

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
CÂMPUS GOIÂNIA
MESTRADO PROFISSIONAL EM TECNOLOGIA, GESTÃO E SUSTENTABILIDADE

CLEIBER NICHIDA

Detecção de Anomalias em Painéis Fotovoltaicos por Meio da Termografia e Inteligência Artificial

Goiânia, 2024.



INSTITUTO FEDERAL
Goiás

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
CÂMPUS GOIÂNIA

TERMO DE AUTORIZAÇÃO PARA DISPONIBILIZAÇÃO NO REPOSITÓRIO DIGITAL DO IFG - ReDi IFG

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia de Goiás, a disponibilizar gratuitamente o documento no Repositório Digital (ReDi IFG), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IFG.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| ☐ Tese | ☐ Artigo Científico |
| ☒ Dissertação | ☐ Capítulo de Livro |
| ☐ Monografia - Especialização | ☐ Livro |
| ☐ TCC - Graduação | ☐ Trabalho apresentado em evento |
| ☐ Produto Técnico e Educacional - Tipo: _____ | |

Nome completo do autor: CLEIBER NICHIDA

Matrícula: 20212011280072

Título do trabalho: Detecção de Anomalias em Painéis Fotovoltaicos por Meio da Termografia e Inteligência Artificial.

Autorização - Marque uma das opções

1. ☒ Autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso aberto);
2. ☐ Autorizo disponibilizar meu trabalho no Repositório Digital do IFG somente após a data ____/____/____ (Embargo);
3. ☐ Não autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso restrito).

Ao indicar a opção **2 ou 3**, marque a justificativa:

- ☐ O documento está sujeito a registro de patente.
- ☐ O documento pode vir a ser publicado como livro, capítulo de livro ou artigo.
- ☐ Outra justificativa: _____.

Declaração de distribuição não-exclusiva

O/A referido/a autor/a declara que:

- i. o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- ii. obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para

conceder ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;

- iii. cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

Goiânia, 15/03/2024.

Local

Data

(Assinado Eletronicamente)

Assinatura do Autor e/ou Detentor dos Direitos Autorais

Documento assinado eletronicamente por:

■ **Cleiber Nichida**, 20212011280072 - Discente, em 19/06/2024 15:14:12.

Este documento foi emitido pelo SUAP em 19/06/2024. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifg.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 537415

Código de Autenticação: 81df0f9510



Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Rua 75, nº 46, None, Centro, GOIÂNIA / GO, CEP 74055-110
(62) 3227-2767 (ramal: 2767)

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
CÂMPUS GOIÂNIA
MESTRADO PROFISSIONAL EM TECNOLOGIA, GESTÃO E SUSTENTABILIDADE

CLEIBER NICHIDA

Detecção de Anomalias em Painéis Fotovoltaicos por Meio da Termografia e Inteligência Artificial

Programa de Pós-Graduação *Stricto Sensu* em Tecnologia, Gestão e Sustentabilidade do Instituto Federal de Educação, Ciência e Tecnologia de Goiás - Dissertação de Mestrado Profissional. Área de Concentração: Tecnologia de Sistemas de Produção Limpa. Linha de Pesquisa: Energias Renováveis.

Orientador: Prof. Dr. José Luis Domingos

Coorientador: Prof. Dr. Carlos Roberto da Silveira Júnior

Goiânia, 2024.

N5142d Nichida, Cleiber.

Detecção de anomalias em painéis fotovoltaicos por meio da termografia e inteligência artificial / Cleiber Nichida. – Goiânia: Instituto Federal de Educação, Ciência e Tecnologia de Goiás, 2024.

82 f. : il.

Orientador: Prof. Dr. José Luis Domingos.

Coorientador: Prof. Dr. Carlos Roberto da Silveira Júnior.

Dissertação (Mestrado) – Mestrado Profissional em Tecnologia, Gestão e Sustentabilidade, Programa de Mestrado em Tecnologia, Gestão e Sustentabilidade, Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

1. Sistemas fotovoltaicos. 2. Redes Neurais Convolucionais. 3. Diagnóstico de anomalias. I. Domingos, José Luis (orientador). II. Silveira Júnior, Carlos Roberto da (coorientador). III. Instituto Federal de Educação, Ciência e Tecnologia de Goiás. IV. Título.

CDD 621.47



INSTITUTO FEDERAL
Goiás

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
CÂMPUS GOIÂNIA

PARECER 5/2024 - GYN-CMTGS/GYN-GPPEX/CP-GOIANIA/IFG

**SERVIÇO PÚBLICO FEDERAL
INSTITUTO FEDERAL DE EDUCAÇÃO CIÊNCIA E TECNOLOGIA DE GOIÁS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
IFG CÂMPUS GOIÂNIA
MESTRADO EM TECNOLOGIA, GESTÃO E SUSTENTABILIDADE**

CLEIBER NICHIDA

**DETECÇÃO DE ANOMALIAS EM PAINÉIS FOTOVOLTAICOS POR MEIO DE TERMOGRAFIA E
INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada ao Programa de Pós-Graduação em Tecnologia, Gestão e Sustentabilidade do Instituto Federal de Educação Ciência e Tecnologia de Goiás como requisito parcial à obtenção do título de Mestre.
Área de Concentração: Tecnologia de Sistemas de Produção Limpa.
Linha de Pesquisa: Energias de Fontes Renováveis

Aprovada em: 15/03/2024

Banca examinadora:

Prof. Dr. José Luis Domingos - Presidente e orientador - IFG Goiânia
Prof. Dr. Carlos Roberto da Silveira Júnior - Coorientador - IFG Goiânia
Prof. Dr. Ricardo Henrique Fonseca Alves - Avaliador - PETROBRAS
Prof. Dr. Raphael de Aquino Gomes - Avaliador - IFG Goiânia
Prof. Dr. Édipo Henrique Cremon - Avaliador - IFG Goiânia

Documento assinado eletronicamente por:

- Carlos Roberto da Silveira Junior, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 25/03/2024 09:05:32.
- Raphael de Aquino Gomes, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 21/03/2024 08:48:25.
- RICARDO HENRIQUE FONSECA ALVES, RICARDO HENRIQUE FONSECA ALVES - Outros - Ifg - Câmpus Goiânia (10870883000225), em 20/03/2024 17:59:20.
- Edipo Henrique Cremon, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 20/03/2024 16:02:31.
- Jose Luis Domingos, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 20/03/2024 15:06:08.

Este documento foi emitido pelo SUAP em 14/03/2024. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifg.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 519166
Código de Autenticação: ca52d107b7



Rua 75, nº 46, None, Centro, GOIÂNIA / GO, CEP 74055-110
Sem Telefones cadastrados

Dedicatória

Este trabalho é dedicado a todos aqueles que me acompanharam e me apoiaram em todos os momentos desta jornada, em especial à minha família, que suportou minha indisponibilidade por longos períodos, tanto física quanto emocionalmente, para que este trabalho pudesse ser desenvolvido.

Agradecimentos

À minha esposa Luciana de Moura Umake Nichida e aos meus filhos Caio Umake Nichida e Lara Umake Nichida, que me deram suporte, forças e motivos a mais para superar cada obstáculo. Aos demais familiares, especialmente minha mãe, que com suas palavras de incentivo tornaram menos árduos os esforços dispendidos com pesquisas, testes e escrita do trabalho.

Ao Instituto Federal de Goiás que abre suas portas para perpetuar o conhecimento à toda a comunidade. Aos meus professores do programa de mestrado que me ensinaram os duros caminhos de uma pesquisa científica, e aos colegas de mestrado que caminharam juntos comigo nessa jornada, dividindo suas angústias e alegrias.

Aos membros da banca, que dispuseram de seu valioso tempo para apreciação do trabalho e que com suas valiosas recomendações engrandeceram a escrita dessa dissertação.

Ao meu orientador, professor José Luis Domingos pela paciência e dedicação em não me deixar desistir pelo caminho e, ao meu coorientador, professor Carlos Roberto da Silveira pelo impulso inicial e orientações ao longo do percurso.

Enfim, agradeço a todos aqueles que direta ou indiretamente contribuíram para que esse trabalho fosse realizado.

Resumo

Título: Detecção de Anomalias em Painéis Fotovoltaicos por Meio da Termografia e Inteligência Artificial

Autor: Cleiber Nichida

Orientador: Dr. José Luis Domingos

Coorientador: Prof. Dr. Carlos Roberto da Silveira Júnior

Módulos fotovoltaicos são os elementos mais expostos de um sistema fotovoltaico, estando sujeitos a vários tipos de anomalias tais como: defeitos de fabricação, problemas com armazenamento e manuseio ou fatores ambientais, demandando cuidados para não ocorrer perda de eficiência além do previsto pelos fabricantes. O diagnóstico precoce de anomalias nos painéis e suas correções são de grande importância para a conservação de sua produção de energia elétrica, da segurança e da manutenção de sua viabilidade econômica. Trabalhos com foco na automatização do processo de identificação de anomalias em módulos fotovoltaicos vêm sendo desenvolvidos e publicados. O presente estudo propõe um modelo de rede neural para análise de imagens termográficas de painéis instalados em usinas em operação, com o propósito de aumentar a eficiência no diagnóstico de anomalias e auxiliar na tomada de decisão das equipes de operação e manutenção. Para tanto, agrupou-se de uma forma não observada em trabalhos relacionados, as anomalias em classes que demandam o mesmo tipo de intervenção, realizando ainda uma comparação de resultados com modelos pré-treinados. O modelo proposto apresenta acerto de mais de 90% na classificação de anomalias em imagens termográficas dos painéis fotovoltaicos.

Palavras-chave

Diagnóstico de Anomalias, Operação e Manutenção, Redes Neurais Convolucionais, Sistemas Fotovoltaicos, Visão Computacional

Abstract

Title: Detection of Anomalies in Photovoltaic Panels by Thermography and Artificial Intelligence

Author: Cleiber Nichida

Advisor: Dr. José Luis Domingos

Coadvisor: Prof. Dr. Carlos Roberto da Silveira Júnior

Photovoltaic modules are the most exposed elements of a photovoltaic system, being subject to various types of anomalies such as: manufacturing defects, problems with storage and handling or environmental factors, requiring care to avoid loss of efficiency beyond that predicted by the manufacturers. The early diagnosis of anomalies in the panels and their corrections are of great importance for the conservation of its electrical energy production, safety and maintenance of its economic viability. Work focusing on automating the process of identifying anomalies in photovoltaic modules has been developed and published. The present study proposes a neural network model for analyzing thermographic images of panels installed in operating plants, with the purpose of increasing efficiency in diagnosing anomalies and assisting in decision-making by operation and maintenance teams. To this end, anomalies were grouped in a way not observed in related works in classes that require the same type of intervention, also carrying out a comparison of results with pre-trained models. The proposed model presents an accuracy of more than 90% in the classification of anomalies in thermal images of photovoltaic panels.

Keywords

Anomaly Diagnosis, Computer Vision, Convolutional Neural Networks, Operation and Maintenance, Photovoltaic Systems

Lista de Figuras

Figura 1	– Funcionamento de uma célula fotovoltaica.	24
Figura 2	– Topologia de ligação em inversor tipo <i>string</i>	25
Figura 3	– Gráficos das curvas tensão, corrente e potência de um módulo fotovoltaico de 450 W.	27
Figura 4	– Exemplo de detecção de pontos quentes por câmera termográfica infravermelha e suas respectivas imagens no espectro visível....	30
Figura 5	– Imagem termográfica de um módulo com sujidade (a), correspondente a imagem do espectro visível (b). A imagem (c) apresenta a imagem termográfica dos módulos sombreados (d).	30
Figura 6	– Arquitetura da LeNet-5 na tarefa de reconhecimento de um dígito manuscrito.	37
Figura 7	– Procedimento de uma Rede Neural Convolutacional 2-D.	38
Figura 8	– Exemplo de Matriz de Confusão com três classes.	41
Figura 9	– Etapas da metodologia.	43
Figura 10	– Amostras de imagens classificadas da base de dados.	46
Figura 11	– Fluxograma da programação.	50
Figura 12	– Diagrama da estrutura da Rede Neural Convolutacional Simples proposta.	51
Figura 13	– Diagrama de Execução da Validação Cruzada <i>K-fold</i>	53
Figura 14	– Cenário 1 - matriz de confusão gerada utilizando a base de dados com 20.000 amostras.	59
Figura 15	– <i>Recall</i> resultante do Cenário 1.	59
Figura 16	– Exemplo de imagens de classes apresentando padrões com semelhança.	60
Figura 17	– Cenário 2 - introdução de <i>K-fold</i> e base de dados aumentada para 24.000 amostras.	61
Figura 18	– <i>Recall</i> por classes resultantes do Cenário 2.	61
Figura 19	– Cenário 3 - base de dados aumentada para 60.000 amostras. .	62
Figura 20	– <i>Recall</i> por classes resultantes do Cenário 3.	63
Figura 21	– Cenário 4 - 9 classes e base de dados com 45.000 amostras. ..	64
Figura 22	– <i>Recall</i> por classes resultantes do Cenário 4.	64
Figura 23	– Cenário 5 - 3 classes e base de dados com 45.000 amostras. ..	65
Figura 24	– <i>Recall</i> por classes resultantes do Cenário 5.	65
Figura 25	– Cenário 6 - VGG-16, 3 classes e base de dados com 45.000 amostras.	66
Figura 26	– <i>Recall</i> por classes resultantes do Cenário 6.	67

Figura 27 – Cenário 7 - utilizando o modelo ResNet50 com base de dados com 45.000 amostras.	68
Figura 28 – <i>Recall</i> por classes resultantes do Cenário 7.	68

Lista de Tabelas

Tabela 1	–	Descritivo e quantidade de amostras de cada classe na base de dados disponibilizada pela empresa RaptorMaps.	47
Tabela 2	–	Tabela-resumo dos resultados obtidos das execuções dos <i>scripts</i>	69

Lista de Quadros

Quadro 1 – Técnicas de detecção de anomalias.	26
Quadro 2 – Requisitos mínimos para inspeção por IRT segundo a IEC TS 62446-3:2017.....	32
Quadro 3 – Trabalhos relacionados e as técnicas de Inteligência Artificial utilizadas.	45

Lista de Abreviaturas e Siglas

ABNT	Associação Brasileira de Normas Técnicas
ABSOLAR	Associação Brasileira de Energia Solar
ANAC	Agência Nacional de Aviação Civil
ANEEL	Agência Nacional de Energia Elétrica
DL	<i>Deep Learning</i>
IA	Inteligência Artificial
ICAO	<i>International Civil Aviation Organization</i>
IEC	<i>International Electrotechnical Commission</i>
IRENA	<i>International Renewable Energy Agency</i>
ML	<i>Machine Learning</i>
RNA	Redes Neurais Artificiais
RNC	Redes Neurais Convolucionais
VC	Visão Computacional

Lista de Símbolos

CA	Corrente Alternada
CC	Corrente Contínua
I_{sc}	Corrente de Curto Circuito
P_{max}	Máxima potência
s	segundos
V	Tensão
V_{oc}	Tensão de circuito aberto

Sumário

1	Introdução	19
1.1	Objetivos	22
2	Referencial Teórico	23
2.1	Sistema Fotovoltaico	23
2.1.1	Painéis Fotovoltaicos	23
2.1.2	Inversor de Frequência	24
2.2	Métodos de Inspeção dos Módulos Fotovoltaicos	25
2.2.1	Inspeção Visual	26
2.2.2	Análise da Curva I-V	27
2.2.3	Inspeção por Uso de Radiação	28
2.2.3.1	Imagem Eletroluminescente	28
2.2.3.2	Termografia Infravermelha	29
2.3	Uso de Aeronaves Remotamente Pilotadas associado à Termografia	31
2.4	Anomalias em Módulos Fotovoltaicos	33
2.5	Inteligência Artificial e Aprendizado de Máquina	33
2.5.1	Categorias de ML	34
2.5.2	Rede Neural Convolucional	35
2.5.3	VGG-16	38
2.5.4	ResNet50	38
2.5.5	Overfitting	39
2.5.6	Aumento Artificial da Quantidade de Amostras	39
2.5.7	Métricas de Avaliação em Aprendizado de Máquina	39
2.5.7.1	Matriz de Confusão	41
3	Metodologia	42
3.1	Etapas da Realização do Trabalho	42
3.1.1	Revisão Bibliográfica	43
3.1.2	Escolha da Arquitetura da Rede Neural	44
3.1.3	Base de Dados	45
3.1.4	Aumento Artificial de Amostras	47
3.2	Programação	48
3.3	Treinamento da Rede Neural	52
3.4	Validação Cruzada	52
3.4.1	Métricas para Avaliação dos Resultados	53
3.5	Execução dos cenários	54
3.5.1	Cenário Referência	54

3.5.2	Introdução da Validação Cruzada e Aumento Artificial de Dados	54
3.5.3	Junção de Classes	55
3.5.4	Modelo Final da RNC Proposta.....	55
3.5.5	Modelo VGG-16	56
3.5.6	Modelo ResNet50	57
4	Resultados	58
4.1	Cenário de Referência	58
4.2	K-Fold e Aumento Artificial de Dados	60
4.3	Junção de Classes	63
4.4	Modelo Final da RNC	63
4.5	Modelo VGG-16	65
4.6	ResNet50.....	67
4.7	Síntese dos Resultados	67
4.8	Discussões.....	68
5	Conclusões e Sugestões para Futuros Trabalhos	71
	Referências	73

Introdução

A partir da crise petrolífera em 1973, que gerou uma contenção mundial na produção de petróleo e teve como consequência um aumento significativo de problemas relacionados ao uso de seus derivados, muitos países procuraram diversificar sua matriz energética (Oliveira e Gomes, 2018). No final dos anos 1990, o aumento de ações que procuram reduzir o impacto ambiental na geração de energia elétrica e ainda a distribuição irregular de chuvas que provocou a redução dos níveis dos reservatórios das hidrelétricas no Brasil, acelerou a procura por fontes de energia elétrica não derivadas de combustíveis fósseis ou de hidrelétricas (Oliveira e Gomes, 2018).

O crescimento do número de instalações de sistemas fotovoltaicos no país é uma vertente da busca por geração de energia elétrica por meio de fontes alternativas. A inserção da matriz energética relacionada à geração de energia elétrica fotovoltaica no Brasil é recente e evoluiu significativamente somente a partir das resoluções normativas RN482/2012 (ANEEL, 2012) e RN687/2015 (ANEEL, 2015) da Agência Nacional de Energia Elétrica (ANEEL). Tais resoluções trouxeram em seus textos a permissão do acessante da rede de energia elétrica no país, de produzir sua própria energia elétrica a partir de fontes limpas e renováveis, e a possibilidade da unidade consumidora injetar na rede de distribuição o seu excedente de energia elétrica produzido, e receber créditos por este, possibilitando a compensação em quilowatt-hora (kWh). Em janeiro de 2022, foi promulgada a Lei 14.300 (BRASIL, 2022) que criou o marco legal da geração distribuída no Brasil, trazendo a garantia legal para tal modalidade de geração de energia no país.

Como consequência da implantação da regulamentação, aliada à queda dos preços dos equipamentos e também à crescente potência dos módulos e inversores, a capacidade instalada de geração fotovoltaica no Brasil, segundo a Associação Brasileira de Energia Solar (ABSOLAR), saltou de cerca de 7 megawatts (MW) em 2012 para mais de 39.857 MW em fevereiro de 2024, ocupando o segundo lugar na matriz energética brasileira (representando 17,5% do total de potência instalada de geração no país).

No relatório publicado em 2019 pelo *International Renewable Energy Agency* (IRENA), foi apresentada a projeção de que a capacidade instalada de geração de energia por sistemas fotovoltaicos no mundo atingirá 2.840 gigawatts-pico (GWp) no ano 2030, representando um aumento de 452,95% em relação ao ano de 2020 (IRENA, 2019). Diante do exposto, é esperado um aumento nos casos de anomalias no funcionamento de módulos fotovoltaicos, uma vez que são os elementos instalados ao tempo e submetidos à ação de forças da natureza, gerando custos de manutenção com os mesmos (Hu *et al.*, 2014).

No trabalho de Mustafa *et al.* (2020), foram estudados fatores ambientais que influenciam na produção de uma usina fotovoltaica em funcionamento e demonstrou-se que existe uma redução significativa de desempenho dos módulos sombreados ou que apresentem sujidades. Os fabricantes de painéis fotovoltaicos em geral garantem o funcionamento com rendimento de no mínimo 80% da capacidade inicial ao final de 25 anos de utilização. Essa garantia leva em conta a diminuição de desempenho causada pelo funcionamento regular que inclui, por exemplo, microfissuras que não podem ser evitados (Kurukuru *et al.*, 2019). Além desses, alguns dos outros defeitos já identificados em módulos fotovoltaicos são: os associados aos defeitos da estrutura, defeitos de encapsulamento, defeitos no vidro, falhas nos cabos e conectores, defeitos da cobertura traseira e outros (Tsanakas, Ha e Buerhop, 2016).

A utilização da IRT para a avaliação de gradientes de temperatura em sistemas fotovoltaicos é apontada como apropriada por não requerer a interrupção do funcionamento do sistema. Sua utilização possui algumas limitações, devido à emissividade, a presença de vidro sobre as células e as influências das condições do ambiente sobre as mesmas (Garcia *et al.*, 2012). Apesar disso, a IRT pode ser utilizada para detecção de anomalias nos barramentos, soldas, bolhas, manchas e áreas quentes (Kaplani, 2012).

Métodos de inspeção dos módulos fotovoltaicos vêm sendo estudados a fim de diagnosticar falhas precocemente e assim mitigar os efeitos dessas anomalias, manter a eficiência na geração de energia das plantas e prolongar a vida útil de seus componentes. Entre os métodos investigados estão: inspeção visual, medição de desempenho, a utilização de eletroluminescência e a termografia infravermelha - Infrared Thermography (IRT). A utilização da IRT para a avaliação de gradientes de temperatura em sistemas fotovoltaicos é apontada como apropriada por não requerer a interrupção do funcionamento do sistema. Sua utilização possui algumas limitações, devido à emissividade, a presença de vidro sobre as células e as influências das condições do ambiente sobre as mesmas (Garcia *et al.*, 2012). Apesar disso, a IRT pode ser utilizada para detecção de anomalias nos barramentos, soldas, bolhas,

manchas e áreas quentes (Kaplani, 2012).

Uma limitação em relação à utilização da IRT associada ao uso de *drones* é a quantidade de imagens que pode ser analisada por um especialista, demandando tempo e dedicação, trazendo prejuízos para a geração de energia e de tempo de mão de obra qualificada. Os esforços que vêm sendo dispensados para o desenvolvimento de um sistema de classificação automática das imagens coletadas são então justificados. Trabalhos como Bommes *et al.* (2021), Le *et al.* (2021) e Alves *et al.* (2021) entre outros referenciados neste trabalho, demonstram que os avanços alcançados no campo da utilização Inteligência Artificial (IA) para detecção de padrões em imagens podem ser de grande valia para o desenvolvimento desta área.

Pierdicca *et al.* (2018) utilizaram um método para detecção de falhas no qual foi criado um conjunto de dados baseado em 3.336 imagens térmicas, segmentados manualmente por especialistas e apresentou resultados considerados eficazes. Esse procedimento, apesar do resultado, consome muito tempo para replicar a técnica utilizando câmeras e alturas de voo diferentes. Uma solução para melhorar a aplicabilidade do uso de imagens na detecção e classificação de falhas em sistemas fotovoltaicos é a utilização de técnicas de IA para esta tarefa, as quais se mostram eficientes e confiáveis (Akram *et al.*, 2020).

Um método de diagnóstico de falhas com detecção seguido de isolamento do tipo de falha foi proposto no trabalho de Chouay e Ouassaid (2017), onde aplicaram-se dois algoritmos diferentes utilizando Redes Neurais Artificiais (RNA) para tal processo. No trabalho de Haque *et al.* (2019), foi proposto um sistema utilizando termografia e IA para monitoramento em tempo real, com o emprego de processamento digital de sinais para redução de ruídos nas imagens, antes da aplicação do algoritmo de detecção de falhas baseado em RNA. Por meio da utilização de duas Redes Neurais Convolucionais (RNC) foi proposto um sistema de diagnóstico por Herraiz, Marugán e Márquez (2020) onde, além da detecção de pontos quentes, a localização dos módulos anômalos também é indicada. O trabalho de Alves *et al.* (2021) traz um estudo sobre a utilização da mesma base de dados que é utilizada no presente, aplicando uma RNC com relativo sucesso na classificação das imagens dessa base de dados. Adicionalmente, ilustra o efeito da alta variação do número de amostras entre classes na eficácia do modelo por meio de simulações.

No trabalho de Hwang, Ku e Chan (2021), os autores sugerem algumas técnicas de tratamento de imagem, como por exemplo, a correção de gama, função limite, o algoritmo de aprendizado de máquina chamado XGBoost, ajustes de hiperparâmetros e seleção de recursos, para melhorar o aprendizado e a eficiência do sistema de detecção de anomalias.

De acordo com a literatura pesquisada, o pré-processamento das imagens

poderá ser utilizado na detecção de bordas para que os limites dos módulos sejam delineados, e assim, as medições de temperatura não se confundam com as das superfícies em volta dos mesmos. Ainda contribui para a redução de ruídos que possam causar erros de interpretação por parte do sistema (Hwang, Ku e Chan, 2021; Bommers *et al.*, 2021; Oliveira, Aghaei e Rüther, 2020).

O presente trabalho propõe o treinamento de uma IA que utiliza a Visão Computacional (VC) especificamente voltada para sistemas fotovoltaicos. destinada à detecção e classificação de anomalias em imagens termográficas, utilizando técnicas de *Deep Learning* (DL). Uma RNC é utilizada em conjunto com a junção de classes que requerem intervenções similares por parte das equipes de manutenção. Diversos experimentos foram conduzidos para aprimorar a precisão, confiabilidade e generalização dessa rede. O principal objetivo é criar um sistema de detecção de anomalias que efetivamente auxilie nas decisões das equipes de manutenção em sistemas fotovoltaicos.

Esse trabalho se diferencia de pesquisas anteriores ao focar na criação de um sistema que não apenas detecta anomalias mas também classifica essas anomalias considerando intervenções similares necessárias para a manutenção das usinas fotovoltaicas. A ênfase na utilidade prática do sistema para a tomada de decisões nas equipes de manutenção destaca a relevância e originalidade deste trabalho em comparação com pesquisas anteriores na mesma área.

1.1 Objetivos

O presente estudo tem por objetivo geral avaliar algoritmos de RNC para a detecção de anomalias em módulos fotovoltaicos de plantas em funcionamento a partir da varredura das imagens coletadas em IRT utilizando técnicas de IA, auxiliando assim a identificação de possíveis falhas e a tomada de decisão sobre o tipo de intervenção que se fará necessária na planta.

Os objetivos específicos que podem ser destacados são:

- a) Desenvolver um aprendizado de máquina suficientemente confiável para aplicação em plantas fotovoltaicas em funcionamento;
- b) Implementar uma solução que permita identificar padrões e classificar anomalias de imagens em IRT de módulos fotovoltaicos em funcionamento a partir do uso de uma RNA;
- c) Avaliar a performance dessa RNA para o reconhecimento de anomalias em sistemas fotovoltaicos e;
- d) Analisar cenários de agrupamento de classes de anomalias que demandam intervenções semelhantes por parte das equipes de manutenção.

Referencial Teórico

Neste capítulo procura-se contextualizar os conteúdos utilizados neste trabalho. O conceito básico do funcionamento de uma célula fotovoltaica e da sua ligação para construção de um módulo fotovoltaico é introduzido, além da influência da perda de eficiência em um módulo na produção de todo o arranjo. Algumas técnicas de inspeção para detecção de anomalias nos módulos fotovoltaicos em plantas em funcionamento, as técnicas de IA utilizadas para a classificação das imagens obtidas e as métricas utilizadas para avaliar o desempenho de modelos utilizados são discutidas.

2.1 Sistema Fotovoltaico


Para que se converta a irradiação luminosa em energia elétrica utilizável por máquinas e equipamentos tem-se como principais componentes de um sistema de geração de energia fotovoltaica os módulos fotovoltaicos e os inversores de frequência.

2.1.1 Painéis Fotovoltaicos

A energia gerada através da conversão direta da radiação solar em energia elétrica é conhecida como energia fotovoltaica e se dá por meio de um dispositivo conhecido como célula fotovoltaica (ABNT, 2020). De acordo com Nascimento (2004), cada célula solar compõe-se de camada fina de material composto por Silício dopado tipo-N e outra com maior espessura de Silício dopado tipo-P. Na região da junção dos dois forma-se um campo elétrico causado pelos elétrons livres do Silício tipo-N que ocupam as lacunas da estrutura do Silício tipo-P. Com a incidência da luz solar sobre essa estrutura, os fótons chocam-se com os elétrons da estrutura do Silício transformando-os em condutores e, devido a influência do campo elétrico gerado pela junção P-N orientando o movimento, estes fluem da camada P para a camada N e quando conectada a um circuito elétrico mantém o fluxo de elétrons neste. A Figura 1 ilustra o funcionamento de uma célula fotovoltaica.

Por meio da ligação elétrica em série e paralelo de um conjunto de células fotovoltaicas devidamente encapsuladas em uma estrutura é produzido um módulo fotovoltaico em que se obtém níveis de tensão (V) e corrente (I) propícios à sua utilização em um sistema de geração de energia (Mäki e Valkealahti, 2011). Essa energia é gerada em corrente contínua (CC) e necessita de um inversor de frequência para sua conversão em corrente alternada (CA), além de compatibilizar os níveis de tensão adequados para sua utilização nos circuitos e redes elétricas.

Figura 1 – *Funcionamento de uma célula fotovoltaica.*



Fonte: Adaptado de Cosmos Magazine (2017).


Fatores que reduzem a potência de saída de um módulo fotovoltaico são considerados como falhas ou anomalias (Madeti e Singh, 2017). Tais falhas têm como algumas possíveis causas, citadas por Madeti e Singh (2017): sombras, excrementos de pássaros, acúmulo de poeira ou neve na superfície do painel fotovoltaico, desligamento elétrico, perdas de fiação e envelhecimento.

2.1.2 Inversor de Frequência

Dentre as funções cumpridas pelo inversor para alimentar a rede elétrica com a energia gerada pelos módulos fotovoltaicos, pode-se citar a modulação da corrente em uma forma de onda senoidal e a conversão de CC em CA (Calais *et al.*, 2002).

Em um sistema fotovoltaico em que se utilize um inversor tipo *string* vários módulos são conectados em série para formar um arranjo, permitindo que as baixas tensões e correntes das células possam ser adequadas ao funcionamento do inversor de frequência. Na Figura 2 pode-se observar os painéis ligados em série, formando arranjos (a) que serão conectados em paralelo aos sistemas de proteção (b) e estes às entradas do inversor de frequência (c).

Figura 2 – Topologia de ligação em inversor tipo *string*.



Fonte: Adaptado de Nazer *et al.* (2021)

2.2 Métodos de Inspeção dos Módulos Fotovoltaicos

De acordo com Tina, Cosentino e Ventura (2016), pode-se classificar as técnicas de detecção e classificação de falhas em duas categorias principais: os métodos visuais e térmicos e os métodos elétricos. Os métodos visuais são utilizados para identificação de anomalias como quebra de painel, descoloração, escurecimento e sujeira na superfície. Por sua vez, os métodos elétricos são usados para determinar as características elétricas de um sistema fotovoltaico em módulo, série ou arranjo,

sendo utilizados em diferentes partes de um sistema fotovoltaico, tanto no lado de CC quanto no lado de CA. No Quadro 1 visualizam-se os métodos de cada categoria (Hong e Pula, 2022) e algumas das técnicas de detecção de falhas mais utilizados nos trabalhos avaliados por Madeti e Singh (2017).

Quadro 1 – *Técnicas de detecção de anomalias.*

Métodos Visuais e Térmicos	Métodos Elétricos
Infravermelho / Imagem Termográfica	Técnica Baseada em Dados Climáticos
Inspeção Visual	Análise de características I-V
Imagem Eletroluminescente	Medição de Perdas de Potência
Termografia de Bloqueio	Medições de Corrente e Tensão
Métodos Visuais e Térmicos Integrados com Técnicas de Inteligência Artificial	Modelo Baseado em Variações de I-V com a Temperatura
	Análise do Espectro de Tensão e de Corrente
	Técnicas de Estatística e Processamento Sinais

Fonte: Madeti e Singh (2017), compilado pelo autor.

2.2.1 Inspeção Visual

De acordo com Madeti e Singh (2017), a inspeção visual normalmente é a etapa inicial para determinar a condição de uma planta fotovoltaica, incluindo seus módulos e outros componentes. Diretrizes para inspeção visual estão incluídas nos padrões da norma 61215 da *International Electrotechnical Commission* (IEC) (IEC, 2021). Nesse método, rachaduras, amarelamento, desalinhamento, delaminações, bolhas, corrosão da estrutura, caixa de junção defeituosa, rastros de caracóis e sujeira podem ser observadas. A partir das conclusões obtidas nesta etapa, decisões sobre inspeção mais detalhada, testes adicionais e ações a serem tomadas serão recomendados (Quater *et al.*, 2014; Hong e Pula, 2022).


Em um método de inspeção em que se utilize somente imagens do espectro visível para detecção de anomalias em módulos de plantas em funcionamento, algumas limitações podem ser citadas: as imagens podem ser afetadas pelas condições de luz, efeitos de sombreamento além de não possibilitar a detecção de danos internos aos módulos (Le *et al.*, 2021). Entretanto, por meio de treinamento e especializa-

ção adequados, esse método pode detectar e classificar alguns tipos de falhas com precisão e a um baixo custo (Madeti e Singh, 2017).

2.2.2 Análise da Curva I-V

A curva I-V mostra os possíveis pontos de operação de corrente e tensão de um módulo fotovoltaico ou cadeia de módulos. Seu gráfico inicia na corrente de curto-circuito e termina na tensão de circuito aberto, sendo o pico de potência localizado no joelho da curva I-V, indicando o ponto de operação em que o sistema apresenta a maior potência de saída (Sarikh *et al.*, 2018). Durante a operação normal, as características I-V seguem uma curva particular, que muda durante uma falta. Também chamada de Análise de I-V ou Voltametria, permite a determinação dos parâmetros básicos dos componentes fotovoltaicos, podendo ser realizada em laboratório ou diretamente na instalação (Haque *et al.*, 2019). Na Figura 3 são apresentadas as curvas características de corrente, tensão e potência de um módulo de 540 W (a) e também o gráfico das curvas da corrente de curto-circuito (I_{sc}), tensão de circuito aberto (V_{oc}) e máxima potência (P_{max}), em função da temperatura (b).

Figura 3 – Gráficos das curvas tensão, corrente e potência de um módulo fotovoltaico de 450 W.



Fonte: Adaptado de Jinko Solar (2023)

A partir do monitoramento dos parâmetros elétricos, extrai-se informações sobre a condição operacional do ambiente em relação à temperatura, irradiação e sombreamento, além da possibilidade de se observar as incompatibilidades elétricas e mecânicas. As curvas I-V e de potência características de cada módulo são fornecidas pelos fabricantes em suas folhas de dados. Por meio desses parâmetros é possível

realizar a modelagem computacional do módulo e prever seu comportamento para comparação com as medições, avaliando se o seu rendimento está coerente com o comportamento esperado. A interpretação dos desvios da curva podem então indicar alguns tipos de falha (Sarikh *et al.*, 2018).

A coleta de dados das curvas de um módulo pode ser realizada através de um traçador de curvas, como por exemplo o modelo PVPM1000CX do fabricante Emona Instruments PTY LTD (PV Engineering, 2016). Nesse caso, uma inconveniência é a impossibilidade de execução sem a interrupção do circuito, gerando perdas e riscos para o operador do equipamento de medição, uma vez que o equipamento deve se conectar fisicamente ao gerador fotovoltaico para que se possa fazer as medições e comparar com os parâmetros teóricos. Segundo a norma 16274 da Associação Brasileira de Normas Técnicas (ABNT) (ABNT, 2018), o ensaio com o traçador só se faz necessário em “sistemas de maior complexidade”, por ser a curva I-V uma informação complementar no diagnóstico global de um conjunto de módulos fotovoltaicos.

2.2.3 Inspeção por Uso de Radiação

Diagnósticos por uso de radiação apresentam como métodos principais de investigação de defeitos em painéis fotovoltaicos: a IRT, a eletroluminescência, a fotoluminescência e a microplasma luminescência (Hu *et al.*, 2014).

2.2.3.1 Imagem Eletroluminescente

Dentre os métodos que utilizam o princípio da luminescência, a eletroluminescência é a mais comum pela menor complexidade dos equipamentos e procedimentos a serem adotados. Para realizar a técnica, o módulo fotovoltaico deve ser alimentado por uma fonte de corrente contínua, limitada à corrente de curto circuito especificada pelo fabricante, para estimular a recombinação radiativa nas células fotovoltaicas, emitindo luminescência que poderão ser captadas por câmeras de alta resolução que detectam o comprimento de onda próxima ao infravermelho (Haque *et al.*, 2019). Este procedimento deve ser realizado em um ambiente com baixa irradiação, impossibilitando assim o diagnóstico em condições de máxima potência (Fadhel *et al.*, 2019).

A eletroluminescência é uma técnica de grande precisão e que consegue detectar a presença e localização de algumas anomalias como rachaduras e *shunts* nas células e potencial de degradação induzida com grande eficiência (Tsanakas, Ha e Shakarchi, 2017). É muito útil no processo de fabricação dos módulos, mas para sua aplicação em uma planta em funcionamento deve-se extrair o módulo da planta

para teste individual ou aplicar uma fonte de tensão no arranjo, o que requer que a instalação esteja preparada para corrente inversa ao sentido normal (Ballestín-Fuertes *et al.*, 2020; Haque *et al.*, 2019). Além disso, pode-se citar como limitadores de sua utilização em plantas de larga escala: a inspeção não é realizada em momento de máxima potência, uma fonte de grande potência deve ser utilizada para o caso de uma planta grande e por ser um ensaio puramente qualitativo e não quantitativo (Tsanakas, Ha e Buerhop, 2016).

2.2.3.2 Termografia Infravermelha


A IRT é uma técnica de inspeção não destrutiva e não invasiva que requer instrumentação mínima, realizada com a utilização de equipamentos sensíveis ao comprimento de onda infravermelho termal e tem como base a detecção da radiação emitida naturalmente pelos corpos com intensidade proporcional à sua temperatura (ABNT, 2022; BAUER, WESTFALL e DIAS, 2013; Oliveira, Aghaei e Rütther, 2020).

Essa técnica se baseia no fenômeno físico de que todo objeto que esteja com temperatura acima do zero absoluto (zero Kelvin) emite radiação. Para o registro das imagens térmicas o equipamento que se utiliza é o termovisor ou termocâmera. Esse equipamento monitora a temperatura e o fluxo de calor, fornecendo subsídios para a avaliação de materiais e do comportamento térmico (Holland e Reusser, 2016), fazendo a captura de imagem da radiação eletromagnética do infravermelho de ondas longas na faixa de comprimento de onda de 8 a 12 micrômetros emitida pelos objetos (Dunderdale *et al.*, 2020; IEC, 2017). A Figura 4 apresenta imagens capturadas por câmera termográfica e suas respectivas correspondências no espectro visível.

Gradientes de calor aparecem como pontos brilhantes em imagens térmicas por Infravermelho e indicam anomalias em módulos fotovoltaicos (Madeti e Singh, 2017). A Figura 5 apresenta exemplos de imagens termográficas (a e c) e suas correspondentes do espectro visível (b e d) em um arranjo fotovoltaico, onde se pode notar pontos quentes ou pontos mais frios em um ou mais módulos, os quais são identificados através dos pontos mais claros ou escuros nas imagens.


A partir do uso de imagens termográficas é possível a observação de áreas quentes e diferenças de temperatura nas células de um módulo (Aghaei *et al.*, 2015). Com efeito, despontam estudos que utilizam capturas de imagens termográficas do espectro infravermelho a fim de detectar anomalias em módulos em uma planta fotovoltaica em funcionamento. Essa técnica é empregada para avaliar o comportamento térmico das instalações fotovoltaicas, sendo utilizada para detectar pontos quentes, investigar o efeito de sombras e sujidades sobre os módulos,

Figura 4 – *Exemplo de detecção de pontos quentes por câmara termográfica infravermelha e suas respectivas imagens no espectro visível.*



Fonte: Fadhel *et al.* (2019)

Figura 5 – *Imagem termográfica de um módulo com sujidade (a), correspondente a imagem do espectro visível (b). A imagem (c) apresenta a imagem termográfica dos módulos sombreados (d).*



Fonte: Buerhop *et al.* (2022).

evidenciar defeitos de material e isolamento em painéis fotovoltaicos (ABNT, 2018; Ferreira, 2018; Le *et al.*, 2021). As vantagens da utilização da termografia vão além da possibilidade de diagnóstico sem a necessidade de desligamento da planta: o menor tempo despendido com a operação, a capacidade de realização do monitoramento em uma grande área, o custo relativamente baixo e ainda por ser um ensaio não destrutivo, são pontos relevantes a considerar (Kurukuru *et al.*, 2019; Usamentiaga *et al.*, 2014).

Para a inspeção termográfica, existem normas que devem ser observadas, dentre as quais a mais específica para a inspeção em sistemas fotovoltaicos é a IEC TS 62446-3:2017. No Brasil, as ABNT NBR 15572:2013; ABNT NBR 15424:2006; ABNT NBR 15763:2009; ABNT NBR 15718:2009 e ABNT NBR 15866:2010 são normas que orientam quanto às inspeções por termografia.

A utilização da IRT possui algumas limitações, devendo ser observadas as características do local, materiais e as influências das condições do ambiente sobre as mesmas (Garcia *et al.*, 2012). Para a realização da coleta de imagem termográfica do módulo fotovoltaico, o sistema deve estar operando sob irradiância mínima de 600 Wm^{-2} e com condições climáticas estáveis (ABNT, 2018).

2.3 Uso de Aeronaves Remotamente Pilotadas associado à Termografia

ARP é, de acordo com a *International Civil Aviation Organization* (ICAO), uma aeronave operada sem piloto humano a bordo, controladas remotamente por uma base em solo, ou podem ter seu percurso pré-definido e programado (ICAO, 2015). Modelos denominados *drones*, são um tipo de ARP de pequeno porte e que pelo seu baixo custo, facilidade de operação e simplicidade regulamentar são os mais utilizados em pesquisas na área de manutenção de plantas fotovoltaicas. Os modelos mais avançados já têm incorporados ao seu modelo câmera de alta resolução espacial no espectro visível e câmera termográfica. De acordo com a Agência Nacional de Aviação Civil (ANAC), modelos de *drones* com até 250 g e que não ultrapassem 121,92 metros (400 pés) de altura em voo, não necessitam de documento emitido pela instituição para realizar seus voos. Ressalte-se porém que a mesma agência indica que os usuários devem conhecer e seguir as normas contidas na Instrução de Comando da Aeronáutica ICA100-40/2020 (BRASIL, 2020).

Um exemplo de *drone* equipado com câmera térmica infravermelha e com

câmera de espectro visível é o modelo Mavic 3T fabricado pela empresa DJI¹ que está disponível no mercado. As especificações de sua câmera infravermelha atende aos requisitos mínimos da IEC TS 62446-3:2017 (Quadro 2).

Quadro 2 – *Requisitos mínimos para inspeção por IRT segundo a IEC TS 62446-3:2017.*

Recurso	Mínimo
Comprimento de onda infravermelho	2 μm a 5 μm ou 8 μm a 14 μm
Faixa de temperatura do objeto	-20° C a 120° C
Faixa de temperatura ambiente	-10° C a 40° C
Sensibilidade térmica	NETD $\leq 0,1$ K at 30° C
Resolução geométrica	1) Módulo fotovoltaico: máx. 3 cm da borda do módulo por pixel ² 2) Conexões elétricas: A resolução geométrica deve corresponder à menor área do objeto para ser verificado
Erro absoluto da medição	$< \pm 2$ K
Parâmetros ajustáveis	Emissividade (ϵ), temperatura refletida (T _{refl})
Funções ajustáveis	Foco, nível de temperatura e o período
Funções de medição	Ponto de medição, área de medição com média e máximo temperatura
Calibração	O sistema de medição (câmera, lente, abertura e filtro) deve ser calibrado de forma rastreável pelo menos a cada dois anos. A calibração deve ser documentada. Se a câmera estiver não conforme, poderá ser reajustado pelo fabricante.
Documentação	Armazenamento da imagem infravermelha com todas as informações radiométricas a serem capaz de determinar temperaturas absolutas. Imagens não radiométricas só pode fornecer padrões e, eventualmente, diferenças de temperatura.

Fonte: IEC (2017), adaptado pelo autor.

¹<https://enterprise.dji.com/pt-br/mavic-3-enterprise/specs>

2.4 Anomalias em Módulos Fotovoltaicos

Em plantas fotovoltaicas uma área relativamente grande é necessária para que se produza energia elétrica suficiente para seu aproveitamento. Por esse motivo, existe grande possibilidade que haja alguma iluminação não uniforme ou sombreamento parcial em algum módulo ou parte dele. No caso de um arranjo formado por módulos conectados em série a perda de eficiência em um módulo reflete-se em perda de potência em todos os módulos conectados nesse arranjo, sendo este fenômeno conhecido como *mismatch* (Hu *et al.*, 2014). Podem ser considerados fatores causadores de *mismatch*: sujidades, sombreamento parcial e incompatibilidades entre os módulos (Lorente *et al.*, 2014). Assim sendo, o monitoramento e manutenção dos módulos são requisitos para que a planta produza energia de forma eficiente.

Algumas causas comuns de degradação dos módulos que podem diminuir sua vida útil são: fatores ambientais tais como irradiação, temperatura, umidade, carga mecânica, sujidades e agentes químicos (naturais e industriais), além de fatores de estresse internos dentre os quais pode-se citar o processo de fabricação, arquitetura do módulo ou materiais utilizados e incompatibilidade de componentes (Aghaei *et al.*, 2022). Um dos objetivos da avaliação dos módulos em campo é descobrir os mecanismos de degradação destes, por ser um dos principais motivos para a diminuição do desempenho dos módulos fotovoltaicos ao longo de sua vida útil (Packa *et al.*, 2016). As falhas em um sistema fotovoltaico podem ser categorizados em permanentes ou temporários de acordo com sua duração (Madeti e Singh, 2017), onde falhas permanentes são aquelas que demandam intervenção direta na planta, com possível substituição de componentes ou de alteração no *layout* dos arranjos dos módulos da mesma.

2.5 Inteligência Artificial e Aprendizado de Máquina

Segundo Russell e Norvig (2004), o primeiro trabalho de grande relevância reconhecido como o início para se chegar à IA foi realizado por Warren Macculloch e Walter Pitts em 1943, que sugeriram um modelo de neurônios artificiais no qual cada neurônio era caracterizado como “ligado” ou “desligado”. O próximo grande passo foi dado por Alan Turing, que publicou o artigo intitulado “*Computing Machinery and Intelligency*” em 1950 onde apresentou o Teste de Turing. Entretanto, o termo “Inteligência Artificial” definido como “a ciência e engenharia de fabricação de máquinas inteligentes”, foi introduzida oficialmente por John McCarthy em 1956 em uma conferência em Dartmouth College (Collins *et al.*, 2021)

Um dos pilares do conceito de IA é o *Machine Learning* (ML) ou Aprendizado de Máquina que corresponde à construção de programas e rotinas que melhorem seu desempenho por meio de amostras (Tom, 1997). Esta técnica tem como um dos seus princípios a inferência indutiva para a derivação de conhecimento novo e predição de conhecimentos futuros. Quanto maior a quantidade e a qualidade dos dados inseridos, maior a chance de se obter resultados mais significativos. Para tanto, é necessário, além de uma quantidade considerável de amostras para o treinamento do computador, assegurar qualidade dos mesmos (LUDERMIR, 2021). O aprendizado de máquina qualifica sistemas com a capacidade de aprender e melhorar de forma automática, de acordo com sua experiência sem a necessidade de alterações explícitas em seu algoritmo (Choudhary e Gianey, 2017). Com o avanço da tecnologia e a disponibilidade cada vez maior de dados, é esperado que o ML tenha um papel cada vez mais importante no desenvolvimento de soluções para os mais diversos desafios.

A utilização de VC vem sendo beneficiada pelo desenvolvimento de uma subárea do ML que é o DL. É aplicado em RNC produzindo excelentes resultados em processamento de vídeo, reconhecimento de objetos, classificação e segmentação de imagens, processamento de linguagem natural, reconhecimento de fala e muitos outros campos (Chai *et al.*, 2021). O uso de técnicas de IA empregando esses modelos vem sendo pesquisada para ferramentas de diagnóstico de falhas em módulos fotovoltaicos, propondo sistemas preditivos com capacidade contínua de melhoria e adaptação às mudanças. Aplicações que se utilizam de DL incluem VC, processamento de linguagem natural, reconhecimento de vídeo e/ou voz e finanças e bancos (Chai *et al.*, 2021).

Algumas categorizações de anomalias em painéis fotovoltaicos utilizam-se de um recurso disponível para desenvolvimento do ML, o TensorFlow que é uma plataforma de código aberto que possui ferramentas, bibliotecas e recursos comunitários para que pesquisadores desfrutem do ML de última geração e também para que os desenvolvedores possam implementar aplicativos com tecnologia de ML (TensorFlow, 2020). O TensorFlow ainda pode ser utilizado na plataforma colaborativa Google Colaboratory, o que torna a tarefa de desenvolvimento em equipe mais simples (TensorFlow, 2022).

2.5.1 Categorias de ML

O ML tem avançado nos últimos anos destacando-se as áreas de VC. O ML consiste em projetar algoritmos que permitem que um computador aprenda, encontrando regularidades estatísticas ou outros padrões nos dados (Ayodele, 2010). Os algoritmos de ML podem ser organizados principalmente em aprendizagem

supervisionada, não supervisionada, semissupervisionada e por reforço (Ayodele, 2010).

No aprendizado de máquina supervisionado um sistema é treinado aproveitando dados de saída conhecidos e rotulados para utilização em problemas de classificação de dados. Cada exemplo é descrito por um vetor de valores (atributos) e pelo rótulo da classe associada, formando um conjunto de exemplos para treinamento (Mahesh, 2020). O conjunto de dados de entrada é dividido em amostras de treinamento e testes. Esses exemplos de treinamento fornecem ao sistema as respostas corretas, permitindo que ele aprenda a mapear os dados de entrada para os rótulos desejados, ou seja, construir um classificador que possa determinar corretamente a classe de novos exemplos ainda não rotulados (Sen, Hajra e Ghosh, 2020; LUDERMIR, 2021).

Uma aprendizagem não supervisionada caracteriza-se por modelar um conjunto de entradas onde exemplos rotulados não estão disponíveis. Algoritmos não possuem respostas corretas determinando por conta própria as características principais dos dados. Quando novos dados são introduzidos, utiliza os recursos apreendidos anteriormente para reconhecer a classe dos dados (Mahesh, 2020).

Pode-se citar ainda o algoritmo de aprendizagem semissupervisionada que combina exemplos rotulados e não rotulados para gerar uma função ou classificador apropriado, além da aprendizagem por reforço na qual o algoritmo aprende uma política de como agir dada uma observação do mundo, onde cada ação tem algum impacto no ambiente e o ambiente fornece *feedback* e orienta o algoritmo de aprendizagem (Ayodele, 2010).

2.5.2 Rede Neural Convolutional

As RNA são métodos para reconhecer padrões complexos ou numerosos com função de aprendizado dentro da própria rede (Alves, 2020). A técnica de RNA tem como premissa processar de forma matemática tarefas específicas de maneira semelhante aos neurônios biológicos. São em geral mais assertivas em tarefas complexas do que as técnicas tradicionais de computação (Mayo e Leung, 2018). Segundo Chen *et al.* (2015), os modelos de aprendizagem profundo são classificadores poderosos utilizados para reconhecimento de padrões.

Em meio às diferentes arquiteturas de RNA, as RNC demonstram superioridade em tarefas de reconhecimento visual, tais como classificação de imagens e detecção de objetos. É um tipo de rede neural onde um filtro denominado *kernel* de convolução é aplicado às imagens, sendo capaz de extrair características dos dados de entrada (Li *et al.*, 2022).

O *kernel* convolucional, também chamado de filtro ou máscara, é uma matriz de pesos que é aplicada por meio da operação de convolução sobre a imagem de entrada, definindo o padrão que a rede procura nas regiões da imagem. É o elemento que desliza sobre a imagem. Os produtos pontuais entre os elementos do *kernel* e os elementos correspondentes da imagem são calculados para obter a resposta da convolução. Essa operação de convolução é essencialmente um processo de sobreposição e multiplicação de elementos do *kernel* com os elementos correspondentes da imagem de entrada, seguido pela soma dos produtos resultantes (Wu, 2017; Li *et al.*, 2022). Isso produz uma resposta de convolução que destaca regiões da imagem onde o padrão definido pelo *kernel* se assemelha ao padrão presente na imagem. Ainda segundo Li *et al.* (2022), a RNC possui vantagens tais como:


- a) Conexões mais localizadas, reduzindo o número de conexões de cada neurônio com a camada anterior, diminuindo o número de parâmetros e acelerando a convergência;
- b) Compartilhamento de peso, onde um grupo de conexões pode compartilhar os mesmos pesos, o que reduz ainda mais os parâmetros e;
- c) Redução da dimensão de *downsampling* em que uma camada de *pooling* aproveita o princípio da correlação local da imagem (onde considera-se que os *pixels* vizinhos em uma imagem possuem correlação ou padrão) para reduzir a resolução de uma imagem, o que pode reduzir a quantidade de dados enquanto retém informações úteis.

A estrutura moderna da RNC foi descrita primeiramente em 1989, aplicada em classificação de dígitos manuscritos por LeCun *et al.* (1989), a partir da qual foi desenvolvido o LeNet-5 com múltiplas camadas em que poderia se utilizar o treinamento com o *Backpropagation* (Gu *et al.*, 2018). A Figura 6 apresenta uma representação das camadas utilizadas na arquitetura LeNet-5 (Lecun *et al.*, 1998), onde a rede é dividida em oito camadas. Essa rede foi projetada para trabalhar com imagens 32x32 *pixels*.

Resumidamente, na camada de entrada é inserida a imagem a ser analisada, seguindo para uma alternância de três camadas convolucionais e três camadas de *pooling* alternadas. Dentro das camadas de convolução (C1, C3 e C5) são aplicados filtros convolucionais às imagens contidas nas camadas anteriores, e seguem-se camadas de *pooling* para redução das dimensões da saída da camada de convolução (S2 e S4), utilizando a operação de *max pooling* para selecionar os valores mais altos em regiões sobrepostas. Após a camada C5, duas camadas densas são introduzidas seguidamente, sendo estas totalmente conectadas, nas quais uma função de ativação é aplicada utilizando a função tangente hiperbólica, ajudando a introduzir não-linearidades na rede (Lecun *et al.*, 1998). Uma terceira camada também totalmente

conectada, é utilizada com o número de neurônios correspondente às classes de saída desejadas. A função *Softmax* é aplicada para obter as probabilidades de classificação para cada classe.

Figura 6 – *Arquitetura da LeNet-5 na tarefa de reconhecimento de um dígito manuscrito.*



Fonte: Adaptado de Tsirigotis *et al.* (2023).


Já em 2012 foi proposto por Kirzhevsky, Sutskever e Hinton (2012) uma arquitetura semelhante à LeNet-5, porém com uma profundidade maior, obtendo sucesso e que foi denominada AlexNet. A partir de então, outros trabalhos surgiram explorando a profundidade da rede para melhorar a aproximação ao alvo (Gu *et al.*, 2018). Apesar das inúmeras variantes de arquiteturas RNC na literatura, seus componentes básicos são muito semelhantes ao proposto no LeNet-5, consistindo em três tipos de camadas: camadas convolucionais, *pooling* e totalmente conectadas (Gu *et al.*, 2018).

Uma das arquiteturas de RNC amplamente utilizada, é a que utiliza 2-D. Na RNC 2-D a entrada é geralmente uma imagem ou um conjunto de imagens, representadas como matrizes bidimensionais de *pixels*, onde cada *pixel* pode conter valores de intensidade ou cor. Sua dimensão é determinada pelo tamanho da imagem e o número de canais de cores. Utiliza-se o *padding* (preenchimento) para adicionar bordas de zeros ao redor da imagem de entrada, a fim de preservar a dimensionalidade espacial durante a convolução e reduzir o efeito de borda, ou seja, para não se perder informações das bordas da imagem.

A Figura 7 ilustra o procedimento de uma RNC 2-D no qual o núcleo convolucional percorre os dados originais com um *stride* igual a dois, tendo como resultado final uma (*Max Pooling*) (Li *et al.*, 2022). O *stride* é a quantidade de passos que o filtro de convolução dá ao se mover pela imagem de entrada. Um

stride de valor um, por exemplo, indica que o filtro se move uma posição de pixel por vez. O *stride* afeta o tamanho do mapa de características resultante e a quantidade de sobreposição entre as janelas de convolução. Ao final da convolução aplica-se o *max pooling* para reduzir a dimensionalidade espacial do mapa de características produzido pela camada de convolução. O treinamento dessa rede neural convolucional é considerado de relativa baixa complexidade e gera resultados coerentes, mesmo quando as imagens são capturadas em diferentes condições (Geng, Zhou e Cao, 2017).

Figura 7 – *Procedimento de uma Rede Neural Convolucional 2-D.*



Fonte: Adaptado de Li *et al.* (2022).

2.5.3 VGG-16

A VGG-16 é uma arquitetura de RNC utilizada para tarefas de classificação de imagens, especialmente projetado pelo *Visual Geometry Group* da Universidade de Oxford para o conjunto de dados ILSVRC (*ImageNet Large Scale Visual Recognition Challenge*). A VGG-16 é composta por uma série de camadas convolucionais seguidas por camadas totalmente conectadas. Os principais conceitos associados à arquitetura VGG-16, são: a entrada em tamanho e padrão de cor padronizado, pré-processamento com um único procedimento, filtro convolutacional 3x3, camadas de redução de tamanho, camadas totalmente conectadas ao final, e uso da função de ativação *ReLU* (Simonyan e Zisserman, 2015).

2.5.4 ResNet50

A ResNet foi proposta inicialmente por He *et al.* (2015) para utilização de funções residuais para diminuir a complexidade e a degradação de desempenho quando a rede se torna muito profunda. Propõe que em vez de tentar aprender

diretamente o mapeamento desejado, a rede deve tentar aprender a diferença entre esse mapeamento e a de entrada, ou seja, uma função residual.

A ResNet-50 implementa a aprendizagem residual em blocos, onde a saída de uma camada é adicionada à entrada, permitindo que a rede aprenda as diferenças entre as representações em vez de tentar aprender a função de transformação completa. Essas conexões de atalho são realizadas através da adição da entrada original à saída do bloco de convolução (He *et al.*, 2015).

2.5.5 Overfitting

O *overfitting* é um efeito indesejado, indicando que o modelo pode funcionar bem para os dados de treinamento, mas pode não apresentar os mesmos resultados para dados nunca antes vistos. Como esse efeito pode estar relacionado ao desbalanceamento da base de dados, à baixa quantidade de amostras em algumas classes de anomalias e, ainda ao excesso de iterações (Thanapol *et al.*, 2020).

Para mitigar esse efeito é comum a utilização de técnicas de aumento e equalização da quantidade de amostras, realizando procedimento de aumento artificial da base de dados, além do estabelecimento de um limite da quantidade de iterações (Basnet, Chun e Bang, 2020).

2.5.6 Aumento Artificial da Quantidade de Amostras

A capacidade de generalização dos modelos é um dos grandes desafios na confecção de uma rede neural. Generalização refere-se à diferença de desempenho quando se comparam os resultados de um modelo utilizando os dados de treinamento em relação ao mesmo executado com dados novos que não foram utilizados anteriormente (dados de teste) (Shorten e Khoshgoftaar, 2019). Ampliar artificialmente o seu número de imagens de treinamento ajuda a melhorar o procedimento geral de aprendizagem e o desempenho (Kamilaris e Prenafeta-Boldú, 2018).

Alves *et al.* (2021) utilizaram-se do aumento artificial de dados através de transformações geométricas como inversões verticais e horizontais para aumentar o número de imagens de classes menos representadas e dessa forma, minimizar o impacto da pouca quantidade de amostras em algumas classes da base de dados utilizada.

2.5.7 Métricas de Avaliação em Aprendizado de Máquina

Para a avaliação dos resultados do treinamento supervisionado de uma RNC, existem várias métricas que são utilizadas e a sua escolha depende do tipo

de problema enfrentado (Japkowicz e Shah, 2011). Algumas dessas métricas serão descritas nessa seção.

Uma das métricas mais simples e de fácil percepção é a acurácia, que mostra a relação entre o número de acertos e a quantidade total de amostras utilizadas. A acurácia é calculada pela Equação 1, onde NPC indica o número de predições corretas e NTP o número total de predições. Essa métrica apresenta a desvantagem de induzir ao erro quando a quantidade de amostras das classes apresenta grande desbalanceamento (Fernández *et al.*, 2019).

$$Acurácia = \frac{NPC}{NTP} \quad (1)$$

A Precisão expõe as predições que corretamente se revelaram realmente positivas (Murphy, 2022). É calculada pela Equação 2, onde VP indica as predições verdadeiramente positivas e FP as predições falsamente apontadas como positivas. Essa métrica indica a capacidade de não rotular uma amostra negativa como positiva.

$$Precisão = \frac{VP}{VP + FP} \quad (2)$$

Outra métrica utilizada para mensurar os resultados de um modelo de rede neural é a Sensibilidade ou *Recall*. Mostra a proporção de predições positivas corretas dentre todos os pontos positivos que um modelo poderia ter feito, fornecendo uma indicação de predições positivas perdidas (Powers, 2020). A Sensibilidade pode ser representada pela Equação 3 na qual FN representa as predições falsamente negativas.

$$Recall = \frac{VP}{VP + FN} \quad (3)$$

Uma métrica que compara as duas métricas anteriores é o *F1-Score*, onde a média harmônica entre as duas é calculada e seu valor é dado pela Equação 4 (Murphy, 2022).

$$F1-Score = 2 \times \frac{Precisão \times Recall}{Precisão + Recall} \quad (4)$$

Um *F1-Score* próximo de 1 indica um bom equilíbrio entre Precisão e *Recall*, significando que o modelo está acertando tanto na identificação correta dos verdadeiros positivos quanto na minimização dos falsos positivos e falsos negativos.

2.5.7.1 Matriz de Confusão

A matriz de confusão é uma ferramenta de avaliação de desempenho utilizada em tarefas de classificação para avaliar a exatidão das predições de um modelo (Luque *et al.*, 2019). É uma tabela cruzada que registra o número de ocorrências entre dois avaliadores, a classe verdadeiro/real e a classe predita pelo classificador (Grandini, Bagli e Visani, 2020). Para uma avaliação mais qualitativa do desempenho do classificador, considera-se que os resultados apresentados por uma matriz de confusão apresentam os resultados mais coerentes com o real índice de acertos do classificador treinado, apontando os ajustes a serem implementados no algoritmo. Seus resultados apresentam (Fawcett, 2006):

- a) valores situados na diagonal principal indicam os resultados classificados como “verdadeiro positivo”, onde apresentam as predições corretas, ou seja, quando a classe que se avalia é corretamente predita;
- b) os resultados “Falso positivo”, que ocorrem quando uma amostra que pertence à outra classe é classificado como pertencente à classe avaliada, e;
- c) os resultados “Falso negativo”, que ocorrem quando uma amostra pertencente à classe procurada é classificada como pertencente à classe distinta da avaliada.

Na Figura 8 é apresentada um exemplo de matriz de confusão, onde são representadas três classes reais e outras três preditas, classificadas por um sistema. Nesse exemplo, o sistema classificou corretamente cinco amostras X1, três X2 e onze X3. Observando-se somente a classe X1 a matriz apresenta: cinco classificações “Verdadeiro Positivo”; três “Falsos Negativos”: em que amostras pertencentes à classe X1 foram classificados incorretamente como X2 e; dois “Falso Positivo”: onde X2 foram identificados como X1.

Figura 8 – Exemplo de Matriz de Confusão com três classes.

Matriz de Confusão				
		Classe Predita		
		X1	X2	X3
Classe Real	X1	5	3	0
	X2	2	3	1
	X3	0	2	11

Fonte: Adaptado de Grandini, Bagli e Visani (2020).

Metodologia

Este capítulo descreve a metodologia utilizada para a escolha da técnica, ferramentas, base de dados e do desenvolvimento do sistema proposto, o qual baseia-se em normas técnicas, em folhas de dados de equipamentos e em trabalhos correlatos.

3.1 Etapas da Realização do Trabalho


A partir da avaliação de trabalhos anteriores, cujos temas são relacionados com o presente, foram selecionadas algumas técnicas de rede neural que poderiam ser aplicáveis ao propósito da pesquisa e também ferramentas que poderiam ser utilizadas para possibilitar a execução da mesma. A partir dessa seleção foi planejada a rede neural para que fosse possível detectar padrões de anomalias em imagens IRT de painéis fotovoltaicos.

A opção pela RNC se deu por seus resultados relatados em aplicações similares, em que foi proposto o reconhecimento de padrões em imagens, e por suas ferramentas que facilitam a implementação de RNC, tais como o TensorFlow e o Keras, que além de possuírem variadas ferramentas dedicadas ao tratamento de imagens e detecção de padrões, apresentam também vasta documentação disponibilizada e ainda são gratuitas. Por meio da revisão bibliográfica, a base de dados foi selecionada para a configuração e treinamento dessa RNC. Os hiperparâmetros foram ajustados e então realizaram-se testes monitorando-se a evolução das métricas de desempenho, principalmente a matriz de confusão, observando-se classe a classe os resultados até a obtenção dos resultados desejados. As etapas seguidas por esse trabalho são detalhadas na Figura 9. As seções seguintes apresentam as etapas contidas no fluxograma.

3.1.1 Revisão Bibliográfica

Nessa etapa, realizou-se uma busca em bases de dados listados no portal Periódicos CAPES ¹ por trabalhos relacionados à aplicação de IA em diagnósticos por imagens IRT de anomalias em painéis fotovoltaicos. Coletou-se e avaliou-se publicações cujos temas ou assuntos relacionam-se à IA, IRT e técnicas de detecção de anomalias em painéis fotovoltaicos. Essa pesquisa foi realizada por meio de palavras-chaves tais como “anomaly”, “Photovoltaic Panel” e “Convolutional Neural Network”, sendo selecionados os trabalhos de maior relevância. Nessa etapa ainda foi escolhida a base de dados *InfraredSolarModules*, disponibilizada pela equipe *RaptorMaps* (Millendorf, Obropta e Vadhavkar, 2020).

Figura 9 – Etapas da metodologia.



Fonte: Elaborado pelo autor.

Após essa seleção inicial, foi realizado uma filtragem de publicações com um recorte temporal dos últimos cinco anos para que se investigasse o estado da arte e as mais recentes técnicas aplicadas na detecção automática de anomalias. Utilizou-se plataforma Mendeley utilizada para a separação e catalogação dos trabalhos. Selecionaram-se os trabalhos em que a metodologia de coleta de dados e cujas técnicas de AI apresentam maiores relações com o tema proposto.

¹<https://www.periodicos-capes.gov.br.ezl.periodicos.capes.gov.br/>

3.1.2 Escolha da Arquitetura da Rede Neural

Foram avaliados trabalhos dos últimos anos que propuseram a utilização de ferramentas computacionais para classificar imagens em IRT coletadas de painéis e plantas fotovoltaicas em funcionamento. Procurou-se durante o processo de seleção das técnicas de análise de imagens buscar na literatura recente as que obtiveram os resultados mais promissores e com maiores possibilidades de implementação. Dentre as técnicas de IA avaliadas, foram escolhidas as que aplicaram Redes Neurais Artificiais e, dentro destas, as que se utilizaram Redes Neurais Convolucionais para a classificação das anomalias dos módulos. Uma vez que a RNC é projetada principalmente para reconhecer formas bidimensionais, cujo grau de invariância quanto aos modos de distorção sejam altos, após aprender um certo padrão em uma posição específica de uma imagem, a rede convolucional é capaz de reconhecê-lo em qualquer outro local da mesma (Haykin, 2001). Algumas vantagens da utilização de uma RNC descritas por Saleh e Hamoud (2021) são:

- a) As RNCs podem ser consideradas extratores automáticos de recursos da imagem, e a engenharia de características (que transforma dados brutos em características) não é necessária;
- b) A RNC usa efetivamente informações de *pixels* adjacentes para diminuir a amostra da imagem primeiro por operação de convolução e, em seguida, usa uma camada de predição no final;
- c) A RNC inclui os múltiplos usos do operador de convolução no processamento de imagens;
- d) A arquitetura RNC combina implicitamente os benefícios obtidos por um treinamento de rede neural padrão com a operação de convolução para lidar eficientemente com as tarefas solicitadas como classificação, reconhecimento e identificação e;
- e) A RNC também é escalável para grandes conjuntos de dados.

A Tabela 3 apresenta os trabalhos mais significativamente relacionados com o presente e seu modelo de rede neural empregado.

Foram testados modelos de RNC simples com três camadas convolucionais e uma camada densa, o modelo VGG-16 e também o modelo ResNet-50, para avaliar o comportamento dos mesmos em relação à base de dados utilizada. Esses últimos modelos foram escolhidos por apresentarem os melhores resultados nos trabalhos avaliados.

Quadro 3 – *Trabalhos relacionados e as técnicas de Inteligência Artificial utilizadas.*

Autor	Técnica Utilizada
Dunderdale <i>et al.</i> (2020)	RNC (VGG-16, MobileNet)
Bommes <i>et al.</i> (2021)	RNC (ResNet-50)
Akram <i>et al.</i> (2020)	RNC
Bommes <i>et al.</i> (2022)	RNC (ResNet-34, k-NN)
Le <i>et al.</i> (2021)	RNC (Vários modelos de ResNet)
Herraiz, Marugán e Márquez (2020)	RNC (R-CNN)
Espinosa, Bressan e Giraldo (2020)	RNC (<i>Backpropagation</i>)
Manno <i>et al.</i> (2021)	RNC
Alves <i>et al.</i> (2021)	RNC

Fonte: Compilado pelo autor.

3.1.3 Base de Dados

Bases de dados contendo imagens de anomalias em painéis solares são difíceis de encontrar para que se possa desenvolver técnicas de análise da saúde desses componentes. Isso se deve à falta de conjuntos de dados públicos com imagens detalhadas e classificadas das falhas nos painéis solares. Por esse motivo, o estudo “*InfraredSolarModules*” foi realizado pela empresa Raptor Maps, e disponibilizado de forma livre na plataforma Github² para que pesquisadores pudessem utilizá-la (Millendorf, Obropta e Vadhavkar, 2020).


As imagens contidas nessa base de dados foram classificadas em 11 classes de anomalias. Outra classe, contendo 10.000 imagens de módulos que estavam em funcionamento classificado como normal também foi incluída, totalizando assim 12 classes e 20.000 amostras. Importante destacar que a classe de funcionamento considerado normal foi incluída para que outras anomalias não incluídas nas 11 classes de anomalias apresentadas pudessem ser detectadas em outros trabalhos (Millendorf, Obropta e Vadhavkar, 2020).

Os dados foram agregados pela equipe da empresa e coletados utilizando aeronaves controladas por sistemas não tripulados equipados com imagens termográficas em infravermelho de ondas médias ou longas (3-13,5µm). Além disso, foram coletadas imagens do espectro visível correspondentes, usadas durante a classifica-

²<https://github.com/RaptorMaps/InfraredSolarModules>

ção para aumentar a acurácia (Millendorf, Obropta e Vadhavkar, 2020). Segundo os autores, a coleta foi feita respeitando as orientações que constam na IEC (2017). As imagens possuem uma resolução de 24 x 40 *pixels* e foram rotuladas por especialistas, auxiliados pelas imagens do espectro visível. As configurações mínimas da câmera termográfica infravermelha que a IEC (2017) sugere são aquelas apresentadas na Tabela 2. A base de dados resultante, disponibilizada contém somente as imagens em IRT. A Figura 10 apresenta exemplos de imagens de cada classe de anomalia que estão contidas nesse estudo.

Figura 10 – *Amostras de imagens classificadas da base de dados.*



Fonte: Adaptado de Le *et al.* (2021).

Na Tabela 1 são relacionadas as anomalias identificadas, suas respectivas quantidades e suas descrições, que foram classificadas e rotuladas nessa base de dados. Uma das limitações percebidas para o uso dessa base de dados escolhida, além da baixa resolução das imagens, é o desbalanceamento da quantidade de imagens de algumas classes, pode causar baixa acurácia na classificação das mesmas (Alves *et al.*, 2021). Apesar dessas limitações, essa base de dados foi utilizado em outros trabalhos como os de Alves *et al.* (2021) e o de Le *et al.* (2021), sendo assim uma escolha considerada adequada para utilização por fornecer parâmetros de comparação para os resultados obtidos.

Tabela 1 – *Descritivo e quantidade de amostras de cada classe na base de dados disponibilizada pela empresa RaptorMaps.*

Anomalia	Amostras	Descrição
Célula	1.877	Ponto quente em uma única célula com geometria retangular.
Múltiplas Células	1.288	Pontos quentes em formato retangular em múltiplas células.
Trincas	940	Anomalia no módulo causada por trincados na superfície do módulo.
Ponto quente	249	Apresentam um único ponto de aquecimento no módulo.
Múltiplos pontos quentes	246	Apresenta mais do que um ponto quente no módulo.
Sombreamento	1.056	Obstrução da luz solar por vegetação, estruturas ou fileiras adjacentes.
Diodo	1.499	Diodo de desvio ativado, onde 1/3 do módulo apresenta aquecimento.
Múltiplos Diodos	175	Múltiplos diodos de desvio ativados, onde 2/3 do módulo apresenta aquecimento.
Vegetação	1.639	Módulo sombreados por vegetação.
Sujidades	204	Anomalia causada por sujidades, pó ou outros detritos na superfície do módulo.
Desligado	827	O módulo desligado com aquecimento em toda a superfície.
Sem Anomalias	10.000	Módulo em operação normal.

Fonte: Adaptado de Millendorf, Obropta e Vadhavkar (2020).

3.1.4 Aumento Artificial de Amostras

Uma base de dados balanceada, com as classes com quantidades de amostras equilibradas, é muito difícil de se encontrar ou produzir somente por meio da coleta de dados. Além disso, é possível que a quantidade de dados existente sobre um determinado objeto ou classe seja muito pequena para treinar a rede.

Uma das consequências de se utilizar uma base de dados limitada ou desbalanceada, é que a RNC pode não produzir a generalidade necessária para trabalhar com o conjunto de dados de teste. O modelo poderá sofrer o indesejado efeito de *overfitting*, ou seja, o modelo tender à especialização na base utilizada,

apresentando assim uma acurácia elevada no treinamento mas não repetindo o desempenho nos testes.

Para minimizar o impacto desse desbalanceamento, alguns trabalhos utilizam técnicas de aumento de dados como a descrita no trabalho de Alves *et al.* (2021), onde aumentou-se artificialmente a quantidade de imagens de classes que apresentavam pequena base de dados por meio de deslocamentos (0,2) aplicado na largura e do espelhamento horizontal e vertical das amostras existentes. Tal estratégia se mostrou eficaz para o aumento da assertividade da rede treinada.

Além da aplicação de modificações já implementadas no trabalho de (Alves *et al.*, 2021) tais como pequenas rotações e espelhamentos horizontais e verticais nas imagens originais para aumentar artificialmente o número de amostras, foram adicionadas outras modificações nas imagens existentes para aumentar a abrangência da representatividade das imagens: modificações aleatórias dentro de intervalos (2% a -2%) no brilho e pequenas rotações de até 5° também foram incluídas por meio da ferramenta *Image Data Generator* pertencente à biblioteca Keras.

3.2 Programação

Para a confecção e execução do modelo de RNA, escolheu-se a linguagem Python. A linguagem de programação Python é uma linguagem *Open-Source* de propósito geral, muito utilizada em *Data Science*, ML e desenvolvimento de aplicações, sendo bastante versátil, apresenta farta documentação técnica, vasta biblioteca de recursos e aplicabilidade em projetos que utilizam IA.

Foi utilizada para o desenvolvimento do *script*, a plataforma livre e colaborativa Colaboratory³, disponível na internet para programação em linguagem Python que permite o compartilhamento do desenvolvimento do código, além de permitir a utilização de recursos computacionais de servidores do Google.

A configuração do equipamento em que se executou o código, variou devido a disponibilidade dos servidores do Google, pois a execução dos códigos depende da alocação dinâmica de recursos. Em geral, utilizou-se uma GPU NVIDIA Tesla T4 com 15 GB de RAM disponíveis. Quando não foi possível utilizar esse conjunto de *hardware*, o código foi direcionado para execução em CPU (não especificado) com um núcleo físico, dois lógicos e 12 GB de RAM, ocasionando uma redução de desempenho e aumento do tempo gasto para execução do modelo. Para efeito de comparação de tempo de execução, os cenários escolhidos como pontos de referência que não

³<https://colab.research.google.com/>

puderam ser executados em GPU em sua primeira execução, foram executados novamente quando a GPU foi disponibilizada.

Uma biblioteca muito utilizada em Python para o desenvolvimento de redes neurais profundas é o TensorFlow. Essa biblioteca multiplataforma de código aberto é desenvolvida pelo time Google Brain Team⁴. Uma característica importante dessa biblioteca é o suporte que a comunidade de usuários disponibiliza (Kapoor *et al.*, 2022). Utilizou-se ainda o Keras⁵, uma interface de alto nível que faz a ligação com o TensorFlow, facilitando a utilização desse recurso. Essa interface tem como principais vantagens citadas pelo desenvolvedor: a facilidade de uso, os modelos modulares e compostos e a facilidade de extensão.


Um modelo sequencial do TensorFlow foi utilizado para configurar o cenário que serviu de base para o desenvolvimento do sistema. Esse modelo é recomendado por sua simplicidade e eficiência em termos de treinamento e inferência, sendo baseado nos trabalhos de Kirzhevsky, Sutskever e Hinton (2012) e em uma simplificação do modelo proposto por Simonyan e Zisserman (2015). Para o treinamento da RNA, utilizou-se a base de dados *InfraredSolarModules*. Após os testes com esse modelo, configurou-se ainda cenários que se utilizaram de modelos pré-treinados para investigar seus desempenhos frente ao modelo proposto. O algoritmo elaborado para o desenvolvimento do *script* inclui as etapas apresentadas no fluxograma da Figura 11.

Nesse algoritmo, a Etapa 1 envolve a instalação de bibliotecas e módulos necessários à execução do software. Uma vez instaladas as bibliotecas, a importação do pacote da base de dados, contendo as imagens e o arquivo contendo os rótulos das imagens, baixados diretamente da plataforma Github. No processo de descompressão, cada imagem é salva em pastas conforme o tipo de anomalia e a contagem de arquivos é realizada para uso em estatísticas. As etapas seguidas para a elaboração do código são apresentadas:

Etapa 1 - Importar e instalar as bibliotecas: onde as bibliotecas tais como a biblioteca Numpy para trabalhar com vetores, OS para trabalhar com diretórios de sistema, PIL para manipulação de imagens, TensorFlow para utilizar recursos de ML, Pathlib para trabalhar com caminhos de sistema de arquivos, Matplotlib para plotar gráficos e imagens, Shutil para copiar arquivos e Pandas que fornece estruturas de dados e funções de manipulação de dados entre outras;

⁴<https://www.tensorflow.org/?hl=pt-br>

⁵<https://keras.io/>

Figura 11 – *Fluxograma da programação.*

Fonte: Elaborado pelo autor.

Etapa 2 - Importar a base de dados: a partir de um URL especificado é obtida a base de dados utilizada para treinamento da rede e seus dados são extraídos para um diretório específico;

Etapa 3 - Montagem dos diretórios com a separação das classes: descompactam-se dentro das respectivas pastas, os arquivos contendo a base de dados de imagens e rótulos, com base nas classes atribuídas a eles;

Etapa 4 - Definir o modelo da RNC: os hiperparâmetros das camadas convolucionais e densas são definidos, indicando a quantidade dessas camadas e suas sequências;

Etapa 5 - Configurar os hiperparâmetros: número de iterações, dimensões das amostras, dimensões dos filtros convolucionais e modelos de otimizadores são configurados,


Etapa 6 - Treinamento do modelo: execução do modelo, e;

Etapa 7 - Avaliação dos resultados obtidos: as métricas são apresentadas e os resultados do modelo avaliados.

Indicações que se obteve no trabalho de Saleh e Hamoud (2021) serviram

como referência para a escolha dos hiperparâmetros iniciais tais como o tamanho dos lotes, número de camadas de convolução e suas ativações, quantidade de iterações e as configurações das camadas densas. Figura 12 apresenta o diagrama da rede proposta. A estrutura da rede foi montada em camadas convolucionais seguidas por camadas de *pooling* com redução de dimensionalidade.

Figura 12 – Diagrama da estrutura da Rede Neural Convolucional Simples proposta.



Fonte: Elaborado pelo autor

Uma camada de normalização dos dados é aplicada à imagem a ser processada para a certeza de padronização dos dados de entrada, escalando os valores dos pixels para um intervalo específico (entre 0 e 1) pois algoritmos de aprendizado de máquina podem funcionar melhor trabalhando nesse intervalo. Técnicas de normalização são abordadas por Goodfellow, Bengio e Courville (2016). Ao normalizar as entradas procura-se mitigar os efeitos da mudança na distribuição das entradas.

Funções de ativação desempenham um papel fundamental no aprendizado da rede neural, ao introduzirem não linearidades nas operações, permitindo assim, que a rede aprenda e represente relações complexas nos dados. A função de ativação utilizada no presente trabalho foi a ReLU (Rectified Linear Activation). Ela é uma função simples e eficaz que retorna zero para valores negativos e o próprio valor para valores positivos. É calculada através da Equação 5. A principal vantagem de usar a função ReLU sobre outras funções de ativação é a não ativação de todos os neurônios ao mesmo tempo, pois se a entrada for negativa ela será convertida em zero e o neurônio não será ativado tornando a rede esparsa, eficiente e simples para a computação.

$$ReLU(x) = \max(0, x) \quad (5)$$

Após essa camada convolucional, reduz-se à metade as dimensões da imagem através de uma camada de *max pooling*, retendo assim as características mais importantes detectadas pelo filtro convolucional. Repetiu-se então os procedimento de convolução seguida de *max pooling* por mais duas vezes. Após aplicação desses

procedimentos, a camada *Flatten* foi utilizada para converter a saída das camadas convolucionais em um vetor unidimensional e camada densa, com neurônios totalmente conectados e a camada de saída igual ao número de classes.

3.3 Treinamento da Rede Neural

O treinamento da rede foi realizado utilizando-se vários cenários com variações dos hiperparâmetros definidos inicialmente para a análise dos resultados apresentados. Testou-se novas configurações da rede neural, com diferentes números de filtros convolucionais além de diferentes funções de ativação. Devido à baixa resolução e dimensões reduzidas das imagens de entrada, a aplicação de novas camadas convolucionais não apresentou melhora significativa. Após a execução dos primeiros cenários, notou-se que a baixa quantidade de amostras em algumas classes causava uma influência negativa no desempenho da rede nas mesmas. Optou-se então por incluir uma etapa de aumento artificial de dados após a verificação da quantidade de imagens copiadas por classe. Nessa etapa foram realizados os procedimentos de aumento artificial de amostras sugeridos na Seção 3.1.4. Levou-se em consideração o tempo gasto para as iterações, a disponibilidade de recursos computacionais e a progressão do aprendizado da rede. Os resultados apreendidos nas métricas Precisão, *Recall* e *F1-Score*, e na matriz de confusão ofereceram os indicadores para as próximas modificações de hiperparâmetros. A cada modificação foram registradas as configurações utilizadas, os resultados das métricas e a matriz de confusão gerada.

Como mencionado na Subseção 3.2 (Programação), realizou-se testes com dois modelos pré-treinados disponíveis na biblioteca Keras. Os dois modelos (VGG-16 e ResNet 50) foram escolhidos por seus resultados significativos em trabalhos avaliados. O primeiro a ser testado foi o modelo que se utiliza da arquitetura VGG-16, que foi utilizado com sucesso no trabalho de Dunderdale *et al.* (2020). O segundo modelo utilizou a arquitetura ResNet-50 que apresentou resultados significativos no trabalho de Bommes *et al.* (2021).

3.4 Validação Cruzada

A validação cruzada é uma técnica amplamente utilizada na validação de modelos em ciência de dados e aprendizagem de máquina. É utilizada para avaliar o desempenho de um modelo em dados não vistos, reduzindo o risco de *overfitting* (Berrar *et al.*, 2019).

O modelo de validação cruzada *K-fold*⁶ consiste em dividir o conjunto de dados em grupos, onde o valor de K corresponde à quantidade desses grupos. Cada um deles é tratado como um conjunto de dados de treinamento ou validação para avaliar o modelo (Zhang e Liu, 2023). O modelo executa o algoritmo o número K de vezes, sendo que, a cada execução um conjunto da base de dados é separado para teste e o restante utilizado para treinamento.

O *K-fold cross validation* é uma boa maneira de avaliar como o modelo se comporta diante de variações nas amostras de treinamento e ajuda a evitar a influência da divisão dos dados na métrica. Testes empíricos em ML mostram que valores bastante confiáveis para o número de dobras são 5 e 10 pois estes valores não causam erros altos em teste de viés e de variância (Marcot e Hanea, 2021). Essa técnica é utilizada para melhorar a validação e reduzir o risco de superespecialização do modelo. Uma vez finalizada a execução da quantidade de dobras, a média das métricas é registrada. A Figura 13 apresenta o diagrama do modelo K-fold de validação cruzada, utilizando cinco dobras (K=5).

Figura 13 – Diagrama de Execução da Validação Cruzada *K-fold*.

Base de Dados					
Iteração 1	Treino	Treino	Treino	Treino	Validação
Iteração 2	Treino	Treino	Treino	Validação	Treino
Iteração 3	Treino	Treino	Validação	Treino	Treino
Iteração 4	Treino	Validação	Treino	Treino	Treino
Iteração 5	Validação	Treino	Treino	Treino	Treino
Dados para treinamento (4/5 do total de amostras)					
Dados para validação (1/5 do total de amostras)					

Fonte: Elaborado pelo autor

3.4.1 Métricas para Avaliação dos Resultados

Foram incluídas as métricas Precisão, *Recall* e *F1-score* para medir a evolução da rede em cada cenário executado, assim como foram observadas as matrizes de confusão geradas. Ressalte-se que a matriz de confusão e a métrica *Recall* foram os indicadores considerados mais significativos para avaliar a evolução da rede pois entende-se que para as equipes de manutenção, uma indicação de anomalia em um módulo que não a possui pode ser objeto de investigação por um especialista e,

⁶https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.KFold.html

assim, não ser descartada prematuramente sem melhor avaliação. Assim, essas duas métricas são apresentadas nos resultados.

3.5 Execução dos cenários

A modificação dos cenários foi realizada em etapas, testando-se várias configurações da arquitetura da rede neural. Avaliou-se ainda o aumento artificial da base de dados e a mudança de quantidade de classes, mesclando-se algumas delas de acordo com o tipo de anomalia. A cada alteração foram comparados os resultados com os de cenários já testados para que se identificassem pontos de melhora ou piora na acurácia da rede.

3.5.1 Cenário Referência

Inicialmente a base de dados foi mantida com a quantidade original de amostras em cada classe de anomalias e foram realizados testes utilizando-se algumas configurações de camadas convolucionais. Foi escolhida a configuração com três camadas convolucionais sequenciais, contendo 32 filtros 3x3 e função de ativação ReLU. Essas camadas foram intercaladas com camadas de redução de dimensionalidade e no final camadas densas com a camada de saída contendo 12 classes. Nesse cenário ainda não se utilizou o *K-Fold*, separando-se aleatoriamente 80% de amostras para o treinamento (16.000 imagens) e os 20% restantes para testes (4.000 imagens). Configurou-se o modelo para realizar 80 iterações, e esse cenário foi registrado e nomeado como Cenário 1 para que se estabelecer os resultados que serviram de parâmetros iniciais.

Uma vez registrados os resultados do Cenário 1 testou-se variações na proporção entre quantidade de amostras para treinamento (75%) e teste (25%), além da quantidade de filtros nas camadas convolucionais, em que se variou de 32 para 64 filtros em cada uma das camadas e também em todas as camadas. A cada variação de hiperparâmetros ou de configuração da RNC, foram anotadas as alterações nos resultados das métricas e também resultados de cada classe na matriz de confusão.

3.5.2 Introdução da Validação Cruzada e Aumento Artificial de Dados

Nos cenários subsequentes, implementou-se uma rotina de validação cruzada por meio da ferramenta *K-fold* da biblioteca *sklearn* conforme descrito na seção 3.4 (Validação Cruzada), para que fosse garantida uma melhor generalização do modelo (Jiang e Wang, 2017). A base de dados foi ampliada para que houvesse maior variação

de imagens, simulando maior ou menor intensidade de brilho, pequena mudança de ângulo no plano cartesiano das imagens e mudança de posição das anomalias através do espelhamento das imagens, para que o modelo pudesse ter mais referências na detecção de padrões nas anomalias.

Para a configuração do modelo utilizando a validação cruzada empregou-se a ferramenta *K-fold* configurada com cinco dobras e, para aumentar artificialmente a quantidade de amostras, utilizou-se a ferramenta *Image Data Generator* da biblioteca *Keras*. Essa ferramenta aplica as modificações descritas nas amostras originais até que se atinja a quantidade de amostras especificada pelo usuário em cada um dos cenários, tal como descrito na seção 3.1.4 (Aumento Artificial de Dados). Para a execução do Cenário 2, a quantidade de amostras foi fixado em 2.000 amostras, totalizando 24.000 amostras no total. A quantidade de amostras da classe Sem Anomalias foi reduzida e as demais sofreram acréscimo até que se atingisse a quantidade estipulada.

Uma forma que se utilizou para averiguar se um aumento maior da base de dados implicaria em melhora do desempenho foi elevando a quantidade equalizada de amostras das classes. O Cenário 3 foi configurado com um aumento de dados em todas as classes para uma quantidade de 5.000 amostras em cada classe, resultando um total de 60.000 amostras. Todos os demais hiperparâmetros foram mantidos em relação ao Cenário 2.

3.5.3 Junção de Classes

Para verificar o impacto que a junção de classes com o mesmo tipo de anomalia e diferenças apenas na quantidade de ocorrências em um único módulo produziria, foi realizado tal procedimento no Cenário 4. As classes Célula e Múltiplas-Células foram reunidas em uma única classe. O mesmo procedimento foi realizado com as classes Diodo e Múltiplos-Diodos e com as classes Pontos-Quentes e Múltiplos-Pontos-Quentes. Nesse cenário, foram então consideradas nove classes no total e a quantidade de amostras foi mantida em 5000 imagens em cada classe, sendo que o aumento de dados foi realizado anteriormente à junção das classes, totalizando assim 60.000 amostras.

3.5.4 Modelo Final da RNC Proposta

Para se atingir o objetivo proposto por esse trabalho foi estabelecido uma nova junção de classes que foi configurada tendo como foco principalmente o auxílio à tomada de decisão das equipes de operação e manutenção das plantas. Classes de

anomalias que exigem um mesmo tipo de intervenção para a solução de seu problema foram reunidas, resultando em três classes:

- a) classe Sem Anomalia, onde são reunidas as imagens de módulos em funcionamento normal, indicando que não são necessárias intervenções;
- b) classe Desconexão, na qual alocam-se as classes de anomalias Ponto-Quente, Múltiplos-Pontos-Quentes, Diodo, Múltiplos-Diodos, Célula, Múltiplas-Células e Módulo-Desligado, que requerem a retirada dos módulos para testes mais aprofundados e ocasionalmente sua substituição, e;
- c) classe Manutenção Básica, que reúne as classes de anomalias Sujidade, Vegetação e Sombreamento, em que em uma manutenção normalmente não é necessário o desligamento da planta e retirada do módulo para realizar tal correção.

Entende-se que de posse dessas informações um especialista pode tomar a decisão da melhor maneira de abordar os problemas que porventura sejam encontrados. Por exemplo, caso sejam encontradas falhas em módulos da classe de anomalias desconexão, o profissional especialista poderá solicitar à equipe de manutenção o desligamento do sistema fotovoltaico e a imediata substituição do módulo detectado com a anomalia.

Nesse cenário foi utilizado uma equalização de 5.000 imagens para cada classe de anomalias antes da junção das classes, mantendo a classe Sem-Anomalia com as 10.000 amostras originais. Para possibilitar a comparação com os resultados com os próximos cenários, os cenários configurados com as arquiteturas VGG-16 e ResNet50 utilizaram os mesmos procedimentos de equalização.

3.5.5 Modelo VGG-16

Por meio da utilização de transferência de aprendizado, testou-se o modelo de rede neural VGG-16. Como sugerido por Zhang *et al.* (2015), a transferência de aprendizado é mais eficaz do que um modelo treinado desde o início, demandando menor custo computacional e com resultados melhores. Esse cenário foi denominado Cenário 6 e para a sua execução foi alterada a resolução das imagens para 55x33 *pixels*, mantendo a proporção original de *pixels* entre as dimensões das imagens. Tal modificação foi necessária pois a resolução mínima da imagem para que se possa utilizar o modelo é de 32x32 *pixel*.

3.5.6 Modelo ResNet50

No Cenário 7 foi utilizada a arquitetura ResNet50, também disponibilizada na biblioteca do Keras. Foi utilizado o mesmo redimensionamento das amostras do Cenário 6, pois as exigências do modelo quanto às dimensões mínimas das imagens são as mesmas.

Resultados

A partir da observação de trabalhos relacionados e da análise da documentação das bibliotecas selecionadas, desenvolveu-se o algoritmo utilizado como base nesse trabalho. Realizou-se testes de funcionalidade do mesmo e cenários foram configurados para verificação do impacto do ajuste de cada hiperparâmetro na eficiência do modelo. Os resultados de cada cenário e suas análises são apresentados nesse capítulo.


4.1 Cenário de Referência

O primeiro cenário foi configurado testando-se diversas opções de valores de hiperparâmetros e em sua composição mais eficiente obteve os resultados apresentados na Figura 14 e na Figura 15. Esses valores de hiperparâmetros foram registrados e se tornaram referência para o arranjo dos outros cenários.

A matriz de confusão apresenta um indicativo sobre os fatores que exerceram influência no resultado geral da rede. Observa-se na Figura 14 que as classes Múltiplas-Células, Ponto-Quente, Múltiplos-Pontos-Quentes, Módulo-Desligado, Sombreamento e Sujidade, obtiveram índices abaixo da média das predições corretas (48,41%). Esse valor foi obtido através do cálculo da média simples da diagonal principal da matriz de confusão.


Observando o gráfico da Figura 17, em que são apresentados os resultados da métrica *Recall* em cada classe (Equação 3), é possível notar que em classes com baixa quantidade de amostras (ver Tabela 1), a identificação correta das instâncias positivas do modelo obtém resultados abaixo de 0,5, onde resultados mais próximos de 1 indicam melhor eficiência do modelo. Além da insuficiência para o treinamento da rede, o desequilíbrio entre as quantidades de amostras de várias classes pode ocasionar desvios na funcionalidade do modelo, podendo prejudicar a convergência e a generalização (Buda, Maki e Mazurowski, 2018). Esse comportamento foi relatado em trabalhos como o de Alves *et al.* (2021).

Figura 14 – *Cenário 1 - matriz de confusão gerada utilizando a base de dados com 20.000 amostras.*



Fonte: Do Autor

Figura 15 – *Recall resultante do Cenário 1.*




Fonte: Do Autor

Outro fator a se considerar é que as imagens IRT de algumas classes apresentam características similares às de outras, como observado na Figura 16,

podendo levar a rede a cometer esses equívocos. Um exemplo desse erro pode ser visualizado na matriz de confusão da Figura 14, em que a rede classificou amostras da classe sujidade como pertencentes à classe trincado em 16,2% do total das análises, sendo tal resultado maior que o acerto da rede nessa classe (8,1%). Classes com maiores quantidades de amostras disponíveis ou com padrões mais definidos, obtiveram maiores índices de acerto.

Figura 16 – *Exemplo de imagens de classes apresentando padrões com semelhança.*




Fonte: Adaptado de Millendorf, Obropta e Vadhavkar (2020)

Dentre as modificações dos hiperparâmetros realizadas, a redução da quantidade de iterações para menos de 80 mostrou-se ineficiente, pois observou-se uma diminuição na acurácia do modelo. Ao aumentar a quantidade de iterações acima de 80 ciclos, foi notado uma tendência à superespecialização (*overfitting*). Para corroborar com essa conclusão, foi testado variações relacionadas à quantidade de iterações (50, 80 e 100) em todos os cenários, para que se pudesse avaliar qual das alternativas apresentaria melhor resultado.

4.2 K-Fold e Aumento Artificial de Dados


Mantendo-se a estrutura do modelo utilizado no Cenário 1 e introduzindo-se uma rotina de validação cruzada e de aumento artificial da quantidade de amostras em todas as classes de anomalias, foi executado o modelo nomeado como Cenário 2. As classes de anomalias receberam amostras geradas artificialmente e a classe Sem Anomalias foi reduzida, para que ficassem equalizadas em 2.000 amostras. Sua execução obteve com resultado uma média ponderada de acertos de 55,71%, apresentando uma melhora de 7,30% em relação ao melhor resultado obtido no Cenário 1. A matriz de confusão resultante da execução desse código é apresentada na Figura 17 e o *Recall* por classes na Figura 18. Com a introdução da validação cruzada, foi notado uma demora maior na execução do *script* mas a generalização do modelo foi incrementada.

Figura 17 – *Cenário 2 - introdução de K-fold e base de dados aumentada para 24.000 amostras.*



Fonte: Do Autor

Figura 18 – *Recall por classes resultantes do Cenário 2.*



Fonte: Do Autor

Promovendo um aumento maior na quantidade de amostras, o Cenário 3 obteve uma melhora em relação ao Cenário 2 em todas as classes conforme constatado na matriz de confusão da Figura 19 e no gráfico do *Recall* (Figura 20).

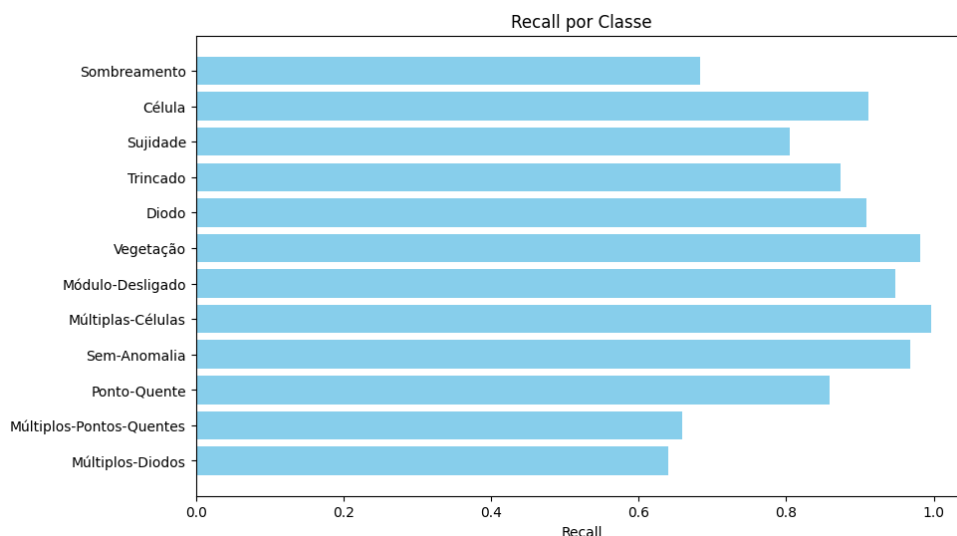
Figura 19 – *Cenário 3 - base de dados aumentada para 60.000 amostras.*

		Matriz de confusão (%)											
Classe Real	Múltiplos-Diodos	64.0	12.7	2.8	0.6	0.1	0.6	0.6	3.6	2.7	1.7	1.5	9.1
	Múltiplos-Pontos-Quentes	12.0	65.9	8.2	0.5	0.1	0.5	0.5	1.1	1.1	1.4	1.9	6.8
	Ponto-Quente	3.3	4.5	85.9	0.3	0.0	0.3	1.7	0.3	0.8	0.4	1.0	1.4
	Sem-Anomalia	0.1	0.4	0.1	96.8	0.4	0.1	0.1	1.0	0.5	0.4	0.0	0.0
	Múltiplas-Células	0.0	0.0	0.0	0.2	99.6	0.0	0.0	0.1	0.1	0.1	0.0	0.0
	Módulo-Desligado	0.3	0.7	0.1	0.2	0.1	94.8	2.5	0.7	0.2	0.3	0.0	0.1
	Vegetação	0.1	0.1	0.1	0.2	0.0	0.4	98.1	0.3	0.1	0.3	0.1	0.3
	Diodo	1.2	0.3	0.0	1.2	0.2	0.9	0.6	90.9	2.7	1.3	0.1	0.6
	Trincado	0.9	0.6	0.1	0.8	0.3	0.5	2.0	5.0	87.4	1.9	0.1	0.4
	Sujidade	1.6	2.9	1.2	0.9	0.3	0.9	1.5	6.0	2.4	80.5	0.4	1.4
	Célula	1.6	0.8	2.3	0.0	0.1	0.2	2.8	0.1	0.1	0.4	91.1	0.6
	Sombreamento	10.8	6.7	2.9	0.4	0.1	0.2	0.9	2.8	2.1	3.1	1.6	68.4
		Múltiplos-Diodos	Múltiplos-Pontos-Quentes	Ponto-Quente	Sem-Anomalia	Múltiplas-Células	Módulo-Desligado	Vegetação	Diodo	Trincado	Sujidade	Célula	Sombreamento
		Classe Predita											

Fonte: Do Autor

Esse cenário confirmou a relação entre o desempenho de acertos do modelo e a quantidade de amostras disponíveis uma vez que nesse cenário equalizou-se a quantidade de amostras em cada classe em 5.000.

Foi notado um aumento no tempo de execução do código, resultado do tempo gasto para geração de imagens adicionais e, principalmente, da quantidade de iterações totais exigidas pela validação cruzada, indicando que o aumento da quantidade de amostras impactou o tempo de execução, limitando assim a utilização desse recurso. Ressalte-se que o ganho na exatidão das predições do modelo compensou o aumento de tempo, uma vez que o modelo atingiu uma média de acertos de 85,29%.

Figura 20 – *Recall por classes resultantes do Cenário 3.*

Fonte: Do Autor

4.3 Junção de Classes


Observando a nova estrutura de classes experimentada na configuração do Cenário 4, verifica-se que não houve diferença significativa da média geral em relação ao Cenário 3, resultando na média de acertos de 84,58% que é praticamente igual à do Cenário 3. Nota-se que, no Cenário 4, a taxa de acerto das classes resultantes da união de duas classes, ficaram numericamente no intervalo entre as taxas de acerto das classes originais obtidas no Cenário 3. Os resultados do Cenário 4 são apresentados na Figura 21 e na Figura 22.

4.4 Modelo Final da RNC

A partir de uma nova forma de reunir as classes em que a classificação das anomalias objetivaram o auxílio às operações de manutenção de um sistema em operação (Cenário 5), como descrito na Seção 3.5.4 (Modelo Final da RNC Proposta), foram obtidos os resultados apresentados na Figura 23 e Figura 24.


Com uma média de acertos de 94,59% e tempo de execução de pouco mais de 44 minutos, os resultados obtidos revelaram uma redução notável nos erros de classificação, consolidando a confiabilidade do modelo. Essa melhoria apresentou uma significativa capacidade de generalização para dados inéditos, proporcionando uma base sólida para a aplicação prática do modelo em dados coletados de painéis em sistemas fotovoltaicos em funcionamento.

Figura 21 – *Cenário 4 - 9 classes e base de dados com 45.000 amostras.*




Fonte: Do Autor

Figura 22 – *Recall por classes resultantes do Cenário 4.*




Fonte: Do Autor

Figura 23 – *Cenário 5 - 3 classes e base de dados com 45.000 amostras.*



Fonte: Do Autor

Figura 24 – *Recall por classes resultantes do Cenário 5.*



Fonte: Do Autor

4.5 Modelo VGG-16


Outro cenário testado utilizou o modelo de rede neural pré-treinada VGG-16 disponibilizada na biblioteca do Keras. Esse cenário foi denominado Cenário 6 e para

a sua execução foi alterada a resolução das imagens para 55x33 *pixels*, mantendo a proporção das dimensões originais das imagens. Tal modificação foi necessária pois a resolução mínima da imagem para que se possa utilizar o modelo é de 32x32 *pixel*.


Os resultados da execução desse modelo são apresentados na Figura 25 e Figura 26 e a média de acertos foi de 93,36%, indicando que o reconhecimento de instâncias positivas no modelo foi inferior ao obtido no Cenário 5. O tempo gasto na execução desse modelo foi de mais de 90 minutos, o que pode ser explicado pelo maior número de camadas convolucionais e pelas dimensões aumentadas das imagens analisadas.

Ressalte-se que uma vez que esse modelo foi projetado inicialmente para receber imagens com resolução 224x224 pixels, existe a possibilidade de que o modelo possa superar a eficiência da rede neural proposta caso seja utilizada uma base de dados com resolução maior que a utilizada no presente trabalho.

Figura 25 – *Cenário 6 - VGG-16, 3 classes e base de dados com 45.000 amostras.*



Fonte: Do Autor

Figura 26 – *Recall por classes resultantes do Cenário 6.*

Fonte: Do Autor

4.6 ResNet50

Analisando-se os resultados apresentados na matriz de confusão resultante do Cenário 7, é possível notar que houve sensível melhora nos acertos das previsões das classes e que a arquitetura obteve resultados ainda melhores que os do Cenário 5 e do Cenário 6, com uma média de acertos de 96,88%, sendo superior à marca obtida no Cenário 5. O tempo gasto para execução desse cenário foi de pouco mais de 120 minutos.

Os resultados obtidos são apresentados na Figura 27 e na Figura 28.

4.7 Síntese dos Resultados

A partir dos resultados apresentados nesse capítulo, observa-se que a partir de imagens termográficas é possível detectar e classificar tipos de anomalias por meio do uso de modelos de IA, e que para uma base de dados com imagens com baixa resolução, uma RNC com poucas camadas pode ser tão eficiente quanto outros modelos complexos pré-treinados.

Após extenso trabalho de pesquisa e experimentação, três *scripts* utilizando diferentes arquiteturas de RNC foram desenvolvidos, podendo ser utilizados como base para um *software* para auxiliar as equipes de manutenção de sistemas fotovoltaicos. A Tabela 2, resume os resultados obtidos e expõe a evolução apresentada pela RNC proposta em cenários com diferentes configurações.

Figura 27 – *Cenário 7 - utilizando o modelo ResNet50 com base de dados com 45.000 amostras.*





Figura 28 – *Recall por classes resultantes do Cenário 7.*



4.8 Discussões

Ao avaliar os resultados obtidos e compará-los com estudos relacionados que empregaram métodos de IA (em especial os modelos de RNC) para detecção e classificação de anomalias em painéis fotovoltaicos, o presente trabalho demonstra convergência com os resultados alcançados pelos mesmos.

Tabela 2 – *Tabela-resumo dos resultados obtidos das execuções dos scripts.*

Cenário	Descrição	Amostras	Classes	Acurácia (%)
1	Cenário 1	20.000	12	48,41
2	Cenário 2	24.000	12	55,71
3	Cenário 3	60.000	12	85,29
4	Cenário 4	45.000	9	84,58
5	Cenário 5	45.000	3	94,59
6	Cenário 6	45.000	3	93,36
7	Cenário 7	45.000	3	96,88

Fonte: Compilado pelo autor.

Um dos pontos observados, comparando-se esses resultados, é a constatação de que o aumento artificial de dados é uma técnica que quando aplicada em bases de dados que não dispõe de quantidades de amostras suficiente, expande a capacidade dos modelos de redes neurais para a detecção de padrões e assim proporciona uma melhora de sua assertividade, confirmando resultados relatados nos trabalhos de Alves *et al.* (2021), Luque *et al.* (2019), Dunderdale *et al.* (2020) e Bommes *et al.* (2021). Outras técnicas existentes de aumento artificial de dados, como as citadas por Perez e Wang (2017) e por Alomar, Aysel e Cai (2023), podem ser testados em trabalhos futuros para verificar seu impacto na melhora dos resultados.

Índices de acertos máximo próximo aos 90% na detecção de anomalias foram obtidos por Dunderdale *et al.* (2020) utilizando diversos modelos de RNC para classificação binária (com ou sem anomalias). Nesse trabalho avaliou uma base de dados com imagens de resolução 224x224x3 *pixels*, aumento de dados e utilizando ainda uma RNC com quatro camadas convolucionais e estrutura próxima à proposta pelo presente trabalho, o que confirma a robustez dos resultados obtidos por uma RNC com essa estrutura.

No trabalho de Alves *et al.* (2021) resultados consistentes foram obtidos em classificação binária utilizando a mesma base de dados aplicada no presente trabalho. Fazendo uso de técnicas de aumento artificial de dados, obteve uma média ponderada de *Recall* de 92%. Assim como o presente trabalho, demonstra que uma RNC com três ou quatro camadas convolucionais e camadas densas ao final, pode realizar satisfatoriamente a detecção de padrões de anomalias em imagens termográficas de módulos fotovoltaicos.

Outra observação que se pode fazer, demonstrado pela bibliografia como os

trabalhos de Alves *et al.* (2021), Bommes *et al.* (2021) e Dunderdale *et al.* (2020) entre outros, e corroborado pelo presente trabalho, é que o aumento artificial de dados leva a um aumento da eficiência da RNC quando existe uma quantidade insuficiente de amostras para que a mesma possa treinar convenientemente.

Já Bommes *et al.* (2022) em seu trabalho, utilizaram uma arquitetura ResNet34 para a mesma classificação binária e obteve resultado de 73,3% até 96,6% pela métrica AUC, que leva em consideração os verdadeiros positivos e os falsos positivos. Foi utilizado uma base de dados própria, coletadas de oito sistemas fotovoltaicos em funcionamento contendo imagens separadas em normais e anômalas em diferentes proporções. O classificador foi aplicado a cada conjunto separadamente. A resolução das amostras utilizadas foi de 64x64 *pixels*. O presente estudo, utilizando o mesmo tipo de modelo de RNC, apresentou resultados robustos que confirmam a eficiência das redes residuais na classificação de imagens.

Outro ponto observado nos resultados obtidos e apresentados nessa seção, assim como nas publicações mencionadas nesse capítulo, é que a quantidade menor de classes resulta em uma maior eficiência da rede na acurácia em classificar corretamente as amostras, corroborando também o estudo de Le *et al.* (2021).

Conclusões e Sugestões para Futuros Trabalhos

O presente trabalho propôs uma arquitetura de rede neural que pode auxiliar o diagnóstico em módulos fotovoltaicos de plantas em funcionamento. Tal procedimento abre a possibilidade de que muitas perdas de eficiência energética relacionadas a anomalias nesses módulos possam ser diagnosticadas e solucionadas com precisão e rapidez, para que a viabilidade econômica desses sistemas seja mantida por períodos mais longos. Traz ainda uma contribuição para o estudo da detecção de anomalias em painéis fotovoltaicos por experimentar e comparar três modelos de redes de diferentes arquiteturas, utilizando uma base de dados com baixa resolução, comparando o tempo gasto por cada uma delas para que se tenha parâmetros de eficiência da rede.

Por meio de produção de cenários, utilizando inicialmente uma arquitetura de RNC com três camadas convolucionais, duas camadas densas e a camada de saída com doze classes, desenvolvida a partir de pesquisa em trabalhos relacionados, várias possibilidades de configurações e modelos de redes neurais foram testadas. A cada modificação das configurações os resultados foram anotados e comparados para o direcionamento das próximas alterações. Evolui-se então o modelo para apenas três classes de interesse para equipes de manutenção de sistemas fotovoltaicos.

Os resultados da melhor configuração dessa rede desenvolvida foram comparados com outros dois modelos pré-treinados, disponibilizados em bibliotecas do Tensor Flow. Os dois modelos (VGG-16 e ResNet50) foram escolhidos para esse comparativo por terem sido utilizados com sucesso em outros trabalhos relacionados.

Os três modelos apresentaram resultados robustos que indicam a viabilidade de sua aplicação em um sistema de detecção automatizado, tendo o modelo proposto o que obteve um desempenho ótimo e menor tempo gasto para sua execução frente aos modelos com arquitetura mais complexa. O modelo ResNet50 obteve os melhores resultados na classificação de anomalias, utilizando uma arquitetura pré-treinada e

Vislumbra-se no modelo de RNC proposto, a possibilidade de aplicação na análise de grandes plantas que podem conter centenas e até milhares de módulos. Essa análise, se conduzida manualmente por um especialista pode consumir um tempo valioso desse profissional e, enquanto não finalizada, continuar gerando perdas de geração de energia elétrica implicando em perdas econômicas.

O aumento e equalização da base de dados mostrou-se efetivo na melhora dos índices de acerto da rede sendo que a disponibilidade de um equipamento robusto para a execução do modelo se mostrou fundamental. O modelo desenvolvido obteve resultados satisfatórios para a aplicação proposta e os modelos pré-treinados mostraram que podem apresentar resultados igualmente eficientes para esse fim.

Para trabalhos futuros pode-se sugerir:

- a) aplicação de imagens coletadas de sistemas fotovoltaicos locais para a validação do modelo proposto;
- b) testar a utilização em equipamentos com maior poder computacional;
- c) caso uma base de dados com imagens com melhor resolução seja disponibilizada, desenvolver os modelos que utilizam arquiteturas pré-treinadas;
- d) estudar outras classes de anomalias não relacionadas na base de dados utilizada, e;
- e) aplicar outras técnicas de aumento de dados e de melhora da resolução de imagens para observar seus efeitos em modelos de RNC.

Referências

ABNT. Norma Brasileira ABNT 16274:2014 Sistemas fotovoltaicos conectados à rede — Requisitos mínimos para documentação, ensaios de comissionamento, inspeção e avaliação de desempenho. 2018. Disponível em: <https://www.normas.com.br/visualizar/abnt-nbr-nm/34048/abnt-nbr16274-sistemas-fotovoltaicos-conectados-a-rede-requisitos-\minimos-para-documentacao-ensaios-de-comissionamento-inspecao-e-\avaliacao-de-desempenho>. Acesso em: 27 de fevereiro de 2022. 28, 31

_____. Norma Brasileira ABNT 10899:2020 Energia solar fotovoltaica — Terminologia. 2020. Disponível em: <https://www.normas.com.br/visualizar/abnt-nbr-nm/8242/abnt-nbr10899-energia-solar-fotovoltaica-terminologia>. Acesso em: 23 de fevereiro de 2022. 23

_____. Norma Brasileira ABNT NBR15424:2022 Ensaios não destrutivos — Termografia infravermelha — Terminologia. 2022. Disponível em: <https://www.normas.com.br/visualizar/abnt-nbr-nm/25611/nbr15424-ensaios-nao-destrutivos-termografia-infravermelha-terminologia>. Acesso em: 23 de fevereiro de 2022. 29

AGHAEI, M.; FAIRBROTHER, A.; GOK, A.; AHMAD, S.; KAZIM, S.; LOBATO, K.; ORESKI, G.; REINDERS, A.; SCHMITZ, J.; THEELEN, M.; YILMAZ, P.; KETTLE, J. Review of degradation and failure phenomena in photovoltaic modules. **Renewable and Sustainable Energy Reviews**, v. 159, p. 112160, 2022. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032122000880>. 33

AGHAEI, Mohammadreza; GRIMACCIA, Francesco; GONANO, Carlo A; LEVA, Sonia. Innovative automated control system for pv fields inspection and remote control. **IEEE Transactions on Industrial Electronics**, IEEE, v. 62, n. 11, p. 7287–7296, 2015. 29

AKRAM, M Waqar; LI, Guiqiang; JIN, Yi; CHEN, Xiao; ZHU, Changan; AHMAD, Ashfaq. Automatic detection of photovoltaic module defects in infrared images with isolated and develop-model transfer deep learning. **Solar Energy**, Elsevier, v. 198, p. 175–186, 2020. 21, 45

ALOMAR, Khaled; AYSEL, Halil Ibrahim; CAI, Xiaohao. Data augmentation in classification and segmentation: A survey and new strategies. **Journal of Imaging**, v. 9, n. 2, 2023. ISSN 2313-433X. Disponível em: <https://www.mdpi.com/2313-433X/9/2/46>. 69

ALVES, Priscila Mello. **Inteligência Artificial e Redes Neurais**. IPEA Instituto de Pesquisa Econômica Aplicada, 2020. Disponível em: <https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/106-inteligencia-artificial-e-redes-neurais>. Acesso em: 20 fev 2022. 35

ALVES, Ricardo Henrique Fonseca; JÚNIOR, Getúlio Antero de Deus; MARRA, Enes Gonçalves; LEMOS, Rodrigo Pinto. Automatic fault classification in photovoltaic modules using convolutional neural networks. **Renewable Energy**, Elsevier, v. 179, p. 502–516, 2021. 21, 39, 45, 46, 48, 58, 69, 70

ANEEL. **AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL, RESOLUÇÃO NORMATIVA Nº 482, DE 17 DE ABRIL DE 2012**. 2012. Disponível em: <http://www2.aneel.gov.br/cedoc/ren2012482.pdf>. Acesso em: 14 de fevereiro de 2022. 19

_____. **AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL, RESOLUÇÃO NORMATIVA Nº 687, DE 24 DE NOVEMBRO DE 2015**. 2015. Disponível em: <http://www2.aneel.gov.br/cedoc/ren2015687.pdf>. Acesso em: 14 de fevereiro de 2022. 19

AYODELE, Taiwo Oladipupo. Types of machine learning algorithms. **New advances in machine learning**, v. 3, n. 19-48, p. 5–1, 2010. 34, 35

BALLESTÍN-FUERTES, Javier; MUÑOZ-CRUZADO-ALBA, Jesús; SANZ-OSORIO, José F.; HERNÁNDEZ-CALLEJO, Luis; ALONSO-GÓMEZ, Victor; MORALES-ARAGONES, José Ignacio; GALLARDO-SAAVEDRA, Sara; MARTÍNEZ-SACRISTAN, Oscar; MORETÓN-FERNÁNDEZ, Ángel. Novel utility-scale photovoltaic plant electroluminescence maintenance technique by means of bidirectional power inverter controller. **Applied Sciences**, v. 10, n. 9, 2020. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/10/9/3084>. 29

BASNET, Barun; CHUN, Hyunjun; BANG, Junho. An intelligent fault detection model for fault detection in photovoltaic systems. **Journal of Sensors**, v. 2020, p. 1–11, 06 2020. 39

BAUER, W.; WESTFALL, G.; DIAS, H. **Física para Universitários - Relatividade, Oscilações, Ondas e Calor**. [S.l.]: AMGH, 2013. 366 p. 29

BERRAR, Daniel *et al.* **Cross-Validation**. 2019. 52

BOMMES, Lukas; HOFFMANN, Mathis; BUERHOP-LUTZ, Claudia; PICKEL, Tobias; HAUCH, Jens; BRABEC, Christoph; MAIER, Andreas; PETERS, Ian Marius. **Anomaly Detection in IR Images of PV Modules using Supervised Contrastive Learning**. 2021. 21, 22, 69, 70

BOMMES, Lukas; HOFFMANN, Mathis; BUERHOP-LUTZ, Claudia; PICKEL, Tobias; HAUCH, Jens; BRABEC, Christoph; MAIER, Andreas; PETERS, Ian Marius. Anomaly detection in ir images of pv modules using supervised contrastive learning. **Progress in Photovoltaics: Research and Applications**, Wiley Online Library, v. 30, n. 6, p. 597–614, 2022. 45, 70

BOMMES, Lukas; PICKEL, Tobias; BUERHOP-LUTZ, Claudia; HAUCH, Jens; BRABEC, Christoph; PETERS, Ian Marius. Computer vision tool for detection, mapping, and fault classification of photovoltaics modules in aerial ir videos. **Progress in Photovoltaics: Research and Applications**, Wiley Online Library, v. 29, n. 12, p. 1236–1251, 2021. 45, 52

BRASIL. **AERONAVES NÃO TRIPULADAS E O ACESSO AO ESPAÇO AÉREO BRASILEIRO**. 2020. Disponível em: <https://publicacoes.decea.mil.br/publicacao/ica-100-40>. Acesso em: 27 de fevereiro de 2023. 31

_____. **DIÁRIO OFICIAL DA UNIÃO, LEI Nº 14.300, DE 6 DE JANEIRO DE 2022**. 2022. Disponível em: <https://in.gov.br/en/web/dou/-/lei-n-14.300-de-6-de-janeiro-de-2022-372467821>. Acesso em: 14 de fevereiro de 2022. 19

BUDA, Mateusz; MAKI, Atsuto; MAZUROWSKI, Maciej A. A systematic study of the class imbalance problem in convolutional neural networks. **Neural Networks**, v. 106, p. 249–259, 2018. ISSN 0893-6080. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0893608018302107>. 58

BUERHOP, Claudia; BOMMES, Lukas; SCHLIPF, Jan; PICKEL, Tobias; FLADUNG, Andreas; PETERS, Marius. Infrared imaging of photovoltaic modules a

review of the state of the art and future challenges facing gigawatt photovoltaic power stations. **Progress in Energy**, IOP Publishing, 2022. 30

CALAIS, M.; MYRZIK, J.; SPOONER, T.; AGELIDIS, V.G. Inverters for single-phase grid connected photovoltaic systems-an overview. *In: 2002 IEEE 33rd Annual IEEE Power Electronics Specialists Conference. Proceedings (Cat. No.02CH37289)*. [S.l.: s.n.], 2002. v. 4, p. 1995–2000 vol.4. 24

CHAI, Junyi; ZENG, Hao; LI, Anming; NGAI, Eric W.T. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. **Machine Learning with Applications**, v. 6, p. 100134, 2021. ISSN 2666-8270. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2666827021000670>. 34

CHEN, Li; WANG, Song; FAN, Wei; SUN, Jun; NAOI, Satoshi. Beyond human recognition: A cnn-based framework for handwritten character recognition. *In: 2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR)*. [S.l.: s.n.], 2015. p. 695–699. 35

CHOUAY, Yassine; OUASSAID, Mohammed. An intelligent method for fault diagnosis in photovoltaic systems. *In: 2017 International Conference on Electrical and Information Technologies (ICEIT)*. [S.l.: s.n.], 2017. p. 1–5. 21

CHOUDHARY, Rishabh; GIANEY, Hemant Kumar. Comprehensive review on supervised machine learning algorithms. *In: IEEE. 2017 International Conference on Machine Learning and Data Science (MLDS)*. [S.l.], 2017. p. 37–43. 34

COLLINS, Christopher; DENNEHY, Denis; CONBOY, Kieran; MIKALEF, Patrick. Artificial intelligence in information systems research: A systematic literature review and research agenda. **International Journal of Information Management**, v. 60, p. 102383, 2021. ISSN 0268-4012. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0268401221000761>. 33

DUNDERDALE, Christopher; BRETTEENY, Warren; CLOHESSY, Chantelle; DYK, E Ernest van. Photovoltaic defect classification through thermal infrared imaging using a machine learning approach. **Progress in Photovoltaics: Research and Applications**, Wiley Online Library, v. 28, n. 3, p. 177–188, 2020. 29, 45, 52, 69, 70

ESPINOSA, Alejandro Rico; BRESSAN, Michael; GIRALDO, Luis Felipe. Failure signature classification in solar photovoltaic plants using rgb images and convolutional neural networks. **Renewable Energy**, Elsevier, v. 162, p. 249–256, 2020. 45

FADHEL, Siwar; DELPHA, Claude; DIALLO, Demba; BAHRI, I; MIGAN, A; TRABELSI, Mohamed; MIMOUNI, Mohamed Faouzi. Pv shading fault detection and classification based on iv curve using principal component analysis: Application to isolated pv system. **Solar Energy**, Elsevier, v. 179, p. 1–10, 2019. 28, 30

FAWCETT, Tom. An introduction to roc analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, 2006. ISSN 0167-8655. ROC Analysis in Pattern Recognition. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016786550500303X>. 41

FERNÁNDEZ, Juan Carlos; CARBONERO, Mariano; GUTIÉRREZ, Pedro Antonio; HERVÁS-MARTÍNEZ, César. Multi-objective evolutionary optimization using the relationship between f 1 and accuracy metrics in classification tasks. **Applied Intelligence**, Springer, v. 49, p. 3447–3463, 2019. 40

FERREIRA, Rafael Augusto Magalhaes. Metodologia para avaliação do desempenho de painéis fotovoltaicos utilizando um modelo elétrico-térmico e termografia quantitativa. Universidade Federal de Minas Gerais, 2018. 31

GARCIA, Sérgio Boscato; ZANESCO, Izete; MOEHLECKE, Adriano; FEBRAS, Filipe Sehn. Análise por termografia de módulos fotovoltaicos com células solares com base ne diferentes malhas de metalização posterior. *In: IV Congresso Brasileiro de Energia Solar (IV CBENS) e V Conferência Latino Americana da ISES, 2012, Brasil.* [S.l.: s.n.], 2012. 20, 31

GENG, Qichuan; ZHOU, Zhong; CAO, Xiaochun. Survey of recent progress in semantic image segmentation with cnns. *Science China Information Sciences*, v. 61, p. 1–18, 2017. 38

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. [S.l.]: MIT Press, 2016. <http://www.deeplearningbook.org>. 51

GRANDINI, Margherita; BAGLI, Enrico; VISANI, Giorgio. **Metrics for Multi-Class Classification: an Overview**. 2020. 41

GU, Jiuxiang; WANG, Zhenhua; KUEN, Jason; MA, Lianyang; SHAHROUDY, Amir; SHUAI, Bing; LIU, Ting; WANG, Xingxing; WANG, Gang; CAI, Jianfei *et al.* Recent advances in convolutional neural networks. **Pattern recognition**, Elsevier, v. 77, p. 354–377, 2018. 36, 37

HAQUE, Ahteshamul; BHARATH, Kurukuru Varaha Satya; KHAN, Mohammed Ali; KHAN, Irshad; JAFFERY, Zainul Abdin. Fault diagnosis of photovoltaic

modules. **Energy Science & Engineering**, Wiley Online Library, v. 7, n. 3, p. 622–644, 2019. 21, 27, 28, 29

HAYKIN, Simon. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001. 44

HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian. **Deep Residual Learning for Image Recognition**. 2015. 38, 39

HERRAIZ, Álvaro Huerta; MARUGÁN, Alberto Pliego; MÁRQUEZ, Fausto Pedro García. Photovoltaic plant condition monitoring using thermal images analysis by convolutional neural network-based structure. Elsevier, 2020. 21, 45

HOLLAND, Stephen D.; REUSSER, Ricky S. Material evaluation by infrared thermography. **Annual Review of Materials Research**, v. 46, n. 1, p. 287–303, 2016. Disponível em: <https://doi.org/10.1146/annurev-matsci-070115-032014>. 29

HONG, Ying-Yi; PULA, Rolando A. Methods of photovoltaic fault detection and classification: A review. **Energy Reports**, Elsevier, v. 8, p. 5898–5929, 2022. 26

HU, Yihua; CAO, Wenping; MA, Jien; FINNEY, Stephen J; LI, David. Identifying pv module mismatch faults by a thermography-based temperature distribution analysis. **IEEE Transactions on Device and Materials Reliability**, IEEE, v. 14, n. 4, p. 951–960, 2014. 20, 28, 33

HWANG, Humble Po-Ching; KU, Cooper Cheng-Yuan; CHAN, James Chi-Chang. Detection of malfunctioning photovoltaic modules based on machine learning algorithms. **IEEE Access**, IEEE, v. 9, p. 37210–37219, 2021. 21, 22

ICAO. “**Manual on Remotely Piloted Aircraft Systems (RPAS)**”. 2015. Disponível em: <https://store.icao.int/en/manual-on-remotely-piloted-aircraft-systems-rpas-doc-10019>. Acesso em: 27 de fevereiro de 2023. 31

IEC. **Photovoltaic (PV) Systems: Requirements for Testing, Documentation and Maintenance. Photovoltaic modules and plants : outdoor infrared thermography**. [S.l.: s.n.], 2017. 29, 32, 46

_____. **Terrestrial photovoltaic (PV) modules - Design qualification and type approval - Part 1: Test requirements**. 2021. IEC 61215-1:2021. 26

IRENA. Future of solar photovoltaic: Deployment, investment, technology, grid integration and socio-economic aspects (a global energy transformation: paper). **International Renewable Energy Agency, Abu Dhabi**, 2019. 20

JAPKOWICZ, Nathalie; SHAH, Mohak. **Evaluating learning algorithms: a classification perspective**. [S.l.]: Cambridge University Press, 2011. 40

JIANG, Gaoxia; WANG, Wenjian. Error estimation based on variance analysis of k-fold cross-validation. **Pattern Recognition**, v. 69, p. 94–106, 2017. ISSN 0031-3203. Disponível em: <https://www.sciencedirect.com/science/article/pii/S003132031730136X>. 54

Jinko Solar. **JKM540-560M-72HL4-(V)-F3-EN.pdf**. 2023. Online. Disponível em: [https://jinkosolarcdn.shwebpace.com/uploads/63da19e2/JKM540-560M-72HL4-\(V\)-F3-EN.pdf](https://jinkosolarcdn.shwebpace.com/uploads/63da19e2/JKM540-560M-72HL4-(V)-F3-EN.pdf). 27

KAMILARIS, Andreas; PRENAFETA-BOLDÚ, Francesc X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, v. 147, p. 70–90, 2018. ISSN 0168-1699. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169917308803>. 39

KAPLANI, E. Detection of degradation effects in field-aged c-si solar cells through ir thermography and digital image processing. **International Journal of Photo-energy**, Hindawi, v. 2012, 2012. 20

KAPOOR, Amita; GULLI, Antonio; PAL, Sujit; CHOLLET, Francois. **Deep Learning with TensorFlow and Keras: Build and deploy supervised, unsupervised, deep, and reinforcement learning models**. [S.l.]: Packt Publishing Ltd, 2022. 49

KIRZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. Imagenet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 25, p. 1097–1105, 2012. 37, 49

KURUKURU, VS Bharath; HAQUE, Ahteshamul; KHAN, Mohammed Ali; TRIPATHY, Arun Kumar. Fault classification for photovoltaic modules using thermography and machine learning techniques. *In*: IEEE. **2019 International Conference on Computer and Information Sciences (ICCIS)**. [S.l.], 2019. p. 1–6. 20, 31

LE, Minhhuy; NGUYEN, Dang Khoa; DAO, Van-Duong; VU, Ngoc Hung; VU, Hong Ha Thi *et al.* Remote anomaly detection and classification of solar photovoltaic modules based on deep neural network. **Sustainable Energy Technologies and Assessments**, Elsevier, v. 48, p. 101545, 2021. 21, 26, 31, 45, 46, 70

LECUN, Yann; BOSER, Bernhard; DENKER, John; HENDERSON, Donnie; HOWARD, R.; HUBBARD, Wayne; JACKEL, Lawrence. Handwritten digit recognition with a back-propagation network. *In*: TOURETZKY, D. (Ed.). **Advances in Neural Information Processing Systems**. Morgan-Kaufmann, 1989. v. 2. Disponível em: https://proceedings.neurips.cc/paper_files/paper/1989/file/53c3bce66e43be4f209556518c2fcb54-Paper.pdf. 36

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. 36

LI, Zewen; LIU, Fan; YANG, Wenjie; PENG, Shouheng; ZHOU, Jun. A survey of convolutional neural networks: Analysis, applications, and prospects. **IEEE Transactions on Neural Networks and Learning Systems**, v. 33, n. 12, p. 6999–7019, 2022. 35, 36, 37, 38

LORENTE, Daniel Gomez; PEDRAZZI, Simone; ZINI, Gabriele; ROSA, Alberto Dalla; TARTARINI, Paolo. Mismatch losses in pv power plants. **SOLAR ENERGY**, PERGAMON-ELSEVIER SCIENCE LTD, v. 100, p. 42–49, FEB 2014. 33

LUDERMIR, TERESA BERNARDA. Inteligência artificial e aprendizado de máquina: estado atual e tendências. *In*: **Estudos Avançados**. [S.l.: s.n.], 2021. v. 35, n. 101, p. 85–94. 34, 35

LUQUE, Amalia; CARRASCO, Alejandro; MARTÍN, Alejandro; de las Heras, Ana. The impact of class imbalance in classification performance metrics based on the binary confusion matrix. **Pattern Recognition**, v. 91, p. 216–231, 2019. ISSN 0031-3203. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0031320319300950>. 41, 69

MADETI, Siva Ramakrishna; SINGH, S.N. A comprehensive study on different types of faults and detection techniques for solar photovoltaic system. **Solar Energy**, v. 158, p. 161–185, 2017. ISSN 0038-092X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0038092X17307508>. 24, 26, 27, 29, 33

MAGAZINE, Cosmos. How solar cells turn sunlight into electricity. **Cosmos Magazine**, 2017. Disponível em: <https://cosmosmagazine.com/technology/how-solar-cells-turn-sunlight-into-electricity/>. 24

MAHESH, Batta. Machine learning algorithms-a review. **International Journal of Science and Research (IJSR)**.^[Internet], v. 9, n. 1, p. 381–386, 2020. 35

MÄKI, Anssi; VALKEALAHTI, Seppo. Power losses in long string and parallel-connected short strings of series-connected silicon-based photovoltaic modules due to partial shading conditions. **IEEE Transactions on Energy Conversion**, IEEE, v. 27, n. 1, p. 173–183, 2011. 24

MANNO, D; CIPRIANI, G; CIULLA, G; DIO, V Di; GUARINO, S; BRANO, V Lo. Deep learning strategies for automatic fault diagnosis in photovoltaic systems by thermographic images. **Energy Conversion and Management**, Elsevier, v. 241, p. 114315, 2021. 45

MARCOT, Bruce G.; HANEA, Anca M. What is an optimal value of k in k-fold cross-validation in discrete bayesian network analysis? **Computational Statistics**, v. 36, n. 3, p. 2009–2031, 2021. ISSN 1613-9658. Disponível em: <https://doi.org/10.1007/s00180-020-00999-9>. 53

MAYO, Ray Cody; LEUNG, Jessica. Artificial intelligence and deep learning – radiology’s next frontier? **Clinical Imaging**, v. 49, p. 87–88, 2018. ISSN 0899-7071. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0899707117302279>. 35

MILLENDORF, Matthew; OBROPTA, Edward; VADHAVKAR, Nikhil. Infrared solar module dataset for anomaly detection. *In: Proc. Int. Conf. Learn. Represent.* [S.l.: s.n.], 2020. 43, 45, 46, 47, 60

MURPHY, Kevin P. **Probabilistic machine learning: an introduction**. [S.l.]: MIT press, 2022. 40

MUSTAFA, Ramadan J.; GOMAA, Mohamed R.; AL-DHAIFALLAH, Mujahed; REZK, Hegazy. Environmental impacts on the performance of solar photovoltaic systems. **Sustainability**, v. 12, n. 2, 2020. ISSN 2071-1050. Disponível em: <https://www.mdpi.com/2071-1050/12/2/608>. 20

NASCIMENTO, Cássio Araújo Do. Princípio de funcionamento da célula fotovoltaica. **Diss. Universidade Federal de Lavras**, 2004. 23

NAZER, Afshin; DRISS, Sina; HADDADI, Amir Mousa; FARHANGI, Shahrokh. Optimal photovoltaic multi-string inverter topology selection based on reliability and cost analysis. **IEEE Transactions on Sustainable Energy**, v. 12, n. 2, p. 1186–1195, 2021. 25

OLIVEIRA, Aline Kirsten Vidal de; AGHAEI, Mohammedreza; RÜTHER, Ricardo. Detecção automática de falhas de sistemas fotovoltaicos por redes neurais convolucionais utilizando a termografia aérea infravermelha. *In: Congresso Brasileiro de Energia Solar-CBENS*. [S.l.: s.n.], 2020. 22, 29

OLIVEIRA, Daniele Melo; GOMES, Mateus das Neves. A energia das ondas do mar frente aos paradigmas da matriz energética brasileira pelo viés de ciência, tecnologia e sociedade. **Revista Mundi Sociais e Humanidades (ISSN: 2525-4774)**, v. 3, n. 1, 2018. 19

PACKA, Juraj; PERNÝ, Milan; ŠÁLY, Vladimír; VÁRY, Michal. Chosen diagnostic methods of photovoltaic modules. *In: 2016 Diagnostic of Electrical Machines and Insulating Systems in Electrical Engineering (DEMISEE)*. [S.l.: s.n.], 2016. p. 29–33. 33

PEREZ, Luis; WANG, Jason. The effectiveness of data augmentation in image classification using deep learning. **CoRR**, abs/1712.04621, 2017. Disponível em: <http://arxiv.org/abs/1712.04621>. 69

PIERDICCA, R.; MALINVERNI, E. S.; PICCININI, F.; PAOLANTI, M.; FELICETTI, A.; ZINGARETTI, P. Deep convolutional neural network for automatic detection of damaged photovoltaic cells. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, XLII-2, p. 893–900, 2018. Disponível em: <https://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-2/893/2018/>. 21

POWERS, David MW. Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation. **arXiv preprint arXiv:2010.16061**, 2020. 40

PV Engineering. **PVPM1000CX Datasheet**. 2016. https://www.pv-engineering.de/fileadmin/user_upload/Produkte/PVPM1000CX/pvpm1000cx-datasheet_01.pdf. Acesso em: 08 de maio de 2023. 28

QUATER, Paolo; GRIMACCIA, F.; LEVA, S.; MUSSETTA, Marco; AGHAEI, Mohammadreza. Light unmanned aerial vehicles (uavs) for cooperative inspection of pv plants. **Photovoltaics, IEEE Journal of**, v. 4, p. 1107–1113, 07 2014. 26

RUSSELL, Stuart J; NORVIG, Peter. **Inteligência artificial**. [S.l.]: Elsevier, 2004. 33

SALEH, Abeer Mohsin; HAMOUD, Talal. Analysis and best parameters selection for person recognition based on gait model using cnn algorithm and image augmentation. **Journal of Big Data**, SpringerOpen, v. 8, n. 1, p. 1–20, 2021. 44, 50

SARIKH, S.; RAOUFI, M.; BENNOUNA, A.; BENLARABI, A.; IKKEN, B. Fault diagnosis in a photovoltaic system through i-v characteristics analysis. *In: 2018 9th International Renewable Energy Congress (IREC)*. [S.l.: s.n.], 2018. p. 1–6. 27, 28

SEN, Pratap Chandra; HAJRA, Mahimarnab; GHOSH, Mitadru. Supervised classification algorithms in machine learning: A survey and review. *In: SPRINGER. Emerging Technology in Modelling and Graphics: Proceedings of IEM Graph 2018*. [S.l.], 2020. p. 99–111. 35

SHORTEN, Connor; KHOSHGOFTAAR, Taghi M. A survey on image data augmentation for deep learning. **Journal of big data**, SpringerOpen, v. 6, n. 1, p. 1–48, 2019. 39

SIMONYAN, Karen; ZISSERMAN, Andrew. **Very Deep Convolutional Networks for Large-Scale Image Recognition**. 2015. 38, 49

TENSORFLOW. **Guia do Keras**. 2020. <https://www.tensorflow.org/guide/keras?hl=pt-br>. Acessado em [05 de janeiro de 2023]. 34

TENSORFLOW. **Google incorporation**. 2022. Disponível em: https://www.tensorflow.org/resources/learn-ml?gclid=CjwKCAiAyPyQBhB6EiwAFUuakpooTJ8YtY-syq91a96DOMS2cVxrjLMtvKBFz7KbqZQ_CTaQ3dUpnhoCajAQAvD_BwE. 34

THANAPOL, Panissara; LAVANGNANANDA, Kittichai; BOUVRY, Pascal; PINEL, Frédéric; LEPRÉVOST, Franck. Reducing overfitting and improving generalization in training convolutional neural network (cnn) under limited sample sizes in image recognition. *In: 2020 - 5th International Conference on Information Technology (InCIT)*. [S.l.: s.n.], 2020. p. 300–305. 39

TINA, Giuseppe Marco; COSENTINO, Fabio; VENTURA, Cristina. Monitoring and diagnostics of photovoltaic power plants. *In: SPRINGER. Renewable Energy in the Service of Mankind Vol II: Selected Topics from the World Renewable Energy Congress WREC 2014*. [S.l.], 2016. p. 505–516. 25

TOM, Mitchell. **Machine Learning**. [S.l.]: McGraw Hill, 1997. 432 p. 34

TSANAKAS, John A; HA, Long; BUERHOP, Claudia. Faults and infrared thermographic diagnosis in operating c-si photovoltaic modules: A review of research and future challenges. **Renewable and sustainable energy reviews**, Elsevier, v. 62, p. 695–709, 2016. 20, 29

TSANAKAS, John A.; HA, Long D.; SHAKARCHI, F. Al. Advanced inspection of photovoltaic installations by aerial triangulation and terrestrial georeferencing of thermal/visual imagery. **Renewable Energy**, v. 102, p. 224–233, 2017. ISSN 0960-1481. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148116309119>. 28

TSIRIGOTIS, Aris; SARANTOGLU, George; SKONTRANIS, Menelaos; DELIGIANNIDIS, Stavros; SOZOS, Kostas; TSILIKAS, Giannis; DERMANIS, Dimitris; BOGRIS, Adonis; MESARITAKIS, Charis. Unconventional integrated photonic accelerators for high-throughput convolutional neural networks. **Intelligent Computing**, v. 2, p. 0032, 2023. Disponível em: <https://spj.science.org/doi/abs/10.34133/icomputing.0032>. 37

USAMENTIAGA, Rubén; VENEGAS, Pablo; GUEREDIAGA, Jon; VEGA, Laura; MOLLEDA, Julio; BULNES, Francisco G. Infrared thermography for temperature measurement and non-destructive testing. **Sensors**, MDPI, v. 14, n. 7, p. 12305–12348, 2014. 31

WU, Jianxin. Introduction to convolutional neural networks. **National Key Lab for Novel Software Technology. Nanjing University. China**, v. 5, n. 23, p. 495, 2017. 36

ZHANG, Xinyu; LIU, Chu-An. Model averaging prediction by k-fold cross-validation. **Journal of Econometrics**, v. 235, n. 1, p. 280–301, 2023. ISSN 0304-4076. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0304407622000975>. 53

ZHANG, Xiangyu; ZOU, Jianhua; HE, Kaiming; SUN, Jian. **Accelerating Very Deep Convolutional Networks for Classification and Detection**. 2015. 56