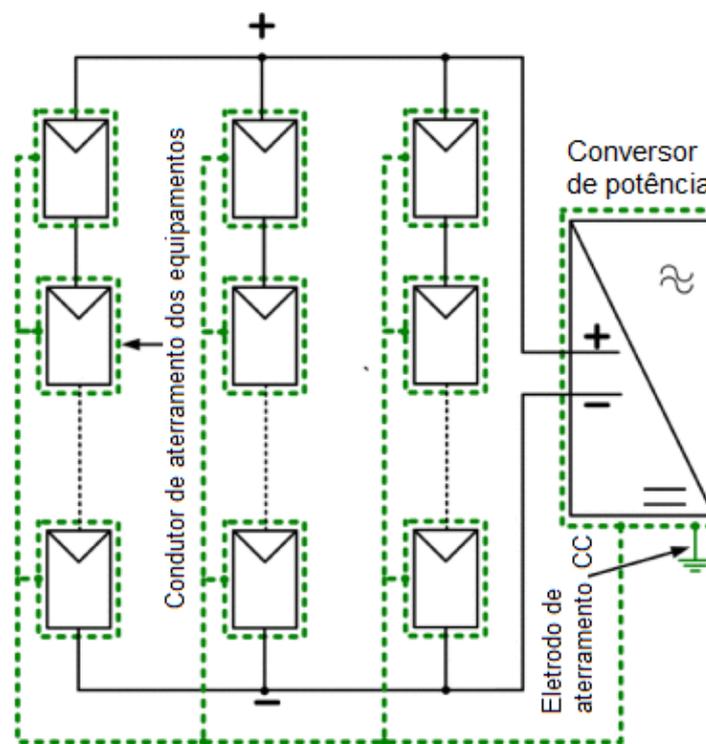
O fusível *GFDI* é utilizado em sistemas aterrados. Quando ocorre uma falha à terra, o fusível é percorrido por corrente, fundindo-se caso a corrente seja maior do que a corrente de limiar de segurança, desligando o inversor e isolando o arranjo fotovoltaico do restante do sistema. A corrente nominal do fusível deve ser maior do que a corrente de fuga para o terra, a fim de evitar atuação indevida (ALAM et al., 2015; MADETI; SINGH, 2017).

A Figura 3.3 ilustra o esquema de um dispositivo de corrente residual *RCD*. Sua função é monitorar a diferença entre a corrente que entra e sai pelos condutores positivo e negativo da *string* ou arranjo monitorado. Em condição normal, a diferença de corrente é igual à corrente de fuga para o terra. Quando ocorre uma falha para o terra, uma parte da corrente retorna pelo condutor de aterramento, tornando a corrente do condutor positivo diferente do negativo, provocando a atuação do *RCD*. A corrente de atuação do *RCD* deve ser maior que a corrente de fuga máxima dos módulos, multiplicada por um fator de segurança maior que 1. O *RCD* pode ser utilizado tanto em sistemas aterrados ou não aterrados e pode detectar falhas para o terra, bem como falhas linha-a-linha (ALAM et al., 2015; MADETI; SINGH, 2017).

Figura 3.2: Sistemas fotovoltaicos a) aterrados b) não aterrados



(a)

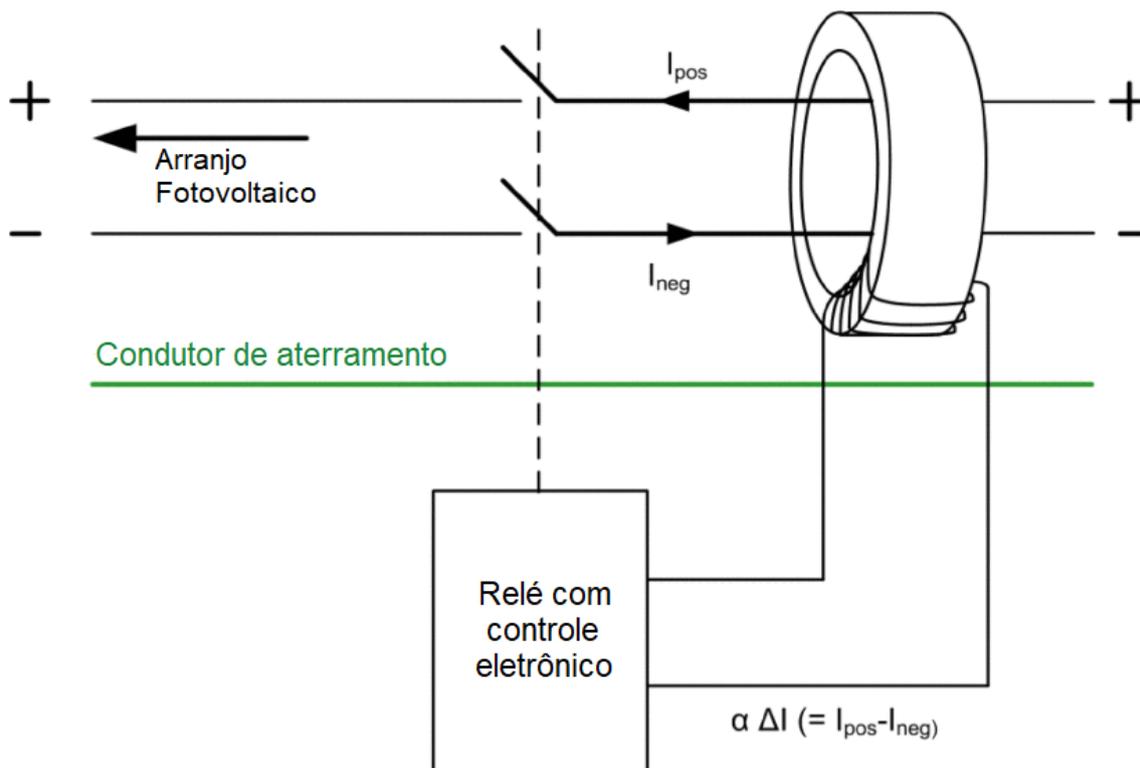


(b)

Fonte: (ALAM et al., 2015)

Nota: Adaptado pelo autor

Figura 3.3: Diagrama esquemático do princípio de funcionamento do RCD



Fonte: (ALAM et al., 2015)

Nota: Adaptado pelo autor

O dispositivo de monitoramento da isolação *IMD* mede a resistência entre os condutores transportadores de corrente (positivo ou negativo) e o terra. Se a resistência for menor que um valor de segurança pré-determinado, o *IMD* pode desligar o sistema. O *IMD* também pode ser implantado em sistemas aterrados, desconectando o *GFDI* no momento da medida, quando o inversor não estiver em funcionamento, normalmente no início do dia. O valor da resistência de atuação do *IMD* deve ser menor que a resistência mínima sob qualquer condição climática multiplicada por um fator de segurança menor que 1 (ALAM et al., 2015; MADETI; SINGH, 2017).

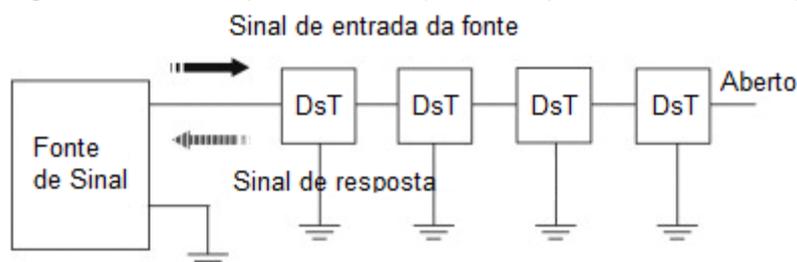
3.4 TÉCNICAS INDEPENDENTES DE DADOS CLIMÁTICOS

São métodos que não necessitam de dados do clima como irradiação solar, temperatura, umidade e velocidade do vento. Nesta categoria se enquadram a reflectometria no domínio do tempo (*TDR - Time Domain Reflectometry*), a medida da capacitância para terra (*ECM - Earth Capacitance Measurement*) e métodos estatísticos.

No método da reflectometria no domínio do tempo (*TDR*), um sinal é aplicado a uma linha de transmissão e o sinal refletido é observado e comparado ao sinal original aplicado. São analisados o tempo de atraso e a forma do sinal refletido (especialmente a polaridade) para identificar pontos na linha de transmissão onde há mudança na impedância. É possível identificar pontos de ruptura dos condutores, aumento das resistências nas conexões entre os módulos e internamente aos módulos (TAKASHIMA; YAMAGUCHI; ISHIDA, 2008b).

A Figura 3.4 ilustra o procedimento da *TDR* e a Tabela 3.1 os sinais de resposta para cada tipo de incompatibilidade (alteração de impedância). A linha de transmissão tem uma impedância característica Z_0 . Se no ponto de incompatibilidade houver uma impedância maior do que Z_0 , a tensão do sinal refletido terá a mesma polaridade do sinal aplicado. Caso contrário, se a impedância for menor do que Z_0 , o sinal refletido terá tensão com polaridade contrária ao do sinal refletido.

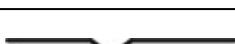
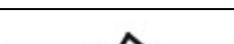
Figura 3.4: Princípio do *TDR* (DsT: dispositivo sob teste)



Fonte:(TAKASHIMA et al., 2009)

Nota: Adaptado pelo autor

Tabela 3.1: Formas de onda de resposta em *TDR* (Z_0 : impedância característica da linha de transmissão)

Tipo de incompatibilidade	Resposta ao Degrau	Resposta ao Impulso
Circuito aberto		
Curto-circuito		
Resistor $R > Z_0$		
Resistor $R < Z_0$		
Indutor		
Capacitor		

Fonte: (TAKASHIMA et al., 2009)

Nota: Adaptado pelo autor

O método *ECM* é utilizado para localizar uma desconexão em uma *string* através da medida da capacitância da linha para o terra utilizando um equipamento de medida chamado LCR (indutância, capacitância e resistência). A *string* é considerada como uma linha de transmissão e a capacitância da linha para o terra é proporcional ao número de módulos conectados. Quando existe uma desconexão na linha, o ponto de desconexão pode ser localizado através da comparação da capacitância medida pelo anodo da *string* com falha, com a de uma *string* sem falha. Este método é chamado de Comparação.

O número de módulos até a desconexão n é calculado por

$$n = (C_x/C_D)M \quad (3.1)$$

Onde:

C_x é a capacitância para o terra até o ponto de falta;

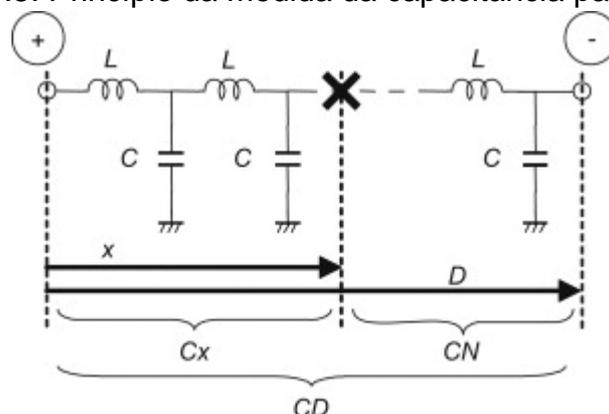
C_D é a capacitância para o terra de uma *string* completa (sem falta);

M é o número total de módulos da *string*.

Na Figura 3.5 pode-se ver o diagrama de uma *string* representada por uma linha de transmissão distribuída, ilustrando o princípio do método *ECM*, onde a

capacitância para o terra é proporcional ao número de módulos até a desconexão.

Figura 3.5: Princípio da medida da capacitância para o terra.



Fonte:(TAKASHIMA et al., 2009)

Caso haja apenas uma *string*, utiliza-se o método chamado de Pinça, onde é medida a capacitância para o terra pelo anodo da *string* e pelo seu catodo. Então é feita a comparação da capacitância medida pelo anodo com a soma das duas (medida pelo anodo mais a medida pelo catodo). Desta forma é possível descobrir entre quais módulos está a desconexão. Este método é independente da irradiância incidente (TAKASHIMA; YAMAGUCHI; ISHIDA, 2008a).

Neste caso, a Equação (3.1) é reescrita como

$$n = \{C_x / (C_x + C_N)\}M \quad (3.2)$$

Onde C_D é substituída por $(C_x + C_N)$. C_x é a capacitância medida a partir do anodo e C_N a capacitância a partir do catodo.

3.5 TÉCNICAS DE ANÁLISE DA CURVA I-V

Essas técnicas detectam falhas nos sistemas fotovoltaicos comparando a curva característica I-V (corrente versus tensão) medida com a esperada. Quando ocorre uma falha, a potência de saída é reduzida e sua curva I-V é alterada. Podem ser analisados dados de tensão e corrente a nível de módulo, de *string* ou de arranjo.

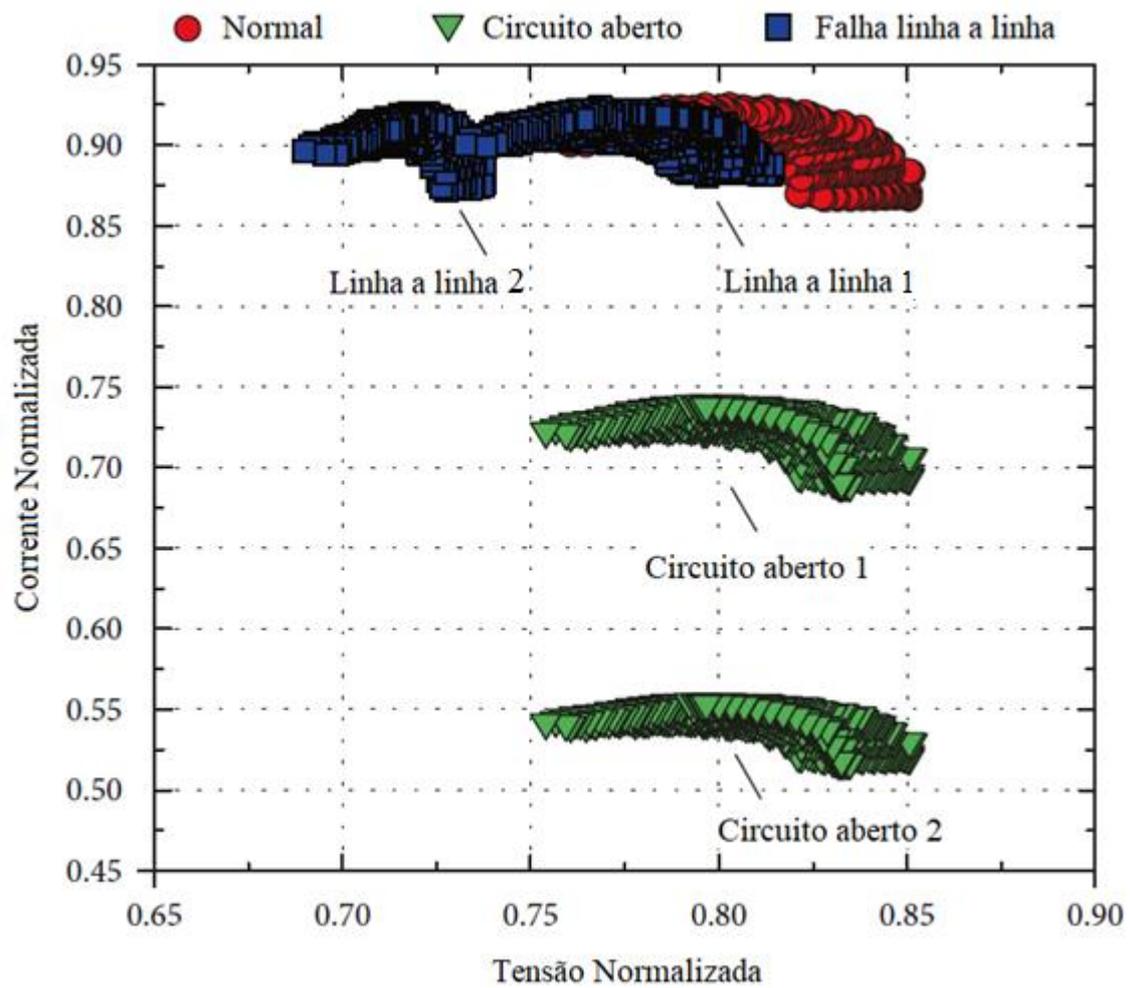
Um dos métodos consiste em uma abordagem de *clusterização* baseada em pico de densidade (LIN et al., 2017). A *clusterização* é um algoritmo de agrupamento de dados não supervisionado. Os dados são compostos de vários pontos com

coordenadas de tensão e corrente. Este método agrupa os dados em grupos chamados *clusters*. O algoritmo se baseia na densidade local de cada ponto (ρ_i) e na distância de cada ponto a pontos de maior densidade que ele (δ_i). Os centros dos clusters tem ρ e δ altos.

Neste método, os dados diários de tensão e de corrente de operação de um arranjo fotovoltaico sob diferentes condições de irradiância e temperatura são analisados e clusterizados. A distribuição dos dados mostra *clusters* significativamente não esféricos, com centro relativamente distante de pontos com densidade local mais alta. Os dados são rotulados com várias condições e utilizados para calcular um vetor de distância mínima entre cada *cluster* e dados de referência gerados por um modelo. De acordo com o vetor de distância, os clusters são identificados em várias condições ou falhas (LIN et al., 2017).

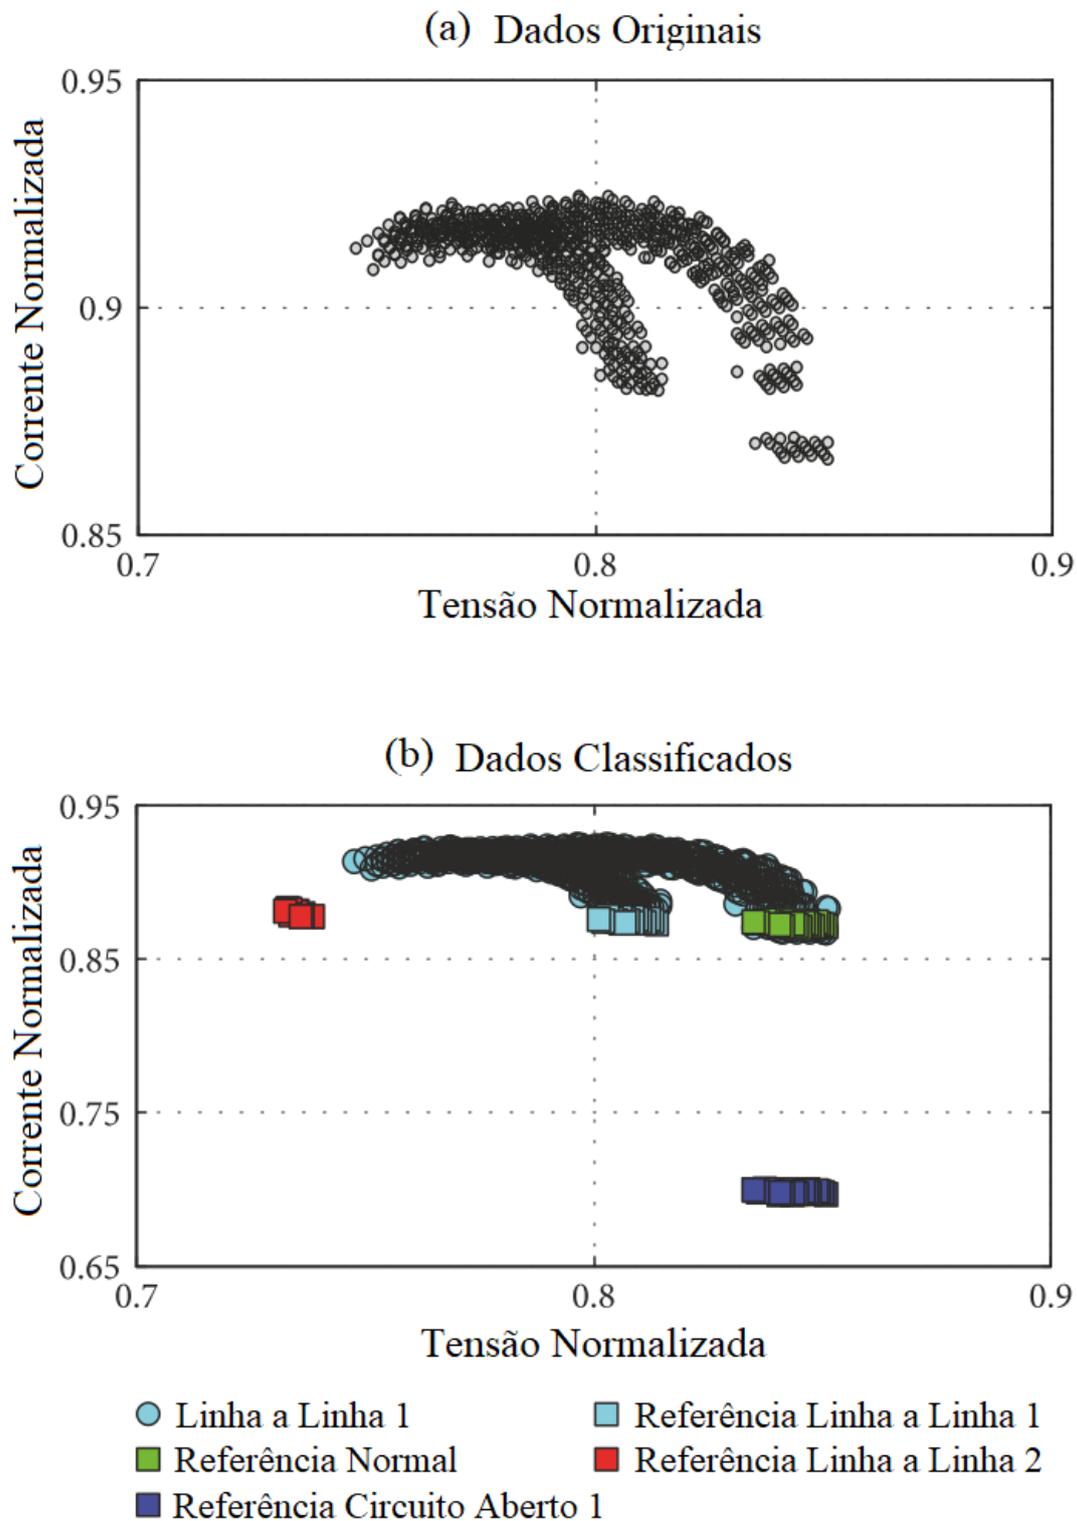
É mostrada na Figura 3.6 a distribuição dos dados de tensão e de corrente de um arranjo fotovoltaico em operação sob uma faixa de valores de irradiação e temperatura em cinco condições diferentes. Os dados de tensão e corrente estão normalizados em relação à tensão de circuito aberto e à corrente de curto-circuito da string, respectivamente. Na Figura 3.7 é mostrada a classificação de dados do arranjo fotovoltaico em duas condições: normal e com falha linha a linha 1. O sistema agrupa os dados em um único cluster devido à superposição dos dados das duas condições e o classifica como falha linha a linha 1. Na Figura 3.8 é mostrada a classificação dos dados do arranjo fotovoltaico em duas condições: normal e em circuito aberto 1. O sistema agrupa os dados 2 clusters e classifica corretamente cada um.

Figura 3.6: Relação entre tensão e corrente de um arranjo para cinco condições de funcionamento



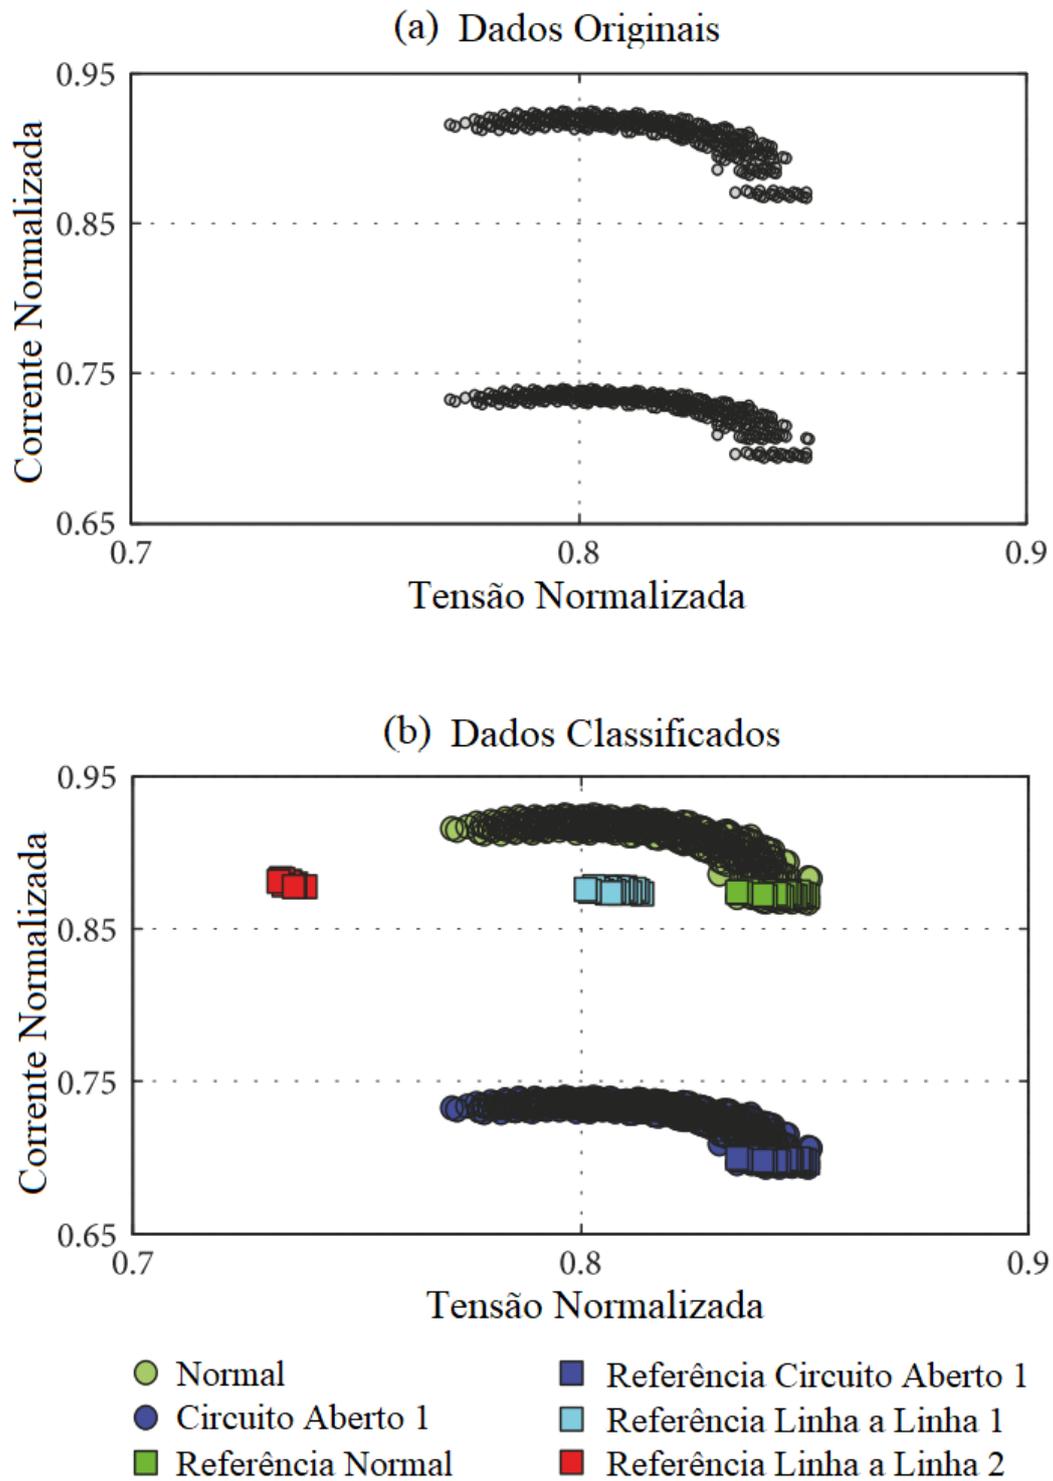
Fonte: (LIN et al., 2017)
Nota: Adaptada pelo autor

Figura 3.7: Classificação dos dados do arranjo fotovoltaico em condição normal e com falha linha a linha 1.



Fonte: (LIN et al., 2017)
 Nota: Adaptada pelo autor

Figura 3.8: Classificação dos dados do arranjo fotovoltaico em condição normal e com falha circuito aberto 1.



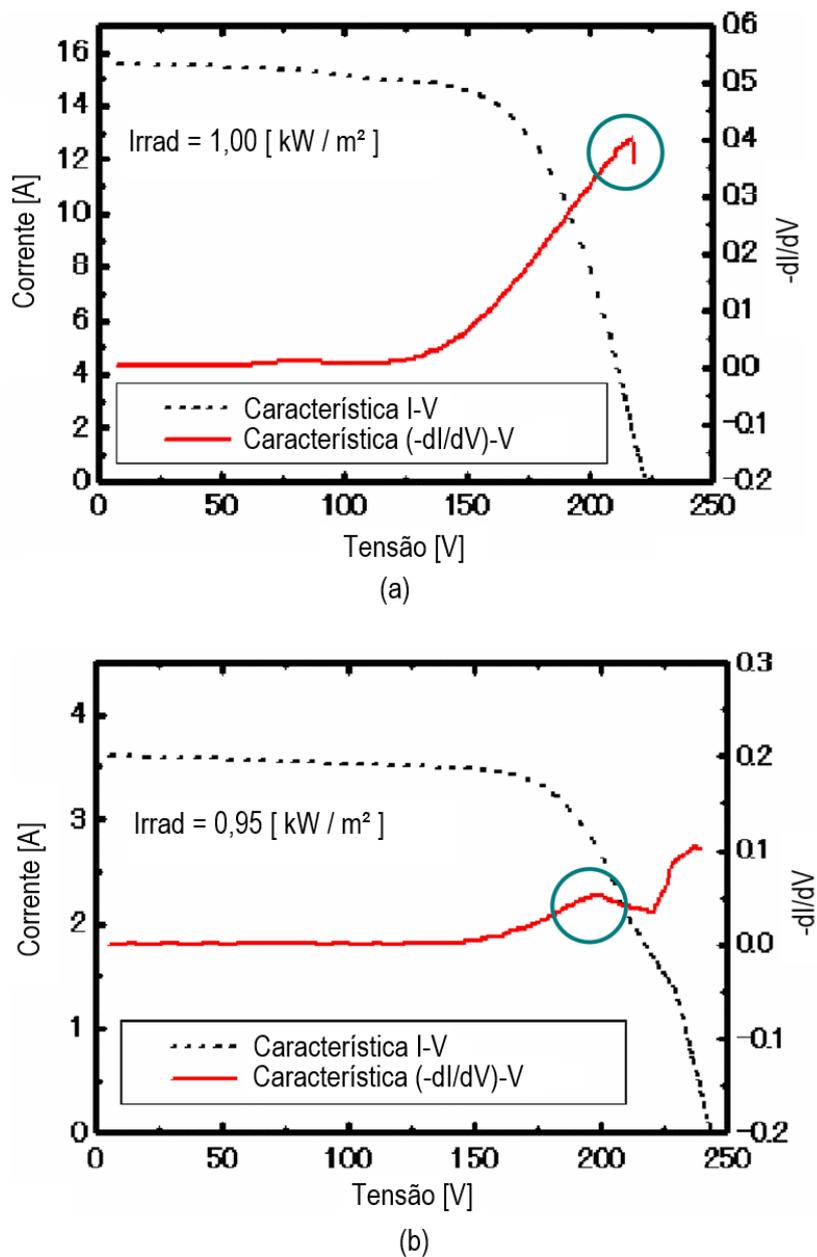
Fonte: (LIN et al., 2017)
 Nota: Adaptada pelo autor

Outro método proposto é o do cálculo da curva característica dada por

$$\left(-\frac{dI}{dV}\right)-V \quad (3.3)$$

Esta curva característica mostra um pico quando existe sombreamento parcial no arranjo fotovoltaico e pode ser utilizada para identificar este tipo de falha (MIWA et al., 2006). As características I-V e $(-dI/dV)$ -V para um arranjo normal e para uma *string* sombreada estão ilustradas na Figura 3.9

Figura 3.9: Características I-V e $(-dI/dV)$ -V: (a) em um arranjo normal;(b) em uma *string* com uma célula sombreada.



Fonte: (MIWA et al., 2006)
Nota: Adaptada pelo autor

A degradação de sistemas fotovoltaicos pode ser estimada através do cálculo de alguns parâmetros indicadores, como o fator de preenchimento FF (*Fill Factor*), a resistência série R_s (*Serie Resistance*) e a resistência paralela R_{sh} (*Shunt Resistance*). Esses parâmetros podem ser obtidos através da análise da curva I-V do módulo fotovoltaico. O parâmetro FF pode ser calculado pela Equação (3.4) (KAPLANIS; KAPLANI, 2011).

$$FF = \frac{P_{max}}{I_{sc} \cdot V_{oc}} \quad (3.4)$$

Onde P_{max} é a potência máxima que o módulo pode fornecer, I_{sc} (*short circuit*) é a corrente de curto circuito, V_{oc} (*open circuit*) é a tensão de circuito aberto.

3.6 TÉCNICA DE COMPARAÇÃO ENTRE AS SAÍDAS REAL E MODELADA DO SISTEMA FOTOVOLTAICO

Nesta técnica, modelos matemáticos são utilizados para simular e prever, baseados nos dados climáticos de irradiância e temperatura, quais seriam os valores de saída da planta fotovoltaica em condições normais. Os dados de saída reais (os medidos) são comparados com os previstos para detectar vários tipos de mau funcionamento do sistema (ABDULMAWJOOD; REFAAT; MORSI, 2018).

Está incluída nessa técnica a análise de perdas de potência, que analisa as perdas de potência no sistema fotovoltaico para detectar falhas. As perdas de potência são calculadas através da comparação entre os dados reais vindos do sistema de monitoramento e os dados simulados. Para calcular a potência gerada pelos módulos fotovoltaicos, é necessário medir dados climáticos como irradiação solar e temperatura ambiente e/ou dos módulos.

Em (CHOUDER; SILVESTRE, 2010) foi proposto um sistema para detecção de falhas baseado nesta técnica e para classificar as falhas foram propostos dois indicadores, R_v (*Ratio voltage*) para tensão, e R_c (*Ratio current*) para corrente, que eram baseados na razão entre valores simulados e medidos.

Em (SILVESTRE et al., 2014) são propostos novos indicadores, (NR_v) para tensão, e (NR_c) para corrente, baseados na razão entre valores medidos e de referência da curva I-V (V_{oc} e I_{sc}) para substituir os propostos em (CHOUDER; SILVESTRE, 2010).

Os novos indicadores tornam o sistema de detecção mais simples, pois não é necessário calcular os valores simulados. Eles são calculados pelas Equações (3.5) e (3.6).

$$NR_c = \frac{I_m}{I_{sc}} \quad (3.5)$$

$$NR_v = \frac{V_m}{V_{oc}} \quad (3.6)$$

Onde I_m e V_m são a corrente e a tensão do arranjo no ponto de máxima potência e I_{sc} e V_{oc} são a corrente de curto-circuito e a tensão de circuito aberto do arranjo fotovoltaico.

Outro sistema de detecção de falha baseado em análise das perdas de potência foi proposto em (CHINE et al., 2014). O sistema se baseia na análise do erro absoluto entre as taxas de desempenho medida e simulada para detectar falhas, na taxa de potência CC-CA para identificar em qual parte do sistema está a falha (CC ou CA), e nos indicadores R_c e R_v para classificar as falhas no lado CC. Esta ferramenta pode detectar diferentes tipos de falhas como falha em um módulo, falha em uma *string*, falha em um inversor e falha geral, que pode incluir sombreamento parcial, envelhecimento, ou erro no *MPPT*.

3.7 TÉCNICAS ESTATÍSTICAS

As técnicas estatísticas são utilizadas para definir limiares para cada parâmetro monitorado no sistema fotovoltaico e, através da comparação dos parâmetros medidos com esses limiares, decidir se o sistema está sob funcionamento normal ou defeituoso (LIVERA et al., 2019).

Em (GAROUDDJA et al., 2017) é proposto um método para detecção de falhas utilizando o gráfico estatístico *EWMA* (*Exponentially Weighted Moving Average* – média móvel exponencialmente ponderada), e o modelo de um diodo para detectar alterações incipientes em um sistema fotovoltaico.

O modelo prevê as coordenadas de tensão, corrente e potência no ponto de máxima potência a partir de dados climáticos de irradiação e temperatura, e esses dados são comparados com os dados reais medidos do sistema fotovoltaico para calcular os resíduos de tensão, corrente e potência, que são as diferenças entre os dados do modelo e os dados reais. Os resíduos são utilizados para gerar gráficos *EWMA*, a partir dos quais é possível detectar e identificar as falhas.

O gráfico de *Shewhart* é utilizado como base para comparação. O gráfico *EWMA* se mostrou superior ao de *Shewhart*, conseguindo detectar falhas de menor intensidade. Seu desempenho superior é atribuído ao fato de a saída do *EWMA* ser composta de uma sequência de médias ponderadas no tempo de todas as observações anteriores do processo monitorado, com peso menor quanto mais antigo forem as observações. A diferença entre os pesos pode ser ajustada por um fator de esquecimento. O método proposto foi capaz de detectar e identificar curto-circuito e circuito aberto, e detectar sombreamento parcial, mas não identificá-lo.

3.8 TÉCNICAS DE APRENDIZADO DE MÁQUINA

Em (CHINE et al., 2016) é apresentada uma técnica para identificar 8 tipos de falhas, utilizando comparação entre dados de corrente e de tensão medidos, e simulados com base em irradiação e temperatura. Caso a diferença ultrapasse um limiar, o sistema é considerado com falha.

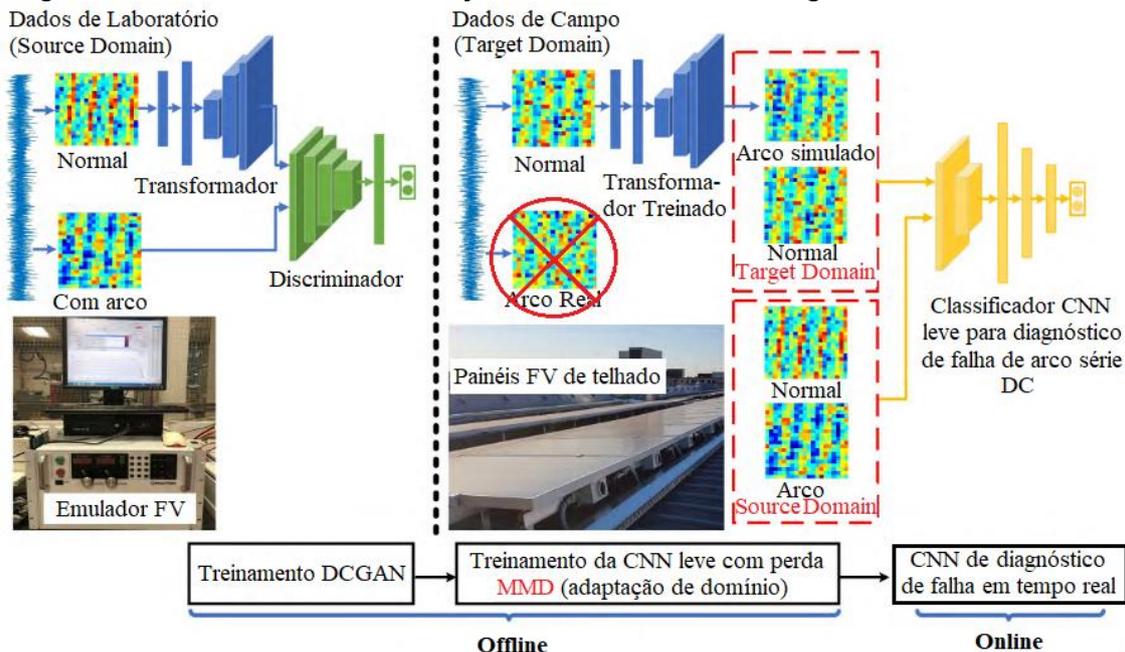
Para classificar a falha, são utilizados dois algoritmos, sendo um baseado em limiares, para a identificação de uma parte das falhas, e o outro baseado em rede neural artificial, para identificar o restante das falhas. Uma implementação em *FPGA* (*Field Programmable Gate Array*) também é apresentada em (CHINE et al., 2016).

Em (LU et al., 2019) é proposto um método baseado em aprendizado de máquina para identificação de arco elétrico. Neste método, é utilizada a técnica *DA-DCGAN* (*Domain Adaptation – Deep Convolutional Generative Adversarial Network*) de adaptação de domínio combinada com rede adversária generativa convolucional profunda. Devido à dificuldade de obter dados de falha em sistemas em campo, a rede é treinada com dados simulados em ambiente de laboratório (*source domain*) e depois adaptados para o sistema em campo (*target domain*).

Primeiramente, uma rede *DCGAN* é treinada para gerar um sinal de corrente com arco a partir de um sinal de corrente normal em ambiente de laboratório. Nesse processo uma rede denominada Transformador (*G*) recebe o sinal da condição normal com objetivo de fornecer um sinal em condição de falha de arco. Outra rede denominada Discriminador (*D*) tem o objetivo de distinguir o sinal de arco simulado do sinal de arco real. Essas duas redes são treinadas num processo adversário, onde a rede *D* é treinada a distinguir o sinal de arco real do simulado, diminuindo o erro de classificação, enquanto a rede *G* é treinada para gerar um sinal de arco simulado o mais similar possível ao real para tentar enganar a rede *D*, ou seja, aumentar o erro de classificação. Conforme o processo evolui o sinal de arco simulado se torna mais parecido com o real.

No próximo passo, a rede *DCGAN* é usada para gerar um sinal de corrente com arco a partir dos dados de campo. Os dados de campo (*target domain*) na condição normal e com arco simulado juntamente com os dados de laboratório (*source domain*) na condição normal e com arco, são utilizados para treinar uma rede *CNN* leve utilizando as funções de perda de entropia cruzada binária e de discrepância média máxima (do inglês *MMD – Maximum Mean Discrepancy*), de forma a diminuir tanto o erro de classificação quanto a diferença entre a classificação dos dados de laboratório e de campo. Esse processo é chamado de adaptação de domínio. Esta metodologia visa diminuir a degradação de desempenho na mudança de domínio (laboratório para campo). Após treinada a rede *CNN* é utilizada para detectar falhas de arco em um sistema *online*. Um transformador de corrente capaz de filtrar as baixas frequências do sinal foi utilizado como sensor. A metodologia foi testada experimentalmente e demonstrou claramente a eficácia da metodologia para aplicações práticas.

Figura 3.10: Processo de obtenção da rede CNN de diagnóstico de arco série.



Fonte: (LU et al., 2019)
Nota: Adaptada pelo autor

3.9 TÉCNICAS DE DETECÇÃO DE ARCO ELÉTRICO

Uma das técnicas de detecção de arco elétrico é a que utiliza o espectro de frequência de tensão ou de corrente do arranjo. O arco elétrico gera um espectro de frequência semelhante ao ruído rosa com amplitude inversamente proporcional à frequência. A faixa de frequência analisada é de 1kHz a 100kHz, pois abaixo de 1kHz existem ruídos gerados pelo sombreamento parcial, enquanto que acima de 100kHz o espectro do arco tem pouca energia, sendo que acima de 500kHz pode haver interferência de antenas de RF. Cabe ressaltar que os conversores CC/CC têm frequência de chaveamento na faixa de 10 a 50kHz (ABDULMAWJOOD; REFAAT; MORSI, 2018; ALAM et al., 2015).

Outra técnica empregada para na detecção de arco elétrico é a utilização de reflectometria no domínio do tempo de espectro espalhado (*SSTD*, do inglês *Spread Spectrum Time Domain Reflectometry*), as quais são aplicadas em (ALAM et al., 2014).

3.10 TÉCNICAS DE DETECÇÃO DE *HOT SPOTTING*

Em (KIM, K. A. et al., 2016) foi proposto um método para detecção de *hot spotting* (aquecimento causado por células polarizadas reversamente) através da medida da impedância CC e da capacitância da *string*. Uma célula de um módulo fotovoltaico foi ensaiada e verificou-se que a impedância CC e a capacitância da célula aumentam quando ela está polarizada reversamente, operando em *hot spotting* (reversamente polarizada devido a sombreamento).

Uma *string* sombreada parcialmente tem comportamento semelhante quanto à resistência e à capacitância. Tendo o modelo de circuito equivalente da célula para pequenos sinais, é possível descrever em qual frequência a resistência (série e paralela) domina e em qual frequência a capacitância domina.

Dois métodos para identificar sombreamento são propostos. O primeiro método utiliza a injeção de duas tensões com frequências diferentes, uma baixa (<300Hz), para medida da impedância CC, e outra alta (10 a 70 kHz), para medir a capacitância. A baixa frequência pode ser derivada da rede da concessionária de energia elétrica (50 ou 60Hz), e a frequência mais alta pode ser a frequência de chaveamento do *MPPT*. A impedância e a capacitância podem ser derivadas da medida da tensão e da corrente em cada uma das frequências, bem como do modelo do circuito equivalente.

O segundo método a ser implantado no *MPPT* mede a impedância CC através da obtenção da inclinação da curva I-V, onde a impedância CC pode ser calculada pela razão entre o intervalo de tensão e o intervalo correspondente de corrente. Esse método é aplicável em *MPPTs* com algoritmos que variem constantemente o ponto de operação para encontrar o ponto de máxima potência (*MPP*, do inglês, *Maximum Power Point*). Um desses algoritmos é o P & O (Perturbar e Observar).

4 REDES NEURAIS

Neste capítulo são apresentados conceitos teóricos necessários para a compreensão do funcionamento de uma rede neural (Seção 4.1), mais especificamente de um tipo de rede neural chamada de rede neural convolucional (Seção 4.2), a qual tem sido empregada com bastante sucesso no reconhecimento de imagens, vídeos, sons, fala e sinais de maneira geral.

4.1 ESTRUTURA

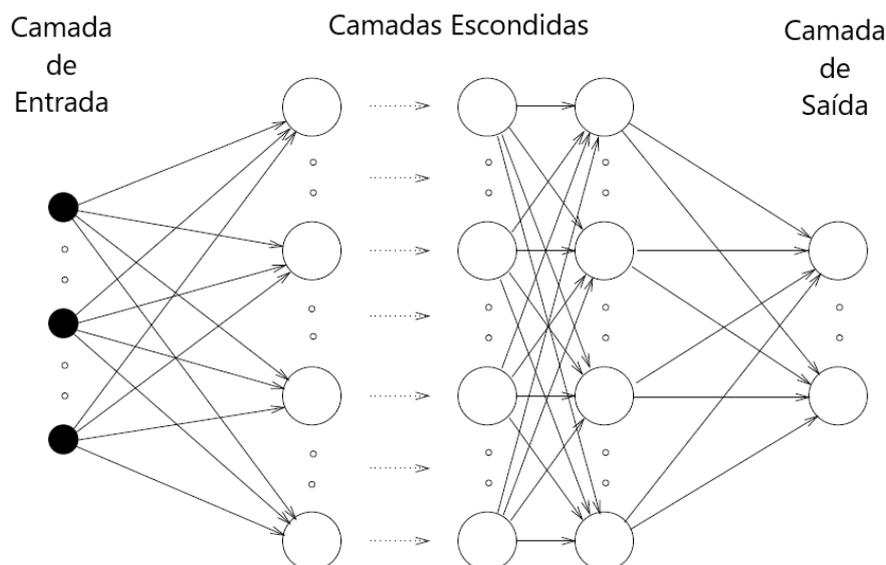
Uma rede neural artificial é um conjunto de vários processadores simples, chamados neurônios, interligados entre si através de conexões unidirecionais (EBERMAM; KROHLING, 2018; HAYKIN, 2001). Essa rede tem características de processamento paralelo e distribuído (COLTHEART et al., 1993; KIM, W.; PITT; MYUNG, 2013; PLAUT; MCCLELLAND, 2010).

Cada neurônio recebe uma ou mais entradas e fornece uma saída. As conexões entre os neurônios controlam o fluxo da informação entre eles, ponderando a influência da saída de cada neurônio sobre os outros aos quais está conectado.

A rede neural é organizada em camadas, conforme pode ser visto na Figura 4.1. A camada que recebe informações do ambiente é a camada de entrada, enquanto a camada que fornece o resultado do processamento é chamada de saída, sendo as demais camadas chamadas de intermediárias ou, mais comumente, camadas escondidas.

As camadas de entrada e de saída são obrigatórias em uma rede neural artificial, enquanto as camadas intermediárias podem variar de 0 a N , onde $N \geq 0$ é um inteiro finito.

Figura 4.1: Estrutura de uma rede neural artificial



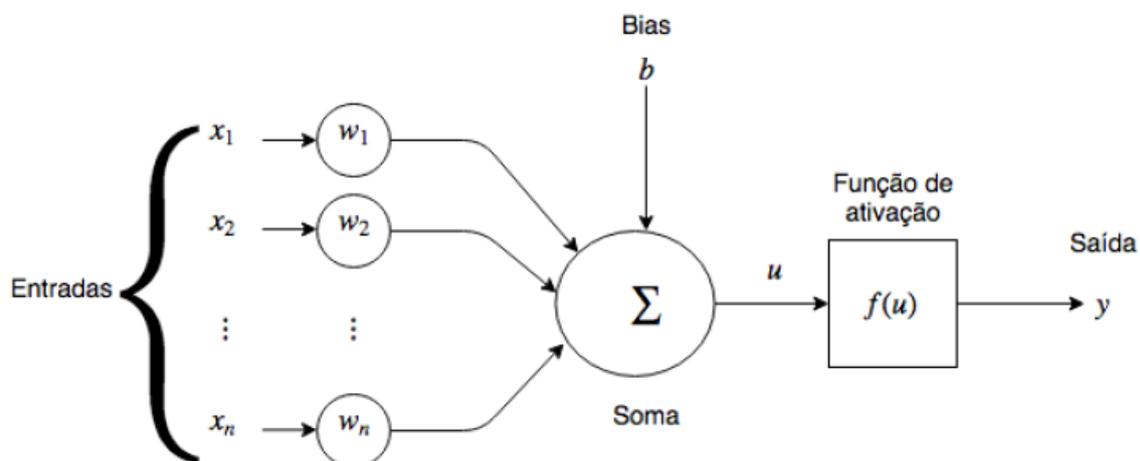
Fonte: (KROSE; SMAGT, 1996)

Nota: Adaptado pelo autor.

4.1.1 Neurônio artificial

O neurônio artificial é a unidade básica de processamento. Sua estrutura e funcionamento é baseada no neurônio natural. O modelo mais utilizado é o proposto por McCulloch e Pitts (EBERMAM; KROHLING, 2018; MCCULLOCH; PITTS, 1943). Ele recebe entradas a serem processadas e fornece uma saída ou ativação. A saída depende das entradas e de um valor constante de deslocamento chamado *bias*. A Figura 4.2 ilustra a estrutura do neurônio artificial.

Figura 4.2: Estrutura do neurônio artificial



Fonte: (EBERMAM; KROHLING, 2018)

O sinal de ativação u é gerado conforme a Equação (4.1), onde b é o bias, x_j é a j -ésima entrada, w_j é o peso correspondente a cada entrada e m é um número inteiro positivo e finito de entradas consideradas. O sinal de ativação u é aplicado a uma função de ativação para gerar a saída y conforme a Equação (4.2) (EBERMAM; KROHLING, 2018).

$$u = \left(\sum_{j=1}^m x_j w_j \right) + b \quad (4.1)$$

$$y = f(u) \quad (4.2)$$

4.1.2 Funções de ativação

A função de ativação restringe a amplitude da saída do neurônio. Por isso, também é chamada de função restritiva. Os intervalos para os quais a saída é restringida são tipicamente $[0,1]$ e $[-1,1]$. As funções com saída no intervalo $[0,1]$ costumam ser chamadas de unipolares e as com saída no intervalo $[-1,1]$ de bipolares. A função de ativação adiciona também uma característica de não-linearidade ao neurônio, possibilitando às redes neurais de camadas múltiplas resolver problemas não lineares.

As funções de ativação mais conhecidas são mostradas na Tabela 4.1, sendo que as funções limiar, sinal e linear por partes têm descontinuidades, enquanto a sigmoide e a tangente hiperbólica são deriváveis em todo o domínio. A função ReLu (unidade linear retificada - do inglês *Retified Linear Unit*) é uma função introduzida mais recentemente e tem várias variantes como *Leaky (LRelu)*, *Parametric (PReLU)*, *Randomized (RReLU)* e a *ELU (Exponential Linear Unit)* (ALOYSIUS; GEETHA, 2017; EBERMAM; KROHLING, 2018; GU et al., 2018; HAYKIN, 2001; LI; YUAN, 2017; RAZA; KHOSRAVI, 2015).

Tabela 4.1: Principais funções de ativação.

Classe	Função
Limiar (degrau unipolar)	$f(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases}$
Sinal (degrau bipolar)	$f(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ -1, & \text{se } u < 0 \end{cases}$
Linear por partes (unipolar)	$f(u) = \begin{cases} 1, & \text{se } u \geq +\frac{1}{2} \\ u, & \text{se } +\frac{1}{2} > u > -\frac{1}{2} \\ 0, & \text{se } u \leq -\frac{1}{2} \end{cases}$
Linear por partes (bipolar)	$f(u) = \begin{cases} 1, & \text{se } u \geq 1 \\ u, & \text{se } 1 > u > -1 \\ -1, & \text{se } u \leq -1 \end{cases}$
Sigmoide unipolar	$f(u) = \frac{1}{1 + e^{-au}}$
Sigmoide bipolar	$f(u) = \frac{1 - e^{-au}}{1 + e^{-au}}$
Tangente hiperbólica	$f(u) = \tanh(u)$
ReLU	$f(u) = \max(0, u)$

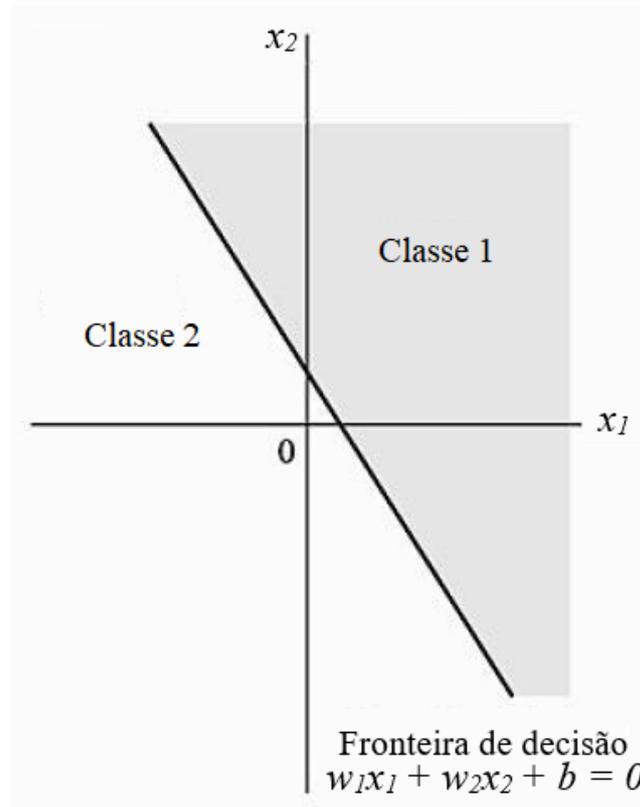
4.1.3 Perceptron

O perceptron é uma rede neural composta por um único neurônio com m entradas, baseado no modelo de McCulloch-Pitts (MCCULLOCH; PITTS, 1943), como o ilustrado na Figura 4.2, com função de ativação do tipo sinal, que é aplicada sobre o sinal de ativação dado na Equação (4.1) para classificar entradas pertencentes a duas classes separáveis linearmente.

O perceptron traça um hiperplano no espaço de m dimensões, dividindo-o em duas regiões onde devem estar localizados os valores de entrada pertencentes a cada uma das classes. Este hiperplano é definido pela Equação (4.3) e está ilustrado na Figura 4.3 para o caso de duas entradas. O *bias* é responsável por deslocar o hiperplano da origem. Isto acontecerá sempre que ele for diferente de zero.

$$\left(\sum_{j=1}^m x_j w_j \right) + b = 0 \quad (4.3)$$

Figura 4.3: Hiperplano de separação de classes no perceptron



Fonte: (HAYKIN, 2001)
Nota: Adaptado pelo autor

O treinamento desta rede consiste em ajustar os pesos w_j e o bias b para que todos os valores de entrada sejam classificados corretamente. Para atingir este objetivo, é necessário fornecer um conjunto de n vetores de entrada e a respectiva saída desejada para cada um dos n vetores, e ajustar os pesos e o bias quando a saída for diferente da desejada. Como simplificação para aplicar o algoritmo, o bias será considerado como se fosse uma entrada fixa de valor +1, multiplicada por um peso b e aplicado ao neurônio.

Os pesos w_j são ajustados se a saída for diferente da desejada. O ajuste aplicado a cada peso w_j e ao bias é igual ao erro multiplicado pela respectiva entrada x_j e uma taxa de aprendizagem η , que deve estar no intervalo $0 < \eta \leq 1$. O valor do novo vetor de pesos é expresso por

$$w_{novo} = w_{atual} + \eta \cdot [d(n) - y(n)] \cdot x(n), \quad (4.4)$$

onde:

$x(n)$ é o vetor de entrada contendo $(m+1)$ elementos, isto é $[+1, x_1(n), x_2(n), \dots, x_m(n)]$;

w_{atual} é o vetor de pesos atuais contendo $(m+1)$ elementos, isto é $[b, w_1, w_2, \dots, w_m]$;

w_{novo} é o novo vetor de pesos após o ajuste com $(m+1)$ elementos, isto é $[b, w_1, w_2, \dots, w_m]$;

$d(n)$ é a saída desejada igual a +1 se $x(n)$ pertencer à classe 1, ou -1, caso pertença à classe 2;

$y(n)$ é a saída real;

η é a taxa de aprendizagem.

A sequência de operações do algoritmo é a seguinte:

Algoritmo de Treinamento do Perceptron	
1:	$w[1..m] = 0$ (inicializa o vetor de pesos com zero);
2:	$n = 1$ (inicializa o índice para o primeiro vetor de entradas);
3:	<u>Enquanto</u> $n \leq N$ (repete até processar todas as entradas);
4:	$y(n) = \text{sinál}[w^T x(n)]$ (calcula a saída do neurônio);
5:	<u>Enquanto</u> $y(n) \neq d(n)$ <u>faça</u> (enquanto a saída for diferente da desejada)
6:	$w = w + \eta \cdot [d(n) - y(n)] \cdot x(n)$ (ajusta os pesos);
7:	<u>Fim</u> (finaliza ajuste de pesos);
8:	$n = n + 1$ (incrementa o índice para o próximo vetor de entradas);
9:	<u>Fim</u> (fim de entradas).

O algoritmo para treinamento desta rede é denominado algoritmo de convergência do perceptron. Rosenblatt (ROSENBLATT, 1958, 1962) provou que esse algoritmo converge para classes linearmente separáveis.

A rede perceptron é capaz de classificar mais de duas classes linearmente separáveis desde que sejam adicionados mais neurônios à rede (HAYKIN, 2001).

4.1.4 *Perceptron de Múltiplas Camadas (Multilayer Perceptron - MLP)*

O perceptron de múltiplas camadas é uma evolução do perceptron de camada única. Essa rede tem uma camada de entrada, uma camada de saída e uma ou mais camadas escondidas. A função de ativação é uma função suave diferenciável em todo seu domínio.

A Figura 4.1, apresentada no início do capítulo, é um exemplo de perceptron de múltiplas camadas. As camadas escondidas possibilitam ao perceptron de múltiplas camadas resolver problemas mais complexos e não lineares, como o do OU Exclusivo, os quais o perceptron de camada única não pode resolver (HAYKIN, 2001).

4.1.5 *Backpropagation*

O método utilizado para treinamento da rede perceptron de múltiplas camadas é chamado de *backpropagation* (retropropagação do erro). O treinamento é realizado apresentando um conjunto de N vetores de entrada e suas respectivas saídas desejadas (conjunto de exemplos de treinamento). Os pesos são ajustados de forma a diminuir a função de custo (ou função de perda) ε_{med} . A função de custo, tal como o erro quadrático e a entropia cruzada, calcula o erro na saída da rede, ou seja, estima quão diferente é o valor apresentado na saída do valor desejado para ela.

A cada vetor de entrada apresentado à rede, são feitos dois passos: a propagação direta, na qual é calculada a saída de cada neurônio de camada para camada desde a entrada até a saída; e a retropropagação, onde, após o cálculo do erro entre a saída desejada e a real, este é propagado no sentido reverso, isto é, da saída para a entrada, calculando-se um ajuste para cada peso de cada neurônio em cada camada, sendo este ajuste proporcional à derivada parcial do erro em relação ao peso a ser ajustado, isto é

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad , \quad (4.5)$$

onde:

n é o índice do exemplo de treinamento (1 a N)

η é a taxa de aprendizagem;

$\varepsilon(n)$ é o erro na camada de saída estimado pela função de custo;
 w_{ji} é o peso sináptico que conecta a saída de um neurônio da camada anterior (índice i) ao neurônio da camada para o qual está sendo feito o ajuste dos pesos sinápticos (índice j);
 Δw_{ji} é o ajuste do peso w_{ji} .

Podem ser utilizadas três estratégias de treinamento diferentes. O modo sequencial, no qual os pesos são atualizados a cada exemplo de treinamento apresentado à rede com base no erro individual; o modo por lote, no qual os pesos são atualizados somente ao final da apresentação de todos os N exemplos de treinamento com base no erro médio ε_{med} ; e o modo por *mini-batches*, que é um intermediário entre os outros dois, que atualiza os pesos após um determinado número de exemplos (menor que N), chamado *mini-batch*.

O primeiro método é o mais simples, pois não é necessário armazenar os resultados de cada exemplo até o final da apresentação dos N exemplos de treinamento, exigindo menos memória.

A média aritmética dos ajustes realizados em cada exemplo de treinamento apresentado à rede é uma estimativa da alteração que seria realizada para minimizar ε_{med} , isto é, o erro médio de todos os N exemplos de treinamento apresentados à rede para treinamento.

A apresentação de todo o conjunto de treinamento com a propagação, retropropagação e ajuste dos pesos para cada vetor de entrada é chamado de época.

Para demonstrar o desenvolvimento das equações do algoritmo de retropropagação, é padronizada a notação onde o índice j se refere a um dos neurônios da camada em processamento. O índice i se refere a um dos neurônios da camada anterior, cujas saídas estão conectadas às entradas do neurônio j , o índice k se refere a um dos neurônios da camada posterior cujas entradas estão conectadas à saída do neurônio j e o índice n se refere a cada um dos vetores de entrada e saída desejada apresentados à rede, para os quais são feitos a propagação e a retropropagação.

A seguir, é feita a demonstração do equacionamento para o modo sequencial e função de perda erro quadrático. A começar pelo erro $e_j(n)$ em cada neurônio da última camada, dado por

$$e_j(n) = d_j(n) - y_j(n) . \quad (4.6)$$

A energia do erro $\varepsilon(n)$ é obtida a partir de

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) , \quad (4.7)$$

onde C representa o conjunto dos neurônios da camada de saída.

Se a função de custo escolhida fosse a entropia cruzada, utilizada normalmente quando a rede neural é usada para classificação de mais de duas classes, $\varepsilon(n)$ seria descrita por

$$\varepsilon(n) = - \sum_{j \in C} d_j(n) \cdot \log(y_j(n)) . \quad (4.8)$$

O erro médio ε_{med} é a média do erro $\varepsilon(n)$ para todos os N exemplos de treinamento apresentados à rede, isto é

$$\varepsilon_{med} = \frac{1}{N} \sum_{n=1}^N \varepsilon(n) \quad (4.9)$$

Se a atualização dos pesos for feita a cada exemplo de treinamento (modo sequencial), ε_{med} se torna igual a $\varepsilon(n)$.

A derivada parcial $\partial \varepsilon(n) / \partial w_{ji}(n)$ na Equação (4.5) pode ser expressa como

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial u_j(n)} \frac{\partial u_j(n)}{\partial w_{ji}(n)} . \quad (4.10)$$

Para um **neurônio de saída**:

- $\partial \varepsilon(n) / \partial e_j(n)$ pode ser calculada derivando a Equação (4.7), obtendo-se

$$\frac{\partial \varepsilon(n)}{\partial e_j(n)} = e_j(n) ; \quad (4.11)$$

- $\partial e_j(n)/\partial y_j(n)$ pode ser calculada derivando a Equação (4.6), obtendo-se

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad ; \quad (4.12)$$

- $\partial y_j(n)/\partial u_j(n)$ é a derivada da função de ativação $f(u_j(n))$, isto é

$$\frac{\partial y_j(n)}{\partial u_j(n)} = f'(u_j(n)) \quad ; \quad (4.13)$$

- $\partial u_j(n)/\partial w_{ji}(n)$ pode ser derivada da Equação (4.1), e é igual à própria entrada x_j do neurônio j , que é a saída do neurônio i (camada anterior), sendo expressa por

$$\frac{\partial u_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad . \quad (4.14)$$

Substituindo as Equações (4.11), (4.12), (4.13) e (4.14) em (4.10), tem-se

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = e_j(n) \cdot -1 \cdot f'(u_j(n)) \cdot y_i(n) \quad . \quad (4.15)$$

Substituindo (4.15) em (4.5), obtém-se

$$\Delta w_{ji}(n) = -\eta \cdot e_j(n) \cdot -1 \cdot f'(u_j(n)) \cdot y_i(n) \quad (4.16)$$

que, ao ser simplificada, é tida como

$$\Delta w_{ji}(n) = \eta \cdot e_j(n) \cdot f'(u_j(n)) \cdot y_i(n) \quad (4.17)$$

que, por fim, pode ser expressa como

$$\Delta w_{ji}(n) = \eta \cdot \delta_j(n) \cdot y_i(n) \quad . \quad (4.18)$$

A Equação (4.18) é chamada de regra delta, onde $\delta_j(n)$ é o gradiente local, dado por

$$\delta_j(n) = e_j(n) \cdot f'(u_j(n)) \quad . \quad (4.19)$$

A energia do erro $\varepsilon(n)$ é função das saídas dos neurônios da última camada. Portanto, para calcular o ajuste dos pesos de um neurônio de uma camada oculta, a derivada parcial $\partial\varepsilon(n)/\partial w_{ji}(n)$ na Equação (4.10) precisa ser calculada recursivamente, pois o erro não está na saída do neurônio j , e sim nos neurônios da última camada.

Para um neurônio na última camada oculta, os neurônios de saída estão na camada posterior. Portanto, $e_j(n)$ não é definida para os neurônios desta camada, de modo que a Equação (4.10) é adaptada para

$$\frac{\partial\varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial\varepsilon(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial u_j(n)} \frac{\partial u_j(n)}{\partial w_{ji}(n)} \quad . \quad (4.20)$$

É preciso calcular $\partial\varepsilon(n)/\partial y_j(n)$, onde $\varepsilon(n)$ é definida como a soma da energia do erro de cada um dos neurônios da camada de saída com índice k , que é a camada imediatamente posterior à última camada oculta com índice j , isto é

$$\varepsilon(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad , \quad (4.21)$$

onde C representa o conjunto de neurônios da camada de saída.

Diferenciando $\varepsilon(n)$ em relação a $y_j(n)$, obtém-se

$$\frac{\partial\varepsilon(n)}{\partial y_j(n)} = \sum_{k \in C} e_k(n) \frac{\partial e_k(n)}{\partial y_j(n)} \quad (4.22)$$

que, pela regra da cadeia para a derivada parcial $\partial\varepsilon(n)/\partial y_j(n)$, fica como

$$\frac{\partial\varepsilon(n)}{\partial y_j(n)} = \sum_{k \in C} e_k(n) \frac{\partial e_k(n)}{\partial u_k(n)} \frac{\partial u_k(n)}{\partial y_j(n)} \quad . \quad (4.23)$$

O erro nos neurônios da camada de saída, é dado por

$$e_k(n) = d_k(n) - y_k(n) \quad . \quad (4.24)$$

A saída dos neurônios da última camada, $y_k(n)$, pode ser expressa em função do sinal de ativação $u_k(n)$ a partir de uma função de ativação f , isto é

$$e_k(n) = d_k(n) - f(u_k(n)) . \quad (4.25)$$

A derivada do erro nos neurônios de saída em relação ao sinal de ativação é

$$\frac{\partial e_k(n)}{\partial u_k(n)} = -f'(u_k(n)) . \quad (4.26)$$

O sinal de ativação dos neurônios da última camada $u_k(n)$ é

$$u_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n) . \quad (4.27)$$

A derivada parcial de $u_k(n)$ em relação à saída do neurônio da última camada escondida é

$$\frac{\partial u_k(n)}{\partial y_j(n)} = w_{kj}(n) . \quad (4.28)$$

Substituindo (4.26) e (4.28) em (4.23), obtém-se

$$\begin{aligned} \frac{\partial \varepsilon(n)}{\partial y_j(n)} &= - \sum_k e_k(n) f'(u_k(n)) w_{kj}(n) \\ &= - \sum_k \delta_k(n) w_{kj}(n) . \end{aligned} \quad (4.29)$$

Substituindo (4.29), (4.13) e (4.14) em (4.20), obtém-se

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = - \sum_k \delta_k(n) w_{kj}(n) \cdot f'(u_j(n)) \cdot y_i(n) . \quad (4.30)$$

Substituindo (4.30) em (4.5), obtém-se

$$\Delta w_{ji}(n) = \eta \cdot \sum_k \delta_k(n) w_{kj}(n) \cdot f'(u_j(n)) \cdot y_i(n) . \quad (4.31)$$

Considerando o gradiente local do neurônio j como

$$\delta_j(n) = f'(u_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad , \quad (4.32)$$

pode-se então reescrever (4.31) como

$$\Delta w_{ji}(n) = \eta \cdot \delta_j(n) \cdot y_i(n) \quad . \quad (4.33)$$

Em resumo, os ajustes aplicados aos pesos seguem a regra delta da Equação (4.33). Para neurônios da camada de saída, calcula-se $\delta_j(n)$ usando a Equação (4.19). Para neurônios de uma camada escondida, calcula-se $\delta_j(n)$ usando a Equação (4.32), que relaciona os gradientes locais, os pesos dos neurônios da camada posterior conectados ao neurônio da camada oculta e a derivada da função de ativação para o argumento do sinal de ativação do neurônio da camada oculta para o qual está sendo calculado o ajuste do peso.

Portanto, para calcular os ajustes dos pesos é necessário apresentar um vetor de entrada, propagá-lo através da rede calculando os sinais de ativação e as saídas de todos os neurônios, calcular o erro em relação à saída desejada e então retropropagar o erro, calculando os gradientes locais e os ajustes dos pesos camada por camada.

É necessário conhecer a derivada da função de ativação para calcular o gradiente local de cada neurônio na rede. A função deve ser contínua para sua derivada existir para qualquer valor do sinal de ativação. Um exemplo de função diferenciável é a sigmoide logística ou unipolar, dada por

$$f_j(u_j(n)) = \frac{1}{1 + e^{-au_j(n)}} \quad , \quad (4.34)$$

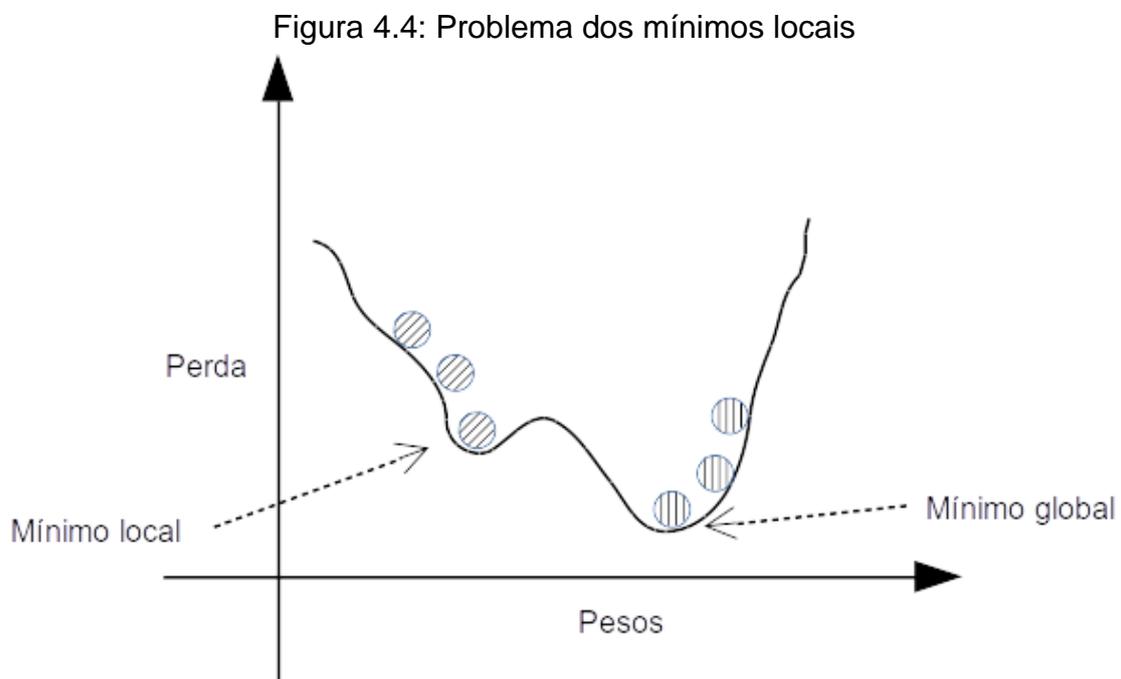
cuja derivada é

$$f'_j(u_j(n)) = \frac{ae^{-au_j(n)}}{[1 + e^{-au_j(n)}]^2} \quad . \quad (4.35)$$

Como $y_j(n) = f_j(u_j(n))$, pode-se expressar $f_j(u_j(n))$ em função de $y_j(n)$, isto é

$$f'_j(u_j(n)) = ay_j(n)[1 - y_j(n)] . \quad (4.36)$$

O parâmetro taxa de aprendizagem η da Equação (4.5) controla o valor dos ajustes dos pesos a cada iteração. Valores altos de η tendem a tornar o processo de aprendizagem instável (oscilatório) devido a ajuste dos pesos muito grandes. Valores baixos de η tornam o processo de aprendizagem mais suave, porém mais demorado, necessitando de um maior número de iterações. Um problema que pode dificultar o processo de treinamento é a ocorrência de mínimos locais na função de custo, que podem impedir a convergência do algoritmo para o mínimo global da função, como ilustrado na Figura 4.4.



Fonte: (SAMPAIO, 2020)

Uma forma de aumentar a taxa de aprendizagem, mas reduzindo o risco de instabilidade e do algoritmo ficar preso em um mínimo local, é adicionar um termo de momento ao ajuste, que é uma fração do ajuste realizado na iteração anterior.

A regra delta com a inclusão do momento é chamada de regra delta generalizada e é expressa por

$$\Delta w_{ji}(n) = \eta \cdot \delta_j(n) \cdot y_i(n) + \alpha \cdot \Delta w_{ji}(n - 1) . \quad (4.37)$$

Existem vários algoritmos para otimização do processo de treinamento, como *Stochastic Gradient Descent (SGD)*, *RMSprop*, *Adam*, *Adagrad* *Adabound* (RIBEIRO; JUNIOR, 2020) que não serão aprofundados neste estudo.

Para um treinamento eficaz, devem ser apresentados à rede exemplos de treinamento que retratem o ambiente externo nas mais diferentes condições possíveis.

Existem alguns critérios para a finalização do treinamento. Um baixo erro de classificação não é suficiente, pois não é garantia de que a rede está conseguindo generalizar o aprendizado para vetores de entrada não apresentados no treinamento. Normalmente, o critério utiliza a avaliação do erro de validação, que será explicado na Subseção 4.1.7.

4.1.6 Algoritmo de retropropagação

O pseudocódigo a seguir, denominado propagação direta, se utiliza de um vetor de entrada x para gerar um vetor correspondente de saída y , onde cada elemento de tal vetor é a saída de um neurônio da última camada da rede neural.

Propagação direta	
1:	<u>Faça</u> para $j = 1$ até $m(0)$ (números de neurônios da camada de entrada);
2:	$y(0, j) = x(j)$ (saída da camada de entrada = entrada);
3:	<u>fim</u> ;
4:	<u>Faça</u> $l = 1$ até L (número de camadas excluindo a entrada);
5:	<u>Faça</u> $j = 1$ até $m(l)$ (número de neurônios da camada); (Calcule o sinal de ativação do neurônio j);
6:	$u(l, j) = w(w_atu, l, j, 0) * 1$ (bias);
7:	<u>Faça</u> $i = 1$ até $m(l-1)$ (número de neurônios camada anterior);
8:	$u(l, j) = u(l, j) + y(l-1, i) * w(w_atu, l, j, i)$ (somatória $x_i \cdot w_{ij}$);
9:	<u>fim</u> ; (Calcule a saída do neurônio j);
10:	$y(l, j) = 1 / (1 + \exp(-a * u(l, j)))$ (sigmoide logística);
11:	<u>fim</u> ;
12:	<u>fim</u> ;

Os pseudocódigos a seguir, denominados retropropagação, se utilizam da saída desejada d e da saída y calculada a partir da propagação direta, a fim de determinar o erro que, na sequência, é usado para o ajuste dos pesos e *bias* de cada neurônio da rede, através do cálculo dos seus gradientes locais.

Retropropagação (Camada de saída)	
1:	<u>Faça</u> para $j = 1$ até $m(L)$ (número de neurônios da camada de saída);
2:	$e(j) = d(j) - y(L, j)$ (erro);
3:	$f_linha = a * y(L, j) * (1 - y(L, j))$ ($f'(u)$ derivada da função de ativação);
4:	$gl(L, j) = e(j) * f_linha$ (gradiente local do neurônio);
5:	$delta_w(d_atu, L, j, 0) = eta * gl(L, j) * 1$ (ajuste do bias);
6:	$w(w_prox, L, j, 0) = w(w_atu, L, j, 0) +$ $+ delta_w(d_atu, L, j, 0) +$ $+ alfa * delta_w(d_ant, L, j, 0);$ (novo bias);
7:	<u>Faça</u> para $i = 1$ até $m(L-1)$ (nº de neurônios da camada anterior);
8:	$delta_w(w_atu, L, j, i) = eta * gl(L, j) * y(L-1, i)$ (ajuste do peso);
9:	$w(w_prox, L, j, i) = w(w_atu, L, j, i) +$ $+ delta_w(d_atu, L, j, i) +$ $+ alfa * delta_w(d_ant, L, j, i);$ (novo peso);
10:	<u>Fim</u> ;
11:	<u>Fim</u> ;

Retropropagação (Camadas ocultas)	
1:	<u>Faça</u> $l = (L-1)$ <u>até</u> 1 (número de camadas excluindo a entrada e a saída);
2:	<u>Faça para</u> $j = 1$ <u>até</u> $m(l)$ (número de neurônios na camada);
3:	$glk = 0$; (inicializa soma dos gradientes da camada posterior);
4:	<u>Faça para</u> $k = 1$ <u>até</u> $m(l+1)$ (número de neurônios da camada posterior);
5:	$glk = glk + gl(L, j) * w(w_atu, l, k, j)$; (soma do gradiente da camada posterior);
6:	<u>fim</u> ;
7:	$f_linha = a * y(L, j) * (1 - y(L, j))$; ($f'(u)$ derivada sigmoide logística);
8:	$gl(l, j) = f_linha * glk$; (gradiente neurônio camada oculta);
9:	$delta_w(d_atu, l, j, 0) = eta * gl(l, j) * 1$; (ajuste do bias);
10:	$w(w_prox, l, j, 0) = w(w_atu, l, j, 0) +$ (novo bias); $+ delta_w(d_atu, l, j, 0) +$ $+ alfa * delta_w(d_ant, l, j, 0)$;
11:	<u>Faça para</u> $i = 1$ <u>até</u> $m(l-1)$ (n^o neurônios da camada anterior);
12:	$delta_w(d_atu, l, j, i) = eta * gl(l, j) * y(l-1, i)$; (ajuste do peso);
13:	$w(w_prox, l, j, i) = w(w_atu, l, j, i) +$ (novo peso); $+ delta_w(d_atu, l, j, i) +$ $+ alfa * delta_w(d_ant, l, j, i)$;
14:	<u>Fim</u> ;
15:	<u>Fim</u> ;
16:	<u>Fim</u> ;

Atualiza os índices	
(atualiza os índices de w e delta a cada apresentação de um exemplo de treinamento);	
1:	<u>Procedimento</u> <i>atualiza_indices</i> (w_{prox} , w_{atu} , d_{atu} , d_{ant});
2:	$aux = w_{prox}$;
3:	$w_{prox} = w_{atu}$;
4:	$w_{atu} = aux$;
5:	$aux = d_{atu}$;
6:	$d_{atu} = d_{ant}$;
7:	$d_{ant} = aux$;
8:	<u>Fim</u> ;

4.1.7 Validação

Uma das características desejáveis para uma rede neural é a capacidade de generalização. Isto é, a rede neural deve ser capaz de classificar corretamente exemplos que não foram utilizados no treinamento. Conforme a rede é treinada, o erro na saída para todos os dados do treinamento tende a diminuir.

Se a rede for treinada excessivamente, corre o risco de ficar muito especializada nos exemplos utilizados no treinamento, não sendo capaz de classificar corretamente outros vetores de entrada que não estiveram presentes no treinamento. Diz-se, neste caso, que a rede teve um sobreajuste, em inglês *overfitting*.

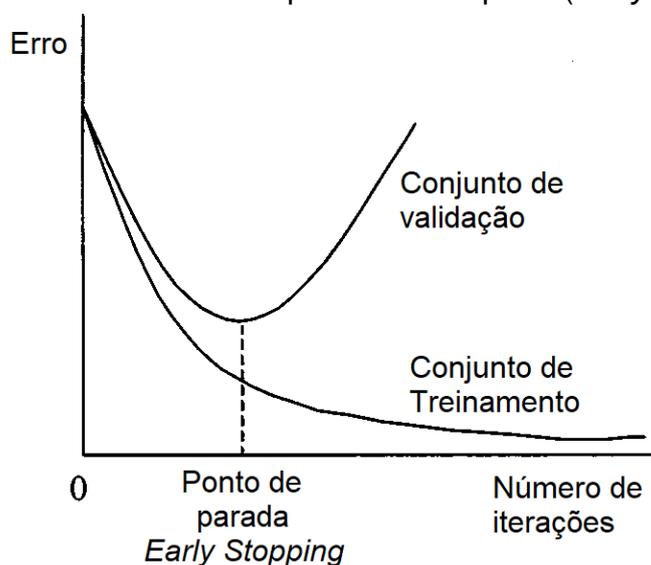
A validação permite avaliar a característica de especialização e generalização da rede. Esse objetivo é conseguido separando uma parte dos dados do treinamento para formar um conjunto de dados de validação. O conjunto de validação não é utilizado no treinamento e permite avaliar se a rede está sendo capaz de generalizar o conhecimento adquirido no treinamento.

Se a quantidade de dados de treinamento for grande em relação ao número de parâmetros livres da rede, o treinamento exaustivo não tem maiores consequências. Caso contrário, a rede pode perder a capacidade de

generalização. Para avaliar o momento de finalizar o treinamento, periodicamente ele é interrompido e são apresentados dados de validação.

O erro relativo aos dados de treinamento diminui conforme a evolução do treinamento. Já o erro relativo aos dados de validação diminui até um certo valor e volta a aumentar. Esse aumento indica que o treinamento está se tornando exaustivo e que a rede está perdendo a capacidade de generalização. Nesse momento o treinamento deve ser finalizado, sendo esse método chamado de treinamento com parada antecipada, ou *early stopping* (HAYKIN, 2001), conforme ilustrado na Figura 4.5.

Figura 4.5: Treinamento com parada antecipada (*Early Stopping*)



Fonte: (GENCAY; MIN QI, 2001)

Nota: Adaptada pelo autor

O momento exato de parar o treinamento não é unanimidade. Em (PRECHELT, 1998), foi feito um estudo para quantizar o momento de parada do treinamento, utilizando vários critérios para isso e analisando-os sob os aspectos de eficiência e eficácia.

Existe ainda a possibilidade da rede se ajustar aos dados de validação. Para afastar esta possibilidade, o desempenho final da rede é avaliado utilizando outro conjunto de dados, chamado de conjunto de teste.

De acordo com resultados de um estudo realizado em (KEARNS, 1997), cerca de 20% dos dados disponíveis para treinamento deve ser reservado para

validação, a fim de atender, de forma aproximadamente ótima, a uma ampla faixa de complexidade de funções alvo modeladas pela rede neural.

4.2 PRÉ-PROCESSAMENTO DOS DADOS

As redes neurais artificiais requerem dados de entrada com valores limitados a intervalos fechados como, por exemplo, os intervalos de 0 a 1, -1 a +1, e ainda um intervalo cujos dados tenham média zero e desvio padrão 1, os quais são intervalos típicos.

A definição do intervalo a ser utilizado depende da função de ativação da rede neural. O intervalo de 0 a 1, por exemplo, é necessário quando a rede neural é baseada em uma função de ativação sigmoide, enquanto o intervalo de -1 a 1 é aplicado quando tal função de ativação é do tipo tangente hiperbólica.

A transformação de dados de entrada de uma rede neural artificial para uma faixa de valores requeridos pela rede é feita aplicando uma função matemática de normalização. Tal ação é denominada de pré-processamento dos dados.

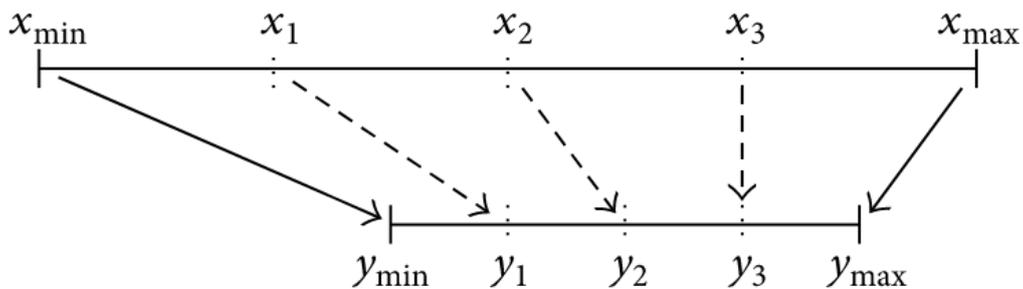
Uma das consequências da normalização dos dados é a diminuição do tempo de treinamento da rede neural artificial. A não normalização dos dados pode causar um efeito extremamente indesejado que é a saturação dos pesos que ajudam a definir a rede neural. Tal saturação pode ocorrer devido à existência de valores de entrada muito grandes, com conseqüente não convergência do processo de treinamento.

Existem vários métodos de normalização, sendo que os principais métodos são as chamadas transformações lineares *MinMax_Scaler* e *Standard_Scaler* (JIN; LI; JIN, 2015; KUMAR; RAGHUWANSHI; SINGH, 2011; RAZA; KHOSRAVI, 2015; SOLA; SEVILLA, 1997; YADHAVAN, 2017).

A transformação *MinMax_Scaler* é dada pela Equação (4.38). A Figura 4.6 ilustra tal método, onde x representa os dados de entrada antes da normalização e y tais dados após a normalização. Observa-se que x está contido em um intervalo cujos limites, inferior e superior, são dados por x_{min} e x_{max} , respectivamente, enquanto que y é o mapeamento de x para valores com novos limites inferior e superior representados por y_{min} e y_{max} , respectivamente (JIN; LI; JIN, 2015).

$$y = \frac{(x - x_{min}) \cdot (y_{max} - y_{min})}{x_{max} - x_{min}} + y_{min} \quad (4.38)$$

Figura 4.6: Método de normalização *MinMax_Scaler*

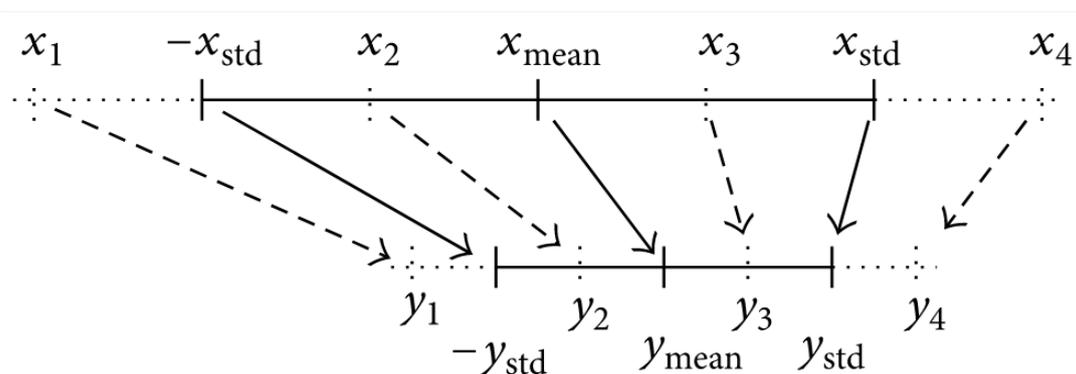


Fonte:(JIN; LI; JIN, 2015)

A transformação *Standard_Scaler* é dada pela Equação (4.39). A Figura 4.7 ilustra tal método, onde x representa os dados de entrada antes da normalização e y tais dados após a normalização. Observa-se que x têm um valor médio x_{mean} e um desvio padrão x_{std} , os quais são mapeados para novos valores y com média y_{mean} e desvio padrão y_{std} .

$$y = \frac{(x - x_{mean}) \cdot y_{std}}{x_{std}} + y_{mean} \quad (4.39)$$

Figura 4.7: Método de normalização *Standard_Scaler*



Fonte:(JIN; LI; JIN, 2015)

4.3 REDES NEURAIAS CONVOLUCIONAIS

As redes neurais convolucionais (*CNN*, do inglês *Convolutional Neural Network*) têm suas camadas ocultas iniciais diferentes da *MLP*. Essas camadas são responsáveis por extrair características da entrada em sua forma espacial original utilizando campos receptivos locais, melhor explicados na subseção 4.3.1.

Sua estrutura teve inspiração em pesquisas sobre o córtex visual de animais, que tem camadas alternadas de células simples e complexas (HUBEL; WIESEL, 1959).

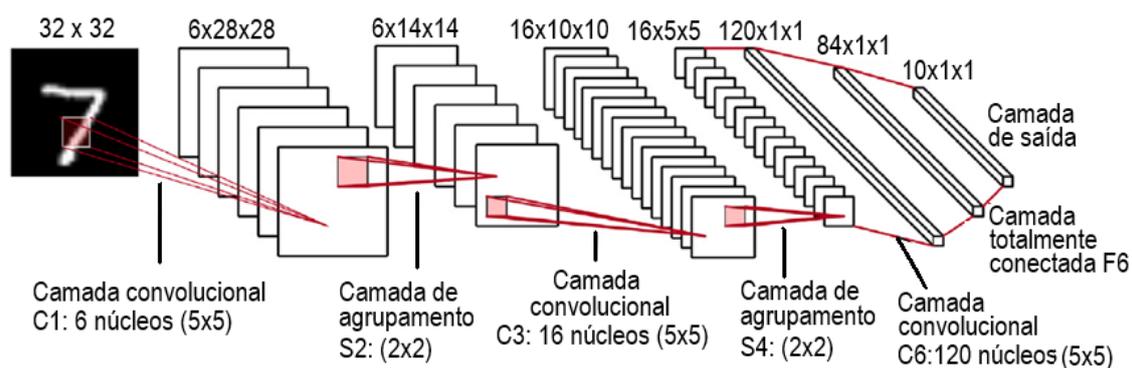
Esse tipo de rede neural foi projetado para processar dados organizados em forma de múltiplas matrizes como sinais, sons e fala (1 dimensão), imagens planas (2 dimensões), vídeos ou imagens tridimensionais (3 dimensões) (EBERMAM; KROHLING, 2018; LECUN; BENGIO; HINTON, 2015).

CNNs têm sido aplicadas em reconhecimento de voz. Entretanto, seu uso mais comum é em aplicações voltadas a visão computacional. Tal tipo de problema requer invariância à translação, rotação e distorção (EBERMAM; KROHLING, 2018; HAYKIN, 2001; LECUN; BENGIO; HINTON, 2015).

A rede neural convolucional tem camadas de extração de características em níveis hierárquicos, onde cada camada extrai novas características baseadas nas características extraídas pelas camadas anteriores (EBERMAM; KROHLING, 2018; GUO et al., 2016; LECUN; BENGIO; HINTON, 2015).

Os dois tipos de camadas que diferenciam a rede neural convolucional das outras arquiteturas são as camadas convolucional e de agrupamento (*pooling*). A Figura 4.8 ilustra a arquitetura da rede neural convolucional LeNet-5 apresentada em (LECUN et al., 1998).

Figura 4.8: Estrutura da rede neural convolucional LeNet-5



Fonte: (GU et al., 2018)

Nota: Adaptada pelo autor

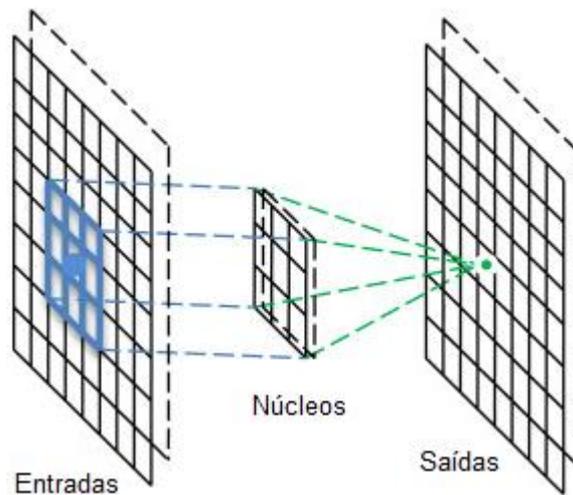
4.3.1 Camada convolucional

A camada convolucional é formada de vários mapas de características em que cada neurônio pertencente a um mapa está conectado a uma determinada quantidade de neurônios adjacentes da camada anterior, chamado de campo receptivo local, através de um conjunto de pesos treináveis. Esse conjunto de pesos é chamado de núcleo convolucional (*kernel*) e tem os mesmos valores para todos os neurônios de um mesmo mapa de características, ou seja, é compartilhado.

Cada posição no mapa de características de saída é a soma dos produtos entre cada entrada do campo receptivo local e seu respectivo peso. Isto é equivalente a uma operação matemática chamada de convolução, onde cada posição na saída equivale a uma posição do núcleo convolucional na camada anterior. Deslocando o núcleo por toda a imagem, tem-se o mapa de característica completo.

Podem ser ajustados o tamanho do núcleo e o passo de deslocamento, chamado também de *stride*. Com a finalidade de ajustar o tamanho do mapa de características, pode ser acrescentada à camada anterior uma borda (*padding*) composta de zeros (EBERMAM; KROHLING, 2018; HAYKIN, 2001; LECUN; BENGIO; HINTON, 2015). A essas variáveis de ajuste da *CNN* dá-se o nome de hiper parâmetros.

Figura 4.9: um mapa de características em uma camada convolucional



Fonte: (GUO et al., 2016)

Nota: Adaptada pelo autor

O tamanho do mapa de característica em cada dimensão (largura ou altura) é dado pela Equação (4.40) (EBERMAM; KROHLING, 2018).

$$T_m = \frac{M + 2p - k}{s} + 1 \quad (4.40)$$

onde:

T_m é o tamanho do mapa de características;

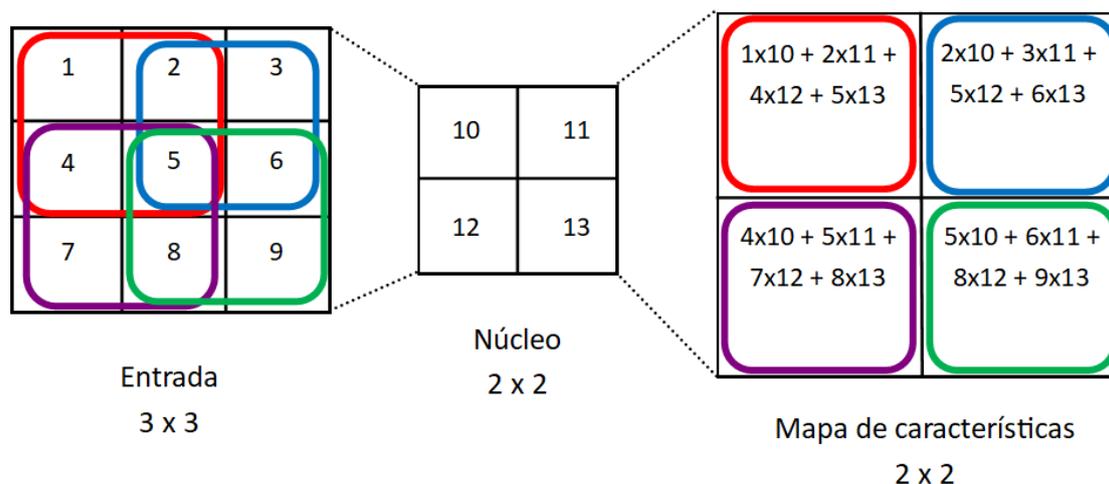
M é o tamanho da camada anterior (entrada);

p é o tamanho da borda;

k é o tamanho do núcleo;

s é o passo de deslocamento (*stride*);

Figura 4.10: Exemplo da operação de convolução (*stride* = 1, sem *padding*)



Fonte: Próprio autor

4.3.2 Camada de agrupamento (*Pooling*)

A função da camada de agrupamento (*pooling*) é diminuir a dimensão e também gerar invariância a pequenos deslocamentos e distorções.

Existem vários tipos de *pooling*. Os mais comuns são o *max pooling* e o *average pooling*, isto é, agrupamento pelo valor máximo e pela média, respectivamente.

A camada de *pooling* opera de modo semelhante à de convolução, com duas diferenças: o *stride* normalmente é igual ao tamanho do núcleo, fazendo com que não haja interseção entre os campos receptivos desta camada, e, ao invés de soma ponderada, a saída de cada neurônio desta camada é simplesmente o máximo valor ou a média dos valores do campo receptivo (*max* e *average pooling*, respectivamente) (EBERMAM; KROHLING, 2018; GUO et al., 2016; LECUN; BENGIO; HINTON, 2015).

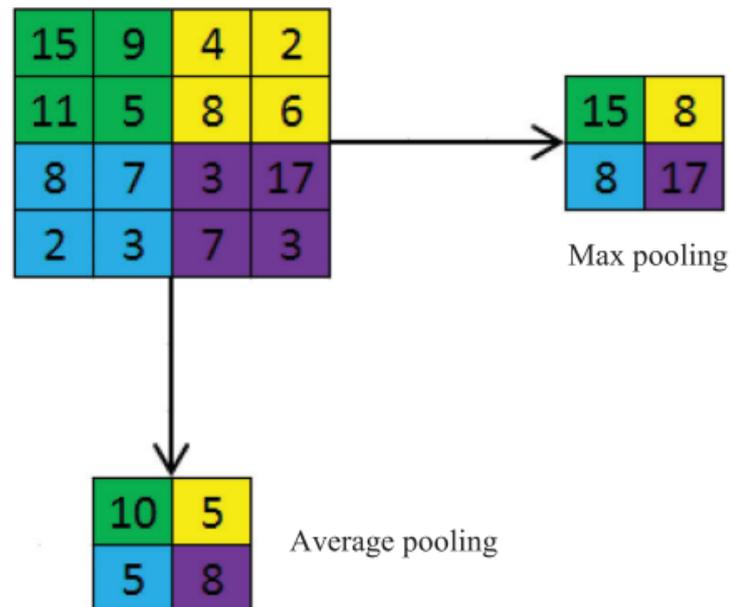
A Figura 4.11 ilustra o funcionamento da camada *pooling* para máximo e média. Cada cor representa um campo receptivo. Pode-se notar que a quantidade de informação é reduzida após a operação.

4.3.3 Camada totalmente conectada

Após algumas camadas de convolução e *pooling*, tem-se a camada totalmente conectada que irá classificar as características extraídas anteriormente. A camada anterior normalmente é composta por vários mapas de características, de uma ou mais dimensões. Esses mapas são redimensionados para um vetor

de dimensão única que é a entrada da camada totalmente conectada (EBERMAM; KROHLING, 2018), normalmente uma *MLP*.

Figura 4.11: Camada *pooling*



Fonte: (RAWAT; WANG, 2017)

4.3.4 Camada de saída com *Softmax*

A camada de saída tem o número de neurônios igual ao número de classes do problema. É conveniente que a saída de cada neurônio seja expressa em forma de uma probabilidade (0 a 1). A saída do neurônio com maior valor é considerada como a resposta da rede neural. Esse comportamento é implementado pela função *Softmax*, descrita pela Equação (4.41) (EBERMAM; KROHLING, 2018).

$$y_j = \frac{e^{x(j)}}{\sum_{i=1}^m e^{x(i)}} \quad (4.41)$$

onde

y_j é a saída de um neurônio j qualquer da camada;

$x(j)$ é a entrada do neurônio j da camada;

$x(i)$ são as entradas de todos os neurônios da camada.

5 METODOLOGIA

Este capítulo apresenta a metodologia adotada para buscar uma solução ao problema de identificação de painéis fotovoltaicos em funcionamento atípico.

Tal metodologia é baseada em procedimentos experimentais realizados em uma pequena planta fotovoltaica real (Seção 5.1). São adquiridas amostras de dados de geração instantânea de tal planta (tensão e corrente) (Seção 5.2). Tais amostras são usadas para o treinamento (Seção 5.4) de um sistema de inteligência artificial que será utilizada para identificar as condições de funcionamento atípico. Para isso, são testadas várias estruturas de redes neurais (Seção 5.3). Dados ambientais de irradiação solar e temperatura são também coletados e apenas armazenados para possível análise futura e validação do trabalho, não sendo utilizados pelo sistema de inteligência artificial.

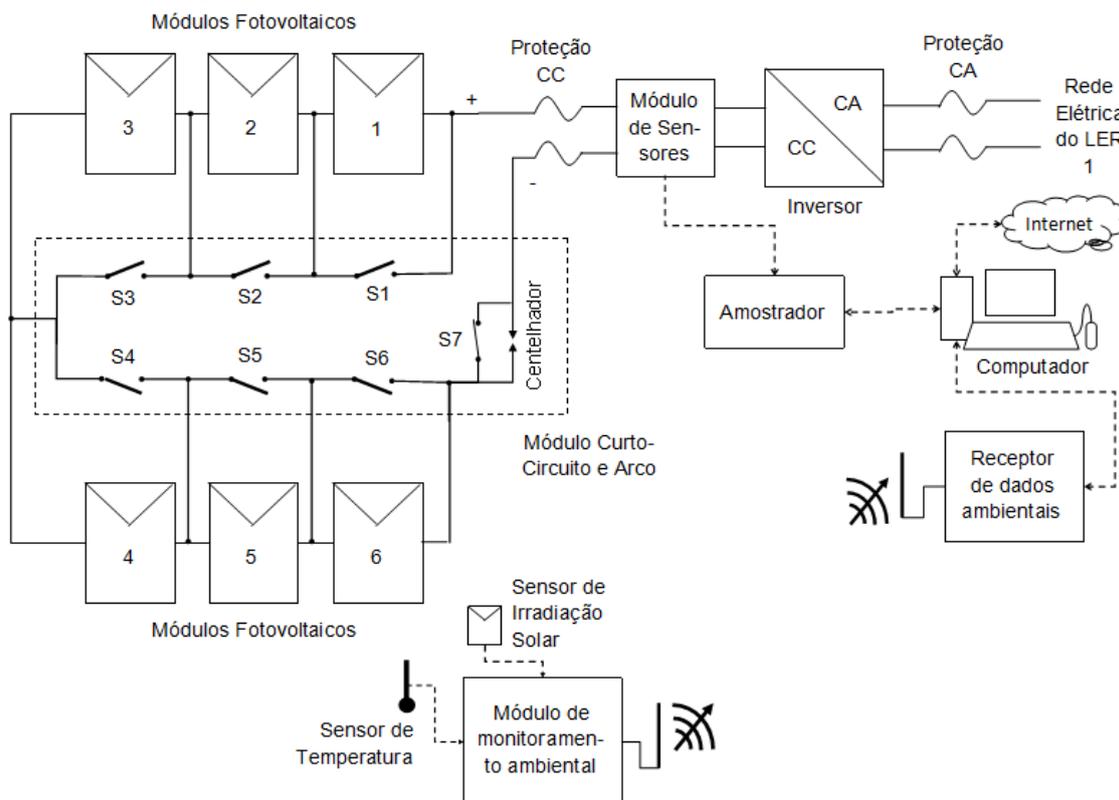
5.1 PLANTA FOTOVOLTAICA

A planta fotovoltaica usada para a realização dos experimentos é composta por uma *string* de seis módulos fotovoltaicos, conforme ilustrado na Figura 5.1. A *string* gera tensão em corrente contínua (CC), a qual é convertida para corrente alternada (CA) através do inversor. Por sua vez, a tensão de CA é injetada na rede elétrica do Laboratório de Energias Renováveis 1 (LER 1), atendendo parte da demanda elétrica do laboratório.

Pode-se ver ainda na Figura 5.1 que, entre a *string* e o inversor, é inserido um módulo com sensores de tensão e corrente, medindo assim a potência instantânea gerada pela *string*. Por fim, tal potência é digitalizada por um amostrador de dados e devidamente armazenada (computador).

Foi construído e adicionado ao sistema um módulo para emular defeitos como curto-circuito em cada módulo fotovoltaico e arco elétrico em um dos condutores que conectam a *string* ao inversor de frequência. O módulo consiste basicamente de um conjunto de chaves elétricas manuais, conforme se pode observar no bloco Curto-Circuito e Arco da Figura 5.1. Sua função é tornar práticas e rápidas as manobras experimentais que envolvem a emulação de funcionamento atípico da *string* fotovoltaica.

Figura 5.1: Estrutura da planta fotovoltaica experimental



Fonte: Próprio autor

5.1.1 String fotovoltaica

Os módulos fotovoltaicos são de silício policristalino com potência de 260 Wp (Watt-pico), ou seja, 260 W na condição padrão de teste (irradiância de 1000W/m², temperatura das células de 25 °C e espectro AM1.5).

A tensão e a corrente fornecidas no ponto de máxima potência são respectivamente 30,4 V e 8,56 A, enquanto a tensão de circuito aberto e corrente de curto-circuito são respectivamente 37,5 V e 9,12 A. As dimensões do módulo são de 1638 x 982 x 40 mm. Outros dados do módulo podem ser consultados no *datasheet* do equipamento disponibilizado no Anexo A.

A corrente nominal da *string* é a mesma de um único módulo, isto é 8,56 A, uma vez que, por definição, em uma *string* todos os painéis estão conectados em série. Por outro lado, em uma *string* a tensão e a potência nominais são iguais, respectivamente, à tensão e à potência de um único painel multiplicadas pelo número de painéis pertencentes a tal *string*.

No caso particular, a *string* utilizada é composta de seis painéis, de modo que a tensão nominal da string é de 182,4 V, enquanto que sua potência nominal é de 1560 W. Esses são os valores nominais para operação no ponto de máxima potência, sob condição padrão de teste.

A *string* foi agrupada fisicamente num formato de matriz de 2 linhas por 3 colunas, com dimensões aproximadas de 3276 x 2946 mm, conforme se vê na Figura 5.2.

Figura 5.2: *String* fotovoltaica

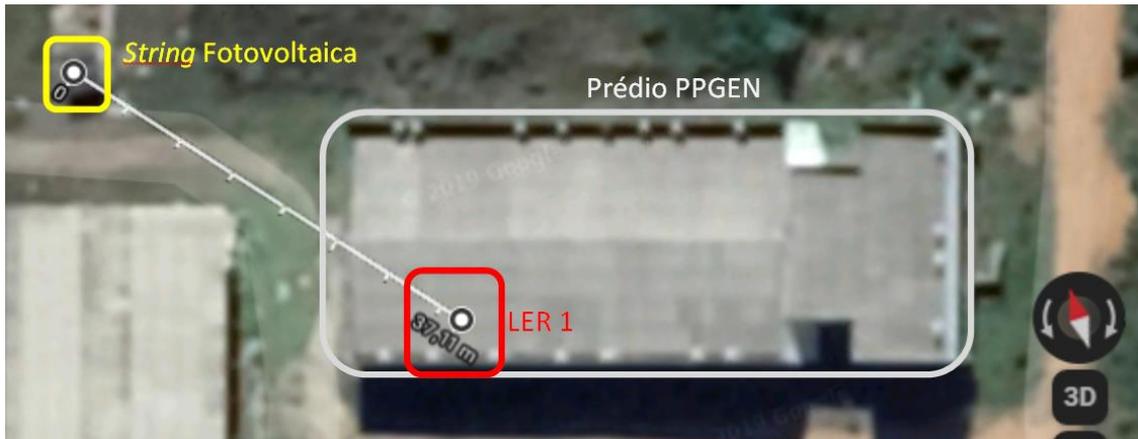


Fonte: Próprio autor

A Figura 5.3 ilustra a localização e o posicionamento relativo dos equipamentos da planta fotovoltaica. A string fotovoltaica está montada conforme se vê na Figura 5.3, a uma distância do LER 1 de aproximadamente 37 m (cada traço na reta branca que une os dois pontos equivale a 5 m). No LER 1 – localizado no prédio do PPGEN (Programa de Pós-Graduação em Energia) – estão contidos todos os demais aparatos experimentais a serem apresentados na sequência.

5.1.1 Inversor

O inversor utilizado é o PHB1500-SS, o qual é mostrado na Figura 5.4. A Tabela 5.1 apresenta as principais características deste inversor. Pode-se destacar em tal tabela a presença de um *MPPT* com eficiência máxima de 97%, além de tensão e corrente CC máximas de 450 V e 12 A, respectivamente, sendo, portanto, compatível com a *string* fotovoltaica apresentada na Subseção 5.1.1.

Figura 5.3: Posicionamento da *string* e do LER 1.

Fonte: Google Maps
Nota: Adaptado pelo autor

Figura 5.4: Inversor



Fonte: Próprio autor

Tabela 5.1: Características do inversor

Dados da Entrada CC	
Max. Potência Fotovoltaica	1800 W
Max. Tensão CC	450 V
Faixa de Operação SPMP (MPPT)	125~400 V
Tensão CC de Partida	125 V
Corrente CC Máxima	12 A
Número de <i>Strings</i> em Paralelo	1
Consumo em Standby	5W
Dados da Saída CA	
Potência CA Nominal	1500W
Max. Potência CA	1650W
Saída Nominal CA	60Hz; 220Vca
Fator de Potência	Unitário
Eficiência	
Max. Eficiência	97.0%
Eficiência SPMP (MPPT)	>99.5%
Dados Gerais	
Topologia	Sem Transformador
Dimensões (L*A*P)	330*350*125 mm
Peso Líquido	12Kg
Grau de Proteção IP	IP65

Fonte: (PHB SOLAR, 2015)

5.1.2 Módulo de sensores

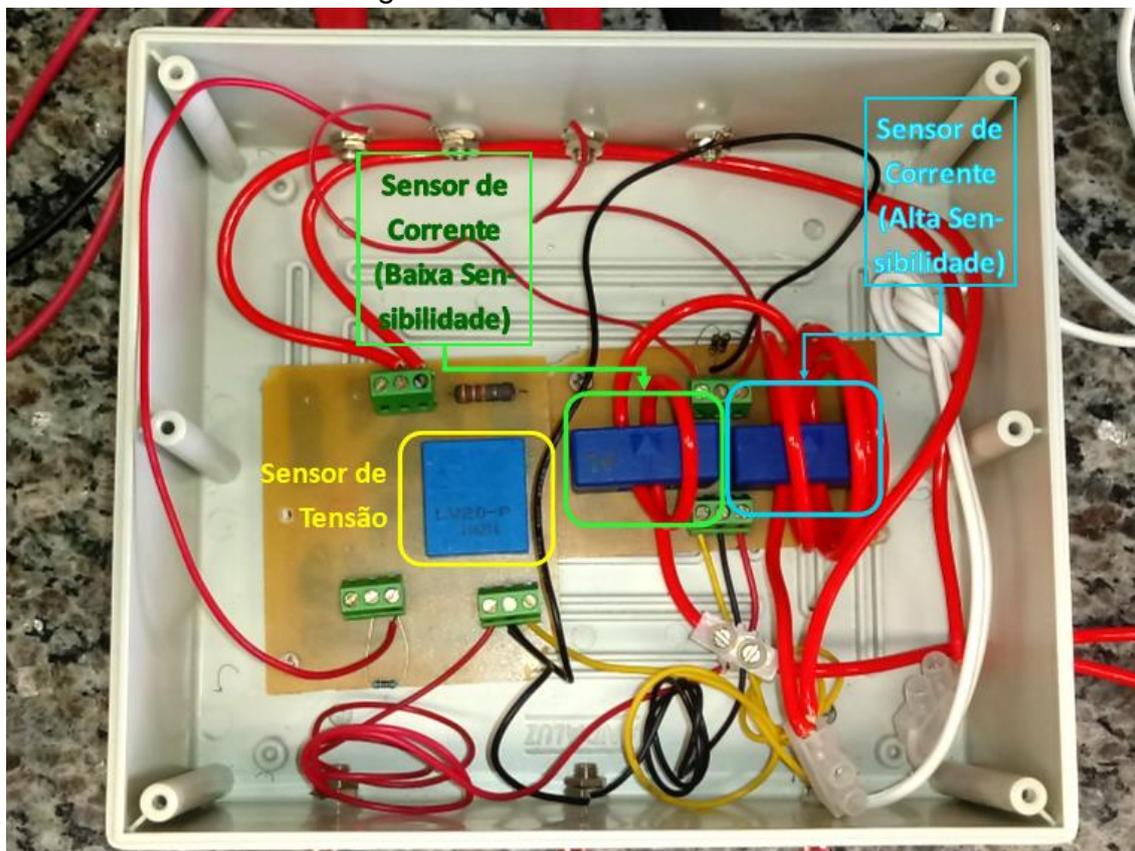
O módulo de sensores usado é composto por um sensor de tensão modelo LV20-P, dois sensores de corrente modelo LA55-P e circuito eletrônico necessário para o correto funcionamento de tais sensores. A Figura 5.5 apresenta o módulo e os referidos sensores nele contidos.

Cabe ressaltar que o motivo para a existência de dois sensores de corrente é que o módulo de sensores foi projetado para a medição de até duas faixas de corrente denominadas aqui de baixa sensibilidade (0 a 35A) e alta sensibilidade (0 a 14A). A baixa sensibilidade é obtida fazendo com que o cabo condutor de

corrente dê duas voltas em torno do sensor, enquanto que a alta sensibilidade se obtém fazendo com que o condutor dê cinco voltas em torno do sensor.

Pelo fato de a *string* fotovoltaica utilizada possuir uma corrente máxima que se encontra em uma faixa inferior a 14 A, usa-se aqui o sensor de alta sensibilidade.

Figura 5.5: Módulo de sensores



Fonte: Próprio Autor

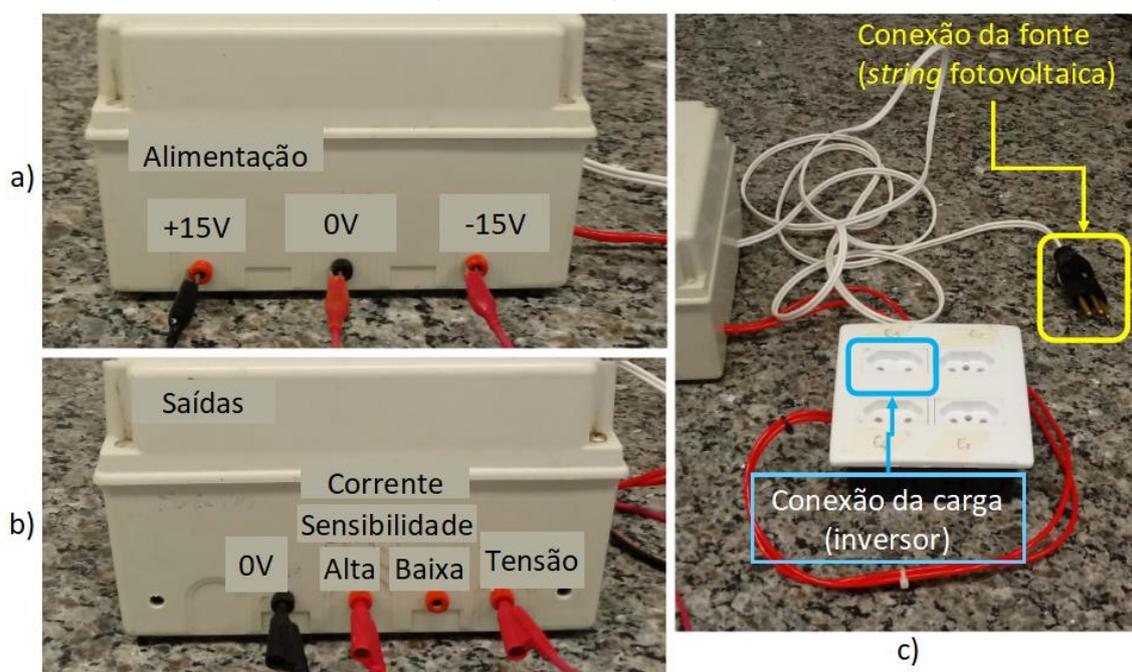
A Figura 5.6 ilustra todas as conexões externas do módulo de sensores. Como se pode observar na figura, o módulo necessita de alimentação simétrica com tensões de +15 e -15 V. Tais conexões são apresentadas em a).

Os sinais de saída com os valores medidos são fornecidos na forma de uma tensão proporcional às propriedades medidas, em relação a um terminal comum (0 V), e são mostrados em b).

As conexões ao circuito de potência incluem a entrada da fonte de potência, no caso a *string* fotovoltaica, e a saída para a carga, no caso o inversor, e estão mostradas em c).

Embora, sejam mostrados quatro pontos de conexão para cargas na Figura 5.6 c), apenas um é de fato utilizado neste trabalho em questão, como já mencionado. Porém, a justificativa dos quatro pontos é que parte do sistema experimental aqui mostrado é também empregado em estudos relacionados com a identificação autônoma de equipamentos em instalações elétricas (FIRMES, 2020; FIRMES; CELESTE; SILVESTRE, 2019) realizados pelo mesmo grupo de pesquisa no qual este autor está inserido.

Figura 5.6: Conexões do módulo de sensores a) alimentação b) sinais de saída c) circuito de potência



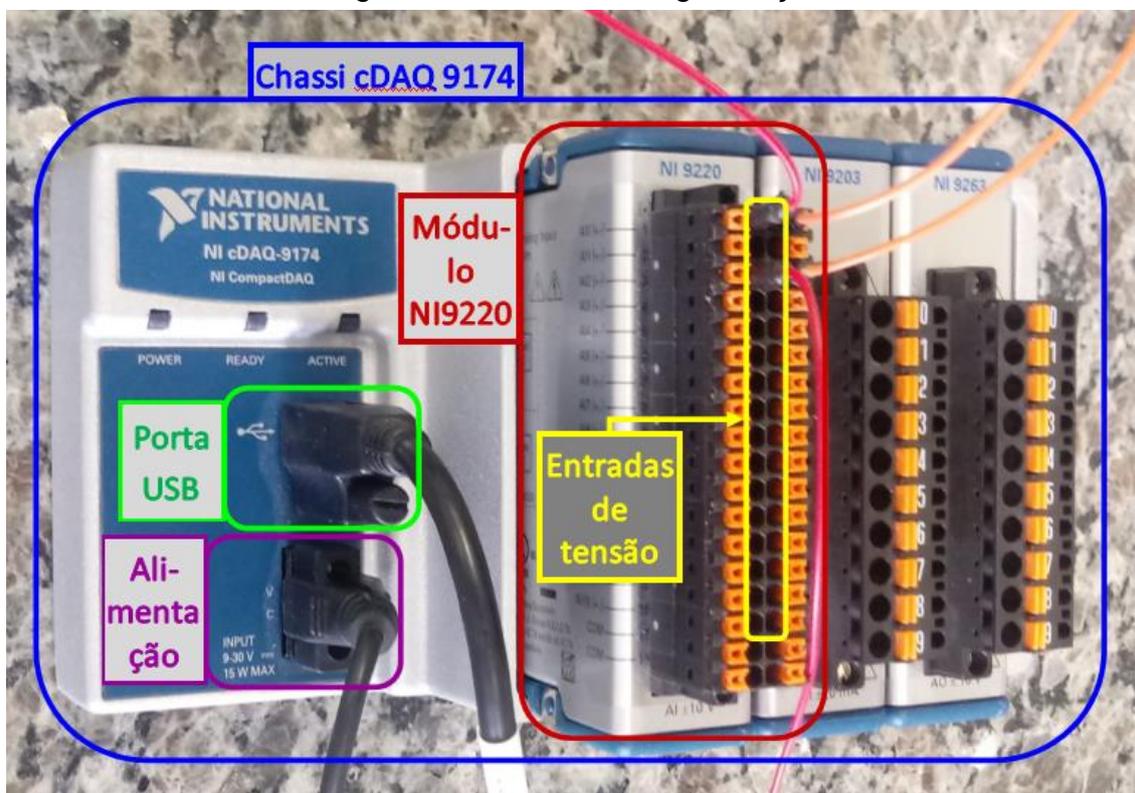
Fonte: Próprio Autor

5.1.3 Módulo de digitalização de dados

O módulo de digitalização de dados é responsável por amostrar os sinais de tensão e corrente entregues pelo módulo de sensores. O módulo de digitalização é composto pelo chassi cDAQ 9174 e pelo cartão NI 9220, ambos da *National Instruments (NI)*. O cartão NI 9220 possui 16 canais de entrada de tensão analógica de ± 10 V. Tais tensões em cada canal são amostradas a uma taxa de até 100.000 amostras por segundo, gerando códigos digitais com uma resolução de 16 bits. Já o chassi cDAQ 9174 permite comunicação via porta USB, por onde são realizadas as configurações necessárias para o uso de cartões nele inseridos, tais como o NI 9220, além de permitir a leitura dos códigos digitais

referentes as digitalizações realizadas. A Figura 5.7 mostra o módulo de digitalização, dando destaque a elementos do módulo relevantes para esta pesquisa.

Figura 5.7: Módulo de digitalização



Fonte: Próprio autor

5.1.4 Módulo de simulação de curto-circuito e arco elétrico

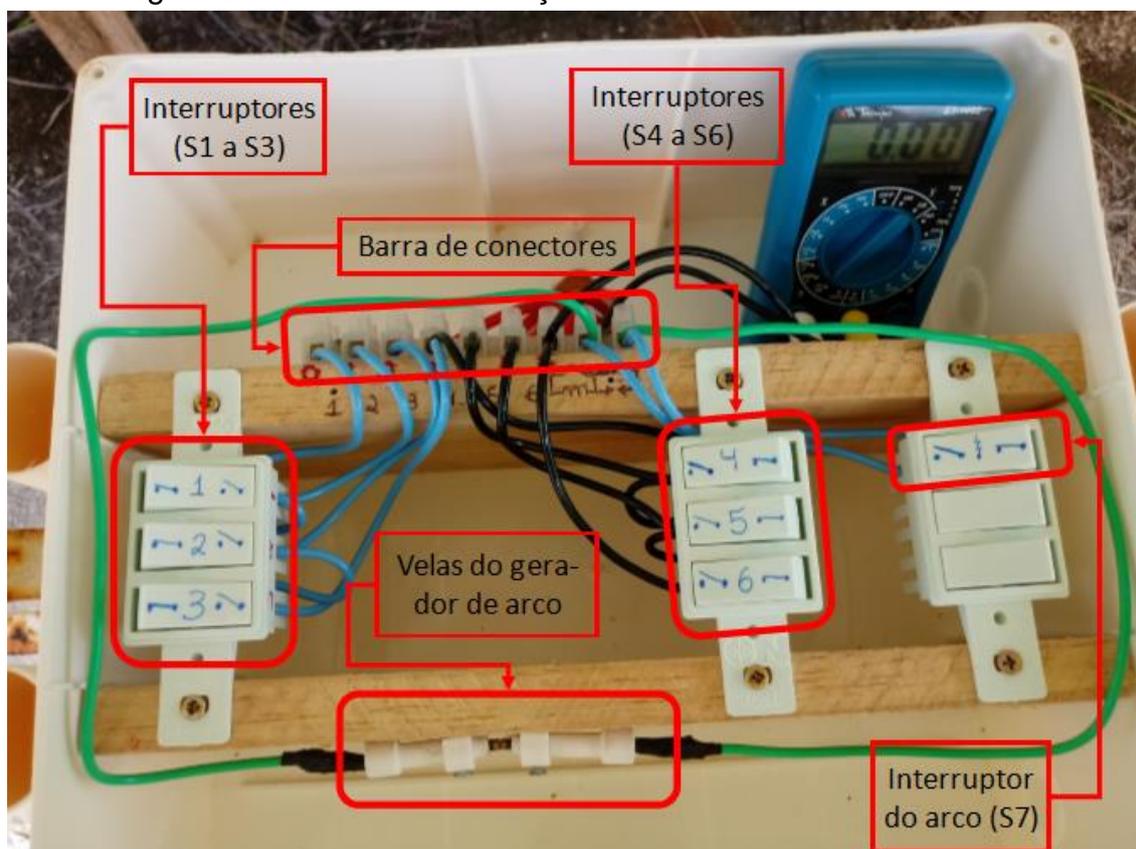
Um módulo de simulação de defeitos foi construído para emular curto-circuito em cada módulo da *string*, bem como reproduzir um arco elétrico no final da *string* (condutor negativo). O módulo é apresentado na Figura 5.8 sendo composto de um interruptor conectado em paralelo com cada módulo (S1 a S6) e um interruptor em paralelo com o gerador de arco (S7).

O gerador de arco é composto de duas velas de ignição (usadas para acendimento de fogão a gás), as quais são separadas por uma distância manualmente ajustável, sendo tal procedimento necessário para a obtenção do efeito requerido, isto é, o arco elétrico.

Em condição normal de funcionamento, os interruptores de simulação de curto-circuito ficam abertos e o do arco elétrico fica fechado para desviar sua corrente (vide Figura 5.1).

A simulação de curto-circuito em um módulo fotovoltaico é feita fechando o interruptor correspondente, que conectará o terminal positivo e negativo do módulo, levando sua tensão para zero. A simulação do arco elétrico é feita primeiramente unindo as velas do gerador de arco, abrindo o interruptor S7, e, em seguida, afastando as velas. Neste momento é gerado um arco elétrico (passagem de corrente através do ar) entre as velas, gerando luz, calor e ruído. Para extinguir o arco, o interruptor S7 deve ser fechado, desviando a corrente das velas.

Figura 5.8: Módulo de simulação de curto-circuito e arco elétrico



Fonte: Próprio autor

5.1.5 Simuladores de sombreamento

Com a finalidade de simular defeitos de sombreamento, foram construídos dois sombreadores. Um para sombrear um painel inteiro e outro para sombrear apenas um setor do painel. Os sombreadores são constituídos de uma tela de

cor preta que bloqueia 50% da luz incidente, a qual é presa em uma moldura de arame grosso galvanizado (com diâmetro de 2 mm aproximadamente). A Figura 5.9 e a Figura 5.10 mostram, respectivamente, o sombreamento de um módulo fotovoltaico inteiro e de apenas um setor de um módulo.

Figura 5.9: Sombreamento de um módulo fotovoltaico inteiro



Fonte: Próprio autor

Figura 5.10: Sombreamento de um setor de um módulo fotovoltaico



Fonte: Próprio autor

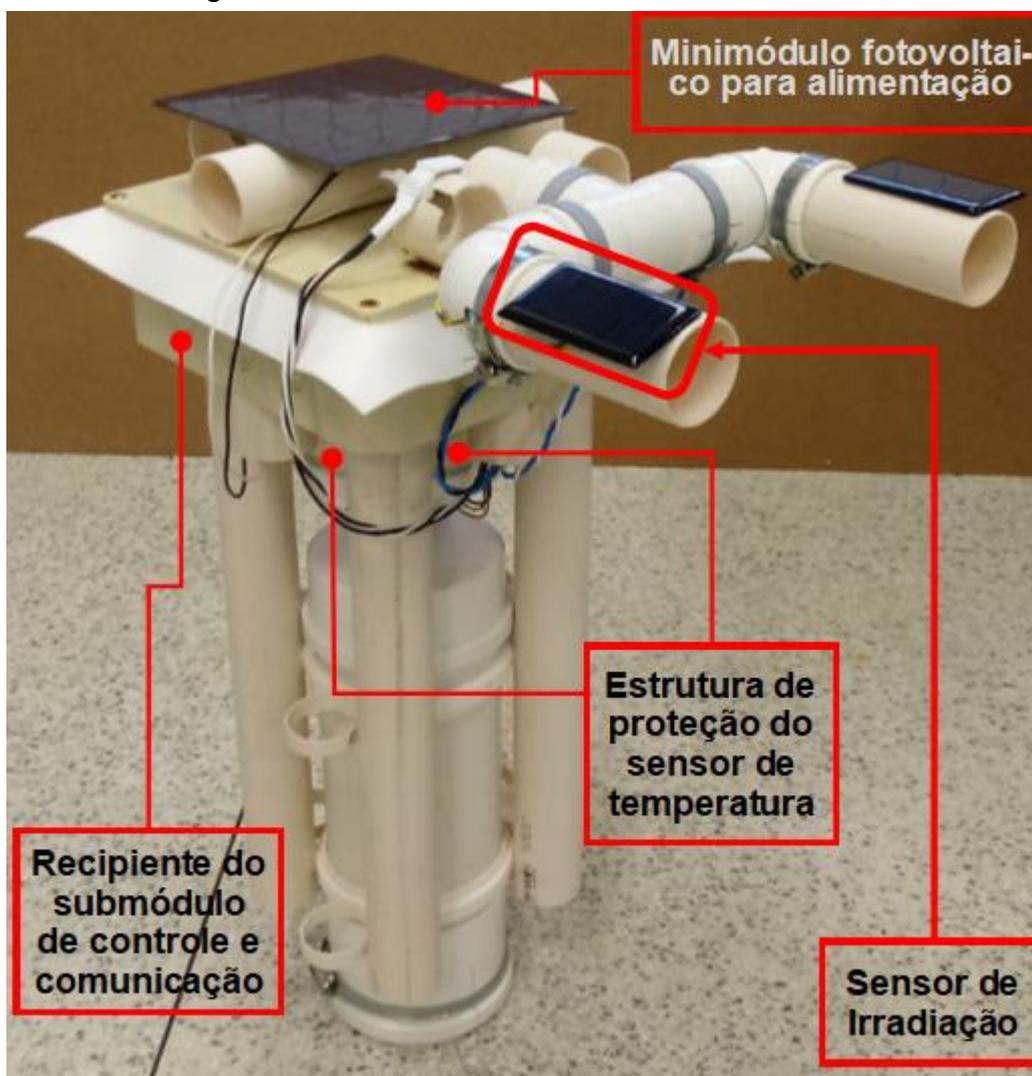
5.1.6 Módulo de monitoramento ambiental

O módulo de monitoramento ambiental (Figura 5.11) é responsável por coletar dados de irradiação solar e de temperatura ambiente. Esses dados serão armazenados para uma eventual contextualização durante análises futuras. Como este módulo deve ficar o mais próximo possível da *string* fotovoltaica, os dados por ele capturados são transmitidos para o sistema computacional remoto por meio de comunicação sem fio unidirecional.

Como mostrado na Figura 5.11, o módulo é constituído de um sensor de irradiação solar (Figura 5.13), um sensor de temperatura (Figura 5.14) e um submódulo de controle e comunicação (Figura 5.12). A estrutura do módulo da Figura 5.11 é constituída de material PVC tubular de 40 mm e 100 mm de

diâmetro. O submódulo de controle e comunicação está contido em um recipiente retangular de PVC de 20 x 20 cm.

Figura 5.11: Módulo de monitoramento ambiental



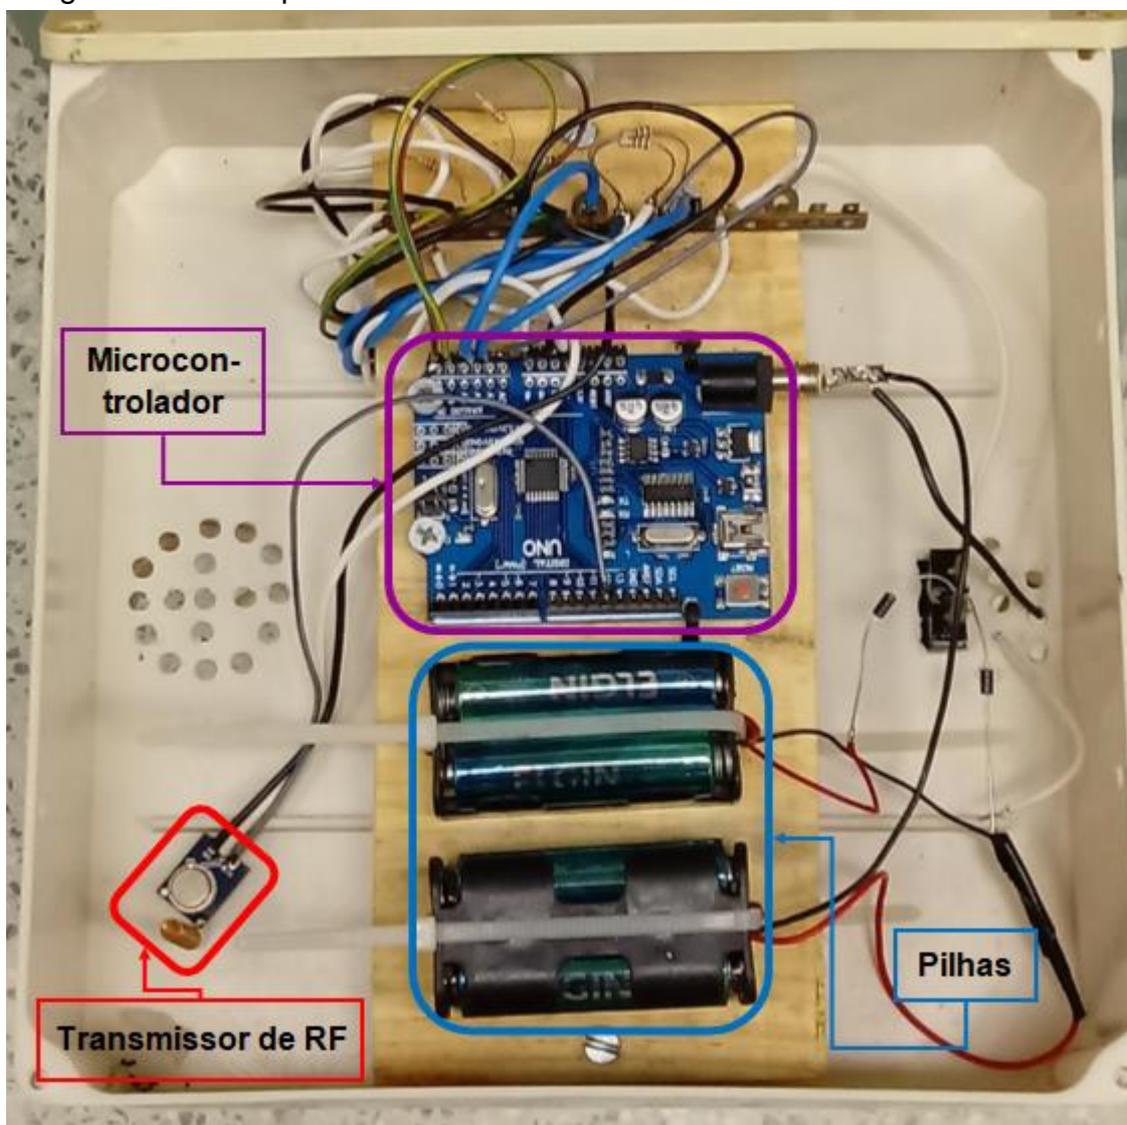
Fonte: Próprio autor

Como pode ser observado na Figura 5.12, o submódulo de controle e comunicação é constituído de um microcontrolador Arduíno Uno, um transmissor de rádio frequência modelo STX882-433 e seis pilhas alcalinas AA de 1,5 V e de aproximadamente 2700 mAh para alimentação de todo o módulo de monitoramento ambiental. Além das pilhas, o módulo é também alimentado por um mini painel fotovoltaico de 9 V e de 330 mA.

O sensor de irradiação é composto de um minimódulo solar de silício policristalino em paralelo com um resistor de baixa resistência (11 Ω), que faz com que o minimódulo solar opere próximo da região de curto-circuito. Os

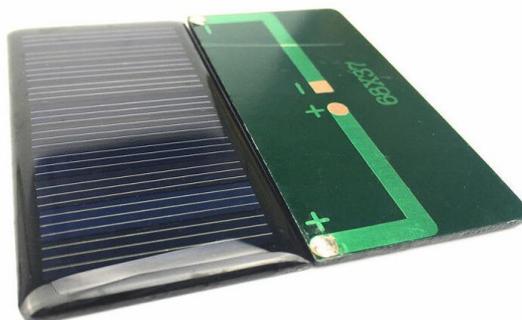
valores nominais de tensão e corrente do minimódulo são, respectivamente, 5 V e 60 mA, e suas dimensões de comprimento e largura são 68 x 37 mm.

Figura 5.12: Componentes internos do módulo de monitoramento ambiental.



Fonte: Próprio autor

Figura 5.13: Minimódulo solar que compõe o sensor de irradiação



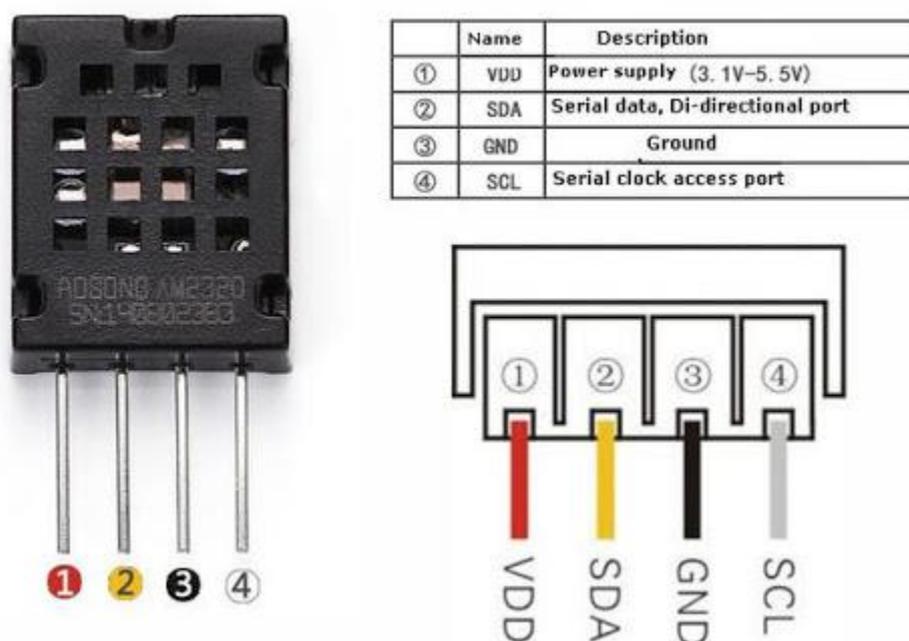
Fonte: (EBAY, 2019)

A corrente que circula no resistor (e sua tensão) será então proporcional à irradiação que incide sobre o minimódulo solar. A tensão sobre o resistor é aplicada a uma entrada analógica do microcontrolador (Figura 5.12) e convertida pelo seu conversor analógico digital para uma representação digital em 10 bits. A faixa de entrada analógica do conversor foi configurada para ter seus limites entre 0 e 1,1 V, que equivalem a uma faixa de valores convertidos de 0 a 1023.

O sensor foi calibrado com o auxílio de uma estação meteorológica, a *Davis Vantage Pro 2*. Detalhes da operação de calibração são apresentados na Subseção 5.1.9.

O sensor de temperatura ambiente usado é o Am2320, mostrado na Figura 5.14, que possui resolução de 0,1 °C, precisão de $\pm 0,5$ °C, e faixa de medição de -40 a 80 °C. A comunicação com o microcontrolador é feita através de um barramento digital no padrão *I2C*. O sensor possui 4 pinos, onde 2 são de alimentação (VDD e GND) e 2 de comunicação no padrão *I2C* (*da*s e *SCL*, para dados e *clock*, respectivamente).

Figura 5.14: Sensor de temperatura AM2320



Fonte: *Datasheet* do fabricante

O sensor de temperatura foi montado embaixo da caixa que abriga o microcontrolador e o transmissor de rádio frequência, no interior de uma

estrutura de proteção, para minimizar os efeitos da incidência direta de radiação solar, conforme pode ser visto na Figura 5.15.

Figura 5.15: Montagem do sensor de temperatura

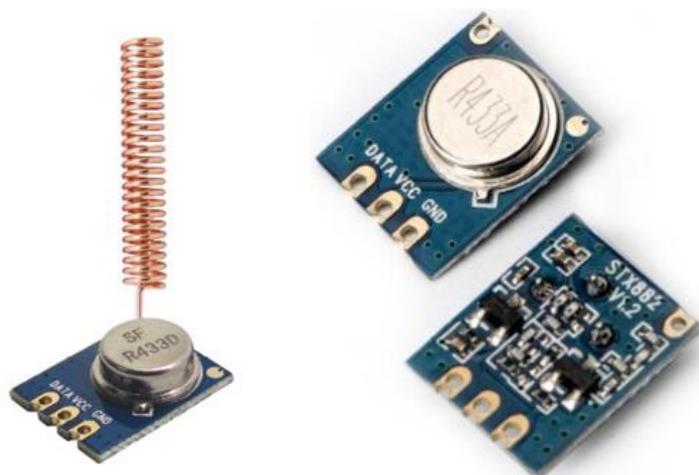


Fonte: Próprio autor

O transmissor de rádio frequência pode ser visto na Figura 5.16. É o modelo STX882-433, fabricado pela NiceRf. O STX882-433 utiliza modulação *ASK* (*Amplitude Shift Keying*) na frequência de 433 MHz e possui uma potência de 50 mW. Ele possui 3 pinos de conexão, sendo 2 de alimentação (*VCC* e *GND*) e 1 de entrada de dados digital (*DATA*).

O microcontrolador Arduíno Uno (em destaque na Figura 5.12) é o responsável por fazer uma leitura periódica dos sensores (digitalização em palavras de 10 bits) e enviar tais dados digitalizados para o módulo receptor a uma taxa de 2000 bits/segundo, uma vez que, como já mencionado, o módulo de monitoramento ambiental se encontra junto à *string* fotovoltaica enquanto que o módulo receptor está localizado nas dependências do LER 1.

Figura 5.16: Transmissor de rádio frequência STX882-433



Fonte: *Datasheet* e site do fabricante (NICERF, 2016b)

Nota: Adaptada pelo autor

5.1.7 Módulo receptor de dados ambientais

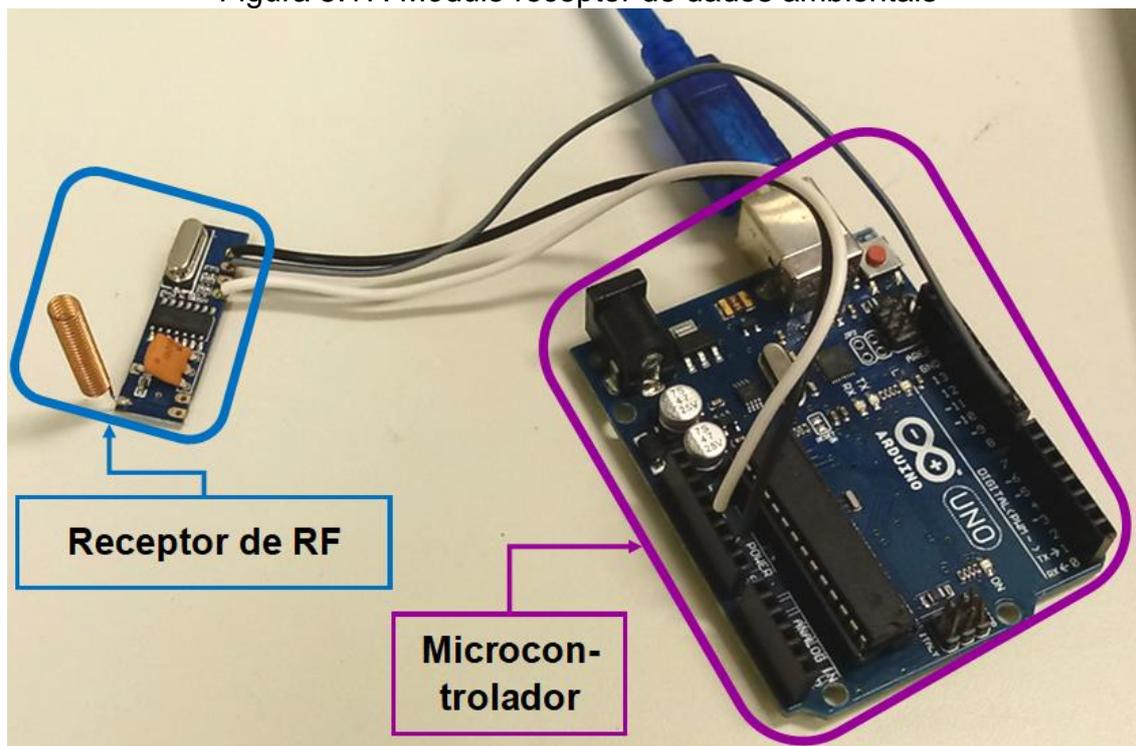
Este módulo, composto basicamente por um microcontrolador Arduino uno e um receptor de radiofrequência (Figura 5.17), é o responsável por receber os dados de irradiação solar e de temperatura ambiente enviados pelo módulo de monitoramento ambiental.

O módulo receptor se comunica com um computador, também localizado nas dependências do LER 1, através de comunicação serial via *USB*. Tal comunicação de dados ocorre apenas quando um comando de captura de dados é emitido por um operador humano via sistema de aquisição de dados implementado em tal computador.

O receptor de rádio frequência, mostrado na Figura 5.18, é o modelo SRX882, fabricado pela NiceRf, funcionando na frequência de 433 MHz, com tensão de alimentação de 5 V e consumo de 2,8 mA.

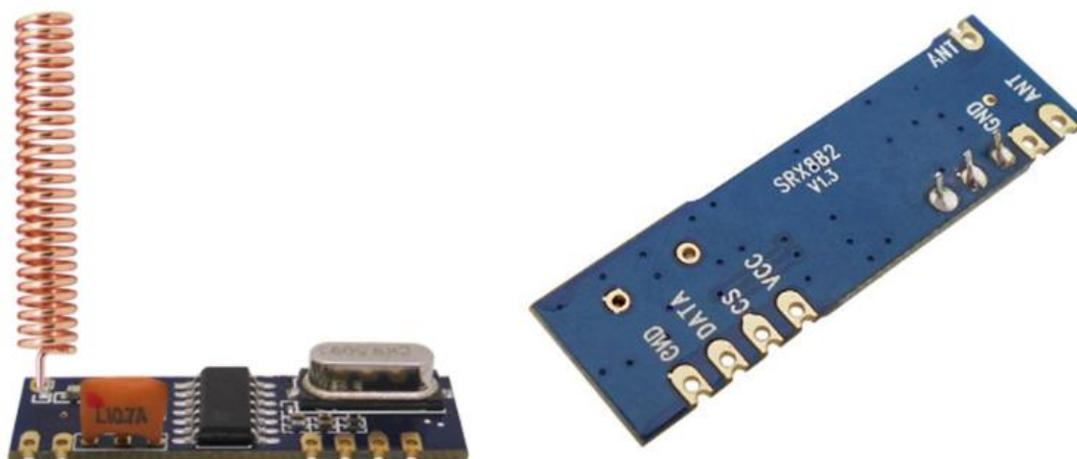
O microcontrolador recebe as mensagens vindas do módulo de monitoramento ambiental através do receptor de rádio frequência e calcula valores médios de irradiação e de temperatura do último 0,5 segundo. As mensagens recebidas antes deste período são descartadas. No momento da aquisição de dados, o computador solicita a esse módulo o envio da última média de irradiação e de temperatura, através de comunicação serial via *USB*.

Figura 5.17: Módulo receptor de dados ambientais



Fonte: Próprio autor

Figura 5.18: Receptor de rádio frequência



Fonte: *Datasheet* e site do fabricante (NICERF, 2016a)

Nota: Adaptada pelo autor

5.1.8 Calibração dos sensores de tensão e corrente

Os sensores de tensão e corrente presentes no módulo de sensores (Figura 5.5) foram calibrados com o auxílio de um multímetro e uma carga elétrica de teste (resistência de aquecimento).

O sensor de corrente foi calibrado montando-se o circuito mostrado na (Figura 5.19), que contém uma fonte de energia elétrica de corrente alternada senoidal

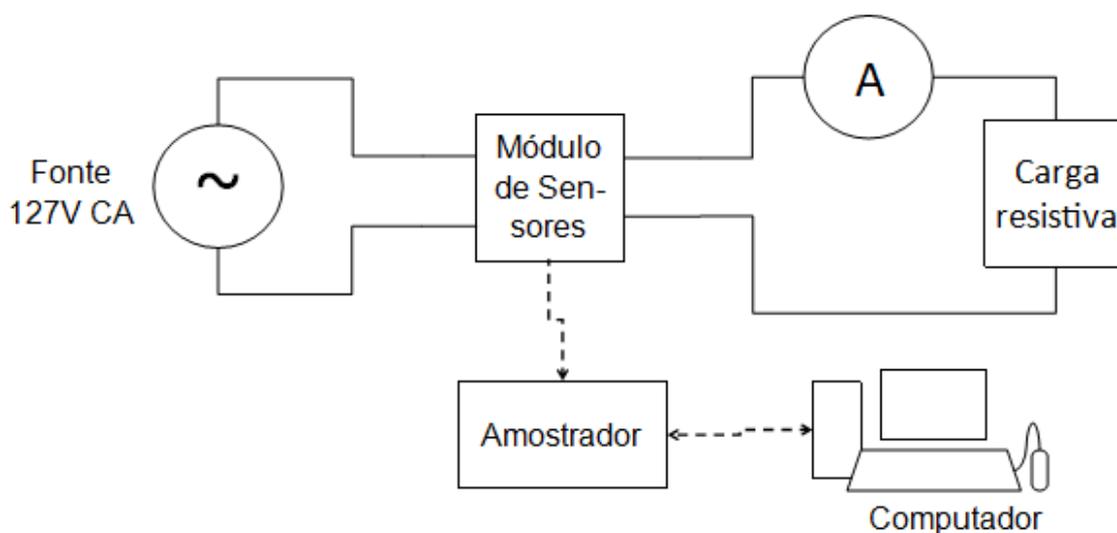
com valor de tensão eficaz de 127 V, o próprio sensor de corrente sob calibração contido no módulo de sensores, um amperímetro portátil de referência e uma carga de teste. Em seguida, foi feita uma aquisição de dados, onde o valor eficaz medido pelo amperímetro de referência foi usado para calcular o valor de pico da senoide, isto é

$$Valor_{pico} = Valor_{eficaz} \cdot \sqrt{2} \quad (5.1)$$

A constante de calibração do sensor de corrente, C_i , que relaciona o valor lido no sensor com o valor da corrente em Amperes (A), foi então calculada através da Equação (5.2).

$$C_i = \frac{Corrente \text{ (Amperes)}}{Valor \text{ no sensor}} = \frac{I_{pico \text{ amperímetro}}}{I_{pico \text{ sensor}}} \quad (5.2)$$

Figura 5.19: Calibração do sensor de corrente



Fonte: Próprio autor

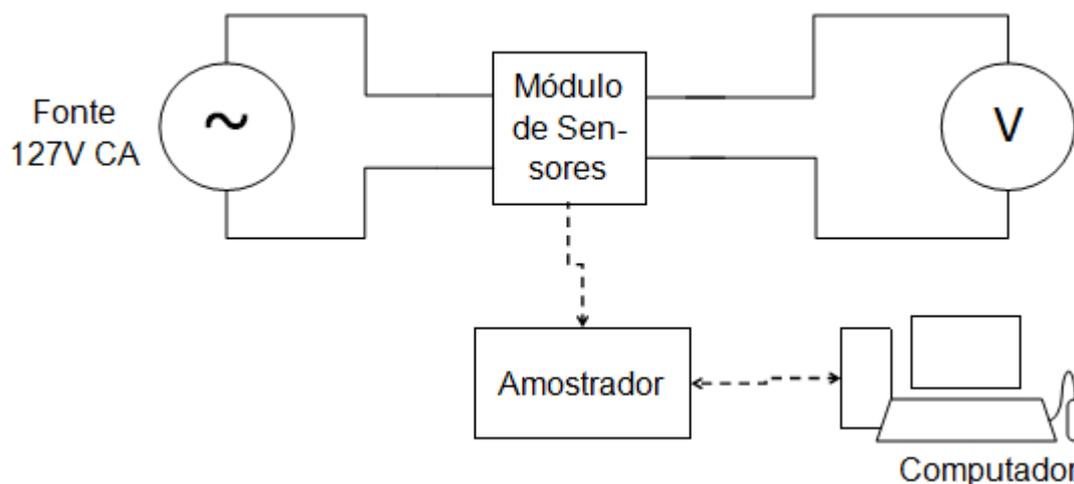
O sensor de tensão foi calibrado de maneira semelhante, onde o amperímetro de referência e a carga de teste da Figura 5.19 foram retirados do circuito e um voltímetro de referência foi conectado na saída do módulo de sensores, como ilustra a Figura 5.20.

Da mesma forma que na calibração do sensor de corrente, foi feita uma aquisição de dados e o valor de pico da senoide de tensão foi calculado através da Equação (5.1), usando-se o valor eficaz lido no voltímetro.

A constante de calibração do sensor de tensão, C_v , que relaciona o valor lido no sensor de tensão sob calibração com o valor da tensão obtida através da Equação (5.1), foi então calculada usando-se

$$C_v = \frac{\text{Tensão (Volts)}}{\text{Valor no sensor}} = \frac{V_{\text{pico voltímetro}}}{V_{\text{pico sensor}}} \quad (5.3)$$

Figura 5.20: Calibração do sensor de tensão



Fonte: Próprio autor

A Tabela 5.2 apresenta o resultado de calibração dos sensores de tensão e corrente.

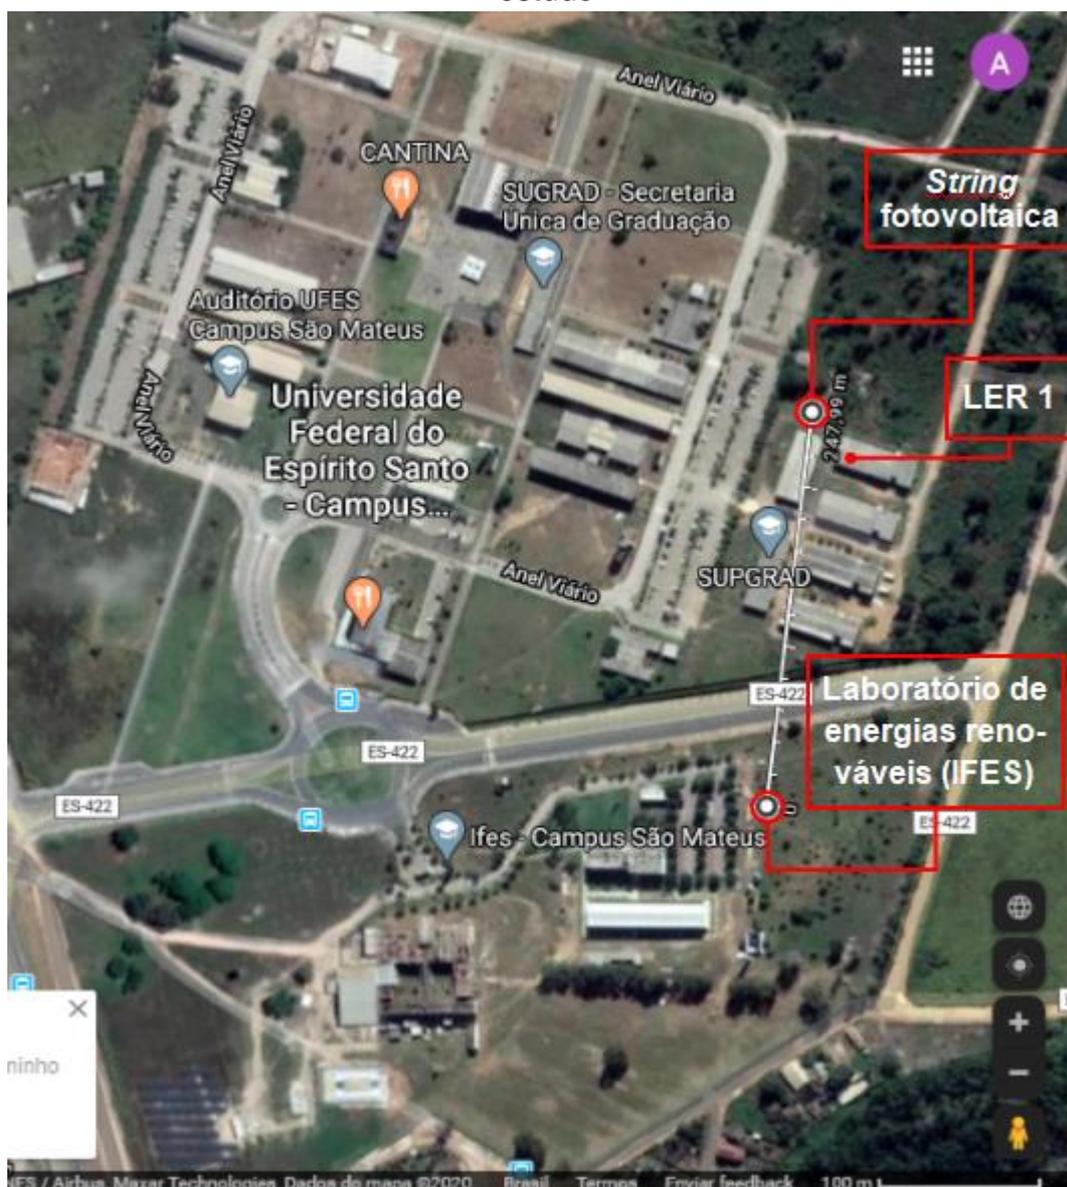
Tabela 5.2: Constantes de calibração dos sensores

	Corrente	Tensão
Valor eficaz no multímetro	5,74 A	127,4 V
Valor de pico lido no sensor	4,07	1,41
Constante de calibração	1,997 (C_i)	127,3 (C_v)

5.1.9 Calibração do Sensor de Irradiação

O sensor de irradiação foi calibrado com o auxílio de uma estação meteorológica *Davis Vantage Pro 2* (Figura 5.22), localizada no Instituto Federal de Ciência e Tecnologia do Espírito Santo (IFES) – Campus de São Mateus, a cerca de 300 m da UFES – Campus de São Mateus. A Figura 5.21 mostra a localização geográfica das duas unidades de ensino.

Figura 5.21: Localização geográfica das instituições de ensino envolvidas no estudo



Fonte: (GOOGLE MAPS, 2020)

O módulo de monitoramento ambiental foi colocado próximo à estação durante um período de cerca de 14 dias. Nesse período, foram coletados dados de irradiação solar medidos pela estação meteorológica de referência a uma taxa de 1 amostra a cada 50 s e do sensor de irradiação solar sob calibração a uma taxa de 1 amostra por minuto.

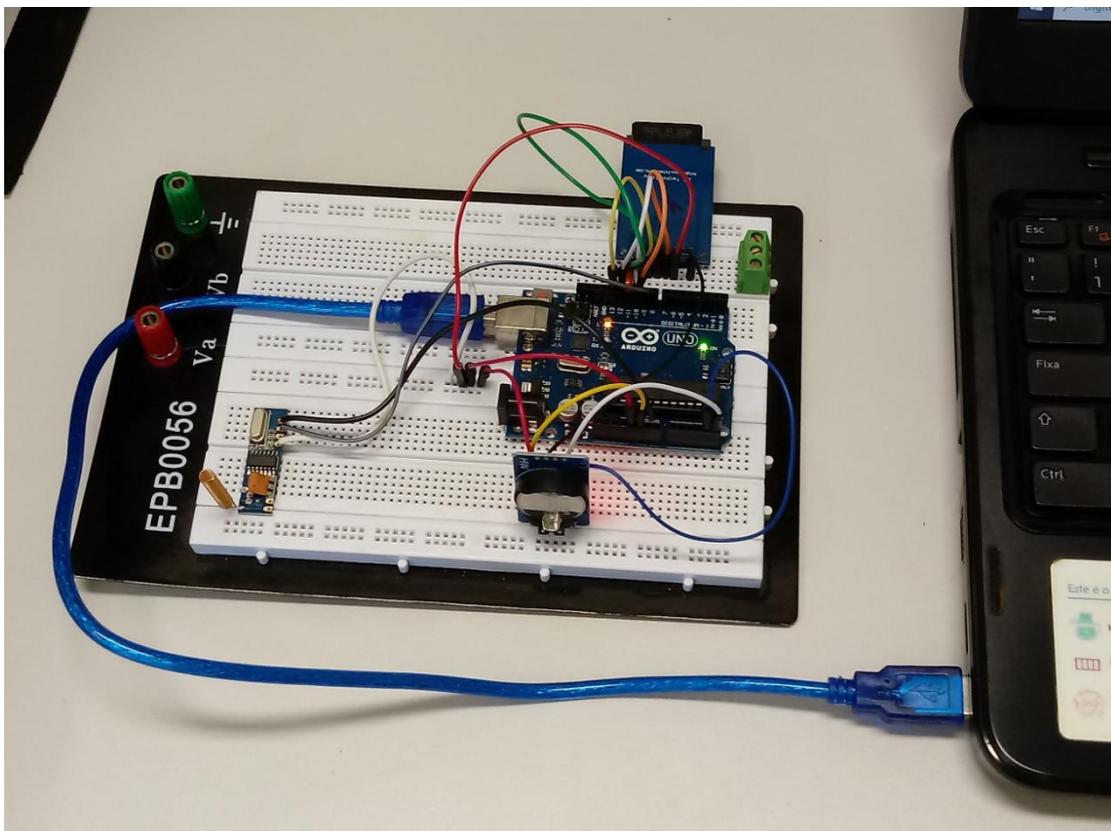
A Figura 5.23 mostra o módulo receptor dedicado à tarefa de calibração do sensor de irradiação, enquanto que a Figura 5.24 apresenta os gráficos correspondentes aos dados coletados entre os dias 14/11/2019 a 21/11/2019.

Figura 5.22: Estação meteorológica e sensor de irradiação



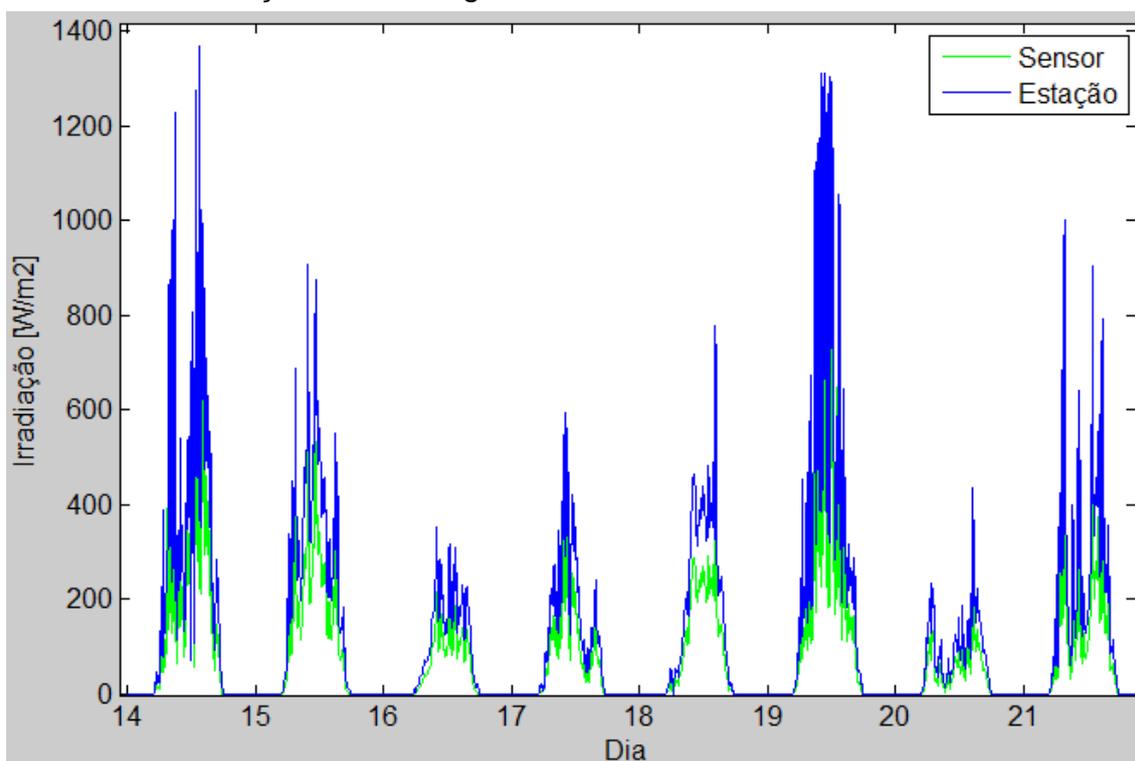
Fonte: Próprio autor

Figura 5.23: Módulo receptor com relógio e cartão SD utilizado na calibração



Fonte: Próprio autor

Figura 5.24: Dados de irradiação solar coletados do sensor em calibração e da estação meteorológica entre os dias 14 a 21/11/2019



Fonte: Próprio autor

Após essa etapa de coleta de dados, iniciou-se uma etapa de pré-processamento, onde as amostras coletadas foram interpoladas, a fim de garantir a mesma quantidade N de amostras provenientes das duas fontes, até porque as taxas de amostragens da estação meteorológica e do sensor de irradiação sob calibração são ligeiramente distintas. Para isso foi usada a interpolação linear.

No passo seguinte, foi aplicado um filtro de média deslizante sobre ambos os dados do sistema de referência e do sistema sob calibração, a fim de eliminar ruídos de alta frequência.

A Figura 5.25 ilustra o filtro utilizado, onde se pode observar que tal filtro atua sobre uma janela de dados que compreende os quinze minutos anteriores e posteriores a cada amostra a ser pré-processada.

Cabe ressaltar que o filtro foi aplicado por três vezes (filtros em cascata), conforme ilustrado no diagrama de blocos da Figura 5.26, garantindo uma suavização considerada adequada para a realização da calibração buscada.

Figura 5.25: Detalhamento do filtro de média deslizante

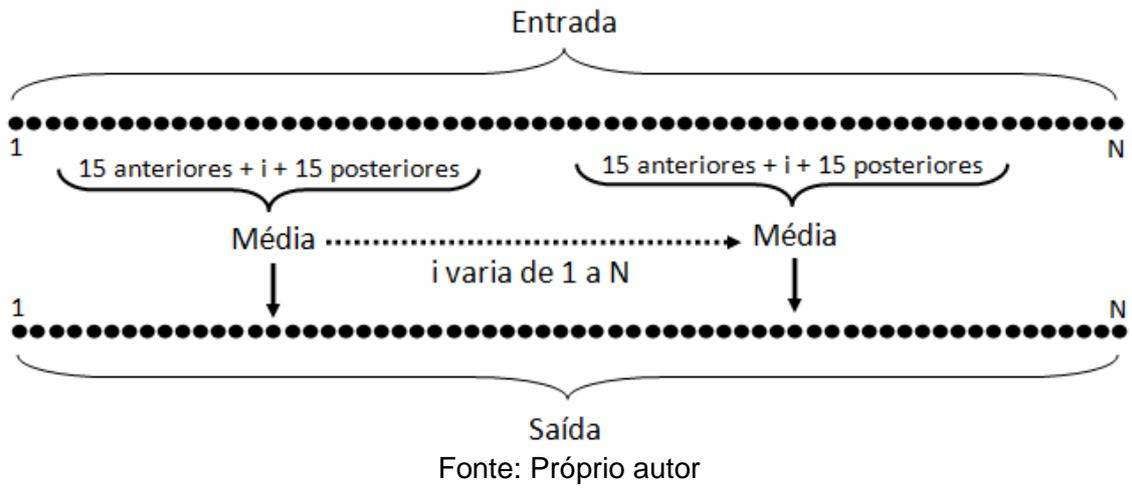
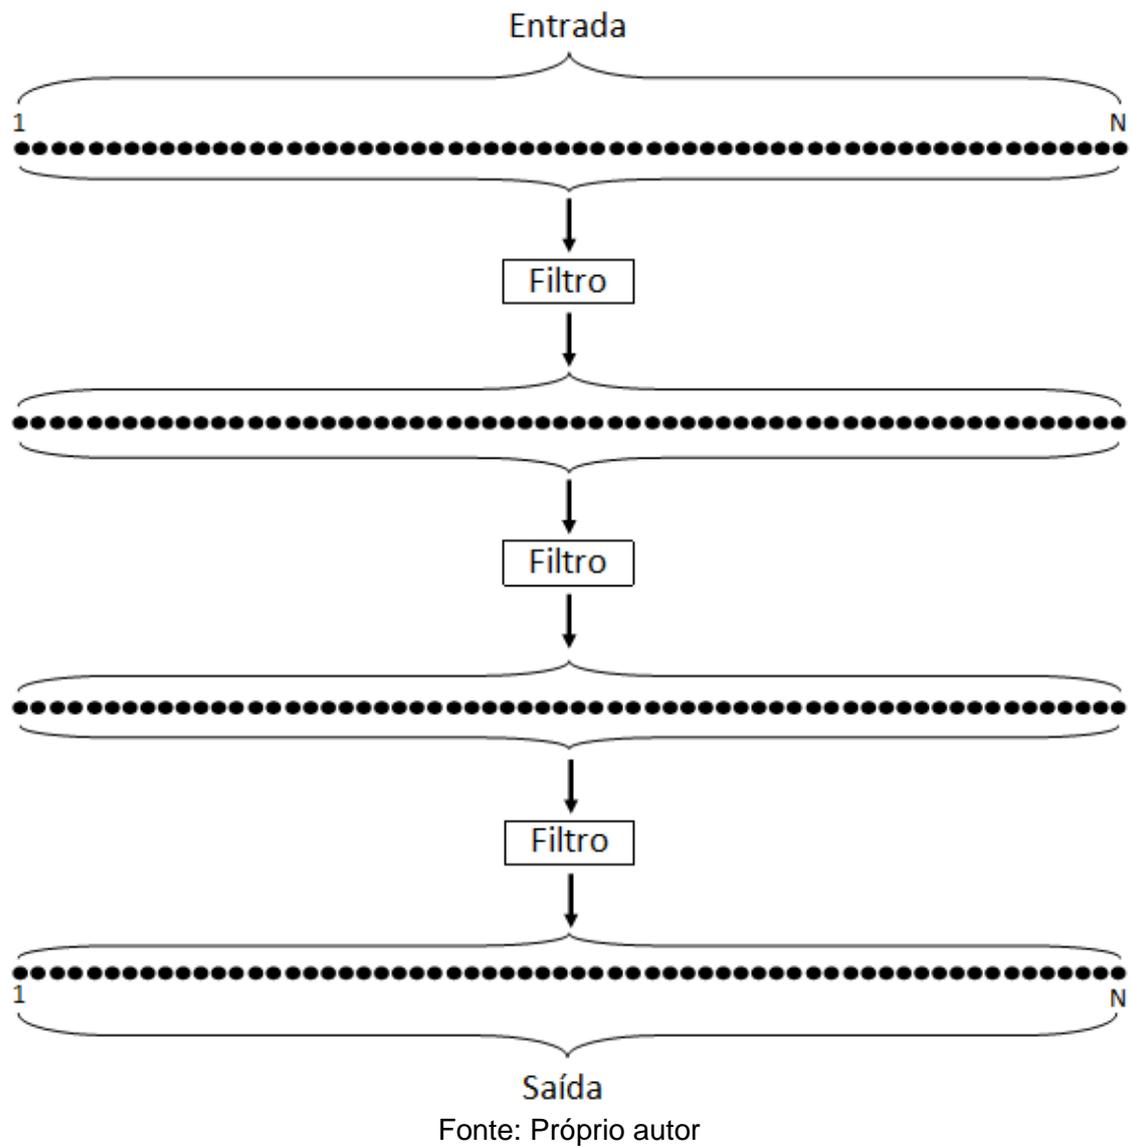
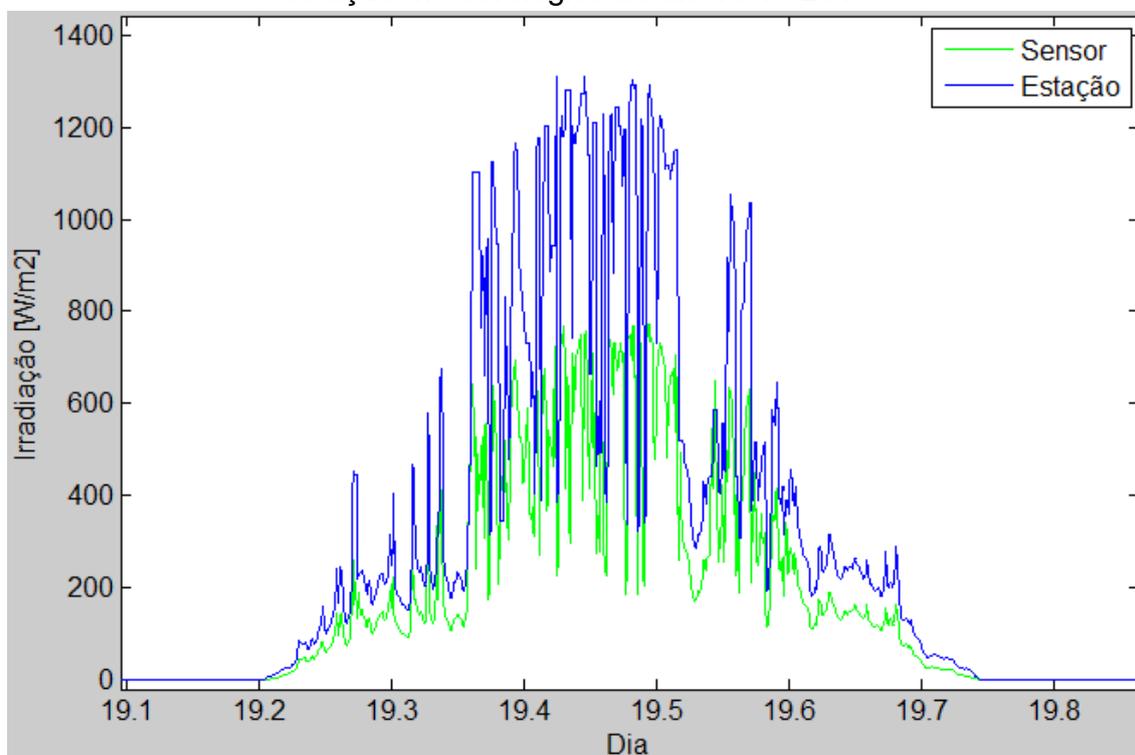


Figura 5.26: Aplicação em cascata do filtro



A Figura 5.27 apresenta os sinais de irradiação solar obtidos durante um dia (19/11/2019), enquanto que a Figura 5.28 mostra os mesmos sinais após serem submetidos ao pré-processamento recém descrito.

Figura 5.27: Dados de irradiação coletados via sensor sob calibração e via estação meteorológica no dia 19/11/2019



Fonte: Próprio autor

Em seguida, foram descartadas todas as amostras dos sinais filtrados inferiores a 100 W/m², desprezando portanto todo o período de pouca ou nenhuma incidência solar (Vide a Figura 5.28).

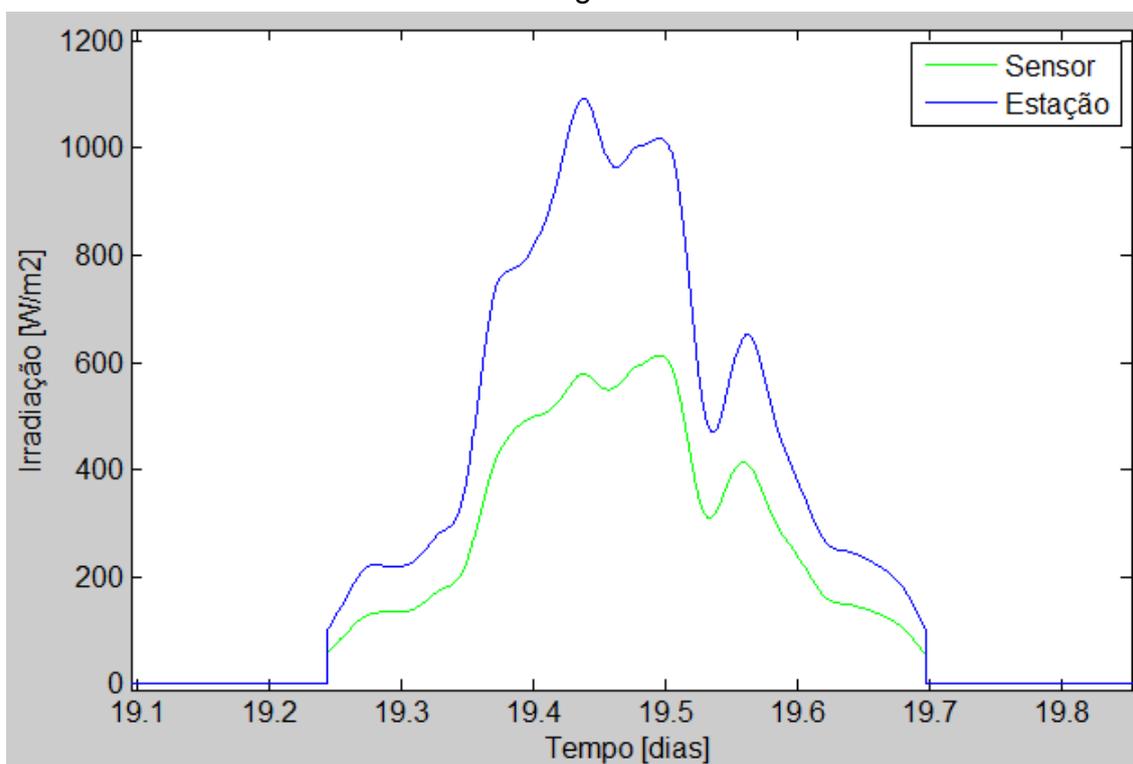
A raiz do erro médio quadrático normalizada pela média (*NRMSE* do inglês *Normalized Root Mean Square Error*) entre os dados de irradiação do sensor e da estação foi calculada utilizando as equações (TAEBI; MANSY, 2017)

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (I_{sensor,i} - I_{ref,i})^2}{N}} \quad (5.4)$$

$$NRMSE = \frac{RMSE}{\bar{I}_{ref}} \quad (5.5)$$

onde N é o número de amostras de irradiação solar, I_{ref} é a irradiação solar do sensor de referência e I_{sensor} é a irradiação solar do sensor sob calibração, resultando em um valor de $NRMSE$ de 0,4687 com base em uma média de $I_{ref} = 365,8 \text{ W/m}^2$.

Figura 5.28: Dados de irradiação do sensor e da estação meteorológica após filtragem.



Fonte: Próprio autor

A seguir, foi obtida a constante de calibração, isto é

$$C_{irr} = \frac{1}{N} \sum_{i=1}^N \frac{I_{sensor}(i)}{I_{ref}(i)} \quad (5.6)$$

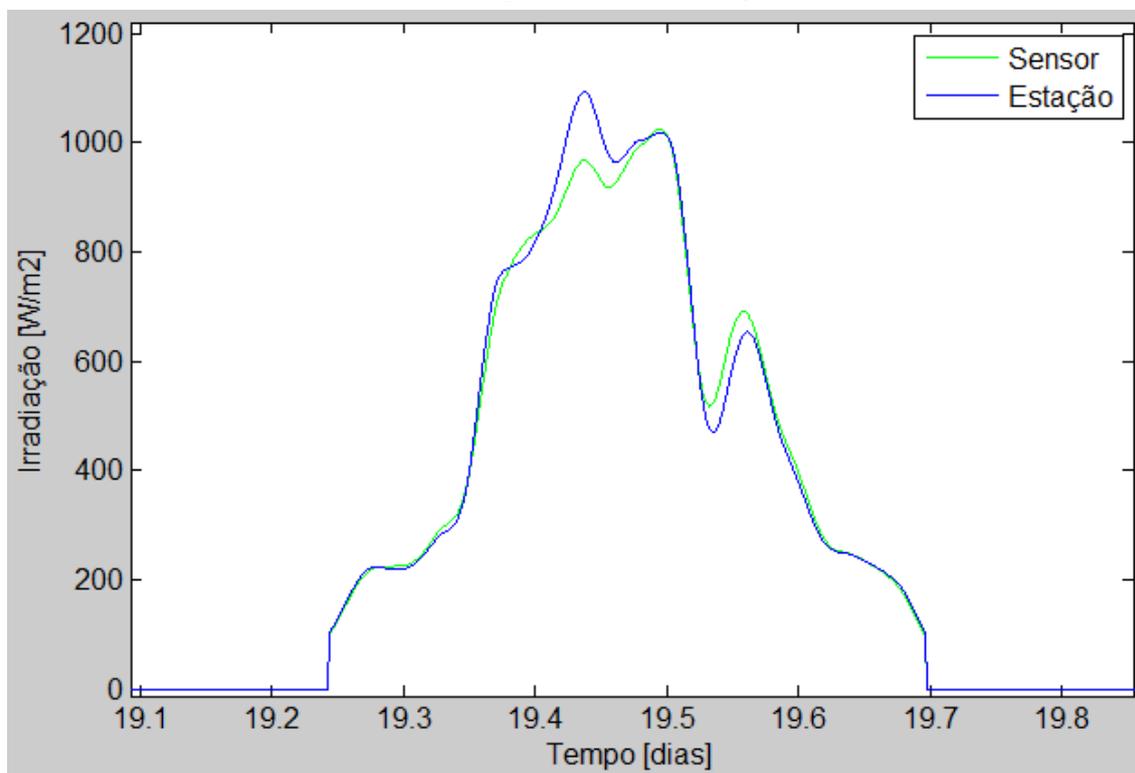
onde N é o número de amostras de irradiação solar, I_{ref} é a irradiação solar do sensor de referência e I_{sensor} é a irradiação solar do sensor sob calibração.

Portanto, as irradiações obtidas pelo sensor devem ser ajustadas aplicando a equação a seguir.

$$Irradiação\left(\frac{W}{m^2}\right) = \frac{Valor\ lido\ no\ sensor}{C_{irr}} \quad (5.7)$$

A Figura 5.29 mostra os dados de irradiação filtrados do sensor e da estação após a calibração. O novo valor de $NRMSE$ calculado após a calibração foi de 0,0643 para o mesmo valor de média de I_{ref} .

Figura 5.29: Dados de irradiação filtrados do sensor e da estação meteorológica após calibração.



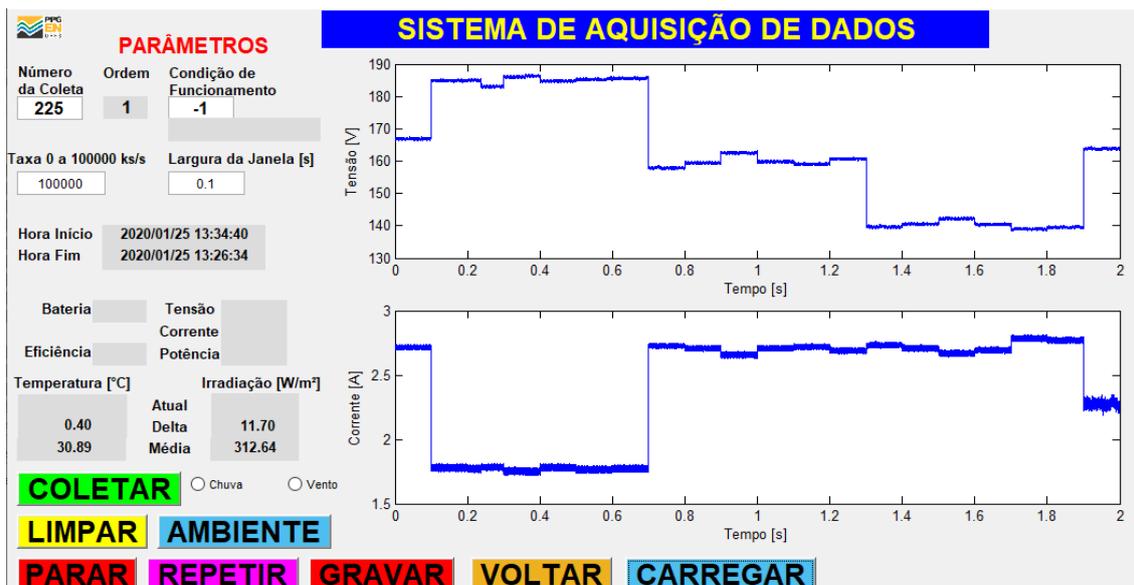
Fonte: Próprio autor

5.1.10 Sistema Computacional

Foi desenvolvido um sistema computacional para auxiliar na aquisição de dados. Com tal sistema, é realizada a configuração dos parâmetros do módulo de digitalização de dados, o controle de aquisição e armazenamento dos dados digitais obtidos por tal módulo e a visualização dos dados adquiridos.

O sistema computacional conta com uma interface gráfica (Figura 5.30), a qual facilita a execução das tarefas, isto é, através da interface gráfica é possível repetir a última aquisição de dados de uma condição de funcionamento, ou voltar na ordem da sequência de uma coleta para repetir aquisições anteriores da coleta atual, caso seja percebido algum erro na emulação das condições de funcionamento.

Figura 5.30: Interface do Usuário



Fonte: Próprio autor

5.2 AQUISIÇÃO DE DADOS

Devem ser adquiridas amostras de tensão e corrente oriundas da geração elétrica da *string* fotovoltaica em 20 condições de funcionamento, sendo uma normal (0) e 19 defeituosas (1 a 19), conforme apresentadas na Tabela 5.3.

As condições de funcionamento defeituoso são forçadas por um operador humano. Para isso, o operador deve estar próximo à *string* fotovoltaica. Ao forçar a condição defeituosa, o operador deve dar o comando <Coletar> na interface gráfica do computador situado no LER1.

Para viabilizar tal operação, considerando que a *string* e o LER 1 estão consideravelmente distantes (vide Figura 5.3), é usado um esquema de acionamento remoto via *smartphone*. Para isso foi usada uma versão gratuita da ferramenta para acesso remoto denominada *VNC Connect*.

Para forçar as condições de funcionamento de 1 a 6, é utilizado o sombreador de módulo inteiro, bloqueando 50% da radiação incidente no módulo correspondente da *string*, conforme mostrado na Figura 5.9.

Tabela 5.3: Codificação das condições de funcionamento da *string* fotovoltaica.

Código	Condição de funcionamento da <i>string</i>
0	Normal
1	Painel #1 inteiro sombreado
2	Painel #2 inteiro sombreado
3	Painel #3 inteiro sombreado
4	Painel #4 inteiro sombreado
5	Painel #5 inteiro sombreado
6	Painel #6 inteiro sombreado
7	Painel #1 com setor sombreado
8	Painel #2 com setor sombreado
9	Painel #3 com setor sombreado
10	Painel #4 com setor sombreado
11	Painel #5 com setor sombreado
12	Painel #6 com setor sombreado
13	Painel #1 em curto-circuito
14	Painel #2 em curto-circuito
15	Painel #3 em curto-circuito
16	Painel #4 em curto-circuito
17	Painel #5 em curto-circuito
18	Painel #6 em curto-circuito
19	Arco elétrico na <i>string</i>

As condições de funcionamento de 7 a 12 são forçadas utilizando o sombreador de um setor de um módulo, bloqueando 50% da radiação solar incidente em um setor do módulo correspondente da *string*, como mostra a Figura 5.10.

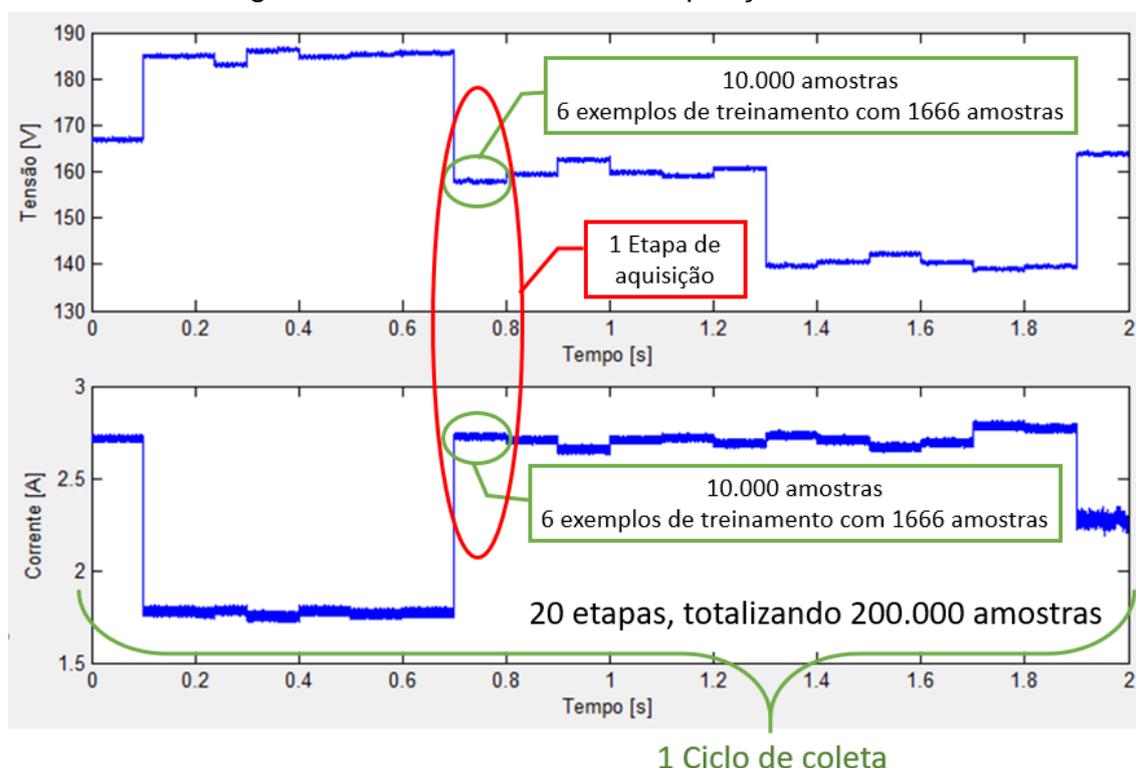
As condições de funcionamento de 13 a 18 são forçadas provocando um curto-circuito entre os terminais de cada módulo, enquanto que a condição 19 é forçada provocando um arco elétrico no terminal negativo da *string*. Esses dois últimos tipos de defeito utilizam o módulo de simulação de defeitos apresentado na Subseção 5.1.4.

Para cada uma das condições de funcionamento apresentadas na Tabela 5.3, devem ser adquiridas amostras da tensão e da corrente em vários horários do dia durante vários dias, com o objetivo de obter dados em diferentes níveis de irradiação solar e temperatura ambiente.

A irradiação solar e a temperatura ambiente também são coletadas em cada aquisição de dados, para uma melhor contextualização do cenário real sob o qual o sistema fotovoltaico esteve submetido..

As aquisições são organizadas da seguinte forma: cada ciclo de coleta é dividido em 20 etapas de aquisição, cada qual correspondente a uma condição de funcionamento diferente. Em cada etapa de aquisição são coletadas amostras de tensão e de corrente, e também registrados dados ambientais (irradiação e temperatura médias) recebidos do módulo receptor de dados ambientais. A Figura 5.31 exibe o detalhamento do processo de aquisição de dados.

Figura 5.31: Detalhamento de aquisição de dados



Fonte: Próprio autor

Cada etapa de aquisição faz uma amostragem simultânea da tensão e da corrente durante um intervalo de tempo de 0,1 s, à uma taxa 100.000 amostras por segundo, totalizando 10.000 amostras de tensão e 10.000 amostras de

corrente. Cada ciclo de coleta tem, portanto, 200.000 ($10.000 * 20$) amostras de tensão e 200.000 amostras de corrente.

A fim de minimizar as variações das condições climáticas (temperatura ambiente e irradiação solar) entre as etapas de aquisição de um mesmo ciclo de coleta, tal ciclo deve ser cumprido no menor tempo possível, ou seja, sem intervalos entre as etapas. Além disso, devem ser realizadas sequências diferentes de condições de funcionamento em cada coleta (quase aleatórias), a fim de proporcionar maior robustez ao sistema de identificação autônomo durante o seu treinamento.

5.3 ESTRUTURA DA REDE NEURAL CONVOLUCIONAL

A rede neural convolucional utilizada é baseada em uma rede usada para identificar cargas elétricas em um circuito elétrico alimentado em corrente alternada com frequência de 60Hz (FIRMES; CELESTE; SILVESTRE, 2019).

Embora a tensão e a corrente fornecidas pelos módulos solares estejam em nível CC, como o sistema de geração de energia está conectado a um inversor, que por sua vez está conectado à rede da concessionária em frequência de 60 Hz, existem oscilações nos sinais de tensão e de corrente provocados pelo chaveamento no inversor e pela influência da corrente alternada da rede da concessionária.

Portanto, assim como em (FIRMES; CELESTE; SILVESTRE, 2019), adota-se como tamanho dos vetores de entrada da rede neural um conjunto de amostras de número equivalente à duração de um período de 60 Hz.

Logo, com uma frequência de amostragem de 100.000 amostras/s, cada ciclo de 60 Hz é representado por 1666 amostras de tensão e 1666 amostras de corrente, ou seja, a camada de entrada da rede neural deve ter vetores com 1666 elementos, e cada exemplo utilizado para treinamento de tal rede será formado por um vetor de tensão e um vetor de corrente contendo 1666 elementos cada um (que servirá de entrada), e da saída desejada correspondente.

Dessa forma, tomando-se o número de amostras obtidas em cada etapa de aquisição, isto é, 10.000 amostras, e dividindo tal número pelo tamanho dos vetores de entrada, isto é 1666, conclui-se que o número de amostras disponível

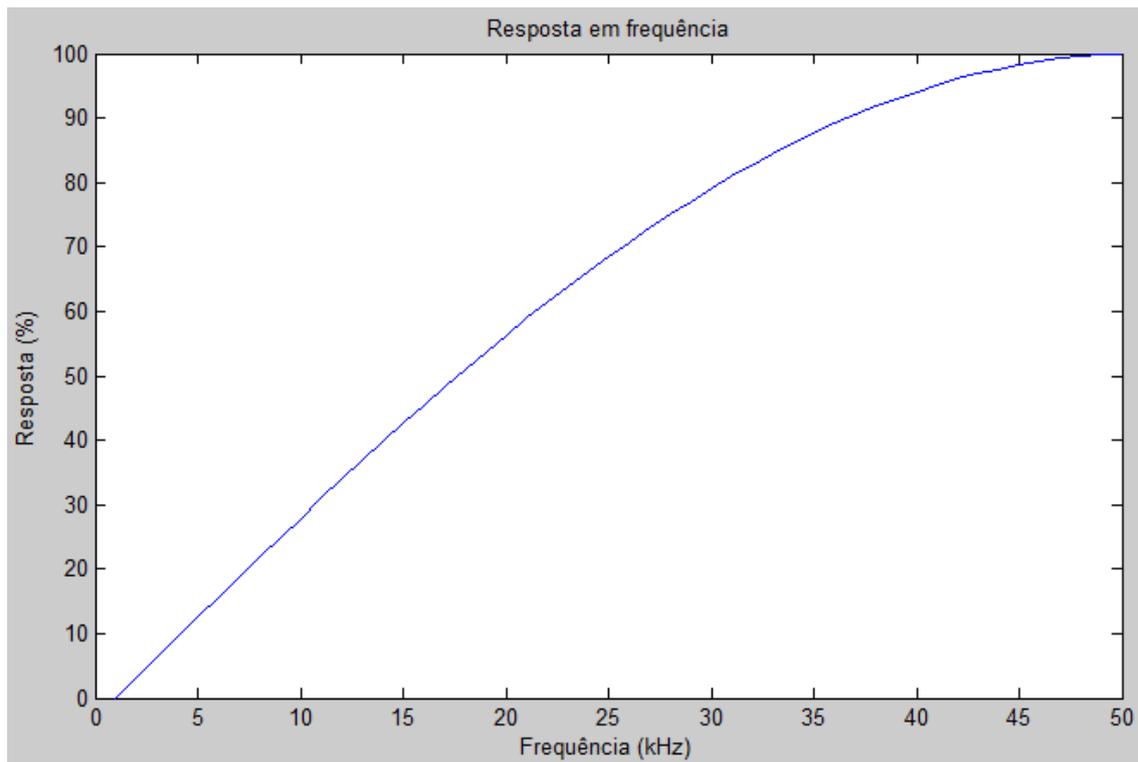
em cada etapa de treinamento é suficiente para gerar 6 exemplos que podem ser utilizados posteriormente para treinamento, validação ou teste da rede neural, e ainda sobram 4 amostras que são ignoradas.

Considerando que N_{cc} é o número de ciclos de coleta, então se tem um total $6*N_{cc}$ exemplos por condição de funcionamento a serem usados para treinamento, validação e teste de redes neurais convolucionais. Por fim, considerando as 20 condições de funcionamento da *string* fotovoltaica, tem-se que a massa de dados obtida corresponderá a $N_e = 120*N_{cc}$ exemplos.

As Figuras 5.33 e 5.34 apresentam a estrutura básica das redes neurais a serem implementadas (treinadas, validadas e testadas) a partir da massa de dados N_e . Como pode ser visto nas figuras, com o objetivo de verificar a sensibilidade do problema aos dados de entrada disponíveis, variou-se o tipo de entrada aplicada à rede, isto é, se os N_e exemplos correspondem a apenas aos dados de corrente, ou apenas aos de tensão, ou de ambos, tensão e corrente, sendo que ainda pode ser aplicado à entrada de corrente um filtro passa-altas gerando uma nova entrada que alimenta camadas convolucionais e de agrupamento independentes, com o objetivo de melhorar a taxa de detecção do arco elétrico.

A introdução do ramo de entrada de corrente com filtro passa-altas é uma tentativa de reprodução de um sistema de detecção de arco elétrico baseado em rede neural apresentada em (LU et al., 2019), no qual é utilizado como sensor um transformador de corrente, que naturalmente filtra as baixas frequências. O filtro implementado é do tipo FIR (*Finite Impulse Response*) de primeira ordem com resposta crescente com a frequência, partindo de zero e chegando a 100% em 50kHz, que corresponde à metade da frequência de amostragem (100kHz), conforme ilustrado na Figura 5.32. Embora esse filtro não tenha bandas de passagem e de corte bem definidas, a frequência de corte, onde a resposta do filtro é de 50% da resposta máxima, acontece entre 17 e 18%.

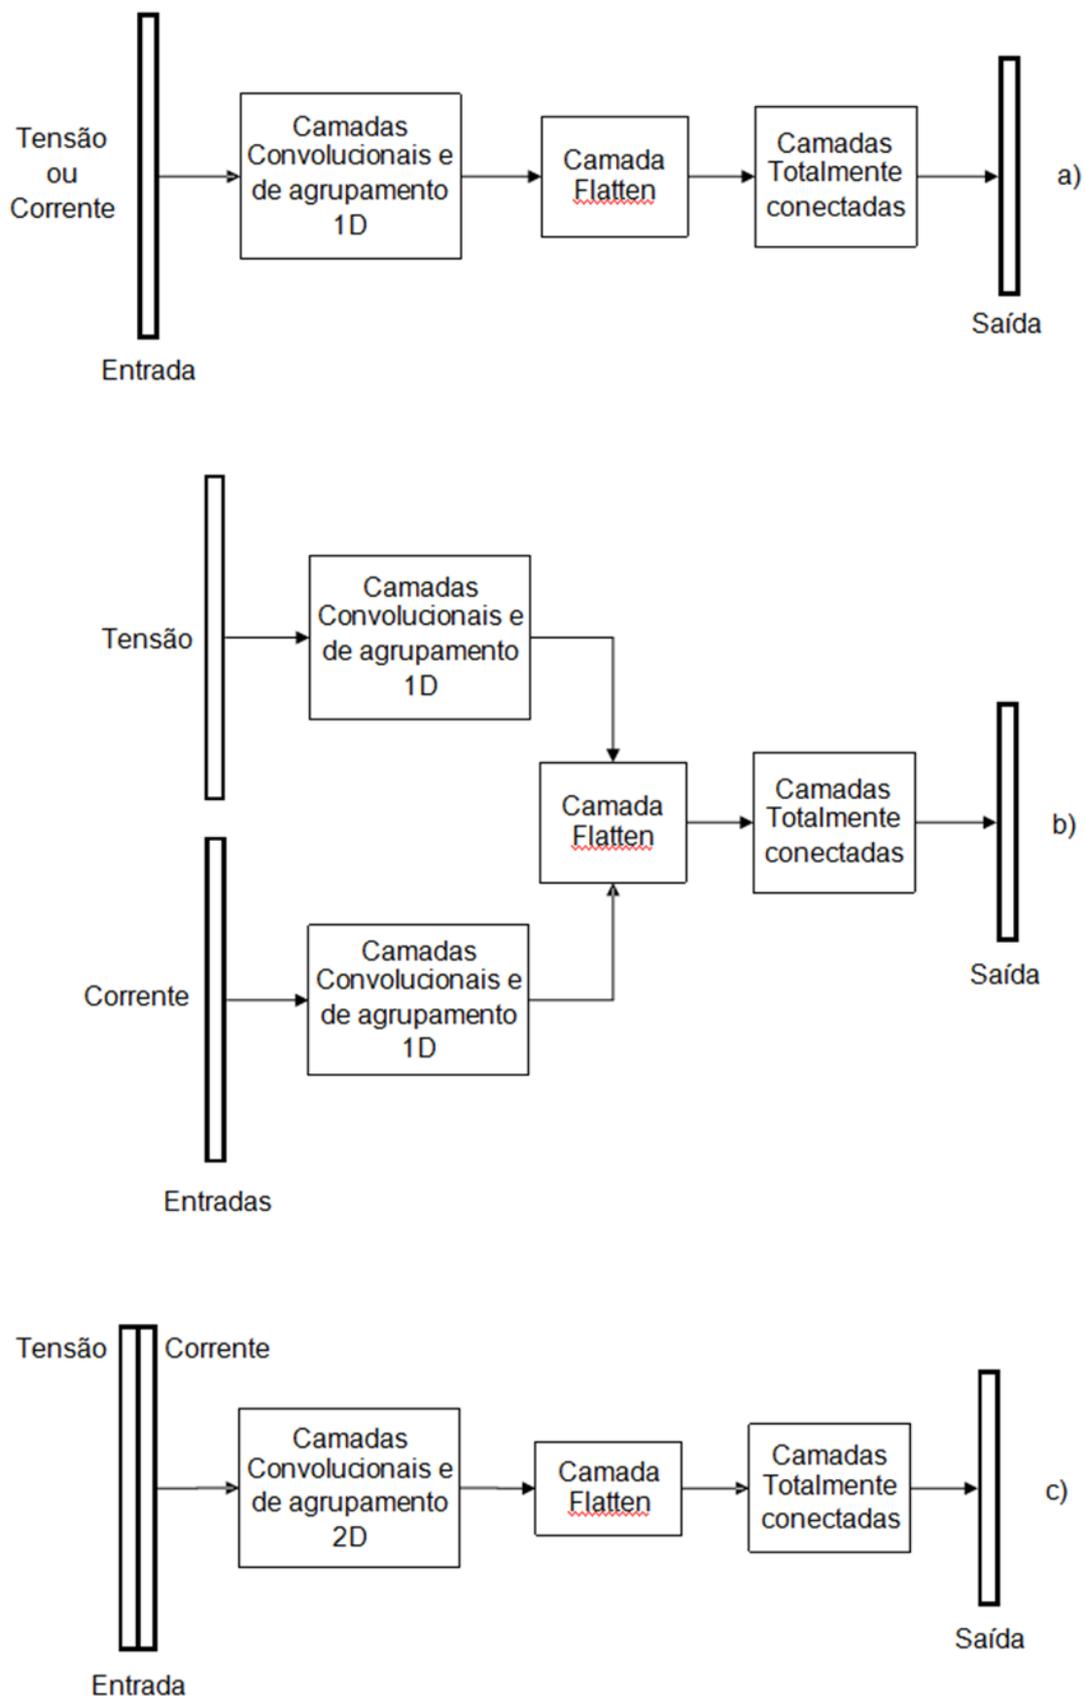
Figura 5.32: Resposta em frequência do filtro passa altas.



Fonte: Próprio autor

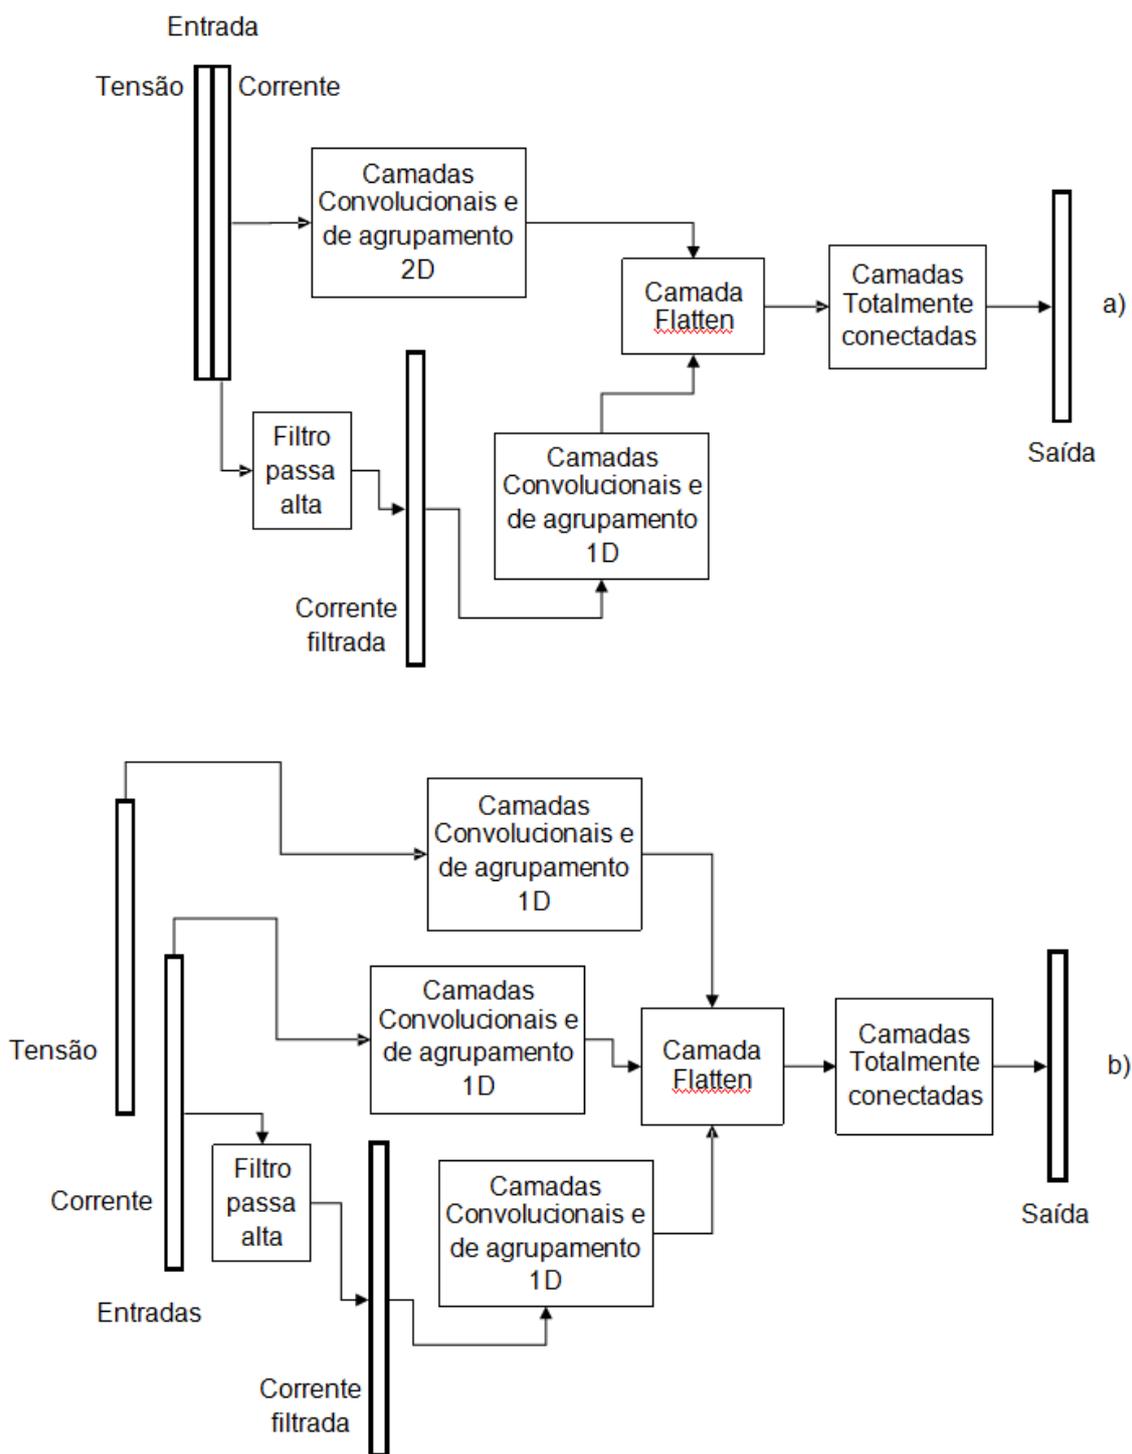
Além de experimentos variando o tipo de entrada da rede sob implementação, são realizados experimentos variando o número de camadas convolucionais e totalmente conectadas da *CNN*.

Figura 5.33: Estrutura das redes neurais: a) redes 1 e 2; b) rede 3 e 10; c) rede 4.



Fonte: Próprio autor

Figura 5.34: Estrutura das redes neurais; a) rede 5; b) redes 6, 7, 8 e 9



Fonte: Próprio autor

A Tabela 5.4 resume a estrutura básica das redes desenvolvidas para detectar as condições de funcionamento da *string* fotovoltaica.

Observa-se ainda na Tabela 5.4 que a Rede 0 é a única rede não convolucional. Ela será usada como uma referência para comparação com as outras redes.

Trata-se de uma rede MLP de 5 camadas que recebe como entrada o valor médio da tensão e da corrente. Logo, as Redes 1 a 10 são do tipo convolucionais. A diferença entre elas está no tipo de convolução, isto é, se 1D ou 2D (uma ou duas dimensões, respectivamente), no número de camadas convolucionais e no número de camadas totalmente conectadas (densas).

Tabela 5.4: Estrutura básica das redes neurais utilizadas.

Tipo de Rede	Entradas			Tipo Convulsão	Nº Camadas Convolucionais		Nº Camadas Densas
	Corrente	Tensão	Corrente filtrada		Tensão e Corrente	Corrente filtrada	
0	sim	sim	não	nenhuma	0	0	5
1	sim	não	não	1D	2	2	4
2	não	sim	não	1D	2	2	4
3	sim	sim	não	1D	2	2	4
4	sim	sim	não	2D	2	2	4
5	sim	sim	sim	2D	2	2	4
6	sim	sim	sim	1D	2	2	4
7	sim	sim	sim	1D	2	2	7
8	sim	sim	sim	1D	2	4	7
9	sim	sim	sim	1D	5	5	7
10	sim	sim	não	1D	5	0	7

As Tabelas 5.5 a 5.14 destacam as características mais relevantes das redes neurais do tipo 0 a 10, respectivamente. Essas redes foram evoluídas experimentalmente a partir da estrutura de uma rede preliminar utilizada no trabalho (FIRMES; CELESTE; SILVESTRE, 2019). Observe que as camadas numeradas com 0 nessas tabelas correspondem a camadas de entrada, enquanto as demais correspondem a camadas de processamento de informação. As redes que são constituídas de mais de uma entrada têm suas camadas numeradas de forma composta (x.y), onde x é o número do ramo de entrada, e y é o número da camada. Cada ramo está associado a uma entrada e segue independente até que a última camada de cada ramo seja concatenada em uma única camada (Flatten).

Tabela 5.5: Estrutura da rede neural 0

Nº Camada	Tipo de Camada	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
0	Entrada	Nenhuma	2	Nenhum
1	Dense	ReLU	2	6
2	Dense	ReLU	2000	6000
3	Dense	ReLU	1500	3.001.500
4	Dense	ReLU	1000	1.501.000
5	Dense	Softmax	20	20.020
Total				4.528.526

Tabela 5.6: Estrutura das redes neurais 1 e 2

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
0	Entrada	Nenhum	Nenhuma	1666	Nenhum
1	Convolução 2D	32 (1 x 2)	ReLU	1665 x 32	96
2	Maxpooling 2D	1 (1 x 2)	Nenhuma	832 x 32	Nenhum
3	Convolução 2D	16 (1 x 2)	ReLU	831 x 16	1040
4	Maxpooling 2D	1 (1 x 2)	Nenhuma	415 x 16	Nenhum
5	Flatten	Nenhum	Nenhuma	6640	Nenhum
6	Dense	Nenhum	ReLU	64	425.024
7	Dense	Nenhum	ReLU	128	8320
8	Dense	Nenhum	ReLU	64	8256
9	Dense	Nenhum	Softmax	20	1300
Total					444.036

Tabela 5.7: Estrutura da rede neural 3

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
1.0	Entrada_1	Nenhum	Nenhuma	1666	Nenhum
1.1	Convolução 1D	32 (1 x 2)	ReLU	1665 x 32	96
1.2	Maxpooling1D	1 (1 x 2)	Nenhuma	832 x32	Nenhum
1.3	Convolução 1D	16 (1 x 2)	ReLU	831x 16	1040
1.4	Maxpooling1D	1 (1 x 2)	Nenhuma	415 x 16	Nenhum
1.5	Flatten	Nenhum	Nenhuma	6640	Nenhum
2.0	Entrada_2	Nenhum	Nenhuma	1666	Nenhum
2.1	Convolução 1D	32 (1 x 2)	ReLU	1665 x 32	96
2.2	Maxpooling1D	1 (1 x 2)	Nenhuma	832 x32	Nenhum
2.3	Convolução 1D	16 (1 x 2)	ReLU	831x 16	1040
2.4	Maxpooling1D	1 (1 x 2)	Nenhuma	415 x 16	Nenhum
2.5	Flatten	Nenhum	Nenhuma	6640	Nenhum
6	Flatten concatenada (1.5 e 2.5)	Nenhum	Nenhuma	13280	Nenhum
7	Dense	Nenhum	ReLU	64	859.984
8	Dense	Nenhum	ReLU	128	8320
9	Dense	Nenhum	ReLU	64	8256
10	Dense	Nenhum	Softmax	20	1300
Total					870.132

Tabela 5.8: Estrutura da rede neural 4

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
0	Entrada	Nenhum	Nenhuma	1666 x 2	Nenhum
1	Convolução 2D	32 (2 x 3)	ReLU	1666 x 2 x 32	224
2	Maxpooling 2D	1 (2 x 1)	Nenhuma	833 x 2 x 32	Nenhum
3	Convolução 2D	16 (2 x 3)	ReLU	833 x 2 x 16	3088
4	Maxpooling 2D	1 (2 x 1)	Nenhuma	417 x 2 x 16	Nenhum
5	Flatten	Nenhum	Nenhuma	13344	Nenhum
6	Dense	Nenhum	ReLU	64	854.080
7	Dense	Nenhum	ReLU	128	8320
8	Dense	Nenhum	ReLU	64	8256
9	Dense	Nenhum	Softmax	20	1300
Total					875.268

Tabela 5.9: Estrutura da rede neural 5

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
1.0	Entrada_1	Nenhum	Nenhuma	1666 x 2	Nenhum
1.1	Convolução2D	32 (5 x 3)	ReLU	1666 x 2 x 32	512
1.2	Maxpooling2D	1 (2 x 1)	Nenhuma	833 x 2 x 32	Nenhum
1.3	Convolução2D	16 (5 x 3)	ReLU	833 x 2 x 16	7696
1.4	Maxpooling2D	1 (2 x 1)	Nenhuma	417 x 2 x 16	Nenhum
1.5	Flatten	Nenhum	Nenhuma	13344	Nenhum
2.0	Entrada_2	Nenhum	Nenhuma	1665 x 1	Nenhum
2.1	Convolução1D	128 (1 x 25)	ReLU	1641x 128	3328
2.2	Maxpooling1D	1 (1 x 2)	Nenhuma	820 x128	Nenhum
2.3	Convolução1D	96 (1 x 50)	ReLU	771x 96	614.496
2.4	Maxpooling1D	1 (1 x 2)	Nenhuma	386 x 96	Nenhum
2.5	Flatten	Nenhum	Nenhuma	37056	Nenhum
6	Flatten Concatenada (1.5 e 2.5)	Nenhum	Nenhuma	50400	Nenhum
7	Dense	Nenhum	ReLU	64	3.225.664
8	Dense	Nenhum	ReLU	128	8320
9	Dense	Nenhum	ReLU	64	8256
10	Dense	Nenhum	Softmax	20	1300
Total					3.869.572

Tabela 5.10: Estrutura da rede neural 6

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
1.0	Entrada_1	Nenhum	Nenhuma	1666	Nenhum
1.1	Convolução1D	32 (1 x 5)	ReLU	1662 x 32	192
1.2	Maxpooling1D	1 (1 x 2)	Nenhuma	831 x32	Nenhum
1.3	Convolução1D	16 (1 x 5)	ReLU	827x 16	2576
1.4	Maxpooling1D	1 (1 x 2)	Nenhuma	413 x 16	Nenhum
1.5	Flatten	Nenhum	Nenhuma	6608	Nenhum
2.0	Entrada_2	Nenhum	Nenhuma	1666	Nenhum
2.1	Convolução1D	32 (1 x 5)	ReLU	1662 x 32	192
2.2	Maxpooling1D	1 (1 x 2)	Nenhuma	831 x32	Nenhum
2.3	Convolução1D	16 (1 x 5)	ReLU	827x 16	2576
2.4	Maxpooling1D	1 (1 x 2)	Nenhuma	413 x 16	Nenhum
2.5	Flatten	Nenhum	Nenhuma	6608	Nenhum
3.0	Entrada_3	Nenhum	Nenhuma	1666	Nenhum
3.1	Convolução1D	128 (1 x 25)	ReLU	1642 x 128	3328
3.2	Maxpooling1D	1 (1 x 2)	Nenhuma	821x128	Nenhum
3.3	Convolução1D	96 (1 x 50)	ReLU	772x 96	614.496
3.4	Maxpooling1D	1 (1 x 2)	Nenhuma	386 x 96	Nenhum
3.5	Flatten	Nenhum	Nenhuma	37056	Nenhum
6	Flatten concatenada (1.5, 2.5, 3.5)	Nenhum	Nenhuma	50272	Nenhum
7	Dense	Nenhum	ReLU	64	3.217.472
8	Dense	Nenhum	ReLU	128	8320
9	Dense	Nenhum	ReLU	64	8256
10	Dense	Nenhum	Softmax	20	1300
Total					3.858.708

Tabela 5.11: Estrutura da rede neural 7

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
1.0	Entrada_1 (Tensão)	Nenhum	Nenhuma	1666	Nenhum
1.1	Convolução 1D	32 (1 x 5)	ReLU	1662 x 32	192
1.2	Averagepooling1D	1 (1 x 2)	Nenhuma	831 x 32	Nenhum
1.3	Convolução 1D	16 (1 x 5)	ReLU	827x 16	2576
1.4	Averagepooling1D	1 (1 x 2)	Nenhuma	413 x 16	Nenhum
1.5	Flatten	Nenhum	Nenhuma	6608	Nenhum
2.0	Entrada_2 (Corrente)	Nenhum	Nenhuma	1666	Nenhum
2.1	Convolução 1D	32 (1 x 5)	ReLU	1662 x 32	192
2.2	Averagepooling1D	1 (1 x 2)	Nenhuma	831 x 32	Nenhum
2.3	Convolução 1D	16 (1 x 5)	ReLU	827x 16	2576
2.4	Averagepooling1D	1 (1 x 2)	Nenhuma	413 x 16	Nenhum
2.5	Flatten	Nenhum	Nenhuma	6608	Nenhum
3.0	Entrada_3 (Corrente filtrada)	Nenhum	Nenhuma	1666	Nenhum
3.1	Convolução 1D	128 (1 x 25)	ReLU	1642 x 128	3328
3.2	Averagepooling1D	1 (1 x 2)	Nenhuma	821x 128	Nenhum
3.3	Convolução 1D	96 (1 x 50)	ReLU	772x 96	614496
3.4	Averagepooling1D	1 (1 x 2)	Nenhuma	386 x 96	Nenhum
3.5	Flatten	Nenhum	Nenhuma	37056	Nenhum
6	Flatten concatenada (1.5, 2.5 e 3.5)	Nenhum	Nenhuma	50272	Nenhum
7	Dense	Nenhum	ReLU	64	3217472
8	Dense	Nenhum	ReLU	128	8320
9	Dense	Nenhum	ReLU	256	33024
10	Dense	Nenhum	ReLU	256	65792
11	Dense	Nenhum	ReLU	128	32896
12	Dense	Nenhum	ReLU	64	8256

Tabela 5.11: Estrutura da rede neural 7 (continuação)

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
13	Dense	Nenhum	Softmax	20	1300
Total					3.990.420

Tabela 5.12: Estrutura da rede neural 8

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
1.0	Entrada (tensão)	Nenhum	Nenhuma	1666	Nenhum
1.1	Convolução1D	32 (1 x 5)	ReLU	1662 x 32	192
1.2	Averagepooling1D	1 (1 x 2)	Nenhuma	831 x 32	Nenhum
1.3	Convolução1D	16 (1 x 5)	ReLU	827 x 16	2576
1.4	Averagepooling1D	1 (1 x 2)	Nenhuma	413 x 16	Nenhum
1.5	Flatten	Nenhum	Nenhuma	6608	Nenhum
2.0	Entrada (Corrente)	Nenhum	Nenhuma	1666	Nenhum
2.1	Convolução1D	32 (1 x 5)	ReLU	1662 x 32	192
2.2	Averagepooling1D	1 (1 x 2)	Nenhuma	831 x 32	Nenhum
2.3	Convolução1D	16 (1 x 5)	ReLU	827 x 16	2576
2.4	Averagepooling1D	1 (1 x 2)	Nenhuma	413 x 16	Nenhum
2.5	Flatten	Nenhum	Nenhuma	6608	Nenhum
3.0	Entrada (Corrente filtrada)	Nenhum	Nenhuma	1666	Nenhum
3.1	Convolução1D	32 (1 x 25)	ReLU	1642 x 32	832
3.2	Averagepooling1D	1 (1 x 2)	Nenhuma	821 x 32	Nenhum
3.3	Convolução1D	64 (1 x 30)	ReLU	792 x 64	61.504
3.4	Averagepooling1D	1 (1 x 2)	Nenhuma	396 x 64	Nenhum
3.5	Convolução1D	128 (1 x 35)	ReLU	362 x 128	286.848
3.6	Averagepooling1D	1 (1 x 2)	Nenhuma	181 x 128	Nenhum
3.7	Convolução1D	256 (1 x 50)	ReLU	132 x 256	1.638.656

Tabela 5.12: Estrutura da rede neural 8 (continuação)

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
3.8	Averagepooling1D	1 (1 x 2)	Nenhuma	66 x 256	Nenhum
3.9	Flatten	Nenhum	Nenhuma	16896	Nenhum
10	Flatten concatenada (1.5, 2.5 e 3.9)	Nenhum	Nenhuma	30112	Nenhum
11	Dense	Nenhum	ReLU	128	3.854.464
12	Dense	Nenhum	ReLU	256	33.024
13	Dense	Nenhum	ReLU	512	131.584
14	Dense	Nenhum	ReLU	256	131.328
15	Dense	Nenhum	ReLU	128	32.896
16	Dense	Nenhum	ReLU	64	8256
17	Dense	Nenhum	Softmax	20	1300
Total					6.186.228

Tabela 5.13: Estrutura da rede neural 9

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
1.0	Entrada (tensão)	Nenhum	Nenhuma	1666	Nenhum
1.1	Convolução1D	32(1x2)	Relu	1665x32	96
1.2	Averagepooling1D	1(1x2)	Nenhuma	832x2	Nenhum
1.3	Convolução1D	64(1x4)	Relu	829x64	8256
1.4	Averagepooling1D	1(1x2)	Nenhuma	414x64	Nenhum
1.5	Convolução1D	128(1x6)	Relu	409x128	49280
1.6	Averagepooling1D	1(1x2)	Nenhuma	204x108	Nenhum
1.7	Convolução1D	256(1x8)	Relu	197x256	262400
1.8	Averagepooling1D	1(1x2)	Nenhuma	98x256	Nenhum
1.9	Convolução1D	512(1x10)	Relu	89x512	1311232
1.10	Averagepooling1D	1(1x2)	Nenhuma	44x512	Nenhum
1.11	Flatten	Nenhum	Nenhuma	22528	Nenhum

Tabela 5.13: Estrutura da rede neural 9 (continuação)

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
2.0	Entrada (Corrente)	Nenhum	Nenhuma	1666	Nenhum
2.1	Convolução1D	32(1x2)	Relu	1665x32	96
2.2	Averagepooling1D	1(1x2)	Nenhuma	832x2	Nenhum
2.3	Convolução1D	64(1x4)	Relu	829x64	8256
2.4	Averagepooling1D	1(1x2)	Nenhuma	414x64	Nenhum
2.5	Convolução1D	128(1x6)	Relu	409x128	49280
2.6	Averagepooling1D	1(1x2)	Nenhuma	204x108	Nenhum
2.7	Convolução1D	256(1x8)	Relu	197x256	262400
2.8	Averagepooling1D	1(1x2)	Nenhuma	98x256	Nenhum
2.9	Convolução1D	512(1x10)	Relu	89x512	1311232
2.10	Averagepooling1D	1(1x2)	Nenhuma	44x512	Nenhum
2.11	Flatten	Nenhum	Nenhuma	22528	Nenhum
3.0	Entrada (Corrente filtrada)	Nenhum	Nenhuma	1666	Nenhum
3.1	Convolução1D	32(1x25)	Relu	1642x32	832
3.2	Averagepooling1D	1(1x2)	Nenhuma	832x32	Nenhum
3.3	Convolução1D	64(1x30)	Relu	792x64	61504
3.4	Averagepooling1D	1(1x2)	Nenhuma	396x64	Nenhum
3.5	Convolução1D	128(1x35)	Relu	362x128	286848
3.6	Averagepooling1D	1(1x2)	Nenhuma	181x128	Nenhum
3.7	Convolução1D	256(1x42)	Relu	140x256	1376512
3.8	Averagepooling1D	1(1x2)	Nenhuma	70x256	Nenhum
3.9	Convolução1D	512(1x50)	Relu	21x512	6554112
3.10	Averagepooling1D	1(1x2)	Nenhuma	11x512	Nenhum
3.11	Flatten	Nenhum	Nenhuma	5632	Nenhum
12	Flatten concatenada (1.11, 2.11 e 3.11)	Nenhum	Nenhuma	50688	0
13	Dense	Nenhum	ReLU	128	6488192
14	Dense	Nenhum	ReLU	256	33.024

Tabela 5.13: Estrutura da rede neural 9 (continuação)

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
15	Dense	Nenhum	ReLU	512	131.584
16	Dense	Nenhum	ReLU	256	131.328
17	Dense	Nenhum	ReLU	128	32.896
18	Dense	Nenhum	ReLU	64	8256
19	Dense	Nenhum	Softmax	20	1300
Total					18.368.916

Tabela 5.14: Estrutura da rede neural 10

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
1.0	Entrada (tensão)	Nenhum	Nenhuma	1666	Nenhum
1.1	Convolução1D	32(1x2)	Relu	1665x32	96
1.2	Averagepooling1D	1(1x2)	Nenhuma	832x2	Nenhum
1.3	Convolução1D	64(1x4)	Relu	829x64	8256
1.4	Averagepooling1D	1(1x2)	Nenhuma	414x64	Nenhum
1.5	Convolução1D	128(1x6)	Relu	409x128	49280
1.6	Averagepooling1D	1(1x2)	Nenhuma	204x108	Nenhum
1.7	Convolução1D	256(1x8)	Relu	197x256	262400
1.8	Averagepooling1D	1(1x2)	Nenhuma	98x256	Nenhum
1.9	Convolução1D	512(1x10)	Relu	89x512	1311232
1.10	Averagepooling1D	1(1x2)	Nenhuma	44x512	Nenhum
1.11	Flatten	Nenhum	Nenhuma	22528	Nenhum
2.0	Entrada (Corrente)	Nenhum	Nenhuma	1666	Nenhum
2.1	Convolução1D	32(1x2)	Relu	1665x32	96
2.2	Averagepooling1D	1(1x2)	Nenhuma	832x2	Nenhum
2.3	Convolução1D	64(1x4)	Relu	829x64	8256
2.4	Averagepooling1D	1(1x2)	Nenhuma	414x64	Nenhum
2.5	Convolução1D	128(1x6)	Relu	409x128	49.280

Tabela 5.14: Estrutura da rede neural 10 (continuação)

Nº Camada	Tipo de Camada	Núcleo (Nº Dimensões)	Função de Ativação	Dimensões da Saída	Nº de parâmetros treináveis
2.6	Averagepooling1D	1(1x2)	Nenhuma	204x108	Nenhum
2.7	Convolução1D	256(1x8)	Relu	197x256	262.400
2.8	Averagepooling1D	1(1x2)	Nenhuma	98x256	Nenhum
2.9	Convolução1D	512(1x10)	Relu	89x512	1.311.232
2.10	Averagepooling1D	1(1x2)	Nenhuma	44x512	Nenhum
2.11	Flatten	Nenhum	Nenhuma	22528	Nenhum
12	Flatten concatenada (1.11 e 2.11)	Nenhum	Nenhuma	45056	0
13	Dense	Nenhum	ReLU	128	5.767.296
14	Dense	Nenhum	ReLU	256	33.024
15	Dense	Nenhum	ReLU	512	131.584
16	Dense	Nenhum	ReLU	256	131.328
17	Dense	Nenhum	ReLU	128	32.896
18	Dense	Nenhum	ReLU	64	8256
19	Dense	Nenhum	Softmax	20	1300
Total					9.368.212

5.4 TREINAMENTO DA REDE NEURAL

A implementação e treinamento da rede neural é realizado em linguagem *Python* no ambiente de desenvolvimento *Colaboratory* do *Google*, utilizando as bibliotecas *Keras* e *Sklearn*, as quais possuem funções específicas para implementação de redes neurais. A biblioteca *Keras* utiliza funções de outra biblioteca chamada *Tensor Flow*, cuja versão utilizada é a 1.x.

Para se usar o ambiente de desenvolvimento da *Google*, é necessário que a massa de dados seja exportada para o espaço de armazenamento do *Google Drive*.

Além das bibliotecas específicas para a implementação das redes neurais, são utilizadas também a biblioteca *Pandas* para a manipulação de dados (leitura e

escrita) e a biblioteca *NumPy* (uma biblioteca para computação científica em *Python*) para o processamento dos dados.

Em seguida, é feito o pré-processamento dos dados. Tal processamento consiste na normalização *MinMaxScaler*, sendo que nas entradas de tensão e de corrente a normalização é feita entre todos os exemplos, enquanto que na entrada de corrente filtrada ela é feita exemplo a exemplo.

Após esse procedimento, os dados são separados em três blocos: treinamento, validação e testes, utilizando a função *train_test_split* da biblioteca *sklearn*. Assim, 20% do total de dados é separado para testes, enquanto que 20% do restante é separado para validação. O restante dos exemplos é utilizado para o treinamento.

O treinamento é realizado utilizando o otimizador *SGD*, tamanho do *batch* de 32 exemplos e momento 0,92.

O ambiente de desenvolvimento *Google Colaboratory* tem um tempo limite de utilização de aproximadamente 30 minutos. Linhas de código que não finalizarem sua execução dentro desse limite retornando o controle para o teclado do usuário, provocam a desconexão do computador que está utilizando o ambiente, causando a perda dos dados armazenados na memória e impedindo o treinamento de prosseguir.

Para tornar o treinamento eficaz ele é dividido em várias etapas cada qual com um número de épocas tal que tenha duração inferior a 1700 segundos, de modo a não ultrapassar o limite e evitar a perda dos resultados do treinamento.

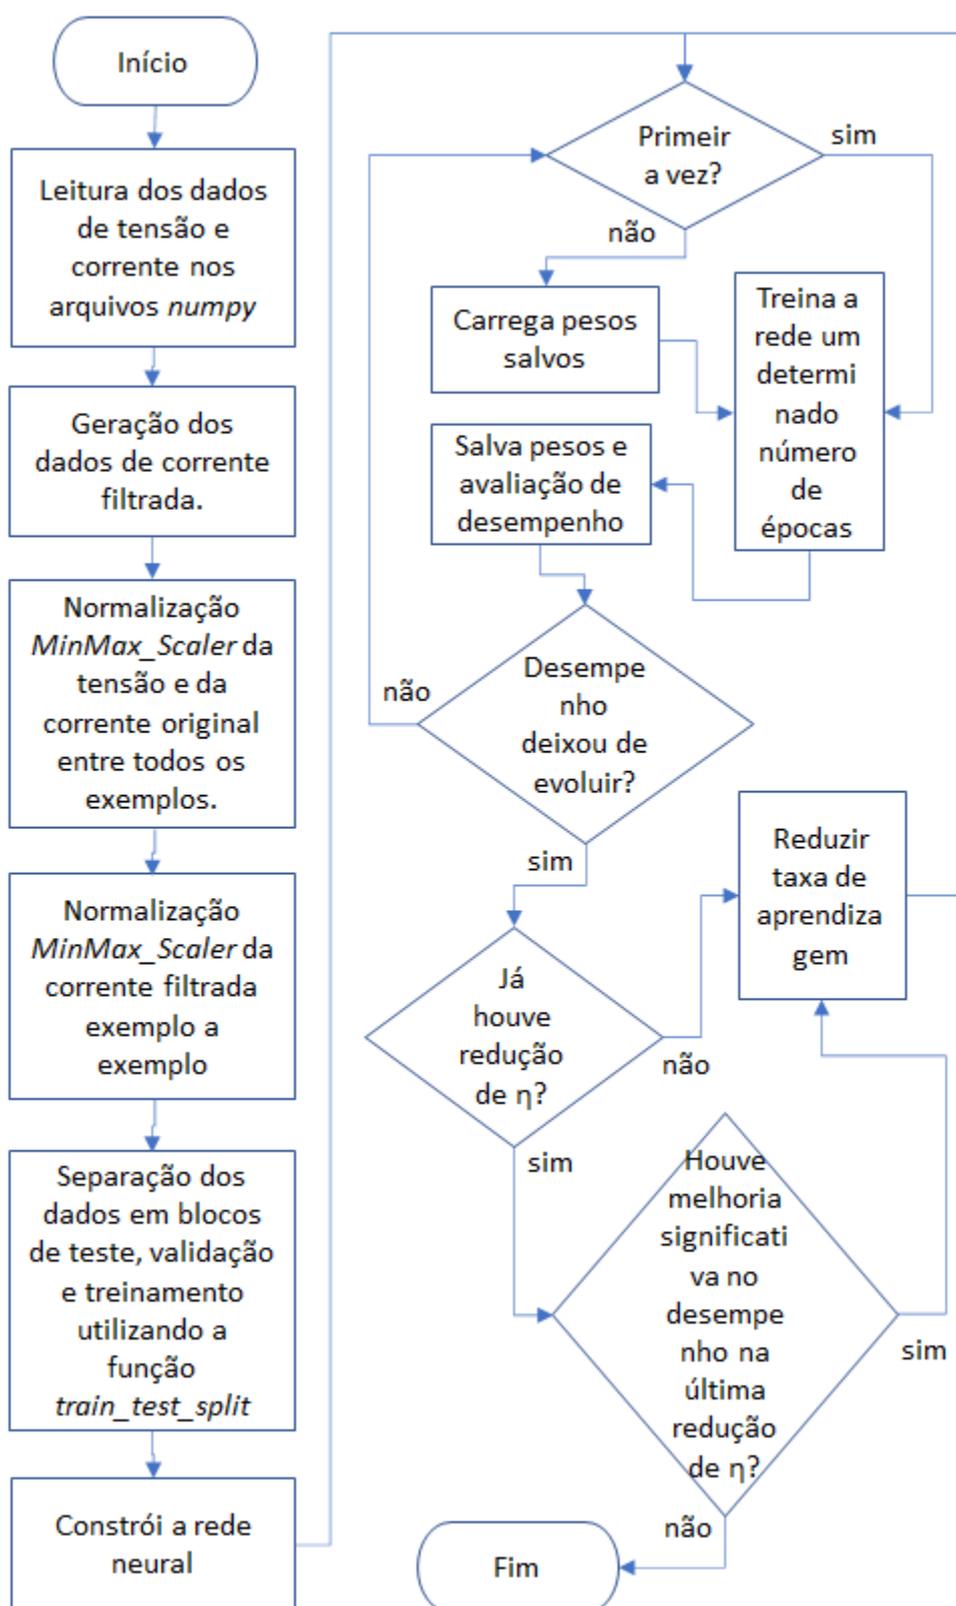
Ao final de cada etapa é salvo em disco o conjunto de pesos que proporciona a melhor acurácia de validação, bem como as acurácias e as perdas no treinamento e na validação obtidas em cada época. Antes de iniciar cada nova etapa de treinamento (com exceção da primeira) é carregado o conjunto de pesos salvo ao final da etapa anterior.

Basicamente cada etapa consiste na execução de um script que lê os dados salvos em disco na etapa anterior, treina a rede um determinado número de

épocas e salva no disco novos dados. Este script é executado, e cada vez que ele termina é reexecutado até que a rede esteja treinada.

A taxa de aprendizagem é alterada de forma manual entre o fim de uma etapa de treinamento e o início de outra, diminuindo seu valor, sempre que se percebe que as acurácias deixaram de aumentar ou ficaram excessivamente ruidosas. As taxas de aprendizagem utilizadas durante cada etapa do treinamento de cada rede, estão disponíveis no Apêndice 3. O fluxograma do processo de treinamento dividido em etapas é mostrado na Figura 5.35.

Figura 5.35: Fluxograma do treinamento dividido em etapas



Fonte: Próprio autor

5.5 MÉTRICAS PARA ANÁLISE

Os parâmetros para comparação das redes podem ser chamados de métricas. Neste trabalho foram utilizadas como métricas a acurácia, os parâmetros treináveis e o tempo de treinamento.

A acurácia é o percentual de classificação correta da rede e indica sua eficácia (acurácia de teste). Esta métrica é obtida após a finalização do processo de treinamento. Os parâmetros treináveis são os pesos e bias dos neurônios da rede, que são ajustados durante o treinamento e estão relacionados com o recurso computacional necessário para que a rede execute sua função de classificação. O número de parâmetros treináveis é obtido após o processo de construção da rede, onde se especifica o número de neurônios de cada camada e o número de camadas da rede, entre outros parâmetros. Já o tempo de treinamento significa quanto se deve esperar para que os pesos da rede estejam ajustados para obter a melhor acurácia possível para a estrutura da rede em questão e depende do problema a ser resolvido, da arquitetura da rede, dos dados de treinamento e do recurso computacional empregado no treinamento. Temos aqui um problema, pois neste trabalho, o recurso computacional não é uniforme com o passar do tempo, o que explicaremos a seguir.

No momento da conexão ao ambiente de desenvolvimento *Google Colaboratory* é disponibilizado ao usuário um recurso computacional. Tal recurso disponibilizado varia conforme a carga do ambiente de desenvolvimento no momento da conexão. Dessa forma a velocidade do treinamento de uma mesma rede pode variar bastante caso haja uma desconexão e o usuário se reconecte para continuar o treinamento (foi observado que o tempo de duração da época ficava duas vezes maior ou menor quando isso acontecia). Devido ao treinamento das redes precisar ser feito em várias etapas, à existência de um tempo limite para execução (conforme explicado na seção anterior 5.4), e ao treinamento de todas as redes utilizadas neste trabalho levar vários dias, as reconexões são frequentes e certamente haverá várias delas. Portanto, em diferentes momentos o usuário terá diferentes recursos computacionais disponíveis, proporcionando diferentes níveis de desempenho. Dessa forma, o tempo gasto no treinamento de cada rede não pode ser utilizado como parâmetro de comparação entre elas, visto que para uma correta comparação deve ser

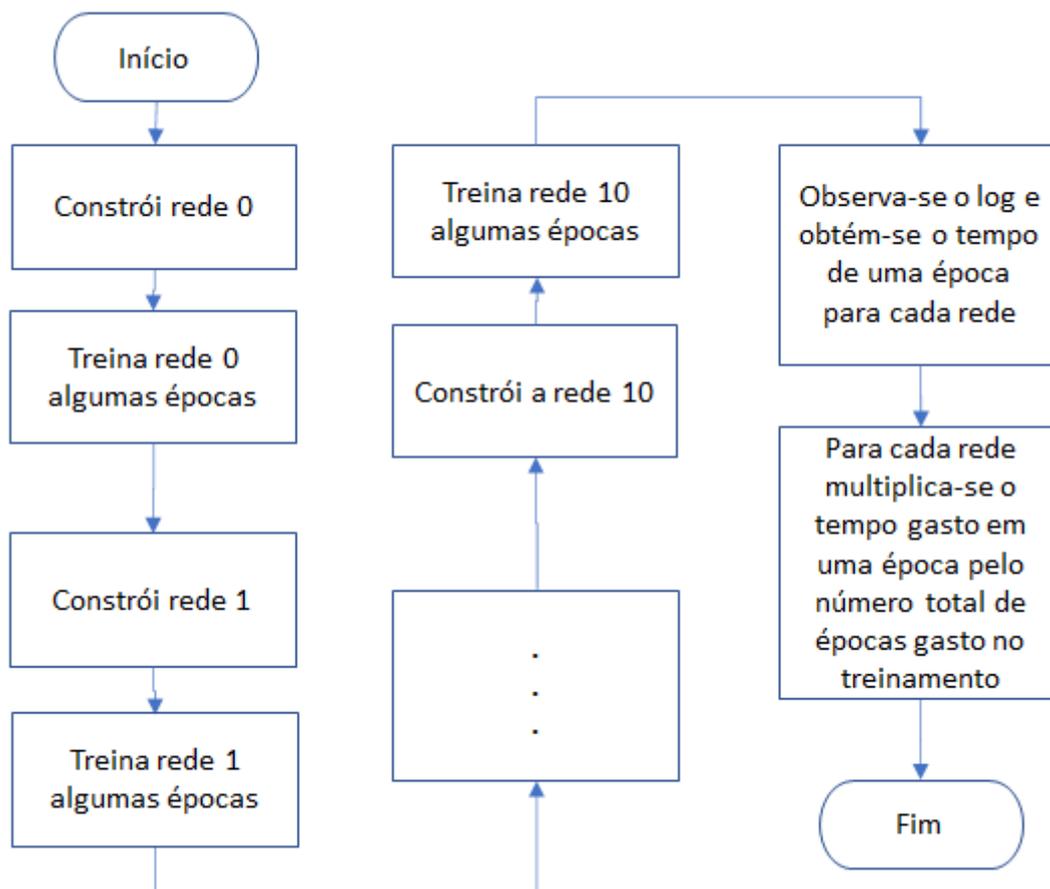
utilizado um recurso computacional que proporcione o mesmo desempenho para todas as redes.

Para resolver este problema, após todas as redes já estarem treinadas, portanto, tendo já disponível o número total de épocas utilizado no treinamento de cada uma delas, com o objetivo de obter um tempo de treinamento que possa ser utilizado para fins de comparação entre elas, foi construído um *script* para executar apenas algumas poucas épocas de treinamento de cada uma das redes (entre 3 e 5 épocas), de forma que o treinamento de todo esse pequeno número de épocas ocorra dentro de um intervalo de tempo curto o suficiente para que não haja nenhuma reconexão ao ambiente de desenvolvimento. Dessa forma, é possível obter um parâmetro (tempo gasto em uma época de treinamento) utilizando o mesmo recurso computacional para cada uma das redes (). Multiplicando este parâmetro pelo respectivo número de épocas utilizado no treinamento, é possível obter um tempo total de treinamento para cada rede que possa ser utilizado para fins de comparação entre elas.

O tempo dispendido em uma época de treinamento pode ser obtido através da observação das mensagens de log do *script* mencionado acima, onde para cada época de treinamento é exibido, junto com outras informações, o número de exemplos utilizados no treinamento e os tempos dispendidos para toda a época e por exemplo de treinamento (Figura 5.37).

O tempo gasto em cada época poderia ser obtido diretamente da mensagem de log, entretanto ainda há um problema. Os valores disponibilizados pela ferramenta de treinamento são exibidos em formato inteiro (arredondado), com unidade de medida variável (s, ms ou μ s), muitas vezes com apenas 1 algarismo significativo (quando o tempo está entre 1 e 9 s), o que introduziria um erro de arredondamento possivelmente grande para essa faixa de valores. Após observação, verifica-se que quando isso acontece (redes menores), o tempo por exemplo fica com 3 algarismos (exibido em μ s). Nestes casos, o tempo da época é obtido através do produto entre o tempo gasto por exemplo pelo número de exemplos. Nos outros casos (redes maiores), foi utilizado diretamente o tempo da época, pois fica com 2 algarismos significativos, enquanto o tempo por exemplo fica com apenas 1 (exibido em ms). Vide Figura 5.38.

Figura 5.36: Fluxograma do processo para obtenção do tempo total de treinamento das redes para comparação



Fonte: Próprio autor

Figura 5.37: Mensagens de log com indicação das informações utilizadas (tempo da época com 1 algarismo significativo)

```

↳ WARNING:tensorflow:From /usr/local/lib/python3.6/dist-packages/keras/backend/

Train on 17368 samples, validate on 4342 samples
Epoch 1/5
17368/17368 [=====] - 4s 247us/step - loss: 2.9957 -

Epoch 00001: val_acc improved from -inf to 0.04698, saving model to /content/
Epoch 2/5
17368/17368 [=====] - 3s 149us/step - loss: 2.9956 -

Epoch 00002: val_acc did not improve from 0.04698 tempo gasto por exemplo
Epoch 3/5 tempo gasto na época
17368 17368 [=====] - 3s 148us/step - loss: 2.9955 -
Nº exemplos
Epoch 00003: val_acc did not improve from 0.04698
Epoch 4/5
17368/17368 [=====] - 3s 146us/step - loss: 2.9954 -

Epoch 00004: val_acc did not improve from 0.04698
Epoch 5/5
17368/17368 [=====] - 3s 149us/step - loss: 2.9953 -

```

Fonte: Próprio autor

Figura 5.38: Mensagens de log com indicação das informações utilizadas (tempo da época com 2 algarismo significativos)

```

history = model.fit([X_train[:, :, 0, :], X_train[:, :, 1, :], I_hi_0_train], Y_tra
batch_size=batch_size,
epochs=epochs,
verbose=1,
validation_data=(X_val[:, :, 0, :], X_val[:, :, 1, :], I_hi_0_val], Y_va
callbacks=[checkpoint])

```

```
end_time = time.time()
```

```
print("Training/validation time was %g seconds" % (end_time - start_time))
```

```
model.save(filepath+'.model')
```

```

↳ Train on 17368 samples, validate on 4342 samples
Epoch 1/3
17368/17368 [=====] - 18s 1ms/step - loss: 2.8958 -

Epoch 00001: val_acc improved from -inf to 0.14947, saving model to /content/
Epoch 2/3 tempo gasto na época
17368 17368 [=====] - 18s 1ms/step - loss: 2.2842 -
Nº de exemplos
Epoch 00002: val_acc did not improve from 0.14947 tempo gasto por exemplo
Epoch 3/3
17368/17368 [=====] - 18s 1ms/step - loss: 2.2080 -

Epoch 00003: val_acc improved from 0.14947 to 0.15845, saving model to /conte
Training/validation time was 57.0091 seconds

```

Fonte: Próprio autor

6 RESULTADOS E DISCUSSÕES

6.1 DADOS ADQUIRIDOS

Nesta seção são apresentados os dados adquiridos para cada uma das 20 condições de funcionamento da *string* fotovoltaica, bem como as condições ambientais (temperatura ambiente e irradiação solar) nos instantes de cada captura.

A Tabela 6.1 mostra o número de amostras de tensão e corrente adquiridos em cada condição de funcionamento. Mostra também o número de exemplos que tais amostras representam. Observe que tal número varia ligeiramente devido a algumas etapas de aquisições terem sido descartadas devido a erro na emulação durante procedimento de aquisição de dados (em alguns poucos ciclos de coleta todas as etapas foram descartadas). Por fim, é possível observar que os dados ambientais obtidos para cada condição de funcionamento é uma fração do número de exemplos (1/6), uma vez que em cada etapa de aquisição (onde se garante as mesmas condições climáticas médias) possibilitam a aquisição de seis exemplos.

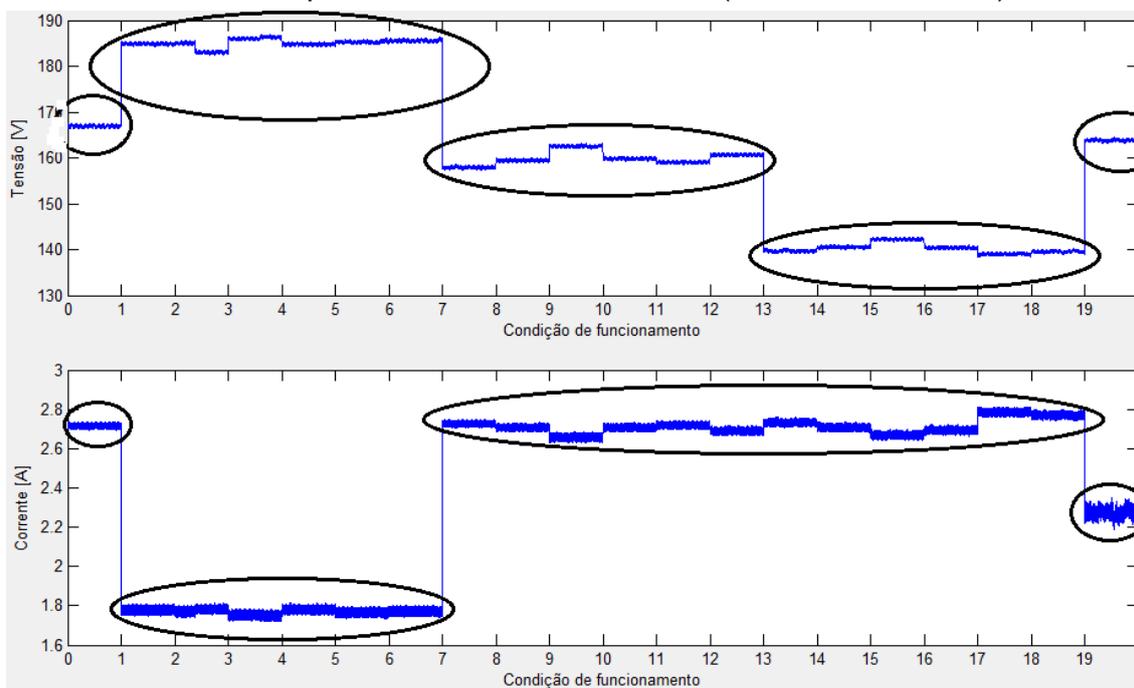
No Apêndice 1 temos os dados dos dias e horários em que ocorreram as capturas de cada ciclo de coleta. É possível observar que tais capturas ocorrem durante 21 dias e em variados períodos de cada dia. A tabela explicita ainda as condições climáticas durante tais capturas, mostrando que os dados foram obtidos com a *string* fotovoltaica sob variadas circunstâncias climáticas (o Apêndice 2 traz mais informações sobre os dados climáticos adquiridos).

Tabela 6.1: Número de amostras adquiridas para cada condição de funcionamento

<i>Condição de Funcionamento da String</i>	<i>Nº de amostras de tensão</i>	<i>Nº de amostras de corrente</i>	<i>Nº de Exemplos</i>	<i>Nº de amostras de temperatura</i>	<i>Nº de amostras de irradiação</i>
0	2.260.000	2.260.000	1356	226	226
1	2.250.000	2.250.000	1350	225	225
2	2.260.000	2.260.000	1356	226	226
3	2.260.000	2.260.000	1356	226	226
4	2.260.000	2.260.000	1356	226	226
5	2.260.000	2.260.000	1356	226	226
6	2.250.000	2.250.000	1350	225	225
7	2.260.000	2.260.000	1356	226	226
8	2.270.000	2.270.000	1362	227	227
9	2.270.000	2.270.000	1362	227	227
10	2.270.000	2.270.000	1362	227	227
11	2.270.000	2.270.000	1362	227	227
12	2.270.000	2.270.000	1362	227	227
13	2.270.000	2.270.000	1362	227	227
14	2.270.000	2.270.000	1362	227	227
15	2.270.000	2.270.000	1362	227	227
16	2.270.000	2.270.000	1362	227	227
17	2.270.000	2.270.000	1362	227	227
18	2.270.000	2.270.000	1362	227	227
19	2.200.000	2.200.000	1320	220	220
Total	45.230.000	45.230.000	27138	4523	4523

A Figura 6.1 mostra os gráficos dos dados de tensão e corrente de um único ciclo de coleta (condições de funcionamento de 0 a 19), onde cada condição está representada por 10.000 amostras de tensão e de corrente, as quais correspondem a seis exemplos, conforme já mencionado.

Figura 6.1: Amostras de tensão e corrente para uma coleta em condições climáticas aproximadamente constantes (ciclo de coleta 225)



Fonte: próprio autor

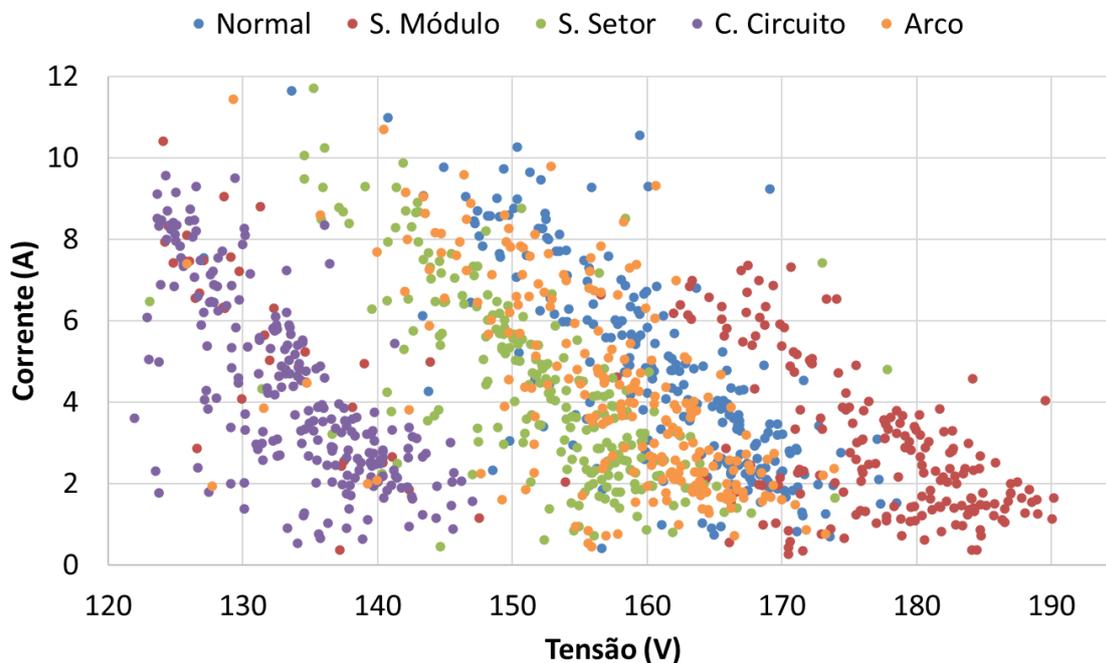
Pode-se observar que as amostras de tensão das janelas de captura (ou etapas de aquisição) apresentam níveis diferentes para cada tipo de condição de funcionamento, sendo esses níveis mais próximos em certos grupos de condições de funcionamento. É possível, portanto, destacar quatro grupos, conforme pode ser visto no gráfico de tensão da Figura 6.1.

Observa-se também na Figura 6.1 que as amostras de corrente correspondentes a cada condição de funcionamento apresentam níveis distintos. Entretanto, como pode ser visto no gráfico de corrente da Figura 6.1, é possível destacar outros três grupos de condições de funcionamento onde tais níveis de corrente são mais próximos.

A Figura 6.2 mostra a relação corrente média *versus* tensão média das cinco condições de funcionamento do módulo 1 (o comportamento é semelhante em todos os módulos): normal; sombreamento parcial do módulo inteiro (S. Módulo);

sombreamento parcial de um setor do módulo (S. Setor); curto-circuito de um módulo (C. Circuito); e arco elétrico em cabo condutor da *string* (Arco).

Figura 6.2: Gráfico Corrente *versus* Tensão por tipo de defeito (módulo 1)



Fonte: próprio autor

Tais agrupamentos foram definidos com base na interseção dos grupos baseados na análise de tensão e de corrente da Figura 6.1 e são formados pelas condições de funcionamento que pertencem ao mesmo tipo de defeito. A Tabela 6.2 detalha tais grupos.

Tabela 6.2: Grupos de condições de funcionamento da *string* fotovoltaica.

Grupo	Defeito	Condições de funcionamento
0	Normal (Sem defeito)	0
1	Sombreamento de módulo	1 a 6
2	Sombreamento de setor	7 a 12
3	Curto-circuito	13 a 18
4	Arco elétrico	19

O gráfico da Figura 6.2 revela uma aparente facilidade em separar grupos de condições de funcionamento da *string* fotovoltaica usando apenas os sinais de tensão nas extremidades da *string* e de corrente gerada pela *string*. Entretanto,

é objetivo neste trabalho identificar com precisão cada uma das 20 condições de funcionamento representadas por tais amostras de tensão e de corrente.

Deseja-se ainda provar que tal tarefa é possível sem a necessidade de usar as informações climáticas, tendo em vista que tais variáveis afetam diretamente as tensões e correntes amostradas.

Provando isso, mostra-se que é possível eliminar a necessidade do monitoramento direto das variáveis climáticas, proporcionando um sistema menos complexo e mais barato.

Além disso, ao eliminar tais variáveis, eliminam-se também duas possíveis fontes de erro, tornando o sistema mais robusto.

6.2 IDENTIFICAÇÃO DE CONDIÇÕES DE FUNCIONAMENTO DA STRING

São mostrados aqui os resultados de identificação de condições individuais de funcionamento da *string* fotovoltaica (Tabela 5.3). Tais resultados são provenientes do uso de cada uma das 11 redes neurais apresentadas no Capítulo 5.

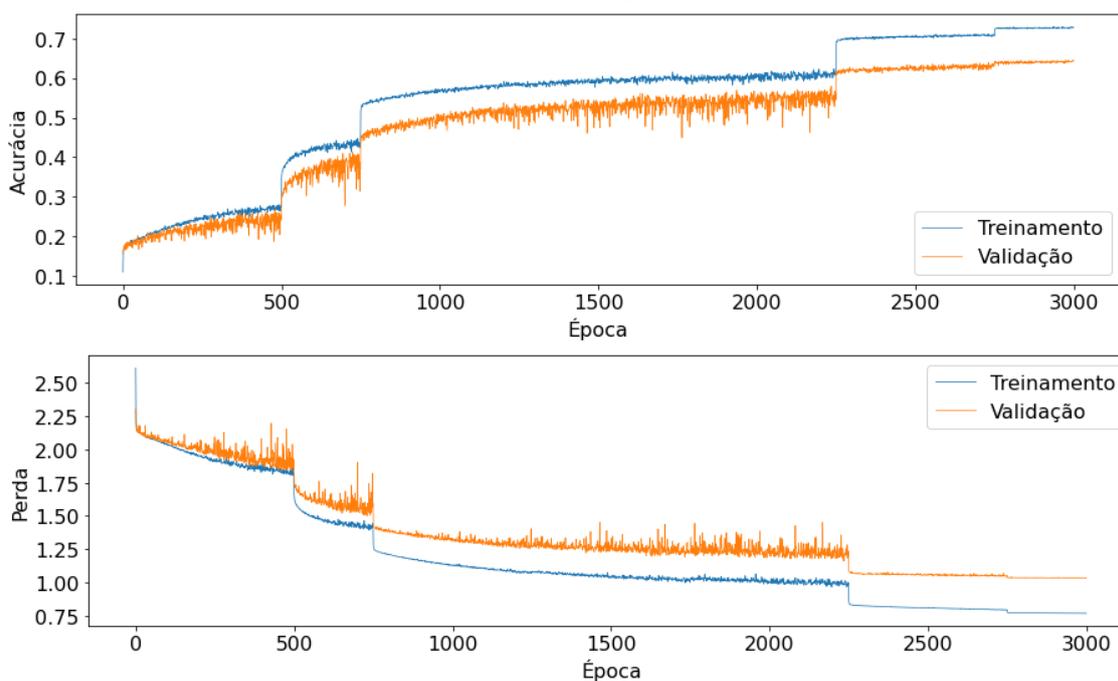
A Tabela 6.3 mostra o desempenho das redes neurais na identificação das condições de funcionamento da *string* fotovoltaica. Como pode ser visto, apenas as redes 7, 8, 9 e 10 são capazes de alcançar uma acurácia média superior a 80%, sendo que a rede 9 apresenta a melhor acurácia, porém exigindo aproximadamente o dobro do tempo de treinamento da rede 8, embora com um número de épocas apenas 8% superior. A rede 10 teve um desempenho próximo da rede 9. Embora tenha aproximadamente metade do número de parâmetros treinados, a rede 10 levou mais que o dobro do tempo para ser treinada, quando comparada com a rede 9.

A rede neural 0 foi a única rede *MLP* (ou seja, não convolucional) testada. Logo, destaca-se aqui seu desempenho para servir de comparação com os resultados obtidos usando redes *CNN*. No caso em particular, a rede 0 levou aproximadamente 2 horas e 15 minutos para executar o treinamento de 3000 épocas. A evolução da acurácia e da perda durante o treinamento e a validação pode ser visto na Figura 6.3

Tabela 6.3: Desempenho das redes neurais na identificação de condições de funcionamento da *string* fotovoltaica.

Rede	Parâmetros treinados	Épocas	Duração de uma época	Tempo total de treinamento	Acurácia de Validação (%)	Acurácia de Teste (%)
0	4.528.526	3000	2,7s	2h 15m	64,44	64,19
1	444.036	5000	3,6s	5h 00m	28,90	27,52
2	444.036	2750	3,6s	2h 45m	36,02	34,38
3	870.132	1625	5,4s	2h 26m	58,66	57,55
4	875.268	1750	5,1s	2h 29m	57,53	56,10
5	3.869.572	75	20s	0h 25m	69,76	70,71
6	3.858.708	75	21s	0h 26m	69,00	70,85
7	3.990.420	260	21s	1h 31m	83,46	83,66
8	6.186.228	250	18s	1h 15m	88,51	88,34
9	18.368.916	270	48s	3h 36m	93,21	94,03
10	9.368.212	1150	25s	7h 59m	92,12	92,24

Figura 6.3: Evolução da acurácia e perda durante o treinamento e a validação da rede 0.



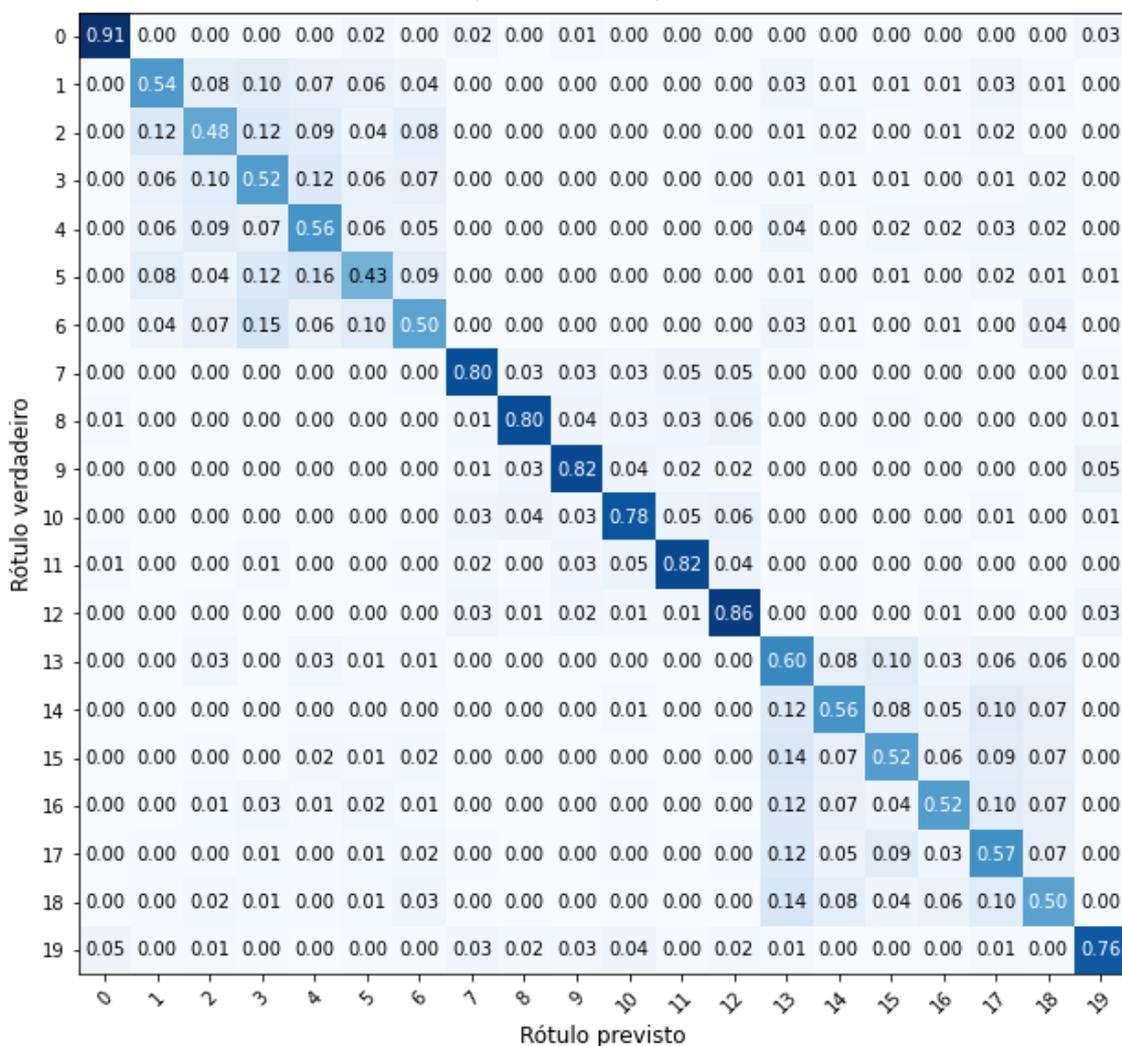
Fonte: Próprio autor

A Figura 6.4 exibe a matriz de confusão das condições de funcionamento para a rede 0. A matriz revela uma acurácia particularmente mais baixa para as classes de sombreamento total e curto-circuito, resultando numa acurácia global de teste de 64,19% para as 20 condições de funcionamento da *string* fotovoltaica,.

Os resultados obtidos com a rede 1 (uma rede com convolução 1D) também são aqui destacados. Isto porque esta rede foi a única que se utilizou apenas da corrente como entrada. A acurácia inferior a 28% mostra que apenas a corrente elétrica como dado de entrada é insuficiente para se obter um desempenho expressivo.

Por um motivo similar, é dado destaque também à rede 2, pois assim como a rede 1, é de convolução 1D. Entretanto, diferente da rede anterior, esta é a única das 9 redes que se utiliza de apenas da tensão como entrada. Embora o resultado tenha sido melhor do que a rede 1, (aproximadamente 34% de acurácia), ainda está distante do resultado obtido com a rede 0.

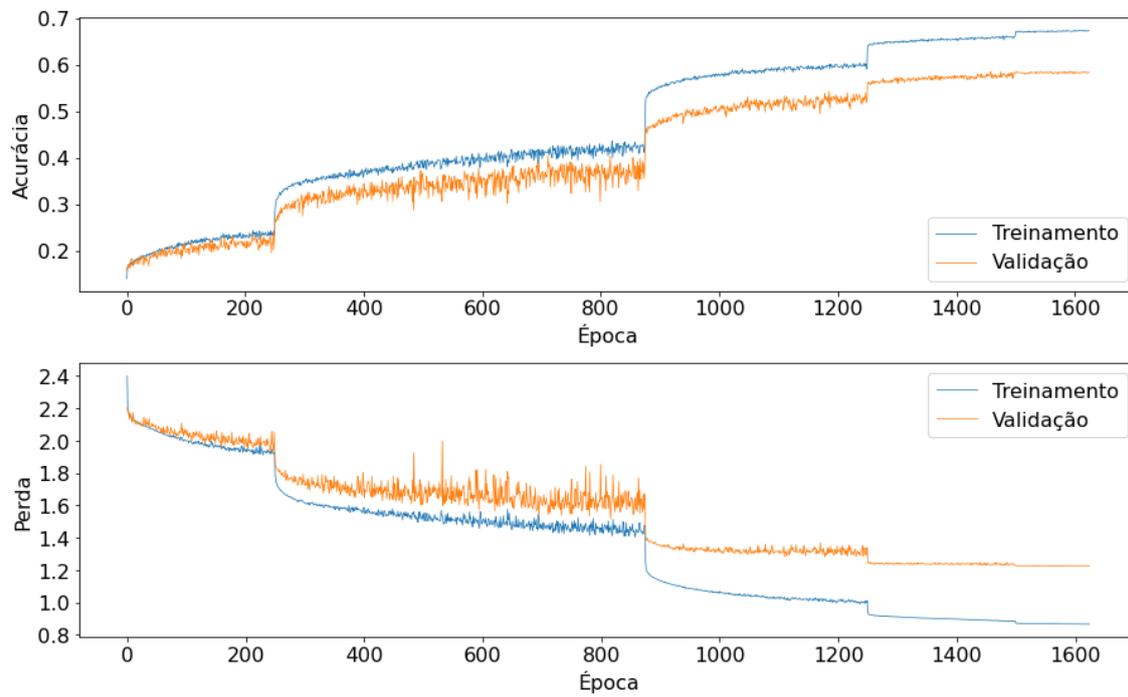
Figura 6.4: Matriz de confusão entre as condições de funcionamento da rede 0 (normalizada)



Fonte: Próprio autor

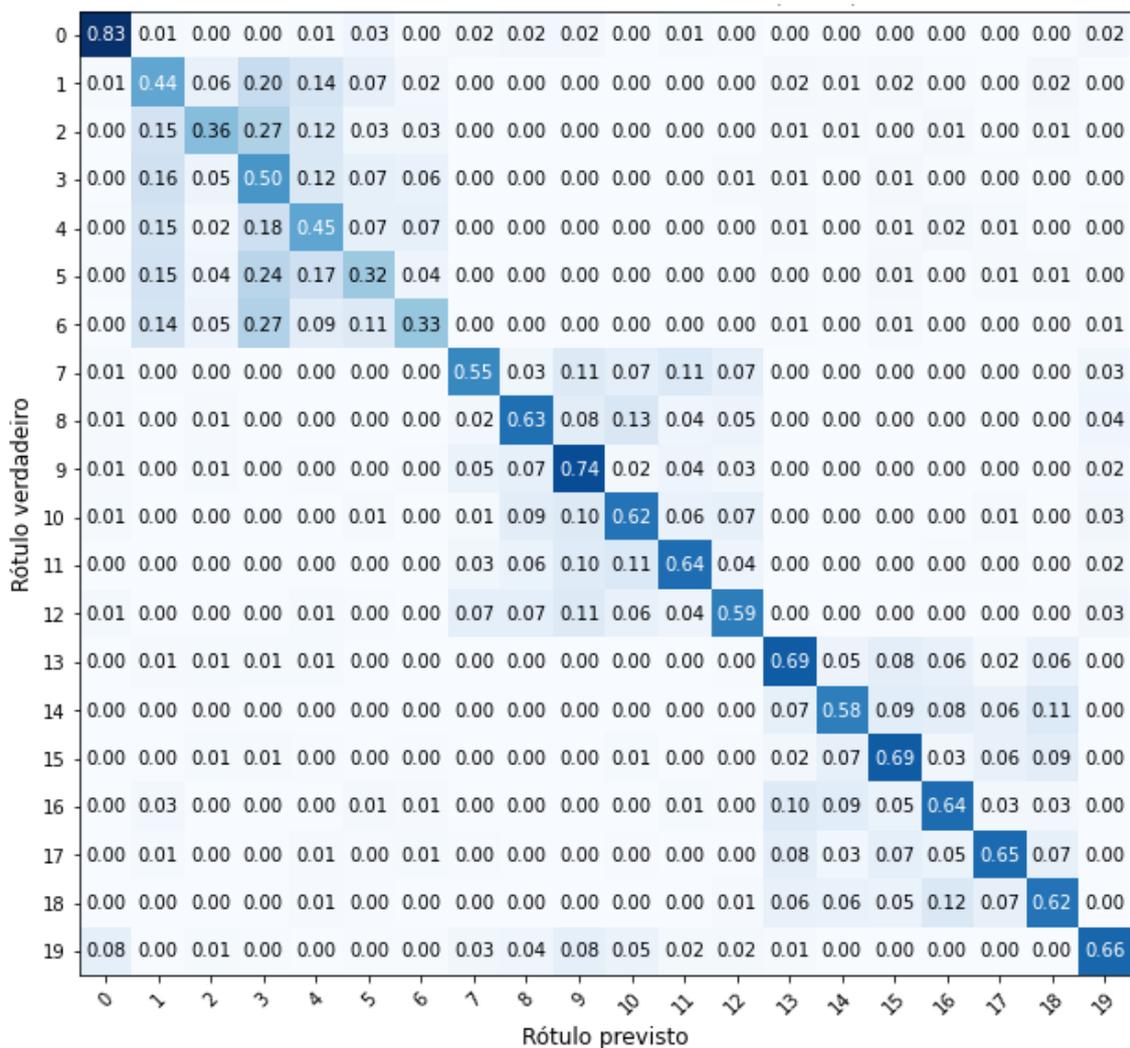
Assim como as redes 1 e 2, a rede 3 também realiza convolução 1D. A diferença com relação às primeiras é que ela usa tanto os dados de tensão quanto os de corrente. Com isso, percebe-se uma melhoria significativa no desempenho (alcançando aproximadamente 57%) em relação as redes 1 e 2. Entretanto, seu desempenho ainda está abaixo da rede 0. O comportamento das acurácias e das perdas durante o treinamento e a validação é mostrado na Figura 6.5, enquanto a matriz de confusão na etapa de teste é mostrada na Figura 6.6.

Figura 6.5: Evolução da acurácia e da perda durante o treinamento e a validação da rede 3



Fonte: Próprio autor

Figura 6.6: Matriz de confusão entre as condições de funcionamento para a rede 3 (normalizada)

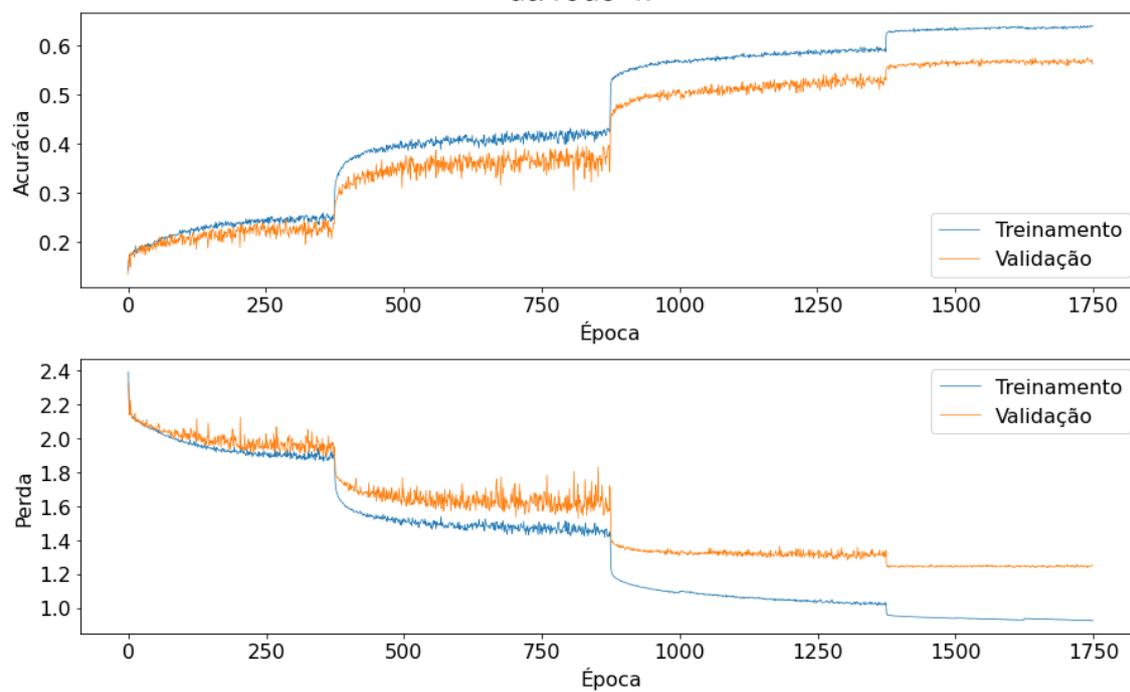


Fonte: Próprio autor

Assim como a rede 3, a rede 4 combina os dados de tensão e de corrente na entrada. A diferença é que a rede 4 aplica convolução 2D. O desempenho desta rede (acurácia de 56,10%) não demonstrou alteração significativa com relação à rede 3, estando ainda abaixo do esperado.

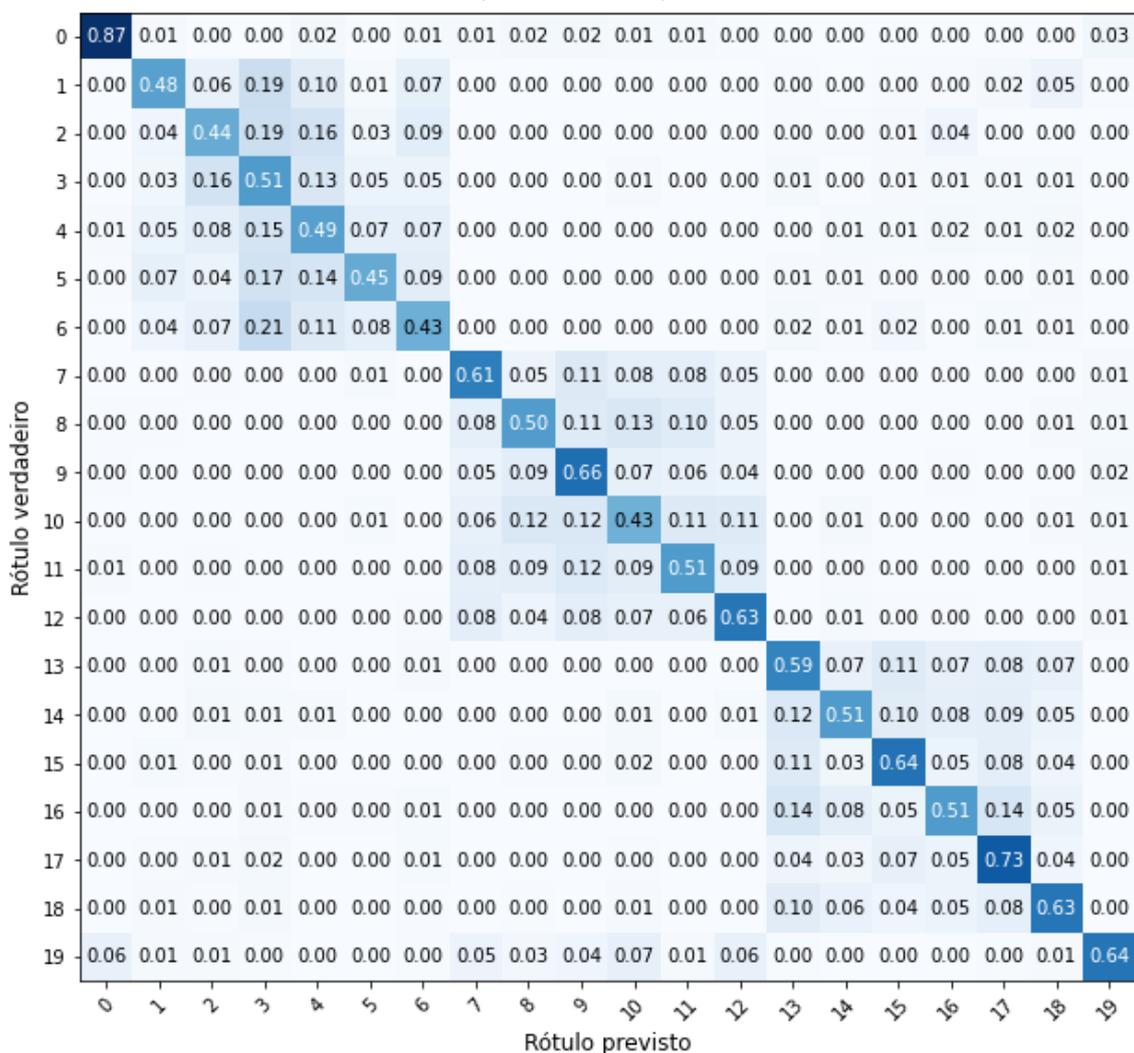
A evolução da acurácia e da perda durante o treinamento e a validação pode ser vista na Figura 6.7. Já a Figura 6.8 apresenta a matriz de confusão obtida a partir da acurácia após o teste da rede 4.

Figura 6.7: Evolução da acurácia e perda durante o treinamento e a validação da rede 4.



Fonte: Próprio autor

Figura 6.8: Matriz de confusão das condições de funcionamento da rede 4 (normalizada)



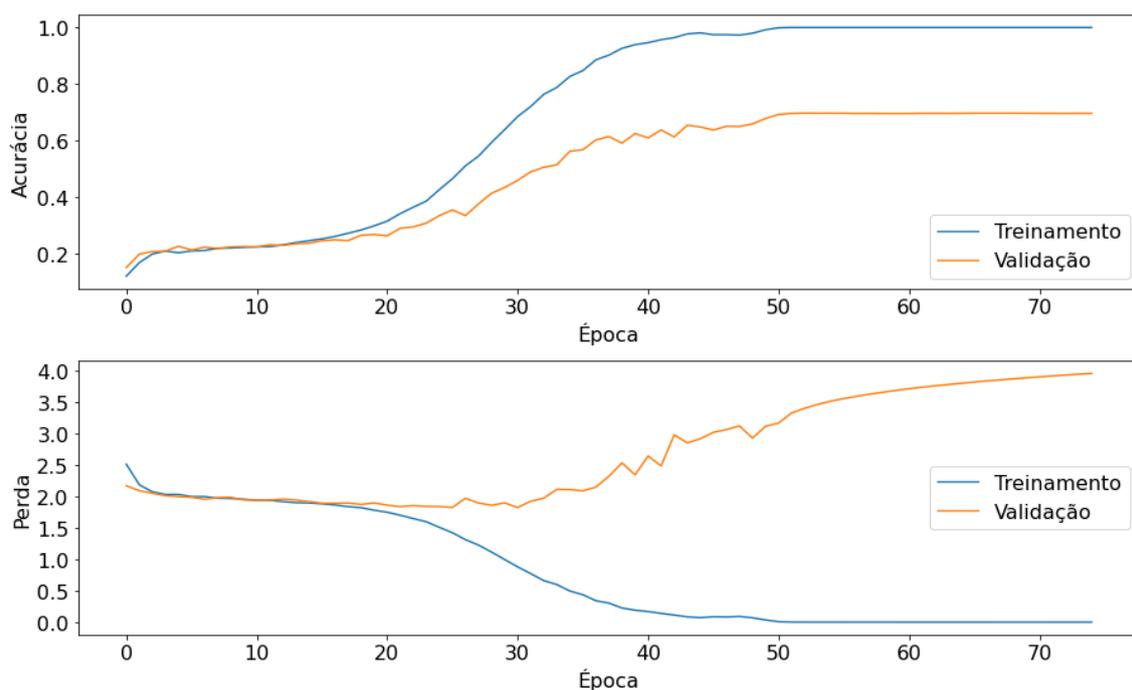
Fonte: Próprio autor

A rede 5, a qual também é uma rede de convolução 2D, apresenta um desempenho significativamente melhor do que a rede 4, alcançando 70,71% de acurácia na identificação das condições de funcionamento. Especificamente na condição de arco elétrico (19), esta rede alcançou 95% de acurácia.

Esse bom desempenho para esta condição pode ser atribuído à utilização de um ramo específico com convolução 1D para processar as altas frequências da corrente, conforme descrito no item 5.3 e ilustrado na Figura 5.34a.

Pode-se observar na Figura 6.9, que a rede 5 apresenta acurácia máxima para os exemplos de treinamento (100%), enquanto que para os de validação a acurácia estabiliza em aproximadamente 70%. Enquanto isso, a perda na validação também aumenta, sinalizando a ocorrência de *overfitting*.

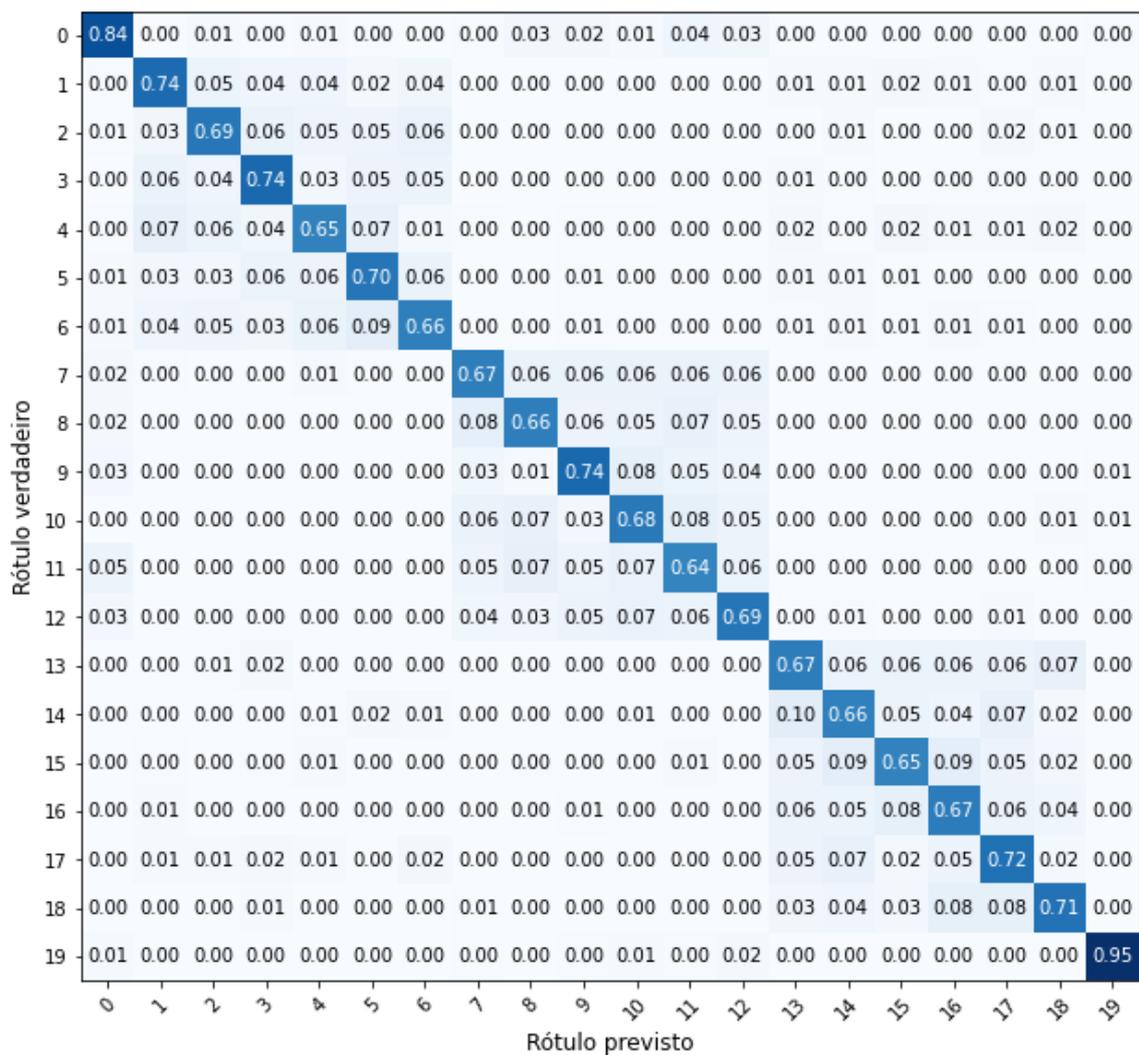
Figura 6.9: Evolução da acurácia e perda durante o treinamento e a validação da rede 5.



Fonte: Próprio autor

A Figura 6.10 mostra a matriz de confusão obtida ao testar a rede 5. Embora tenha apresentado o melhor desempenho até então, esse ainda está longe do objetivo deste trabalho. Além disso, a indicação de *overfitting* inviabiliza ainda mais o uso desta rede.

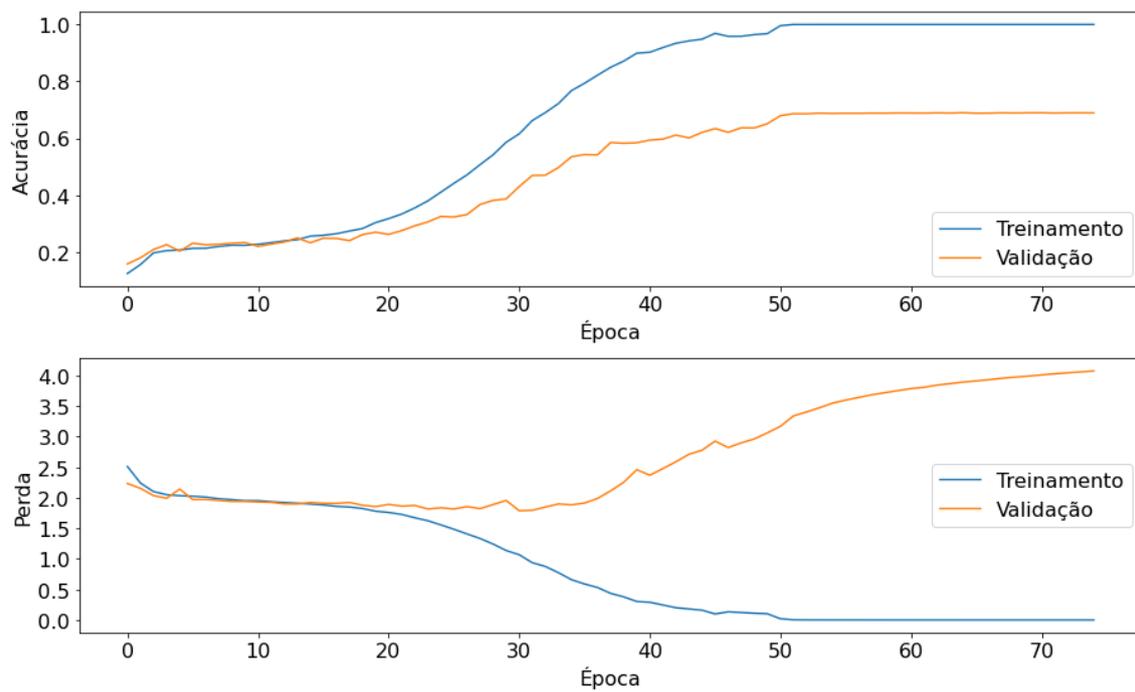
Figura 6.10: Matriz de confusão entre as condições de funcionamento para a rede 5 (normalizada).



Fonte: Próprio autor

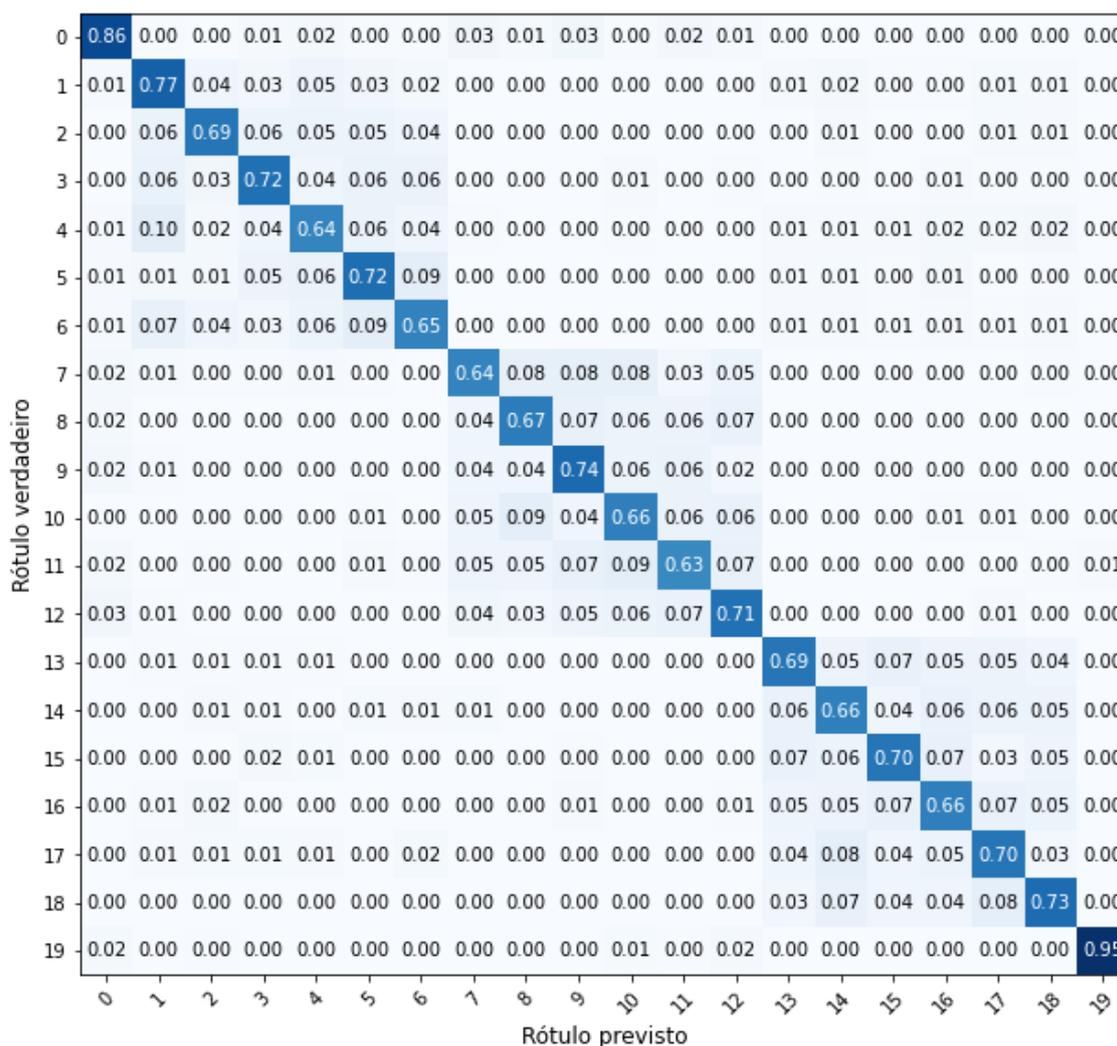
A Figura 6.11 mostra as acurácias de treinamento e validação da rede 6, onde se utiliza a convolução 1D, em vez de 2D, sobre a entrada de tensão e sobre a entrada corrente original. Observa-se um desempenho muito parecido ao da rede 5, inclusive com indicação de *overfitting* (aumento da perda na validação). A Figura 6.12 apresenta a matriz de confusão ao se testar a rede 6.

Figura 6.11: Evolução da acurácia e perda durante o treinamento e a validação da rede 6.



Fonte: Próprio autor

Figura 6.12: Matriz de confusão entre condições de funcionamento para a rede 6 (normalizada).



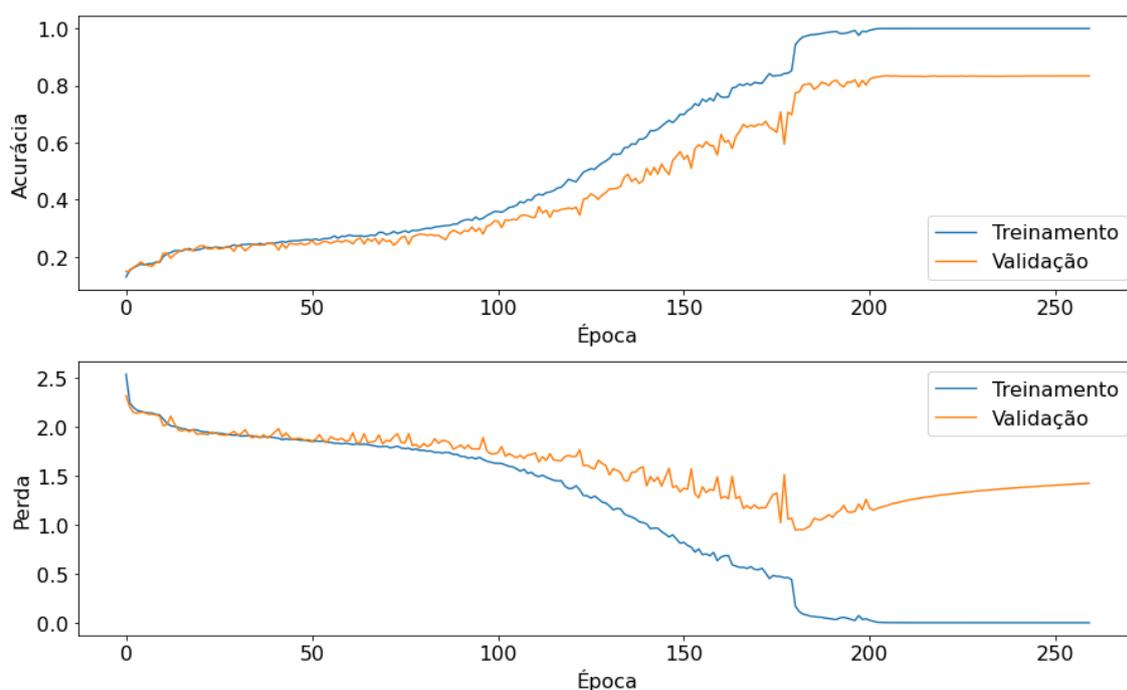
Fonte: Próprio autor

Comparando os resultados das redes 1, 2, 3, 4, 5 e 6 observa-se que a utilização da tensão e da corrente simultaneamente resulta em melhores acurácias do que a utilização da corrente ou da tensão individualmente, e que a utilização de convolução em uma ou em duas dimensões não resultou em diferença significativa nas acurácias. Baseado nestes resultados, iniciou-se um processo de melhoria da rede 5 que apresentou um resultado próximo ao da rede 6 e com uma estrutura mais simples (convolução 1D).

A rede 7 apresenta uma melhora quanto ao overfitting (efeito negativo observado nas redes 5 e 6), como se pode observar na Figura 6.13. Além disso, a rede 7 apresenta uma melhora de desempenho na identificação das condições de funcionamento (Figura 6.14), alcançando uma acurácia de 83,66%. Essa

importante melhora pode ser atribuída ao aumento do número de camadas Densas, que passou de 4 para 7, visto que quanto maior o número de camadas, a rede se torna capaz de separar classes de dados com regiões de superfícies mais complexas entre si.

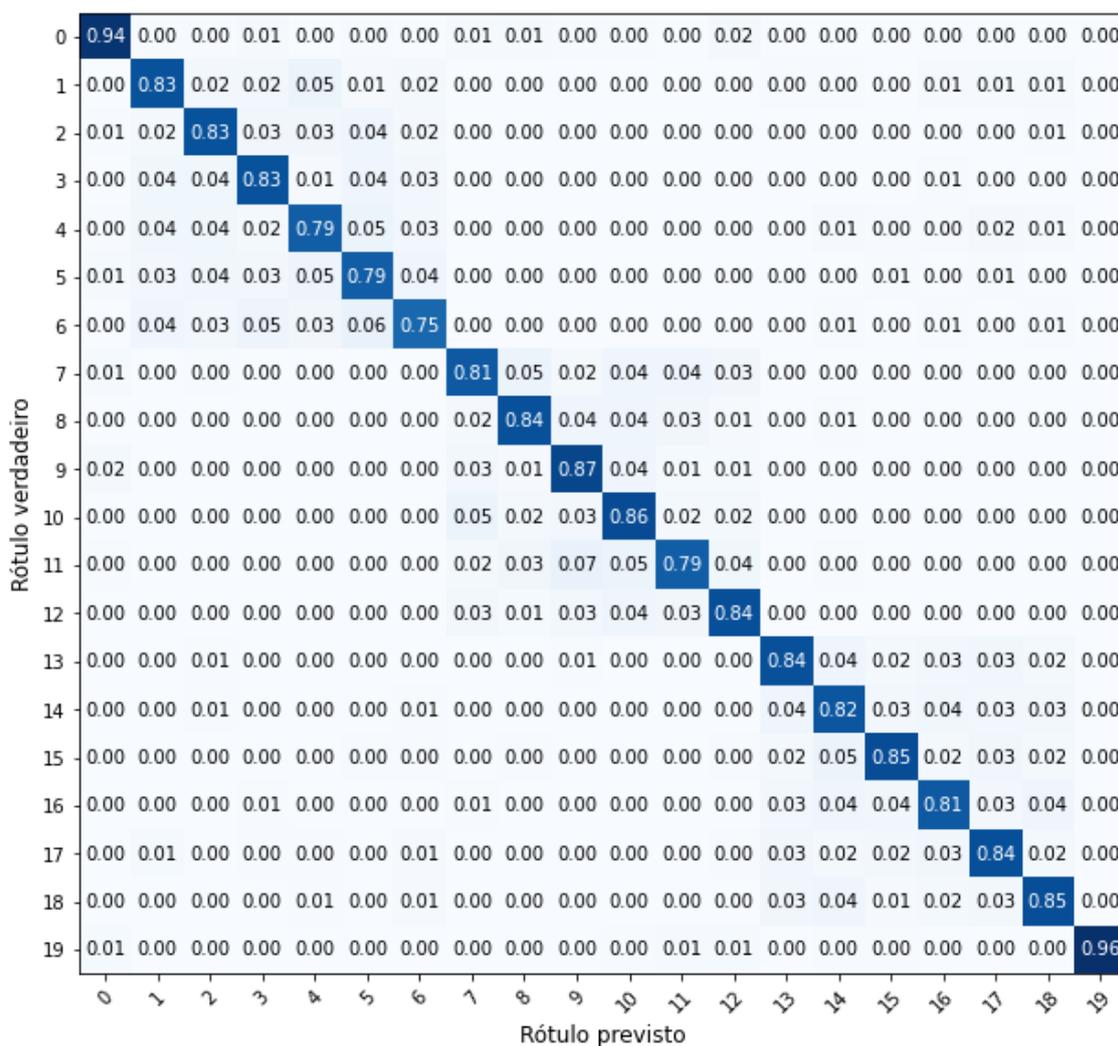
Figura 6.13: Evolução da acurácia e perda durante o treinamento e validação da rede 7.



Fonte: Próprio autor

Cabe ressaltar que a rede 7 representa o resultado final de uma ampla gama de testes de estruturas de redes, onde, no caso específico, foi-se aumentando o número de camadas densas até o ponto em que a rede não apresentasse uma melhora em seu desempenho.

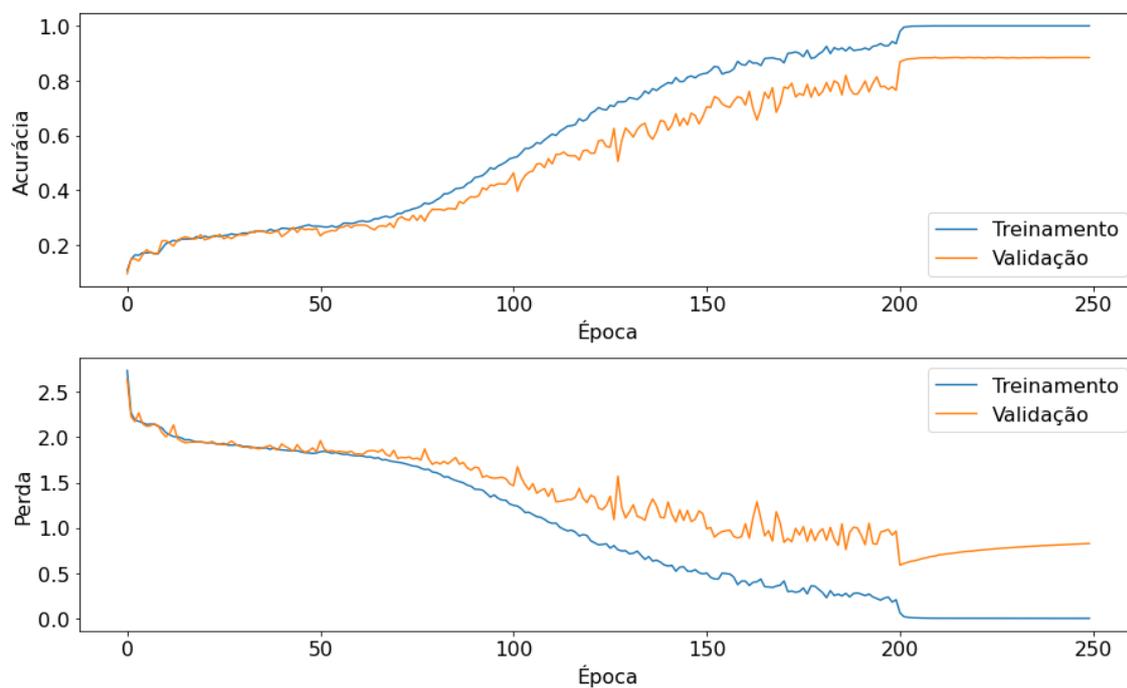
Figura 6.14: Matriz de confusão entre as condições de funcionamento para a rede 7 (normalizada).



Fonte: Próprio autor

A rede 8 difere da rede 7 no número de camadas convolucionais e de agrupamento, sendo 2 camadas na rede 7 e 4 camadas na rede 8. A Figura 6.15 mostra a evolução da acurácia e da perda durante o treinamento e a validação da rede 8. Já a Figura 6.16 mostra a matriz de confusão após o teste da rede 8.

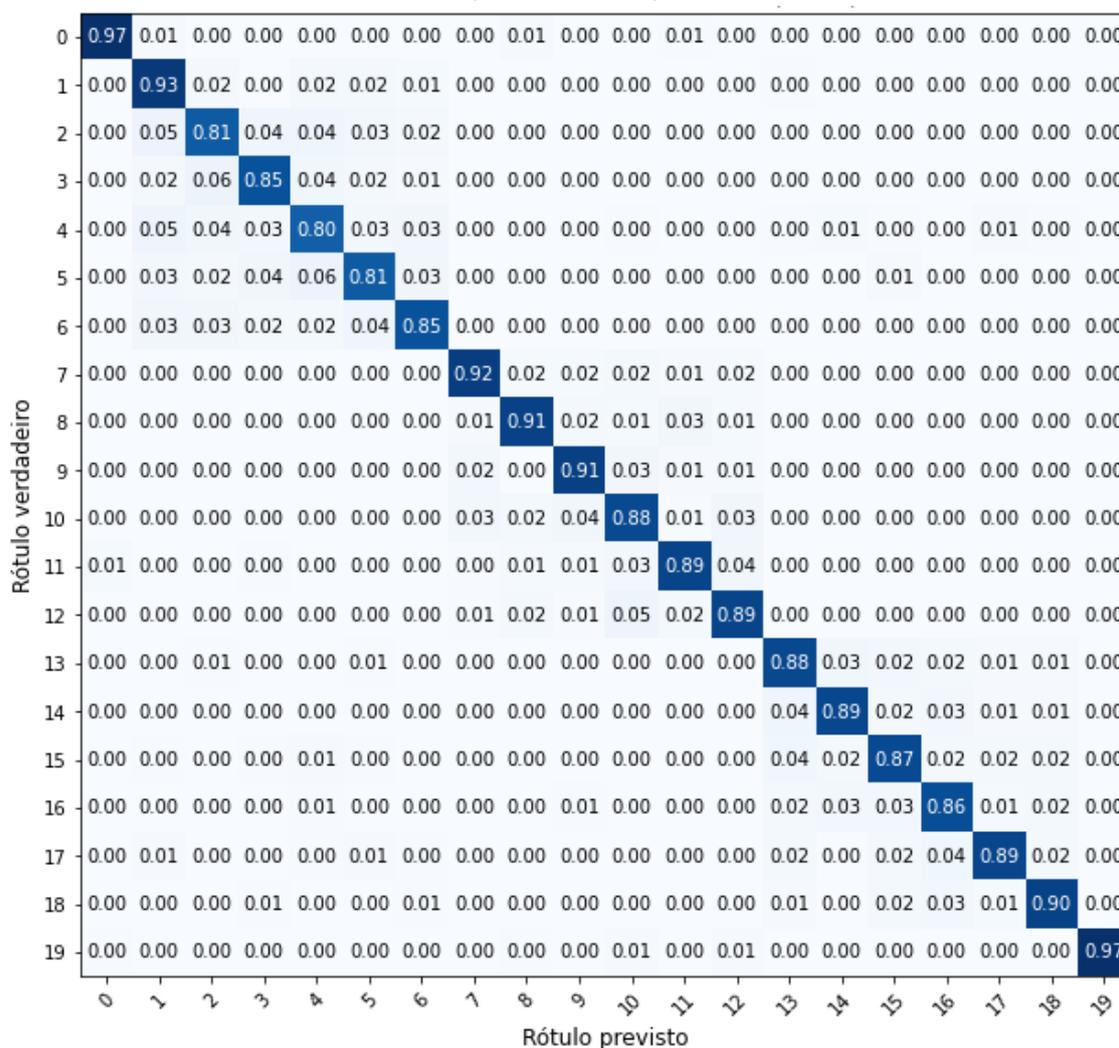
Figura 6.15: Evolução da acurácia e da perda durante o treinamento e a validação da rede 8.



Fonte: próprio autor

É possível perceber uma ligeira melhoria com relação à rede 7, alcançando 88,34%, um valor bem próximo ao objetivo estipulado. Essa melhora é atribuída ao aumento do número de camadas convolucionais da entrada da corrente filtrada de 2 para 4, possibilitando uma melhor extração de características.

Figura 6.16: Matriz de confusão entre condições de funcionamento para a rede 8 (normalizada).



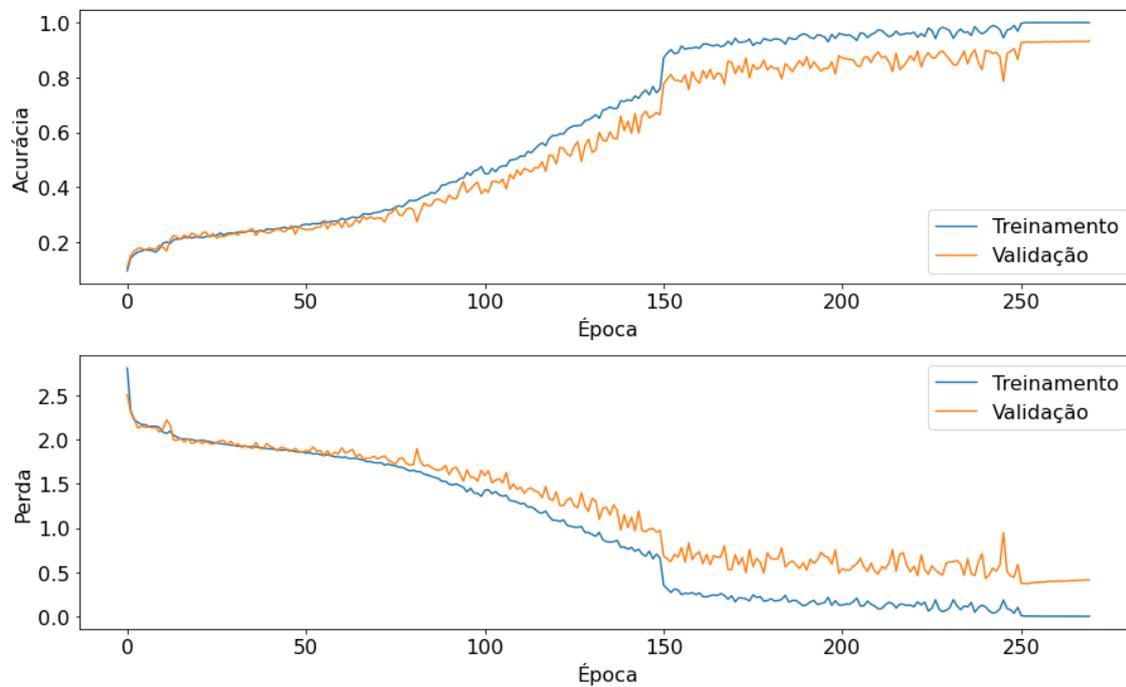
Fonte: Próprio autor

A rede 9 recebeu acréscimo no número de camadas convolucionais das três entradas. As entradas de tensão e de corrente receberam mais três camadas cada uma, passando de 2 para 5, e a entrada da corrente filtrada recebeu mais uma camada passando de 4 para 5. Como resultado, a acurácia obtida na identificação das condições de funcionamento chegou à 94,48%, um valor acima do objetivo estipulado para o problema em questão.

Cabe ressaltar que não houve melhora quando se excedeu o número de camadas convolucionais além daquelas empregadas na rede 9, o que sugere que a melhora da acurácia através do aumento do número de camadas tenha chegado a um limite.

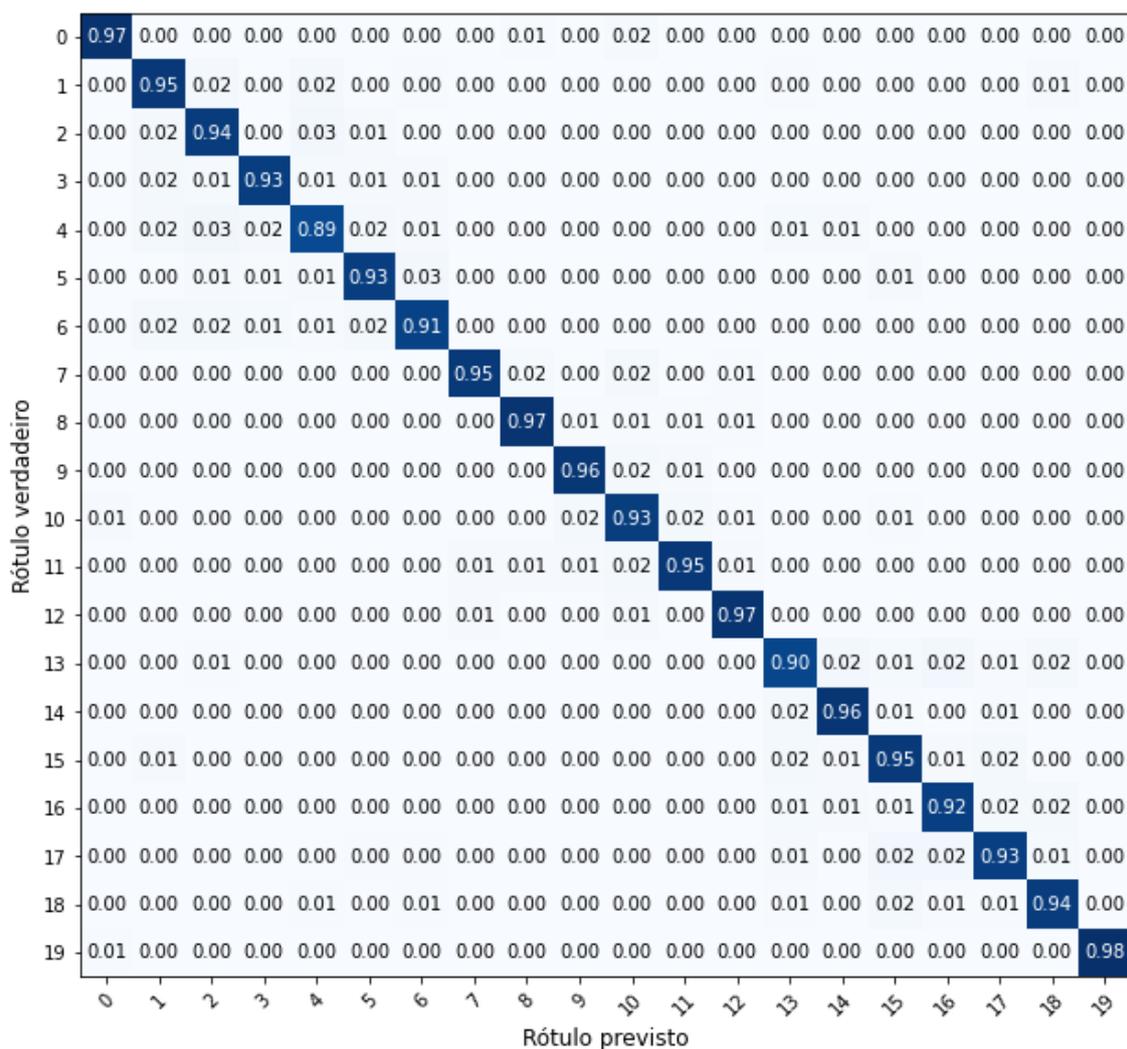
Na Figura 6.17 podem ser vistas a evolução das acurácias e das perdas de treinamento e validação, e na Figura 6.18 a matriz de confusão no teste.

Figura 6.17: Evolução da acurácia e da perda durante o treinamento e a validação da rede 9



Fonte: Próprio autor

Figura 6.18: Matriz de confusão entre condições de funcionamento para a rede 9 (normalizada)



Fonte: Próprio autor

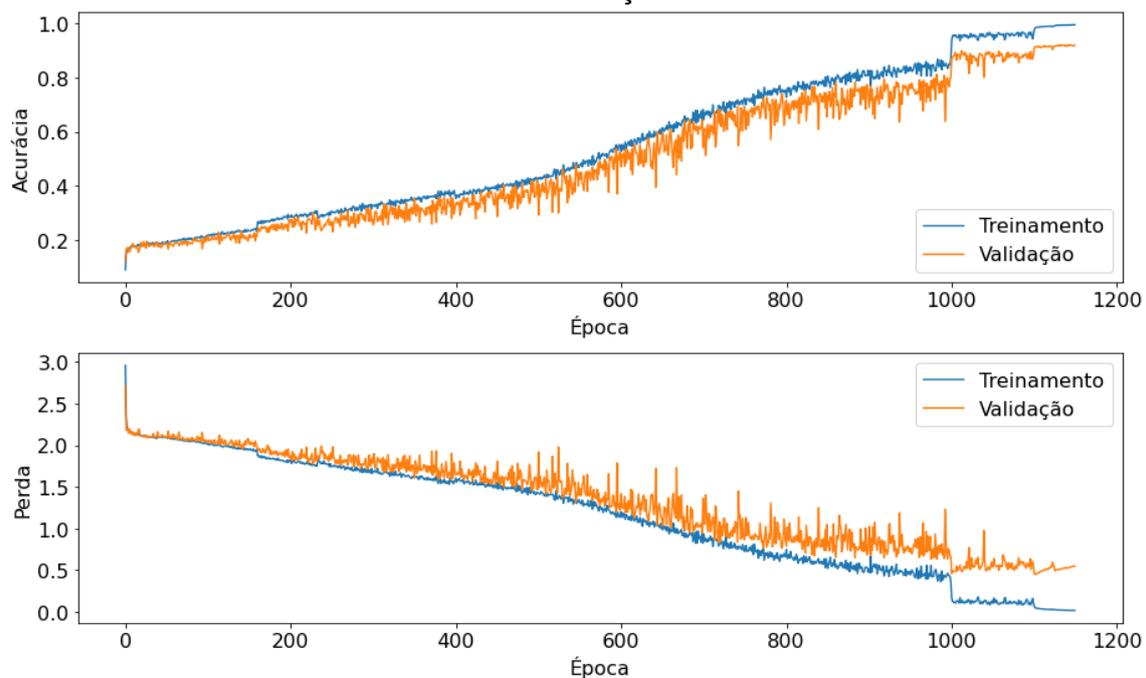
Por fim, o ramo de corrente filtrada foi retirado da rede 9, a fim de testar sua influência, gerando a rede 10. O resultado foi uma ligeira redução na acurácia, 92,24%, durante a identificação das 20 condições de funcionamento. Tal redução está associada a uma diminuição para 87,83% de acurácia na condição de arco elétrico.

Outro efeito negativo observado ao retirar o ramo da corrente filtrada é o grande aumento do tempo de treinamento (vide Tabela 6.3), passando de cerca de 3 h e 36 min para cerca de 8h. O ponto positivo, também mostrado na Tabela 6.3, é a grande redução do número de parâmetros da rede 10 comparada com a rede 9, isto é, caiu para praticamente a metade, o que significa que a rede demandará

menos recursos computacionais (no momento da execução), apesar de ter o processo de treinamento mais demorado.

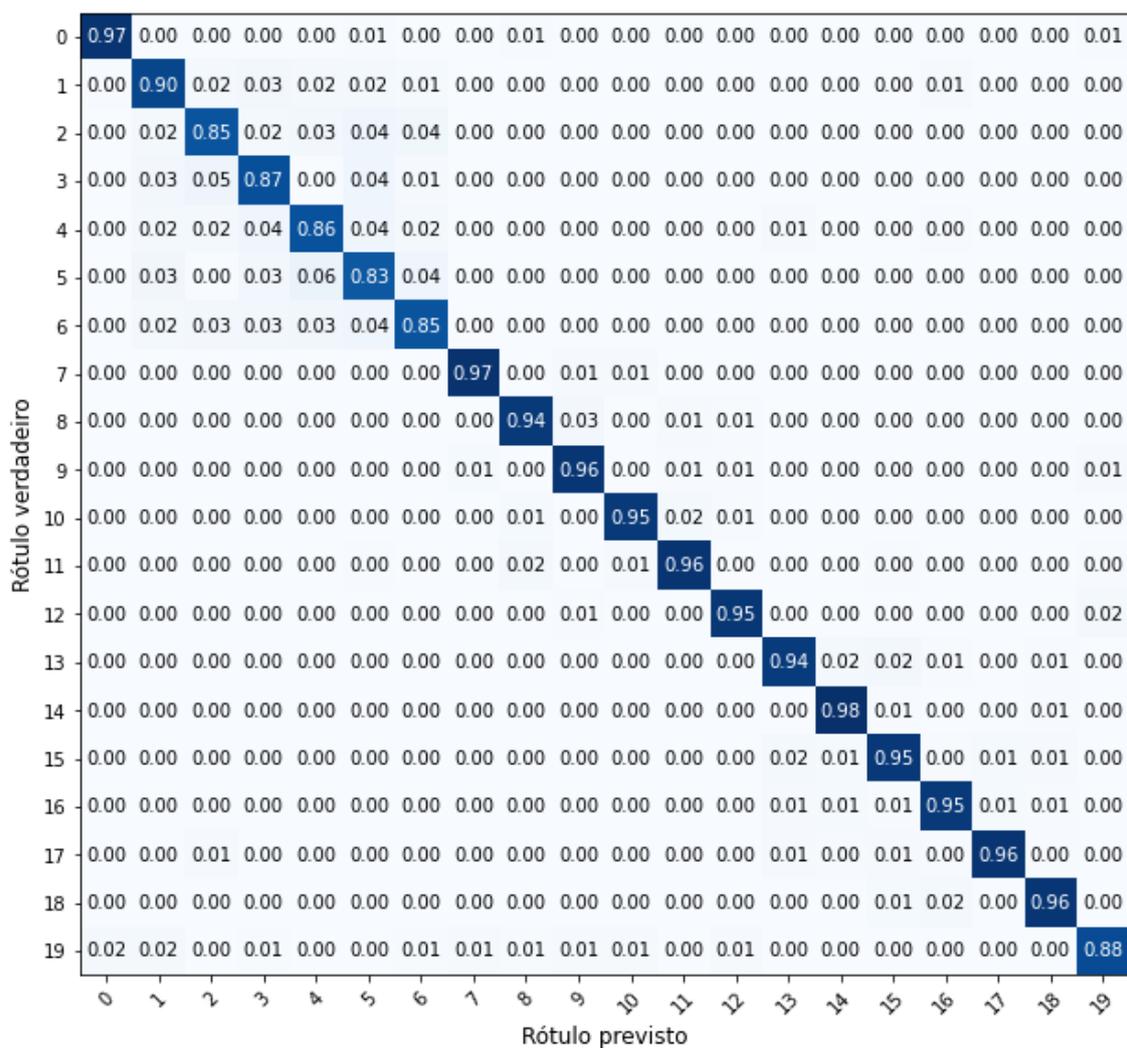
A evolução da acurácia e a matriz de confusão da rede 10 são mostradas na Figura 6.19 e na Figura 6.20, respectivamente.

Figura 6.19: Evolução da acurácia e da perda da rede 10 durante o treinamento e a validação



Fonte: Próprio autor

Figura 6.20: Matriz de confusão entre condições de funcionamento para a rede 10 (normalizada)



Fonte: Próprio autor

7 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Observando os resultados relativos à acurácia de identificação das condições atípicas envolvendo uma *string* fotovoltaica, podemos afirmar que é possível detectar cada uma das 20 condições monitoradas, usando, para isso, apenas amostras da tensão e da corrente, ou seja, sem a necessidade de utilização de dados climáticos e de modelos complexos considerados em metodologias tradicionais.

A indicação de qual é o painel anormal é um ponto positivo do sistema, principalmente se tratando de monitoramento não intrusivo, reduzindo o tempo de manutenção e aumentando a disponibilidade da geração de energia.

Cabe ressaltar que o sistema baseado em redes neurais convolucionais (CNN) foi treinado, validado e testado usando amostras de tensão e de corrente adquiridas durante janelas de tempo de 1 décimo de segundo em 232 ocasiões distintas entre os dias 30/12/2019 e 28/01/2020. Para uma aplicação comercial, faz-se necessário o uso de um banco de dados de um período mais amplo (pelo menos um ano) para treinamento de tais redes.

Embora a rede neural convolucional seja conhecida por extrair automaticamente características necessárias à correta classificação, neste estudo a extração automática de características peculiares dos sinais alternados parece ter sido dificultada pela presença de valor médio diferente de zero (corrente contínua), em maior intensidade tanto em valor absoluto, quanto em sua variação com as condições de funcionamento. Isto foi evidenciado pela dificuldade de identificação do arco elétrico pela rede neural, mesmo quando era possível sua identificação por observação visual do sinal coletado.

O pré-processamento mostrou ter um papel fundamental no desempenho das redes neurais, pois a identificação correta da condição de arco elétrico só foi possível após adotar a normalização da corrente filtrada de cada exemplo individualmente, ao invés de realizá-la entre todos os exemplos.

Sugere-se como continuidade a este trabalho, a substituição do conjunto sensorial (sensores de tensão e de corrente) por modelos com uma maior largura

de banda, tendo em vista que efeitos como o arco elétrico são mais bem caracterizados nas frequências mais altas.

Outras sugestões de trabalhos futuros são a aquisição de dados da *string* fotovoltaica em outros períodos do ano, em especial no inverno, para dar maior robustez ao sistema na identificação das condições atípicas de funcionamento, e implementar esse sistema de forma *online*, observando seu desempenho quanto à acurácia e velocidade.

Uma abordagem ativa é também sugerida como continuação a este trabalho. Consiste em injetar pulsos de alta frequência na linha de transmissão da *string*, saindo do atual módulo sensor em direção à *string*. Neste caso, a *string* deve funcionar como um espelho em certas frequências, de modo que parte do pulso de alta frequência deve refletir de volta através da linha de transmissão, podendo tal reflexo ser capturado pelo módulo sensor. Assim, as amostras do sinal refletido podem ser usadas para treinar, validar e testar *CNNs*.

A vantagem da abordagem ativa proposta em relação à abordagem usada neste trabalho é que as manobras experimentais podem ser realizadas a qualquer momento, inclusive à noite, quando a *string* não está gerando energia elétrica, podendo ainda detectar curto-circuito e circuito aberto.

A otimização de *CNNs*, ou mesmo a utilização de outras técnicas, como a decomposição da tensão e corrente utilizando a *DWT (Discrete Wavelet Transform)*, a fim de maximizar a acurácia e/ou minimizar o tempo de treinamento, o número de parâmetros da rede e os recursos computacionais requeridos, é também uma possibilidade de continuação a este trabalho, tendo em vista que todo o processo de obtenção das arquiteturas de rede tem sido realizado de forma manual e completamente empírico.

As *CNNs* podem ainda ser estendidas, a fim de serem capazes de identificar outras situações atípicas de *string* proporcionadas por outros tipos de defeitos.

A grande dificuldade, para isso, é a de reproduzir os defeitos, até porque muitos desses são de natureza irreversível. Entretanto, uma investigação dedicada ao tema faz-se necessária, a fim de proporcionar um sistema de identificação mais completo.

Devido ao processo de simulação de defeitos combinado com a aquisição dos dados de tensão e corrente para o treinamento da rede neural ser bastante exaustivo para um operador humano, e também demorado, uma outra possibilidade de trabalho futuro pode ser o desenvolvimento de um processo automatizado para simulação dos defeitos e aquisição dos dados necessários ao treinamento da rede, utilizando simulação eletrônica e inteligência artificial, em especial utilizando a técnica *DA-DCGAN*, como em (LU et al., 2019) para geração de dados de funcionamento defeituoso, a partir de dados de funcionamento normal.

Outras questões também podem ser desenvolvidas em trabalhos futuros, como, por exemplo, determinar o tempo mínimo de janela de aquisição e a quantidade mínima de casos necessária, a fim de atender os requisitos como acurácia, tempo de treinamento e número de parâmetros treinados.

8 REFERÊNCIAS

ABDULMAWJOOD, K.; REFAAT, S. S.; MORSI, W. G. Detection and prediction of faults in photovoltaic arrays: A review. abr. 2018, [S.l.]: IEEE, abr. 2018. p. 1–8. Disponível em: <<https://ieeexplore.ieee.org/document/8372609/>>.

ALAM, M. K. et al. A Comprehensive Review of Catastrophic Faults in PV Arrays: Types, Detection, and Mitigation Techniques. **IEEE Journal of Photovoltaics**, v. 5, n. 3, p. 982–997, maio 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7045450/>>.

_____. PV arc-fault detection using spread spectrum time domain reflectometry (SSTDR). set. 2014, [S.l.]: IEEE, set. 2014. p. 3294–3300. Disponível em: <<http://ieeexplore.ieee.org/document/6953848/>>.

ALOYSIUS, N.; GEETHA, M. A review on deep convolutional neural networks. abr. 2017, [S.l.]: IEEE, abr. 2017. p. 0588–0592. Disponível em: <<http://ieeexplore.ieee.org/document/8286426/>>.

BAL, S. et al. Comprehensive Analysis and Experimental Validation of an Improved Mathematical Modeling of Photovoltaic Array. **Advances in Power Electronics**, v. 2015, n. iv, p. 1–11, 2015. Disponível em: <<https://www.hindawi.com/archive/2015/654092/>>.

CHINE, W. et al. A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks. **Renewable Energy**, v. 90, p. 501–512, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.renene.2016.01.036>>.

_____. Fault detection method for grid-connected photovoltaic plants. **Renewable Energy**, v. 66, p. 99–110, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.renene.2013.11.073>>.

CHOUDEY, A.; SILVESTRE, S. Automatic supervision and fault detection of PV systems based on power losses analysis. **Energy Conversion and Management**, v. 51, n. 10, p. 1929–1937, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.enconman.2010.02.025>>.

COLTHEART, M. et al. Models of reading aloud: Dual-route and parallel-distributed-processing approaches. **Psychological Review**, v. 100, n. 4, p. 589–608, 1993. Disponível em: <<http://doi.apa.org/getdoi.cfm?doi=10.1037/0033-295X.100.4.589>>.

DALIENTO, S. et al. Monitoring, Diagnosis, and Power Forecasting for Photovoltaic Fields: A Review. **International Journal of Photoenergy**, v. 2017, p. 1–13, 2017. Disponível em: <<https://www.hindawi.com/journals/ijp/2017/1356851/>>.

DAVARIFAR, M.; RABHI, A.; HAJJAJI, A. El. Comprehensive Modulation and Classification of Faults and Analysis Their Effect in DC Side of Photovoltaic System. **Energy and Power Engineering**, v. 05, n. 04, p. 230–236, 2013. Disponível em: <<http://www.scirp.org/journal/PaperDownload.aspx?DOI=10.4236/epe.2013.54B045>>.

DHERE, N. G.; SHIRADKAR, N. S. Fire hazard and other safety concerns of photovoltaic systems. **Journal of Photonics for Energy**, v. 2, n. 1, p. 022006, 14 dez. 2012. Disponível em: <<http://photonicsforenergy.spiedigitallibrary.org/article.aspx?doi=10.1117/1.JPE.2.022006>>.

EBAY. **100Pcs/Lot 5V 60mA 68X37mm Micro Mini Small Power Solar Cells Panel For DIY Toy**. Disponível em: <<https://www.ebay.com/itm/100Pcs-Lot-5V-60mA-68X37mm-Micro-Mini-Small-Power-Solar-Cells-Panel-For-DIY-Toy-/162599085685>>. Acesso em: 1 mar. 2020.

EBERMAM, E.; KROHLING, R. A. **Uma Introdução Compreensiva às Redes Neurais Convolucionais: Um Estudo de Caso para Reconhecimento de Caracteres Alfabéticos**. Disponível em: <http://www.fsma.edu.br/si/edicao21/FSMA_SI_2018_1_Principal_08_en.pdf>. Acesso em: 27 jun. 2019.

EBNER, R.; KUBICEK, B.; UJVARI, G. Non-destructive techniques for quality control of PV modules: Infrared thermography, electro- and photoluminescence imaging. nov. 2013, [S.l.]: IEEE, nov. 2013. p. 8104–8109. Disponível em: <<http://ieeexplore.ieee.org/document/6700488/>>.

FIRMES, V. P. **Identificação não-intrusiva de cargas similares em Smart Grid usando rede neural convolucional**. 2020. Universidade Federal do Espírito Santo, 2020. Disponível em: <<http://www.energia.ufes.br/pt-br/pos-graduacao/PGEN/detalhes-da-tese?id=14024>>.

FIRMES, V. P.; CELESTE, W.; SILVESTRE, L. J. Identificação não-intrusiva de cargas similares em Smart Grid usando rede neural convolucional. 2019, Ouro Preto - MG - Brasil: Galoa, 2019. p. 792–797. Disponível em: <https://proceedings.science/proceedings/100113/_papers/111235>.

GAROUDJA, E. et al. Statistical fault detection in photovoltaic systems. **Solar Energy**, v. 150, p. 485–499, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.solener.2017.04.043>>.

GENCAY, R.; MIN QI. Pricing and hedging derivative securities with neural networks: Bayesian regularization, early stopping, and bagging. **IEEE Transactions on Neural Networks**, v. 12, n. 4, p. 726–734, jul. 2001. Disponível em: <<http://ieeexplore.ieee.org/document/935086/>>.

GOOGLE MAPS. **Google Maps (UFES/IFES)**. Disponível em: <<https://www.google.com.br/maps/@-18.6766787,-39.8655076,743m/data=!3m1!1e3>>. Acesso em: 23 mar. 2020.

GREEN, M. A. et al. Solar cell efficiency tables (version 50). **Progress in Photovoltaics: Research and Applications**, v. 25, n. 7, p. 668–676, jul. 2017. Disponível em: <<http://doi.wiley.com/10.1002/pip.2909>>.

_____. The path to 25% silicon solar cell efficiency: History of silicon cell evolution. **Progress in Photovoltaics: Research and Applications**, v. 17, n. 3, p. 183–189, maio 2009. Disponível em: <<http://doi.wiley.com/10.1002/pip.892>>.

GU, J. et al. Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, 2018. Disponível em: <<https://doi.org/10.1016/j.patcog.2017.10.013>>.

GUO, Y. et al. Deep learning for visual understanding: A review. **Neurocomputing**, v. 187, p. 27–48, abr. 2016. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0925231215017634>>.

HAYKIN, S. **Redes Neurais. Princípios e Práticas**. 2ª ed. Porto Alegre: Bookman, 2001.

HUBEL, D. H.; WIESEL, T. N. Receptive fields of single neurones in the cat's striate cortex. **The Journal of Physiology**, v. 148, n. 3, p. 574–591, 1 out. 1959. Disponível em: <<http://doi.wiley.com/10.1113/jphysiol.1959.sp006308>>.

JÄGER-WALDAU, A. Snapshot of Photovoltaics—March 2017. **Sustainability**, v. 9, n. 5, p. 783, 9 maio 2017. Disponível em: <<http://www.mdpi.com/2071-1050/9/5/783>>.

JAMSHIDPOUR, E.; POURE, P.; SAADATE, S. Photovoltaic Systems Reliability Improvement by Real-Time FPGA-Based Switch Failure Diagnosis and Fault-Tolerant DC–DC Converter. **IEEE Transactions on Industrial Electronics**, v. 62, n. 11, p. 7247–7255, nov. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7083735/>>.

JIN, J.; LI, M.; JIN, L. Data Normalization to Accelerate Training for Linear Neural Net to Predict Tropical Cyclone Tracks. **Mathematical Problems in Engineering**, v. 2015, p. 1–8, 2015. Disponível em: <<http://www.hindawi.com/journals/mpe/2015/931629/>>.

KABIR, E. et al. Solar energy: Potential and future prospects. **Renewable and Sustainable Energy Reviews**, v. 82, n. September 2017, p. 894–900, fev. 2018. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1364032117313485>>.

KAKRAN, S.; CHANANA, S. Smart operations of smart grids integrated with distributed generation: A review. **Renewable and Sustainable Energy Reviews**, v. 81, p. 524–535, jan. 2018. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1364032117311188>>.

KANNAN, N.; VAKEESAN, D. Solar energy for future world: - A review. **Renewable and Sustainable Energy Reviews**, v. 62, p. 1092–1105, set. 2016. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1364032116301320>>.

KAPLANIS, S.; KAPLANI, E. Energy performance and degradation over 20 years performance of BP c-Si PV modules. **Simulation Modelling Practice and Theory**, v. 19, n. 4, p. 1201–1211, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.simpat.2010.07.009>>.

KEARNS, M. A Bound on the Error of Cross Validation Using the Approximation and Estimation Rates, with Consequences for the Training-Test Split. **Neural Computation**, v. 9, n. 5, p. 1143–1161, jul. 1997. Disponível em:

<<http://www.mitpressjournals.org/doi/10.1162/neco.1997.9.5.1143>>.

KIM, K. A. et al. Photovoltaic Hot-Spot Detection for Solar Panel Substrings Using AC Parameter Characterization. **IEEE Transactions on Power Electronics**, v. 31, n. 2, p. 1121–1130, fev. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7072567/>>.

KIM, W.; PITT, M. A.; MYUNG, J. I. How do PDP models learn quasiregularity? **Psychological Review**, v. 120, n. 4, p. 903–916, 2013. Disponível em: <<http://doi.apa.org/getdoi.cfm?doi=10.1037/a0034195>>.

KROSE, B.; SMAGT, P. Van Der. **An Introduction to Neural Networks**. 8^a ed. Amsterdam: University of Amsterdam, 1996. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=4AB1774ACFA7F97237731F895642DAE3?doi=10.1.1.18.493&rep=rep1&type=pdf>>.

KUMAR, M.; RAGHUWANSHI, N. S.; SINGH, R. Artificial neural networks approach in evapotranspiration modeling: a review. **Irrigation Science**, v. 29, n. 1, p. 11–25, 5 jan. 2011. Disponível em: <<http://link.springer.com/10.1007/s00271-010-0230-8>>.

LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. Disponível em: <<http://ieeexplore.ieee.org/document/726791/>>.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 27 maio 2015. Disponível em: <<http://www.nature.com/articles/nature14539>>.

LI, Y.; YUAN, Y. Convergence Analysis of Two-layer Neural Networks with ReLU Activation. 2017, Long Beach, CA, USA: [s.n.], 2017. p. 1–11. Disponível em: <<http://arxiv.org/abs/1705.09886>>.

LIN, P. et al. A Density Peak-Based Clustering Approach for Fault Diagnosis of Photovoltaic Arrays. **International Journal of Photoenergy**, v. 2017, p. 1–14, 2017. Disponível em: <<https://www.hindawi.com/journals/ijp/2017/4903613/>>.

LIVERA, A. et al. Recent advances in failure diagnosis techniques based on performance data analysis for grid-connected photovoltaic systems. **Renewable Energy**, v. 133, p. 126–143, abr. 2019. Disponível em: <<https://doi.org/10.1016/j.renene.2018.09.101>>.

LU, S. et al. DA-DCGAN: An Effective Methodology for DC Series Arc Fault Diagnosis in Photovoltaic Systems. **IEEE Access**, v. 7, p. 45831–45840, 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8681389/>>.

MADETI, S. R.; SINGH, S. N. A comprehensive study on different types of faults and detection techniques for solar photovoltaic system. **Solar Energy**, v. 158, n. October, p. 161–185, dez. 2017. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0038092X17307508>>.

MAOYI CHANG et al. The reliability investigation of PV junction box based on 1GW worldwide field database. jun. 2015, [S.l.]: IEEE, jun. 2015. p. 1–4.

Disponível em: <<http://ieeexplore.ieee.org/document/7356130/>>.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, dez. 1943. Disponível em: <<http://link.springer.com/10.1007/BF02478259>>.

MELLIT, A.; TINA, G. M.; KALOGIROU, S. A. Fault detection and diagnosis methods for photovoltaic systems: A review. **Renewable and Sustainable Energy Reviews**, v. 91, n. April, p. 1–17, 2018. Disponível em: <<https://doi.org/10.1016/j.rser.2018.03.062>>.

MIWA, M. et al. Diagnosis of a Power Output Lowering of PV Array with a (-dI/dV)-V Characteristic. 2006, [S.I.]: IEEE, 2006. p. 2442–2445. Disponível em: <<http://ieeexplore.ieee.org/document/4060172/>>.

NICERF. **SRX882|433.92MHz 315MHz ASK Superheterodyne Receiver module**. Disponível em: <https://www.nicerf.com/product_132_82.html>. Acesso em: 24 fev. 2020a.

_____. **STX882|433.92MHz module|315MHz TX module|ASK Transmitter Module|long range distance ASK module**. Disponível em: <https://www.nicerf.com/product_132_43.html>. Acesso em: 24 fev. 2020b.

OKE, S. et al. I-V Characteristics of Broken Bypass Diode on PV Module. 2018, Brussels: [s.n.], 2018. p. 1996–2000. Disponível em: <<https://www.eupvsec-proceedings.com/proceedings?paper=45675>>.

PERDUE, M.; GOTTSCHALG, R. Energy yields of small grid connected photovoltaic system: effects of component reliability and maintenance. **IET Renewable Power Generation**, v. 9, n. 5, p. 432–437, 1 jul. 2015. Disponível em: <<https://digital-library.theiet.org/content/journals/10.1049/iet-rpg.2014.0389>>.

PHB SOLAR. **Inversor Solar Fotovoltaico PHB1500-SS PHB3000-SS PHB4600-SS**. Disponível em: <http://www.phb.com.br/PDFs/Produtos/Solar/Inversores/Inversores_PHB.pdf>. Acesso em: 26 jun. 2018.

PINGEL, S. et al. Potential Induced Degradation of solar cells and panels. jun. 2010, [S.I.]: IEEE, jun. 2010. p. 002817–002822. Disponível em: <<http://ieeexplore.ieee.org/document/5616823/>>.

PLAUT, D. C.; MCCLELLAND, J. L. Postscript: Parallel distributed processing in localist models without thresholds. **Psychological Review**, v. 117, n. 1, p. 289–290, 2010. Disponível em: <<http://doi.apa.org/getdoi.cfm?doi=10.1037/0033-295X.117.1.289>>.

PRECHELT, L. Automatic early stopping using cross validation: quantifying the criteria. **Neural Networks**, v. 11, n. 4, p. 761–767, jun. 1998. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0893608098000100>>.

RAWAT, W.; WANG, Z. Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. **Neural Computation**, v. 29, n. 9, p.

2352–2449, set. 2017. Disponível em: <http://www.mitpressjournals.org/doi/abs/10.1162/neco_a_00990>.

RAZA, M. Q.; KHOSRAVI, A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. **Renewable and Sustainable Energy Reviews**, v. 50, p. 1352–1372, out. 2015. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1364032115003354>>.

RIBEIRO, A. M.; JUNIOR, F. de P. S. A. Um Estudo Comparativo Entre Cinco Métodos de Otimização Aplicados Em Uma RNC Voltada ao Diagnóstico do Glaucoma. **Revista de Sistemas e Computação - RSC**, v. 10, n. 1, p. 122–130, 2020. Disponível em: <<https://revistas.unifacs.br/index.php/rsc/article/view/6488>>.

RIORDAN, C.; HULSTRON, R. What is an air mass 1.5 spectrum? (solar cell performance calculations). 1990, Kissimmee, FL, USA: IEEE, 1990. p. 1085–1088. Disponível em: <<http://ieeexplore.ieee.org/document/111784/>>.

ROSENBLATT, F. **Principles of Neurodynamics**. Washington DC: Spartan Books, 1962.

_____. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958. Disponível em: <<http://doi.apa.org/getdoi.cfm?doi=10.1037/h0042519>>.

SABBAGHPUR ARANI, M.; HEJAZI, M. A. The Comprehensive Study of Electrical Faults in PV Arrays. **Journal of Electrical and Computer Engineering**, v. 2016, p. 1–10, 2016. Disponível em: <<https://www.hindawi.com/journals/jece/2016/8712960/>>.

SAMPAIO, C. **Redes neurais e Deep Learning utilizando Java**. Disponível em: <<https://github.com/cleuton/neuraljava>>. Acesso em: 10 jul. 2020.

SILVESTRE, S. et al. New procedure for fault detection in grid connected PV systems based on the evaluation of current and voltage indicators. **Energy Conversion and Management**, v. 86, p. 241–249, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.enconman.2014.05.008>>.

SINGH, G. K. Solar power generation by PV (photovoltaic) technology: A review. **Energy**, v. 53, p. 1–13, maio 2013. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0360544213001758>>.

SOLA, J.; SEVILLA, J. Importance of input data normalization for the application of neural networks to complex industrial problems. **IEEE Transactions on Nuclear Science**, v. 44, n. 3, p. 1464–1468, jun. 1997. Disponível em: <<http://ieeexplore.ieee.org/document/589532/>>.

TAEBI, A.; MANSY, H. Time-Frequency Distribution of Seismocardiographic Signals: A Comparative Study. **Bioengineering**, v. 4, n. 4, p. 32, 7 abr. 2017. Disponível em: <<http://www.mdpi.com/2306-5354/4/2/32>>.

TAKASHIMA, T. et al. Experimental studies of fault location in PV module strings. **Solar Energy Materials and Solar Cells**, v. 93, n. 6–7, p. 1079–1082, jun. 2009.

Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0927024808004583>>.

TAKASHIMA, T.; YAMAGUCHI, J.; ISHIDA, M. Disconnection detection using earth capacitance measurement in photovoltaic module string. **Progress in Photovoltaics: Research and Applications**, v. 16, n. 8, p. 669–677, dez. 2008a. Disponível em: <<http://doi.wiley.com/10.1002/pip.860>>.

_____. Fault detection by signal response in PV module strings. maio 2008b, [S.l.]: IEEE, maio 2008. p. 1–5. Disponível em: <<http://ieeexplore.ieee.org/document/4922843/>>.

TANNOUS, S. et al. Comparative cradle-to-grave life cycle assessment of traditional grid- connected and solar stand-alone street light systems : A case study for rural areas in Lebanon. **Journal of Cleaner Production**, v. 186, p. 963–977, 2018. Disponível em: <<https://doi.org/10.1016/j.jclepro.2018.03.155>>.

TOLEDO, O. M.; OLIVEIRA FILHO, D.; DINIZ, A. S. A. C. Distributed photovoltaic generation and energy storage systems: A review. **Renewable and Sustainable Energy Reviews**, v. 14, n. 1, p. 506–511, jan. 2010. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S136403210900207X>>.

TRIKI-LAHIANI, A.; BENNANI-BEN ABDELGHANI, A.; SLAMA-BELKHODJA, I. Fault detection and monitoring systems for photovoltaic installations: A review. **Renewable and Sustainable Energy Reviews**, v. 82, n. March 2017, p. 2680–2692, fev. 2018. Disponível em: <<https://doi.org/10.1016/j.rser.2017.09.101>>.

VILLALVA, M. G.; GAZOLI, J. R.; FILHO, E. R. Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays. **IEEE Transactions on Power Electronics**, v. 24, n. 5, p. 1198–1208, maio 2009. Disponível em: <<http://ieeexplore.ieee.org/document/4806084/>>.

VILLARINI, M. et al. Optimization of photovoltaic maintenance plan by means of a FMEA approach based on real data. **Energy Conversion and Management**, v. 152, p. 1–12, nov. 2017. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0196890417307926>>.

WOODHOUSE, M. A. et al. **Crystalline Silicon Photovoltaic Module Manufacturing Costs and Sustainable Pricing: 1H 2018 Benchmark and Cost Reduction Road Map**. . Golden, CO (United States): [s.n.], 15 fev. 2019. Disponível em: <<http://www.osti.gov/servlets/purl/1495719/>>.

YADHAVAN, N. Happy sad demarcation from facial images using neural networks. **International Journal of Advanced Research in Computer Science**, v. 8, n. 3, p. 86–90, 2017. Disponível em: <<https://search.proquest.com/docview/1901457488?accountid=32131>>.

ZHAO, Y. et al. Line–Line Fault Analysis and Protection Challenges in Solar Photovoltaic Arrays. **Industrial Electronics, IEEE Transactions on**, v. 60, n. 9, p. 3784–3795, maio 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6221990/>>.

APÊNDICE 1: HORÁRIOS E CONDIÇÕES CLIMÁTICAS MÉDIAS DOS CICLOS DE COLETA

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta.

Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatur a média [°C]
1	30/12/2019	14:02:21	14:14:11	774,60	32,34
2	30/12/2019	14:17:11	14:34:07	700,05	32,12
3	Descartada				
4	Descartada				
5	Descartada				
6	31/12/2019	08:58:41	09:09:44	621,76	30,27
7	31/12/2019	09:55:29	10:05:19	840,67	30,85
8	31/12/2019	10:14:09	10:23:48	1080,96	31,81
9	31/12/2019	11:40:16	11:55:29	982,53	32,01
10	31/12/2019	12:12:11	12:20:50	1004,93	32,43
11	31/12/2019	14:52:46	15:04:51	587,41	31,39
12	31/12/2019	15:18:20	15:31:23	441,12	31,55
13	31/12/2019	15:47:53	15:59:00	362,94	30,96
14	31/12/2019	16:17:24	16:26:16	72,12	29,01
15	31/12/2019	16:45:19	17:10:55	70,62	27,96
16	01/01/2020	08:42:14	08:51:49	709,85	31,29
17	01/01/2020	10:21:23	10:29:35	651,97	31,97
18	01/01/2020	10:31:06	10:40:38	975,72	32,99
19	02/01/2020	08:02:02	08:13:09	567,11	31,68
20	02/01/2020	08:24:45	08:42:16	444,68	30,69
21	02/01/2020	08:44:39	08:56:00	602,92	31,87
22	02/01/2020	08:58:22	09:08:43	744,44	32,85
23	Descartada				
24	02/01/2020	09:55:32	10:08:07	739,80	33,19
25	02/01/2020	10:27:52	10:39:38	741,62	33,76
26	02/01/2020	10:43:31	10:56:24	999,04	34,62
27	02/01/2020	11:14:35	11:30:34	867,58	35,30

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta (continuação).

Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatura média [°C]
28	02/01/2020	11:50:34	12:07:55	420,61	34,43
29	02/01/2020	14:31:34	14:43:50	328,47	31,96
30	02/01/2020	14:47:23	14:57:58	227,02	30,53
31	02/01/2020	14:59:54	15:11:28	251,36	29,94
32	02/01/2020	15:39:05	15:50:32	250,08	29,50
33	02/01/2020	16:09:06	16:22:06	263,54	30,42
34	02/01/2020	16:27:32	16:39:17	142,95	29,51
35	02/01/2020	16:43:39	17:01:56	62,59	28,45
36	03/01/2020	06:42:24	06:56:04	191,88	26,38
37	03/01/2020	06:59:11	07:10:48	249,62	27,65
38	03/01/2020	07:36:42	07:49:11	348,65	28,30
39	03/01/2020	08:12:04	08:24:10	276,83	28,23
40	03/01/2020	08:29:05	08:40:03	428,59	29,29
41	03/01/2020	09:23:27	09:35:02	297,97	29,33
42	03/01/2020	09:46:51	09:57:59	457,05	30,74
43	03/01/2020	10:56:52	11:08:12	375,44	31,94
44	03/01/2020	11:38:17	11:49:11	570,74	33,11
45	03/01/2020	13:36:20	13:44:48	196,47	32,81
46	03/01/2020	13:51:11	14:01:08	842,97	33,88
47	03/01/2020	14:18:43	14:28:13	719,29	33,40
48	03/01/2020	14:40:46	14:58:37	429,43	32,25
49	03/01/2020	15:14:24	15:23:24	483,95	33,05
50	03/01/2020	15:36:36	15:46:16	351,50	33,21
51	03/01/2020	16:00:21	16:10:21	277,62	31,94
52	03/01/2020	16:13:27	16:23:21	228,23	31,36
53	04/01/2020	08:01:43	08:17:08	188,56	27,04
54	04/01/2020	08:40:51	08:52:21	201,99	27,48
55	04/01/2020	08:54:42	09:06:49	309,71	27,76
56	04/01/2020	09:32:56	09:42:10	476,68	29,92

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta (continuação).

Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatura média [°C]
57	04/01/2020	09:54:22	10:02:55	574,04	29,40
58	04/01/2020	10:16:27	10:25:08	469,83	30,47
59	04/01/2020	10:40:08	10:48:52	602,67	31,27
60	04/01/2020	11:46:30	11:55:40	556,49	32,09
61	04/01/2020	12:10:34	12:20:12	845,90	32,92
62	04/01/2020	12:28:03	12:39:03	959,47	34,08
63	04/01/2020	13:57:50	14:07:12	702,53	34,16
64	04/01/2020	14:13:23	14:25:58	544,58	32,83
65	04/01/2020	14:37:09	14:45:49	476,94	30,81
66	04/01/2020	14:54:33	15:01:56	209,43	29,00
67	04/01/2020	15:13:54	15:22:42	350,12	29,52
68	05/01/2020	06:41:24	06:52:45	204,25	28,30
69	05/01/2020	06:54:32	07:05:10	252,55	29,12
70	05/01/2020	07:12:57	07:22:20	322,79	29,56
71	05/01/2020	07:29:33	07:37:22	389,67	30,58
72	05/01/2020	07:51:37	08:00:57	408,12	31,27
73	05/01/2020	08:21:32	08:31:39	596,65	32,10
74	05/01/2020	08:32:37	08:42:42	643,45	32,47
75	05/01/2020	13:29:10	13:40:14	374,69	30,93
76	05/01/2020	13:52:40	14:09:02	586,33	31,95
77	05/01/2020	14:14:08	14:23:35	538,36	31,79
78	05/01/2020	14:25:06	14:33:18	570,41	31,61
79	05/01/2020	15:09:03	15:18:03	310,96	30,98
80	05/01/2020	15:24:44	15:33:45	400,76	30,92
81	05/01/2020	15:34:34	15:43:38	313,35	31,53
82	05/01/2020	15:45:23	15:55:38	257,02	30,63
83	06/01/2020	07:06:02	07:17:54	103,17	27,49
84	06/01/2020	07:29:27	07:38:49	275,74	29,02
85	06/01/2020	07:40:09	07:48:50	262,99	28,78

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta (continuação).

Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatur a média [°C]
86	06/01/2020	08:00:08	08:08:57	398,34	30,10
87	06/01/2020	08:14:49	08:23:04	421,40	31,86
88	06/01/2020	08:26:00	08:33:36	351,66	30,34
89	06/01/2020	09:02:35	09:10:29	657,45	32,77
90	06/01/2020	09:11:59	09:20:18	694,80	33,90
91	06/01/2020	09:38:25	09:47:43	727,02	34,47
92	06/01/2020	09:54:33	10:03:17	696,93	34,08
93	06/01/2020	10:04:10	10:12:36	711,14	34,02
94	06/01/2020	10:24:29	10:32:37	872,60	33,92
95	06/01/2020	10:40:15	10:50:15	688,53	34,90
96	06/01/2020	11:58:06	12:08:16	992,06	34,11
97	06/01/2020	12:10:34	12:19:34	625,40	33,96
98	06/01/2020	12:43:01	12:53:17	499,83	33,40
99	06/01/2020	13:00:37	13:10:07	848,61	33,90
100	06/01/2020	14:38:42	14:49:14	222,38	28,52
101	06/01/2020	14:53:08	15:10:19	268,55	29,17
102	06/01/2020	15:14:14	15:22:51	85,78	28,42
103	07/01/2020	06:22:50	06:42:02	76,79	26,06
104	07/01/2020	06:52:31	07:11:55	179,43	27,49
105	07/01/2020	07:15:28	07:24:57	321,29	29,16
106	07/01/2020	07:26:16	07:36:09	368,46	29,88
107	07/01/2020	07:37:32	07:46:42	414,42	30,97
108	07/01/2020	07:49:09	07:58:00	460,01	31,63
109	07/01/2020	08:19:08	08:28:17	581,27	32,23
110	07/01/2020	08:39:00	08:49:41	654,31	32,40
111	07/01/2020	08:55:26	09:04:39	703,08	32,42
112	07/01/2020	09:43:40	09:52:29	753,59	33,38
113	07/01/2020	10:11:50	10:20:23	835,37	33,86
114	07/01/2020	10:23:22	10:31:05	984,37	34,50

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta (continuação).

Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatura média [°C]
115	07/01/2020	11:25:33	11:35:32	678,92	32,77
116	07/01/2020	11:37:39	11:46:32	987,17	33,67
117	07/01/2020	13:28:59	13:38:15	859,44	33,61
118	07/01/2020	13:39:44	13:49:26	826,46	33,65
119	07/01/2020	14:07:20	14:17:04	753,34	33,35
120	07/01/2020	15:05:34	15:14:10	535,27	32,82
121	07/01/2020	15:26:38	15:36:08	457,75	32,09
122	07/01/2020	15:38:31	15:48:10	406,15	31,70
123	07/01/2020	15:58:21	16:06:28	326,63	31,57
124	07/01/2020	16:13:44	16:21:57	261,49	31,31
125	07/01/2020	16:23:36	16:31:42	220,67	31,61
126	07/01/2020	16:51:13	17:00:03	112,70	30,21
127	08/01/2020	08:59:56	09:08:44	245,11	29,01
128	08/01/2020	09:12:05	09:20:39	439,12	30,20
129	08/01/2020	09:21:32	09:29:20	458,51	31,06
130	08/01/2020	10:11:24	10:19:35	331,19	31,22
131	08/01/2020	10:24:35	10:33:15	409,45	31,16
132	08/01/2020	10:48:33	10:57:20	776,53	32,23
133	08/01/2020	10:59:42	11:08:52	918,60	33,35
134	08/01/2020	11:13:28	11:22:06	556,14	32,68
135	08/01/2020	11:31:54	11:40:23	414,63	31,56
136	08/01/2020	11:52:26	12:01:20	780,63	32,01
137	08/01/2020	12:02:17	12:10:27	522,90	32,57
138	08/01/2020	12:47:58	12:55:41	1098,15	33,19
139	08/01/2020	12:59:22	13:07:44	945,18	33,45
140	08/01/2020	14:22:39	14:30:52	719,83	33,27
141	08/01/2020	14:32:46	14:41:10	684,23	32,64
142	08/01/2020	14:43:07	14:51:38	646,92	33,35
143	08/01/2020	15:37:12	15:50:18	429,30	31,75

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta (continuação).

Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatura média [°C]
144	08/01/2020	15:52:28	16:02:25	366,37	32,54
145	08/01/2020	16:18:58	16:28:43	246,57	31,37
146	08/01/2020	16:31:24	16:40:47	192,92	31,41
147	09/01/2020	08:05:02	08:16:00	521,44	30,82
148	09/01/2020	08:27:23	08:41:06	689,91	32,19
149	09/01/2020	09:13:28	09:23:48	764,46	32,09
150	09/01/2020	09:49:08	09:58:47	606,97	31,48
151	09/01/2020	10:08:58	10:20:54	815,14	32,78
152	09/01/2020	10:35:37	10:44:20	710,05	32,08
153	09/01/2020	11:41:09	11:50:29	385,72	32,90
154	09/01/2020	11:51:11	12:02:10	914,17	33,34
155	09/01/2020	13:11:03	13:20:25	915,97	33,23
156	09/01/2020	13:31:17	13:40:17	867,75	33,62
157	09/01/2020	14:06:27	14:15:40	771,52	33,24
158	09/01/2020	14:26:38	14:41:36	691,75	32,67
159	09/01/2020	14:54:52	15:03:46	600,87	32,29
160	09/01/2020	15:40:32	15:49:24	421,74	32,57
161	09/01/2020	15:59:59	16:15:00	320,53	32,38
162	09/01/2020	16:35:44	16:44:47	174,37	31,13
163	10/01/2020	07:04:45	07:22:36	302,77	29,32
164	10/01/2020	09:45:33	09:55:56	848,49	33,23
165	10/01/2020	10:07:01	10:17:30	827,68	31,62
166	10/01/2020	12:14:01	12:24:30	944,97	33,59
167	10/01/2020	14:45:32	14:54:14	639,44	32,92
168	10/01/2020	15:11:20	15:20:33	538,19	32,94
169	10/01/2020	15:33:47	15:43:18	442,88	32,91
170	10/01/2020	15:47:49	15:57:14	380,29	32,97
171	10/01/2020	16:08:17	16:16:48	269,55	32,53
172	10/01/2020	16:19:10	16:27:59	244,23	32,81

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta (continuação).

Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatura média [°C]
173	11/01/2020	06:28:25	06:42:10	142,82	28,44
174	11/01/2020	06:48:14	06:57:37	209,76	28,65
175	11/01/2020	07:04:56	07:13:29	277,08	29,27
176	11/01/2020	07:22:11	07:31:19	351,20	30,26
177	11/01/2020	07:39:51	07:55:10	451,28	30,69
178	11/01/2020	07:57:32	08:07:24	508,19	30,68
179	11/01/2020	08:08:22	08:21:34	566,40	31,99
180	11/01/2020	08:39:48	08:49:17	455,41	30,16
181	11/01/2020	09:01:15	09:13:43	725,26	31,95
182	11/01/2020	09:34:47	09:43:32	828,97	33,17
183	11/01/2020	09:45:30	09:54:21	705,83	33,19
184	11/01/2020	10:00:27	10:09:14	823,67	33,09
185	11/01/2020	10:17:09	10:26:17	935,32	33,93
186	11/01/2020	10:39:36	10:49:00	1003,89	34,15
187	11/01/2020	10:51:45	11:00:42	1009,57	34,81
188	11/01/2020	11:03:38	11:12:27	1038,19	34,51
189	11/01/2020	12:26:19	12:35:59	772,94	33,62
190	11/01/2020	12:37:32	12:48:15	853,63	33,71
191	11/01/2020	12:59:06	13:08:21	912,54	33,99
192	11/01/2020	13:17:31	13:26:32	897,67	34,24
193	11/01/2020	13:38:47	13:48:51	843,43	34,22
194	11/01/2020	14:10:48	14:21:05	751,17	34,07
195	11/01/2020	14:28:17	14:37:25	697,18	33,90
196	11/01/2020	14:41:18	14:50:36	650,97	33,49
197	11/01/2020	15:03:10	15:13:33	565,56	33,17
198	11/01/2020	15:29:11	15:40:01	456,92	33,46
199	Descartada				
200	11/01/2020	16:18:57	16:28:06	248,41	33,68
201	12/01/2020	06:29:21	06:41:06	141,32	28,89

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta (continuação).

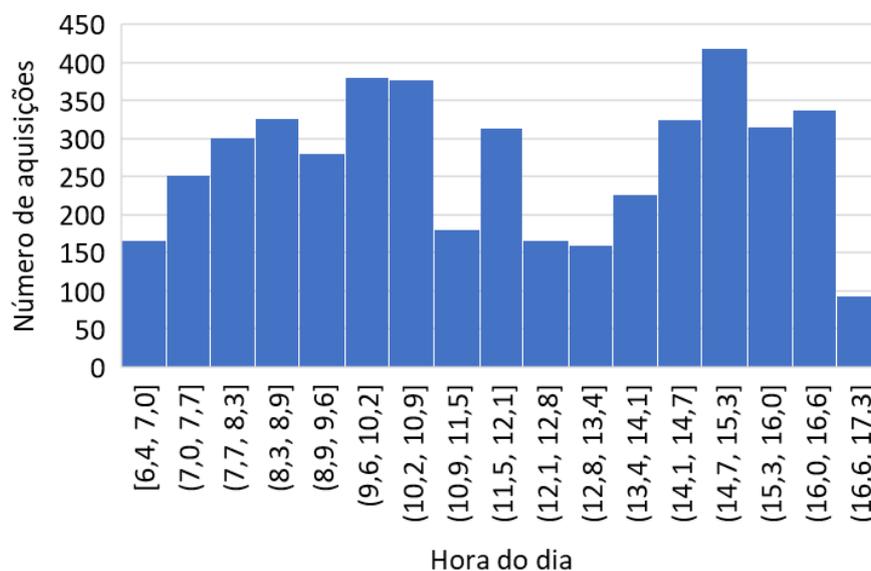
Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatura média [°C]
202	12/01/2020	06:48:02	06:58:20	207,04	29,68
203	12/01/2020	07:24:33	07:33:57	361,23	30,57
204	12/01/2020	07:35:13	07:45:52	410,25	30,93
205	12/01/2020	07:47:58	07:57:45	462,39	31,37
206	12/01/2020	08:00:04	08:09:54	503,30	31,72
207	12/01/2020	08:15:30	08:24:52	586,58	31,45
208	12/01/2020	08:32:09	08:41:07	637,14	32,23
209	20/01/2020	10:52:52	11:03:21	719,54	31,88
210	22/01/2020	09:39:57	09:50:35	240,10	27,51
211	22/01/2020	10:33:52	10:43:51	641,86	29,25
212	22/01/2020	12:04:24	12:22:10	262,58	28,47
213	22/01/2020	13:37:30	13:48:27	228,19	29,11
214	22/01/2020	16:03:45	16:16:19	176,17	28,71
215	23/01/2020	11:22:29	11:33:03	414,01	29,39
216	23/01/2020	13:13:51	13:23:47	273,23	486,65
217	23/01/2020	14:56:03	15:05:58	282,09	28,59
218	24/01/2020	08:58:51	09:10:38	160,45	26,34
219	24/01/2020	11:31:44	11:42:30	225,26	25,89
220	24/01/2020	14:22:04	14:36:20	355,97	26,84
221	25/01/2020	08:15:22	08:25:36	251,71	27,44
222	25/01/2020	09:31:13	09:42:11	343,43	28,61
223	25/01/2020	10:37:03	10:46:30	236,55	29,34
224	25/01/2020	11:47:26	11:56:33	382,29	30,48
225	25/01/2020	13:25:27	13:34:40	312,64	30,89
226	27/01/2020	09:40:27	09:59:10	712,14	30,73
227	27/01/2020	11:42:03	11:51:16	411,75	31,98
228	27/01/2020	12:52:32	13:07:04	407,53	30,50
229	28/01/2020	09:54:35	10:06:02	954,45	33,16
230	28/01/2020	11:48:15	11:57:23	425,79	32,54

Tabela A1.1: Condições climáticas médias em cada ciclo de coleta (continuação).

Nº	Dia Dia/mês/ano	Hora de Início hh:mm:ss	Hora de Fim hh:mm:ss	Irradiação média [W/m ²]	Temperatura média [°C]
231	28/01/2020	13:17:32	13:31:51	484,75	32,87
232	28/01/2020	15:00:08	15:07:40	99,11	29,65

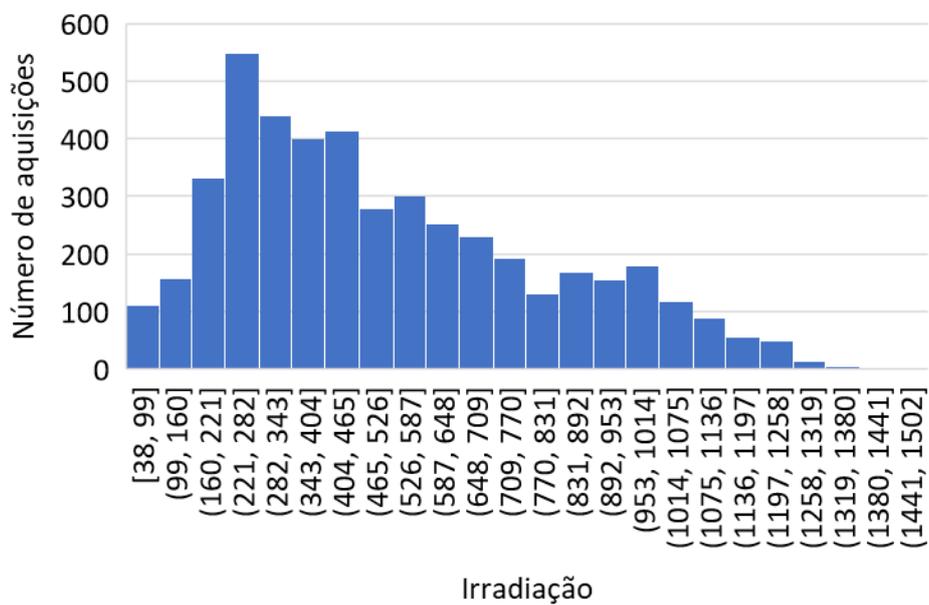
APÊNDICE 2: DADOS CLIMÁTICOS

Figura A2.1 Histograma do número de aquisições por hora do dia.



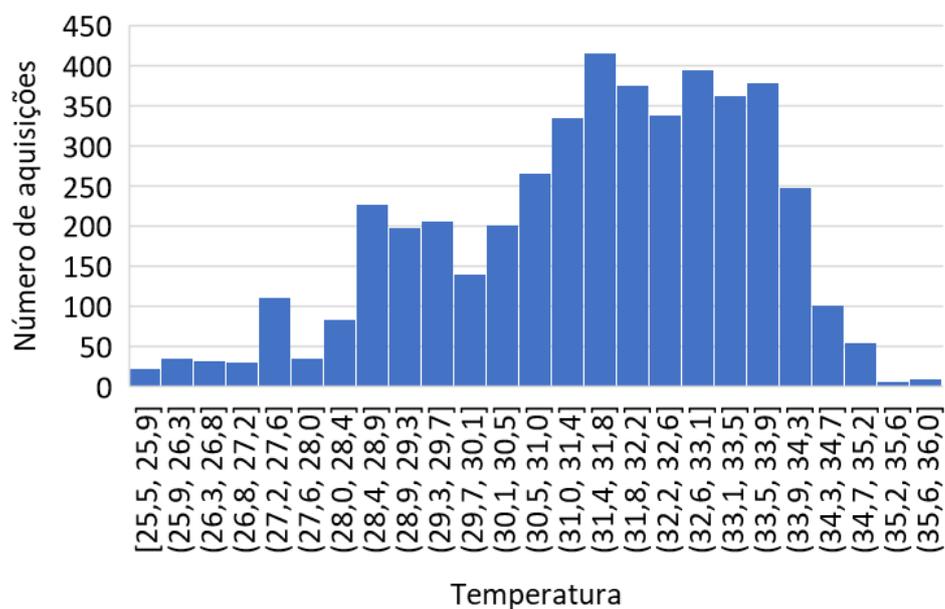
Fonte: Próprio autor

Figura A2.2: Histograma do número de aquisições por irradiação.



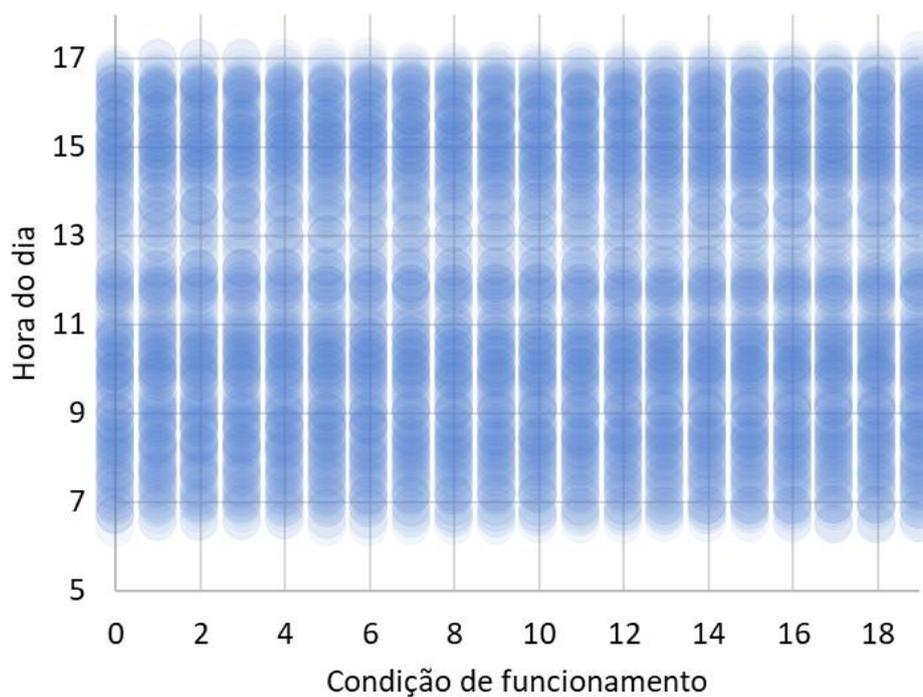
Fonte: Próprio autor

Figura A2.3: Histograma do número de aquisições por temperatura.



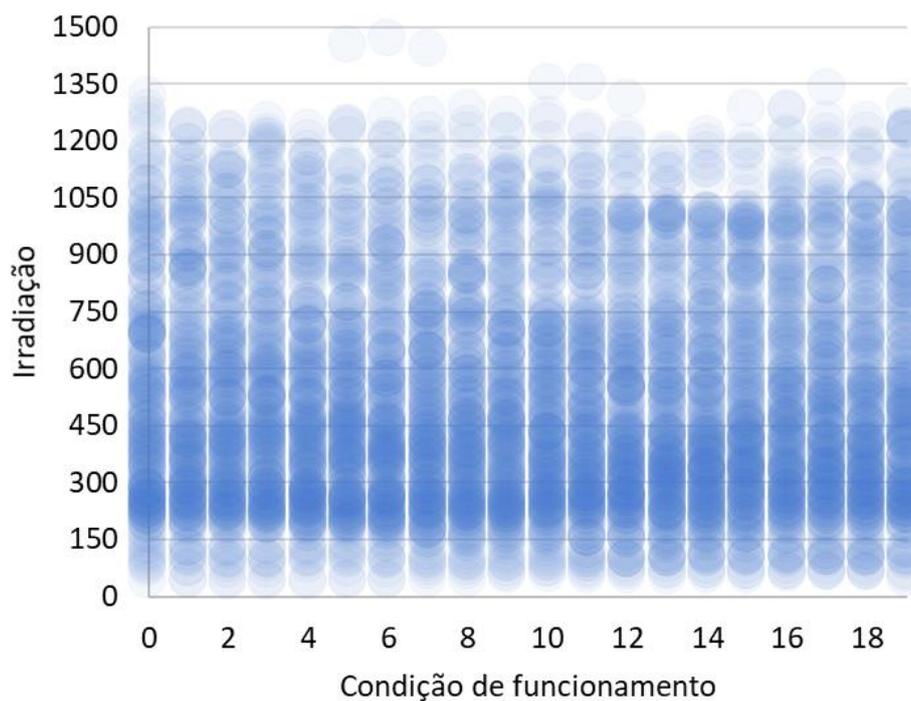
Fonte: Próprio autor

Figura A2.4: Dispersão da hora do dia por condição de funcionamento.



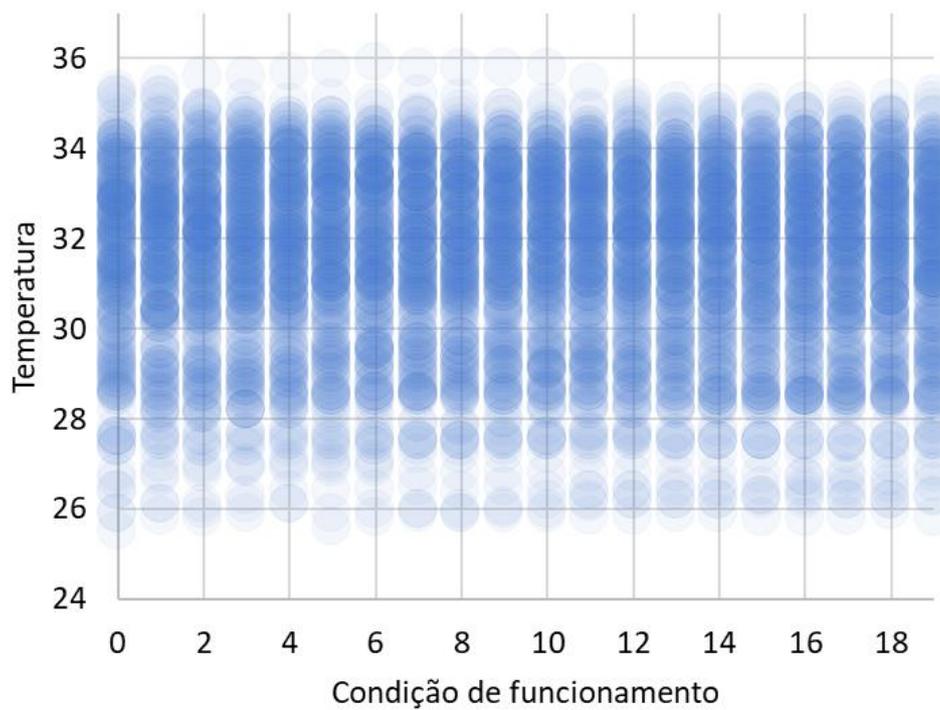
Fonte: Próprio autor

Figura A2.5: Dispersão da irradiação por condição de funcionamento.



Fonte: Próprio autor

Figura A2.6: Dispersão da temperatura por condição de funcionamento.



Fonte: Próprio autor

APÊNDICE 3: TAXAS DE APRENDIZAGEM DURANTE TREINAMENTO DAS REDES NEURAIS

Tabela A3.1: Taxas de aprendizagem durante treinamento das redes neurais

Rede	Nº de Épocas	Taxa de aprendizagem
0	500	0.01
	250	0.002
	2 x 250	0.0005
	2 x 500	0.0005
	2 x 250	0,0001
	250	0,00002
1	250	0.005
	250	0.001
	2 x 500	0.001
	2 x 250	0.001
	500	0.001
	2 x 250	0.0002
	3 x 500	0.0002
	250	0.00005
	250	0.00001
2	2 x 250	0.005
	2 x 500	0.001
	4 x 250	0.0002
	250	0.00005
3	250	0,005
	250	0,001
	100	0,001
	150	0,001
	125	0,001
	3 x 125	0,0002
	2 x 125	0,00005
	125	0,00001
4	250	0,005
	125	0,005
	250	0,001
	2 x 125	0,001
	4 x 125	0,0002
	3 x 125	0,00005
5	50	0,002
	25	0,001
6	50	0,002
	25	0,001

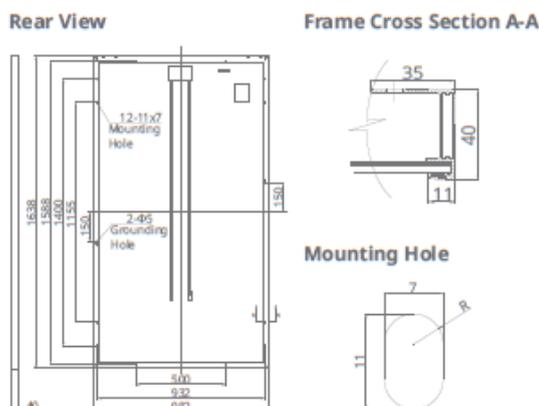
Tabela A3.1: Taxas de aprendizagem durante treinamento das redes neurais (continuação).

Rede	Nº de Épocas	Taxa de aprendizagem
7	100	0,002
	80	0,002
	80	0,001
8	50	0,002
	150	0,002
	50	0,001
9	20	0,002
	80	0,002
	50	0,002
	20	0,001
	30	0,001
	50	0,001
	20	0,0005
10	2 x 20	0,002
	3 x 40	0,002
	40	0,001
	9x100	0,001
	100	0,0005
	25	0,0002
	25	0,0001

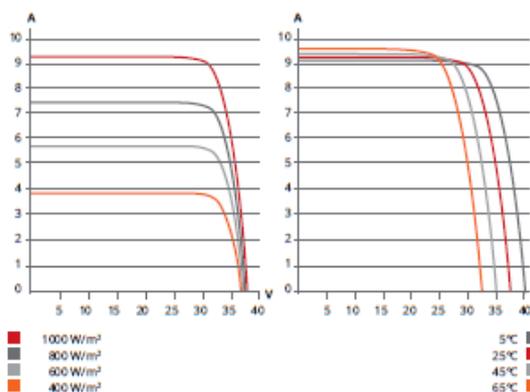
ANEXO A

Datasheet módulo fotovoltaico CS6P-260P

ENGINEERING DRAWING (mm)



CS6P-265P / I-V CURVES



ELECTRICAL DATA / STC*

CS6P	260P	265P	270P
Nominal Max. Power (Pmax)	260 W	265 W	270 W
Opt. Operating Voltage (Vmp)	30.4 V	30.6 V	30.8 V
Opt. Operating Current (Imp)	8.56 A	8.66 A	8.75 A
Open Circuit Voltage (Voc)	37.5 V	37.7 V	37.9 V
Short Circuit Current (Isc)	9.12 A	9.23 A	9.32 A
Module Efficiency	16.16 %	16.47 %	16.79 %
Operating Temperature	-40°C ~ +85°C		
Max. System Voltage	1000 V (IEC) or 1000 V (UL)		
Module Fire Performance	TYPE 1 (UL 1703) or CLASS C (IEC61730)		
Max. Series Fuse Rating	15 A		
Application Classification	Class A		
Power Tolerance	0 ~ + 5 W		

* Under Standard Test Conditions (STC) of irradiance of 1000 W/m², spectrum AM 1.5 and cell temperature of 25°C.

ELECTRICAL DATA / NOCT*

CS6P	260P	265P	270P
Nominal Max. Power (Pmax)	189 W	192 W	196 W
Opt. Operating Voltage (Vmp)	27.7 V	27.9 V	28.1 V
Opt. Operating Current (Imp)	6.80 V	6.88 A	6.97 A
Open Circuit Voltage (Voc)	34.5 V	34.7 V	34.8 V
Short Circuit Current (Isc)	7.39 A	7.48 A	7.55 A

* Under Nominal Operating Cell Temperature (NOCT), irradiance of 800 W/m², spectrum AM 1.5, ambient temperature 20°C, wind speed 1 m/s.

PERFORMANCE AT LOW IRRADIANCE

Industry leading performance at low irradiance, average relative efficiency of 96.5 % from an irradiance of 1000 W/m² to 200 W/m² (AM 1.5, 25°C).

The specification and key features described in this datasheet may deviate slightly and are not guaranteed. Due to on-going innovation, research and product enhancement, Canadian Solar Inc. reserves the right to make any adjustment to the information described herein at any time without notice. Please always obtain the most recent version of the datasheet which shall be duly incorporated into the binding contract made by the parties governing all transactions related to the purchase and sale of the products described herein.

Caution: For professional use only. The installation and handling of PV modules requires professional skills and should only be performed by qualified professionals. Please read the safety and installation instructions before using the modules.

MECHANICAL DATA

Specification	Data
Cell Type	Poly-crystalline, 6 inch
Cell Arrangement	60 (6×10)
Dimensions	1638×982×40 mm (64.5×38.7×1.57 in)
Weight	18 kg (39.7 lbs)
Front Cover	3.2 mm tempered glass
Frame Material	Anodized aluminium alloy
J-Box	IP67, 3 diodes
Cable	4 mm² (IEC) or 4 mm² & 12AWG 1000 V (UL), 1000 mm (39.4 in) (650 mm (25.6 in) is optional)
Connectors	Friends PV2a (IEC), Friends PV2b (IEC / UL)
Standard	26 pieces, 515 kg (1135.4 lbs)
Packaging	(quantity & weight per pallet)
Module Pieces per Container	728 pieces (40' HQ)

TEMPERATURE CHARACTERISTICS

Specification	Data
Temperature Coefficient (Pmax)	-0.41 % / °C
Temperature Coefficient (Voc)	-0.31 % / °C
Temperature Coefficient (Isc)	0.053 % / °C
Nominal Operating Cell Temperature	45±2 °C

PARTNER SECTION



Scan this QR-code to discover solar projects built with this module



ANEXO B

Datasheet do sensor de tensão

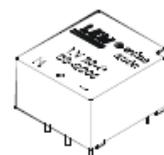


Voltage Transducer LV 20-P

For the electronic measurement of voltages : DC, AC, pulsed..., with a galvanic isolation between the primary circuit (high voltage) and the secondary circuit (electronic circuit).

$$I_{PN} = 10 \text{ mA}$$

$$V_{PN} = 10 \dots 500 \text{ V}$$



Electrical data

I_{PN}	Primary nominal r.m.s. current	10	mA		
I_P	Primary current, measuring range	0 .. ± 14	mA		
R_M	Measuring resistance	$R_{M \min}$	$R_{M \max}$		
				with $\pm 12 \text{ V}$	@ $\pm 10 \text{ mA}_{\max}$
			@ $\pm 14 \text{ mA}_{\max}$	30	100 Ω
		with $\pm 15 \text{ V}$	@ $\pm 10 \text{ mA}_{\max}$	100	350 Ω
	@ $\pm 14 \text{ mA}_{\max}$	100	190 Ω		
I_{SN}	Secondary nominal r.m.s. current	25	mA		
K_N	Conversion ratio	2500 : 1000			
V_C	Supply voltage ($\pm 5\%$)	$\pm 12 \dots 15$	V		
I_C	Current consumption	10 (@ $\pm 15 \text{ V}$) + I_S	mA		
V_d	R.m.s. voltage for AC isolation test ¹⁾ , 50 Hz, 1 mn	2.5	kV		

Features

- Closed loop (compensated) voltage transducer using the Hall effect
- Insulated plastic case recognized according to UL 94-V0
- Optimized.

Principle of use

- For voltage measurements, a current proportional to the measured voltage must be passed through an external resistor R_M , which is selected by the user and installed in series with the primary circuit of the transducer.

Accuracy - Dynamic performance data

X_G	Overall Accuracy @ I_{PN} , $T_A = 25^\circ\text{C}$	@ $\pm 12 \dots 15 \text{ V}$	± 1.1	%
		@ $\pm 15 \text{ V} (\pm 5\%)$	± 1.0	%
ϵ_L	Linearity		< 0.2	%
I_O	Offset current @ $I_P = 0$, $T_A = 25^\circ\text{C}$	Typ	Max	mA
I_{OT}	Thermal drift of I_O	0°C .. +25°C	± 0.10	± 0.30
		+25°C .. +70°C	± 0.14	± 0.40
t_r	Response time ²⁾ @ 90 % of $V_{P \max}$		40	μs

Advantages

- Excellent accuracy
- Very good linearity
- Low thermal drift
- Low response time
- High bandwidth
- High immunity to external interference
- Low disturbance in common mode.

General data

T_A	Ambient operating temperature	0 .. +70	$^\circ\text{C}$
T_S	Ambient storage temperature	-25 .. +85	$^\circ\text{C}$
R_P	Primary coil resistance @ $T_A = 70^\circ\text{C}$	250	Ω
R_S	Secondary coil resistance @ $T_A = 70^\circ\text{C}$	110	Ω
m	Mass	22	g
	Standards ³⁾	EN 50178	

Applications

- AC variable speed drives and servo motor drives
- Static converters for DC motor drives
- Battery supplied applications
- Uninterruptible Power Supplies (UPS)
- Power supplies for welding applications.

Notes : ¹⁾ Between primary and secondary

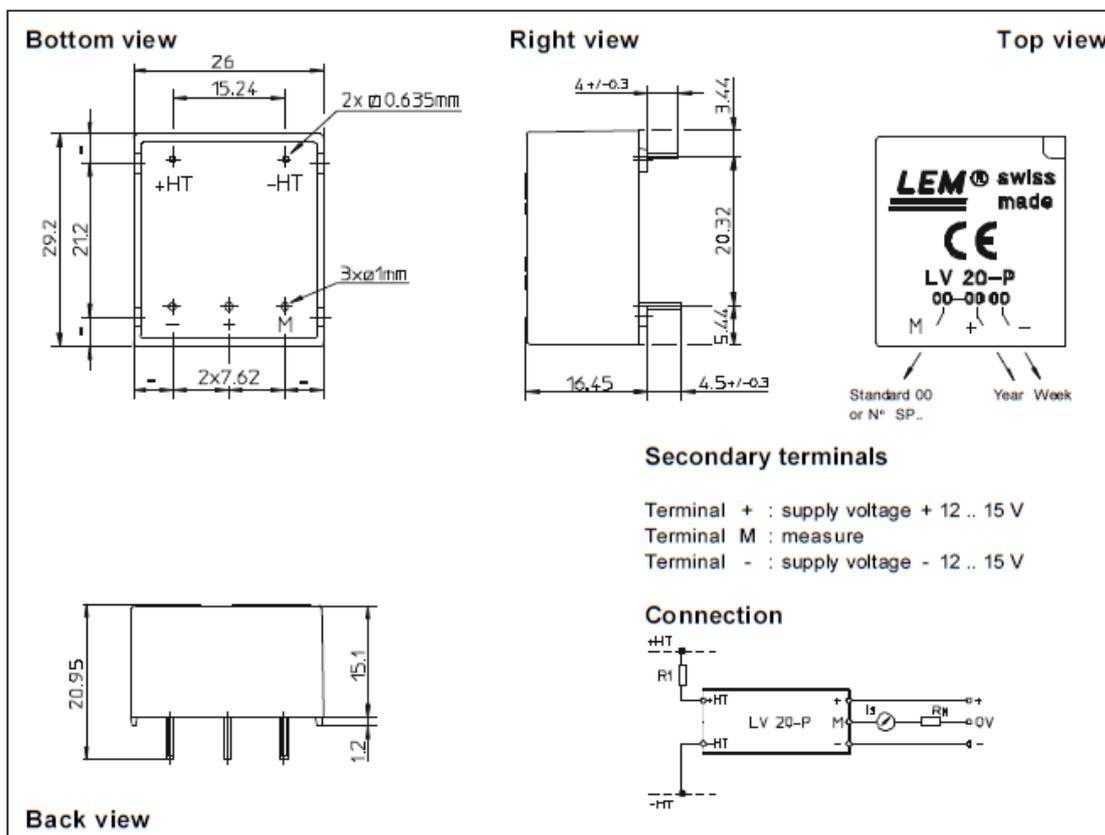
²⁾ $R_M = 25 \text{ k}\Omega$ (L/R constant, produced by the resistance and inductance of the primary circuit)

³⁾ A list of corresponding tests is available

010802/0



Dimensions LV 20-P (in mm. 1 mm = 0.0394 inch)



Mechanical characteristics

- General tolerance ± 0.2 mm
- Fastening & connection of primary 2 pins
0.635 x 0.635 mm
- Fastening & connection of secondary 3 pins $\varnothing 1$ mm
- Recommended PCB hole 1.2 mm

Remarks

- I_s is positive when V_p is applied on terminal +HT.
- This is a standard model. For different versions (supply voltages, turns ratios, unidirectional measurements...), please contact us.

Instructions for use of the voltage transducer model LV 20-P

Primary resistor R_1 : the transducer's optimum accuracy is obtained at the nominal primary current. As much as possible, R_1 should be calculated so that the nominal voltage to be measured corresponds to a primary current of 10 mA.

Example: Voltage to be measured $V_{pn} = 250$ V

a) $R_1 = 25$ k Ω / 2.5 W, $I_p = 10$ mA	Accuracy = ± 1 % of V_{pn} (@ $T_A = +25^\circ\text{C}$)
b) $R_1 = 50$ k Ω / 1.25 W, $I_p = 5$ mA	Accuracy = ± 2 % of V_{pn} (@ $T_A = +25^\circ\text{C}$)

Operating range (recommended): taking into account the resistance of the primary windings (which must remain low compared to R_1 in order to keep thermal deviation as low as possible) and the isolation, this transducer is suitable for measuring nominal voltages from 10 to 500 V.

LEM reserves the right to carry out modifications on its transducers, in order to improve them, without previous notice.

ANEXO C

Datasheet do sensor de corrente



Current Transducer LA 55-P

For the electronic measurement of currents : DC, AC, pulsed..., with a galvanic isolation between the primary circuit (high power) and the secondary circuit (electronic circuit).

$$I_{PN} = 50 \text{ A}$$



Electrical data

I_{PN}	Primary nominal r.m.s. current	50	A				
I_p	Primary current, measuring range	0 .. ± 70	A				
R_M	Measuring resistance @	$T_A = 70^\circ\text{C}$		$T_A = 85^\circ\text{C}$			
			R_{Mmin}	R_{Mmax}	R_{Mmin}	R_{Mmax}	
		with $\pm 12 \text{ V}$	@ $\pm 50 \text{ A}_{max}$	10	100	60	95 Ω
			@ $\pm 70 \text{ A}_{max}$	10	50	60 ¹⁾	60 ¹⁾ Ω
	with $\pm 15 \text{ V}$	@ $\pm 50 \text{ A}_{max}$	50	160	135	155 Ω	
		@ $\pm 70 \text{ A}_{max}$	50	90	135 ²⁾	135 ²⁾ Ω	
I_{SN}	Secondary nominal r.m.s. current	50	mA				
K_N	Conversion ratio	1 : 1000					
V_C	Supply voltage ($\pm 5\%$)	$\pm 12 \dots 15$	V				
I_C	Current consumption	10 (@ $\pm 15 \text{ V}$) + I_S	mA				
V_d	R.m.s. voltage for AC isolation test, 50 Hz, 1 mn	2.5	kV				

Accuracy - Dynamic performance data

X	Accuracy @ I_{PN} , $T_A = 25^\circ\text{C}$	@ $\pm 15 \text{ V} (\pm 5\%)$	± 0.65	%
		@ $\pm 12 \dots 15 \text{ V} (\pm 5\%)$	± 0.90	%
ϵ_L	Linearity		< 0.15	%
I_o	Offset current @ $I_p = 0$, $T_A = 25^\circ\text{C}$	Typ	Max	mA
I_{oM}	Residual current ³⁾ @ $I_p = 0$, after an overload of $3 \times I_{PN}$		± 0.3	mA
I_{oT}	Thermal drift of I_o	0 $^\circ\text{C}$.. + 70 $^\circ\text{C}$	± 0.1	mA
		- 25 $^\circ\text{C}$.. + 85 $^\circ\text{C}$	± 0.1	± 0.6 mA
t_{ra}	Reaction time @ 10 % of I_{pmax}	< 500	ns	
t_r	Response time @ 90 % of I_{pmax}	< 1	μs	
di/dt	di/dt accurately followed	> 200	A/ μs	
f	Frequency bandwidth (- 1 dB)	DC .. 200	kHz	

General data

T_A	Ambient operating temperature	- 25 .. + 85	$^\circ\text{C}$
T_S	Ambient storage temperature	- 40 .. + 90	$^\circ\text{C}$
R_S	Secondary coil resistance @	$T_A = 70^\circ\text{C}$	80 Ω
		$T_A = 85^\circ\text{C}$	85 Ω
m	Mass	18	g
	Standards ⁴⁾	EN 50178	

Notes : ¹⁾ Measuring range limited to $\pm 60 \text{ A}$
²⁾ Measuring range limited to $\pm 55 \text{ A}_{max}$
³⁾ Result of the coercive field of the magnetic circuit
⁴⁾ A list of corresponding tests is available

Features

- Closed loop (compensated) current transducer using the Hall effect
- Printed circuit board mounting
- Insulated plastic case recognized according to UL 94-V0.

Advantages

- Excellent accuracy
- Very good linearity
- Low temperature drift
- Optimized response time
- Wide frequency bandwidth
- No insertion losses
- High immunity to external interference
- Current overload capability.

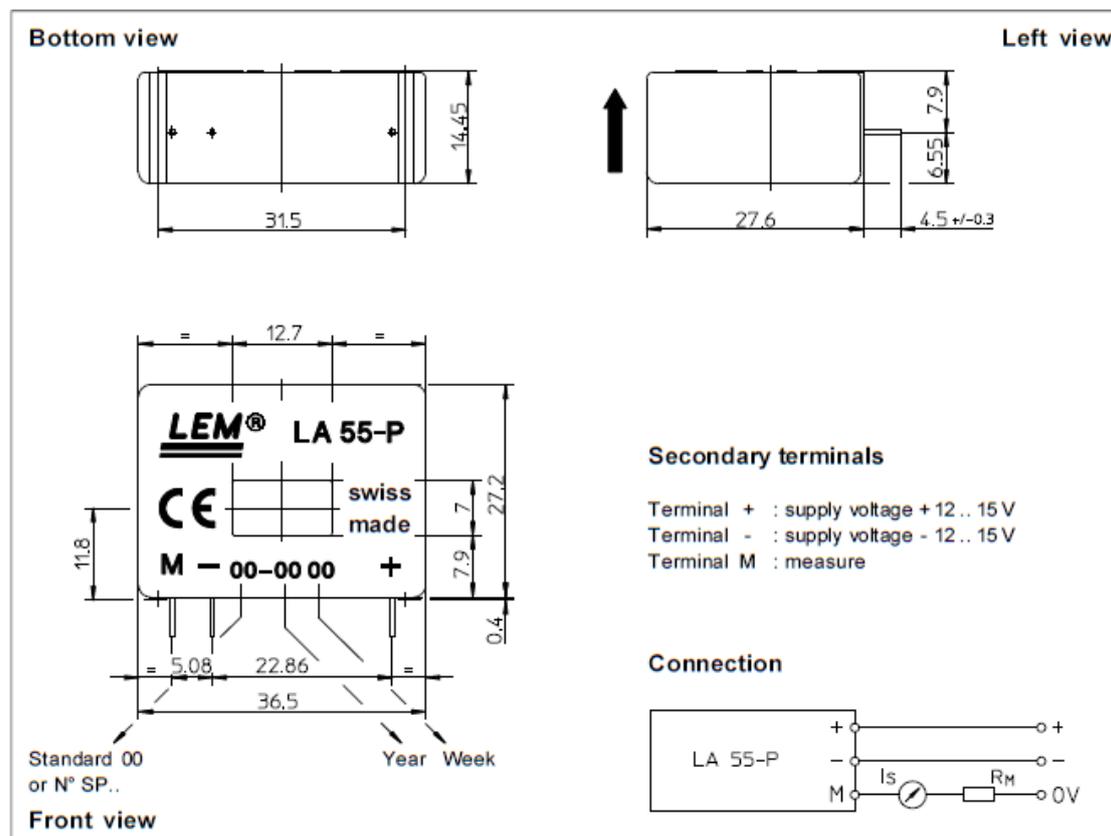
Applications

- AC variable speed drives and servo motor drives
- Static converters for DC motor drives
- Battery supplied applications
- Uninterruptible Power Supplies (UPS)
- Switched Mode Power Supplies (SMPS)
- Power supplies for welding applications.

980706/8



Dimensions LA 55-P (in mm, 1 mm = 0.0394 inch)



Mechanical characteristics

- General tolerance ± 0.2 mm
- Primary through-hole 12.7 x 7 mm
- Fastening & connection of secondary 3 pins
- Recommended PCB hole 0.63 x 0.56 mm
- 0.9 mm

Remarks

- I_s is positive when I_p flows in the direction of the arrow.
- Temperature of the primary conductor should not exceed 90°C.
- Dynamic performances (di/dt and response time) are best with a single bar completely filling the primary hole.
- In order to achieve the best magnetic coupling, the primary windings have to be wound over the top edge of the device.
- This is a standard model. For different versions (supply voltages, turns ratios, unidirectional measurements...), please contact us.