

UNIVERSIDADE FEDERAL DO PAMPA

DAVID JORDÃO MESQUITA BELLINI DOS SANTOS

**ANÁLISE DE IMAGENS TERMOGRÁFICAS NO DIAGNÓSTICO DE
MANUTENÇÃO PREDITIVA**

Alegrete

2021

DAVID JORDÃO MESQUITA BELLINI DOS SANTOS

**ANÁLISE DE IMAGENS TERMOGRÁFICAS NO DIAGNÓSTICO DE
MANUTENÇÃO PREDITIVA**

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

Orientador: Prof. Me. Eliezer Soares Flores

Alegrete
2021

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

S237a Santos, David Jordão Mesquita Bellini dos
ANÁLISE DE IMAGENS TERMOGRÁFICAS NO DIAGNÓSTICO DE
MANUTENÇÃO PREDITIVA / David Jordão Mesquita Bellini dos
Santos.
48 p.

Trabalho de Conclusão de Curso(Graduação)-- Universidade
Federal do Pampa, ENGENHARIA ELÉTRICA, 2021.
"Orientação: Eliezer Soares Flores".

1. Análise termográfica. 2. Aprendizado de máquina. I.
Título.

DAVID JORDÃO MESQUITA BELLINI DOS SANTOS

ANÁLISE DE IMAGENS TERMOGRÁFICAS NO DIAGNÓSTICO DE MANUTENÇÃO PREDITIVA

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

Trabalho de Conclusão de Curso defendido e aprovado em: 27 de setembro de 2021.

Banca examinadora:

Prof. Me. Eliezer Soares Flores

Orientador

UNIPAMPA

Prof. Dr. Marcelo Resende Thielo

UNIPAMPA

Prof. Dr. José Wagner Maciel Kaehler

UNIPAMPA



Assinado eletronicamente por **ELIEZER SOARES FLORES, PROFESSOR DO MAGISTERIO SUPERIOR**, em 27/09/2021, às 20:23, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **JOSE WAGNER MACIEL KAEHLER, PROFESSOR DO MAGISTERIO SUPERIOR**, em 27/09/2021, às 20:24, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **MARCELO RESENDE THIELO, PROFESSOR DO MAGISTERIO SUPERIOR**, em 27/09/2021, às 20:26, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



A autenticidade deste documento pode ser conferida no site https://sei.unipampa.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0623807** e o código CRC **8D296600**.

Universidade Federal do Pampa, Campus Alegrete
Av. Tiarajú, 810 – Bairro: Ibirapuitã – Alegrete – RS CEP: 97.546-550
Telefone: (55) 3422-8400

Ao meu querido avô Vicente de Mesquita (in memoriam), homem mais trabalhador que já tive o prazer de conhecer, o qual enfrentou todas as dificuldades da vida com bom humor e positividade.

AGRADECIMENTOS

Agradeço a toda minha Família, em especial, aos meus pais Geraldo e Eline, meu irmão Pedro Paulo, pelo apoio incondicional.

Ao meu avô Vicente de Mesquita (in memoriam) pelos ensinamentos, pela generosidade, por todas as manhãs de domingo, pelas histórias, e pelo companheirismo ao longo de toda minha vida.

Ao Prof. Me. Eliezer Soares Flores pela confiança, paciência e orientação que tornou este projeto possível.

A todos meus amigos, em especial ao João Carlos Bedinoto, por todos os anos de amizade.

A minha namorada Carine pelo companheirismo e paciência ao longo de todos esses anos de relacionamento.

A todas as pessoas com que tive a oportunidade de conviver durante minha morada em Alegrete.

“A gente se acostuma para não se ralar na aspereza, para preservar a pele. Se acostuma para evitar feridas, sangramentos, para esquivar-se da faca e da baioneta, para poupar o peito. A gente se acostuma para poupar a vida. Que aos poucos se gasta, e que, gasta de tanto acostumar, se perde de si mesma.”

(Marina Colasanti. Eu sei, mas não devia)

RESUMO

A análise termográfica de itens e sistemas elétricos é uma técnica de manutenção preditiva não intrusiva, logo, pode ser aplicada sem interromper a operação do sistema. Atualmente o diagnóstico de condição proveniente da análise termográfica é efetuado por um especialista, seja ele um engenheiro eletricista ou um técnico especializado. Portanto, é uma tarefa que demanda um custo elevado e exige trabalhadores qualificados. Neste trabalho, é proposto um sistema que classifica automaticamente imagens termográficas de fusíveis, com base em características extraídas da imagem por meio de uma rede neural convolutiva pré-treinada, e visa auxiliar profissionais na tomada de decisão. Especificamente, os parâmetros do classificador são ajustados a partir de K-médias produzidas para cada classe de imagens termográficas de fusíveis dos tipos NH e D. A base de dados foi adquirida através de relatórios de análise termográfica e categorizada com o intuito de ser aplicada a tarefas de classificação. Posteriormente, a base de dados foi utilizada no processo de treinamento e validação de uma variedade de arquiteturas de redes convolucionais em conjunto com métodos de classificação, os quais foram avaliados utilizando validação cruzada. O melhor resultado aponta que a rede VGG16 em conjunto com o classificador SVM, devidamente parametrizado, consegue diagnosticar a condição de fusíveis tipo NH e tipo D com uma taxa de acerto de aproximadamente 93%.

Palavras-Chave: Processamento de Imagens, Manutenção Preditiva, Análise Termográfica

ABSTRACT

Thermographic analysis of electrical items and systems is a non-intrusive predictive maintenance technique, so it can be applied without interrupting the operation of the system. Currently the diagnosis condition from thermographic analysis is performed by a specialist, be it an electrical engineer or a technical expert. Therefore, it is a costly task and requires skilled workers. In this paper, we propose a system that automatically classifies thermographic images of fuses, based on features extracted from the image through a pre-trained convolutional neural network, and aims to assist professionals in decision making. Specifically, the classifier parameters are tuned from K-means produced for each class of NH- and D-type fuse thermographic images. The database was acquired from thermographic analysis reports and categorized in order to be applied to classification tasks, then the database was used in the process of training and validating a variety of convolutional network architectures in conjunction with classification methods, which were evaluated using cross-validation. The best results indicate that the VGG16 network in conjunction with the SVM classifier, properly parameterized, can diagnose the condition of NH-type and D-type fuses with a hit rate of approximately 93%.

KeyWords: Image Processing, Predictive Maintenance, Thermographic Analysis

LISTA DE ILUSTRAÇÕES

Figura 1 – Termografia eletromagnética, exemplo 1	20
Figura 2 – Termografia eletromagnética, exemplo 2	20
Figura 3 – Termografia eletromagnética, exemplo 3	20
Figura 4 – Fluxograma da abordagem clássica de processamento e análise de imagens	21
Figura 5 – Arquitetura básica da rede neural convolucional VGG16.	22
Figura 6 – Ilustração genérica do processo de convolução efetuado através da rede convolucional.	23
Figura 7 – Exemplo de funcionamento do método Maxpooling.	23
Figura 8 – Imagens contidas nos relatórios de inspeção termográfica.	27
Figura 9 – Imagens termográficas contidas no novo banco de dados.	28
Figura 10 – Fluxo de trabalho do sistema de processamento e análise de imagens proposto.	30
Figura 11 – Uso da rede VGG16 pré-treinada para extração de características. . . .	31
Figura 12 – Representação dos vetores de características de treino da classe “pouco aquecido”, antes e após o procedimento de balanceamento de amostras. . . .	31
Figura 13 – Representação dos vetores de características de treino da classe “aque- cido”, antes e após o procedimento de balanceamento de amostras. . . .	32
Figura 14 – Representação dos vetores de características de treino da classe “muito aquecido”, antes e após o procedimento de balanceamento de amostras. . . .	32
Figura 15 – Exemplo da aplicação do classificador KNN.	33
Figura 16 – Divisão do base de dados em conjunto de treino, validação e teste. . . .	34
Figura 17 – Esquema de validação cruzada <i>leave-one-out</i> utilizado na etapa de treino e validação do sistema proposto.	35
Figura 18 – Fluxograma do processo de avaliação de hiperparâmetros para uma iteração de validação.	37
Figura 19 – Matriz de confusão apresentando o desempenho da rede convolucional MobileNet em conjunto com o classificador KNN.	38
Figura 20 – Matriz de confusão apresentando o desempenho da rede convolucional VGG19 em conjunto com o classificador Random Forest.	39
Figura 21 – Matriz de confusão apresentando o desempenho da rede convolucional InceptionV3 em conjunto com o classificador Random Forest.	40
Figura 22 – Matriz de confusão apresentando o desempenho da rede convolucional VGG16 em conjunto com o classificador SVM.	41
Figura 23 – Matriz de confusão apresentando o desempenho da rede convolucional VGG19 em conjunto com o classificador SVM.	42

LISTA DE TABELAS

Tabela 1 – Avaliação da condição dos equipamentos de acordo com a variação de temperatura.	28
Tabela 2 – Desempenho rede convolucional MobileNet em conjunto com o classificador KNN	39
Tabela 3 – Desempenho rede convolucional VGG19 em conjunto com o classificador Random Forest	40
Tabela 4 – Desempenho rede convolucional ResNet50 em conjunto com o classificador Random Forest	41
Tabela 5 – Desempenho rede convolucional VGG16 em conjunto com o classificador SVM	42
Tabela 6 – Desempenho rede convolucional VGG19 em conjunto com o classificador SVM	43

LISTA DE ABREVIATURAS E SIGLAS

KNN	<i>K-Nearest Neighbors</i>
SVM	<i>Support Vector Machine</i>
CNN	<i>Convolutional Neural Network</i>
NBR	Norma Brasileira
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
FP	Falso Positivo
FN	Falso Negativo
TC	Temperatura Corrigida
TMA	Temperatura Máxima Admissível

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Trabalhos Relacionados	15
1.2	Objetivo Geral	16
1.2.1	Objetivos Específicos	16
1.3	Organização do Trabalho	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Manutenção	17
2.1.1	Manutenção Corretiva	17
2.1.2	Manutenção Preventiva	17
2.1.3	Manutenção Preditiva	17
2.1.4	Análise Termográfica	18
2.2	Análise e Processamento de Imagens	19
2.2.1	Abordagem Clássica de Processamento e Análise de Imagens	21
2.2.2	Processamento e Análise de Imagens Utilizando <i>Deep Learning</i>	22
2.2.2.1	Redes Neurais Convolucionais	22
2.2.2.2	Balanceamento de Dados	23
2.2.2.3	Classificação	24
2.2.3	Métricas de Desempenho	25
3	MATERIAIS E MÉTODOS	27
3.1	Aquisição do Banco de Imagens	27
3.2	Sistema Proposto	29
3.2.1	Extração de Características	30
3.2.2	Balanceamento do Número de Amostras por Classe Usando <i>k-means</i>	31
3.2.3	Classificação	33
4	RESULTADOS E DISCUSSÃO	34
4.1	Particionamento do Conjunto de Dados e Recursos Computacionais Utilizados	34
4.2	Ajuste dos Hiperparâmetros com o Subconjunto de Validação	35
4.3	Avaliação do Desempenho do Sistema com o Subconjunto de Teste	38
4.3.1	Sistema Proposto Utilizando KNN	38
4.3.2	Sistema Proposto Utilizando <i>Random Forest</i>	39
4.3.3	Sistema Proposto Utilizando SVM	41
5	CONSIDERAÇÕES FINAIS	44
	REFERÊNCIAS	46

1 INTRODUÇÃO

Dhillon (2002) afirma que, desde a revolução industrial, a manutenção de equipamentos é um desafio. Com a globalização e o desenvolvimento tecnológico, as indústrias passaram por um contexto de mecanização e automatização do processo produtivo, visando o aumento de produtividade e a diminuição de custos. Além disso, com a tendência mundial da utilização do sistema *just-in time*, a manutenção se tornou um assunto importante de gerenciamento (HUTCHINS, 1999). A manutenção, quando bem executada, pode ser empregada como um fator estratégico para a competitividade das empresas (CACHADA et al., 2018). Adicionalmente, Dhillon (2002) aponta que um evento (indesejável) tal como um defeito ou falha pode apresentar uma implicação ambiental, ou de segurança imediata. Dessa forma, a manutenção vem recebendo cada vez mais atenção positiva da indústria, havendo assim uma demanda por práticas efetivas de gerenciamento e manutenção de ativos (i.e., sistemas ou itens), bem como por adotar estratégias para manter os equipamentos em operação e reduzir as eventuais falhas.

Conforme estipulado na NBR-5462 (1994), a manutenção é a combinação de ações técnicas e de gerenciamento para manter ou recolocar qualquer item ou sistema de maneira que possa desempenhar a função destinada, sendo usualmente classificada como corretiva, preventiva, ou preditiva. A ação corretiva ocorre quando existe a necessidade de atuação imediata no item ou sistema, onde o mesmo pode apresentar falha ou defeito que prejudique o processo produtivo. A manutenção preventiva é o conjunto de rotinas ou procedimentos previamente definidos que visa prevenir potenciais falhas ou defeitos. Já a ação preditiva consiste no monitoramento do item ou sistema para prever falhas ou defeitos que ainda não estão sendo abordados pela rotinas preventivas, ou que não possuem históricos de falha ou defeito prévio atendidos em ações corretivas.

Em especial, as técnicas de análise termográfica integram um conjunto de metodologias, procedimentos e atividades que suportam a avaliação do comportamento de itens e sistemas, empregados principalmente nos processos produtivos e serviços energéticos de uso final. Visto que tais técnicas são classificadas como preditivas e não intrusivas, tornam-se atraentes, pois não requerem a interrupção da operação dos itens ou sistemas para poderem ser aplicadas.

Com o avanço das técnicas de aprendizado de máquina e o desenvolvimento de redes convolucionais voltadas para o reconhecimento de padrões em imagens (KRIZHEVSKY; SUTSKEVER; HINTON, 2012), atrelado ao fato de que tais redes vêm apresentando resultados promissores em reconhecimento de padrões de sistemas complexos como, por exemplo, classificação de lesões de pele (ESTEVA et al., 2017) e em diversos segmentos, desde a utilização de redes convolucionais para reconhecimento de fala (HAN et al., 2020) até temas relacionados como a identificação de imagens para auxílio de manutenção na rede elétrica (OLIVO; FILHO; JUNIOR, 2020). Portanto, percebe-se a possibilidade de viabilidade da aplicação de técnicas de aprendizado de máquina para o desenvolvimento

de um sistema de processamento e análise de imagens que auxilie na tarefa de avaliação da condição de itens e sistemas elétricos através de imagens termográficas.

1.1 Trabalhos Relacionados

Esta seção visa apresentar trabalhos que tratam de problemas similares ao desenvolvido na pesquisa. Apresenta a aplicação da termografia como técnica efetiva de manutenção preditiva, trata também sobre a utilização da termografia em itens e sistemas elétricos no setor de manutenção industrial. Ademais, discute a utilização de redes convolucionais para o tratamento de problemas que exigem conhecimento especializado.

Santos (2006) inicia sua dissertação descrevendo sobre a influência da manutenção preditiva na confiabilidade do sistema elétrico. Utiliza-se deste artifício de modo a sustentar a importância do uso de técnicas não preditivas, mais especificamente a termografia. O autor discute sobre as limitações da inspeção termográfica, apresentando as normas, tecnologias utilizadas e condições ambientais que influenciam na inspeção termográfica. Trata também sobre resolução do sensor térmico, sensibilidade térmica, entre outros aspectos, para por fim propor procedimentos para utilização da inspeção termográfica. No entanto, o trabalho (SANTOS, 2006) não disponibiliza nenhum exemplo de base de imagens termográficas.

O trabalho de Cezar (2012) utiliza da termografia como método preditivo de manutenção de itens e sistemas no ambiente industrial. O estudo tem o propósito de criar banco de imagens que registre as condições dos elementos do sistema elétrico de uma indústria, de modo a dar suporte ao setor de manutenção na tomada de decisões. O trabalho expõe rotinas, procedimentos de manutenção, análise de problemas e, além disso, apresenta a termografia como técnica não intrusiva. O trabalho dispõe de banco de imagens com diagnósticos estipulados, porém, a base de imagens disponibilizada é escassa, contando com apenas 23 termogramas.

Esteva et al. (2017) desenvolveram uma pesquisa que proporcionou um grande impacto na área de análise de imagens médicas, ressaltando o potencial da utilização de redes neurais convolucionais para solucionar problemas de alta variabilidade. Os autores desenvolveram um método capaz de classificar automaticamente lesões de pele utilizando unicamente uma rede convolucional (CNN), inceptionV3. A atuação do sistema foi comparada ao desempenho de 21 dermatologistas especializados em imagens clínicas, conseguindo apresentar precisão compatível ao dos peritos. Muitos sistemas baseados em CNNs não incluem as etapas de pré-processamento, segmentação e extração de características, diferenciando-se assim do *pipeline* clássico utilizado por sistemas de processamento e análise de imagens.

Olivo, Filho e Junior (2020) desenvolveu uma pesquisa que propõe a identificação de objetos em imagens capturadas por drones com o objetivo de auxiliar na manutenção de redes elétricas. O trabalho compilou uma base de dados com 824 imagens de itens

elétricos, entre eles, transformadores, isoladores, para-raios, entre outros. Foi proposto um modelo de detecção de objetos com base na rede convolucional, *darknet-53*, o qual apresentou resultados promissores dada a quantidade de dados disponíveis. A pesquisa apesar de abordar assunto relacionado se difere, pois efetua a identificação de imagens digitais convencionais e não trata da análise de imagens termográficas.

1.2 Objetivo Geral

Propor um sistema de análise de imagens utilizando redes convolucionais, capaz de auxiliar profissionais na identificação da condição de um item ou sistema elétrico, através de imagens termográficas provenientes de rotinas de manutenção preditivas.

1.2.1 Objetivos Específicos

Os objetivos específicos deste trabalho são :

- Compilar uma base de dados adequada para tarefas de classificação, relacionadas ao tema;
- Treinar modelos utilizando base de dados compilada;
- Avaliar o desempenho do sistema proposto em classificar corretamente amostras inéditas.

1.3 Organização do Trabalho

O trabalho encontra-se estruturado da seguinte forma: O Capítulo 2 apresenta uma revisão bibliográfica sobre os fundamentos abordados na pesquisa. No Capítulo 3 são apresentados os materiais e métodos utilizados para o desenvolvimento da pesquisa, bem como a caracterização e a abordagem da proposta. O Capítulo 4 apresenta a abordagem utilizada para avaliar o sistema proposto, bem como os resultados e a discussão dos resultados. No Capítulo 5 são apresentadas as considerações finais sobre o trabalho desenvolvido e as suas principais contribuições.

2 FUNDAMENTAÇÃO TEÓRICA

Com foco em apresentar de forma resumida e coesa os principais fundamentos envolvidos no desenvolvimento deste trabalho, este capítulo se encontra organizado em três seções. A Seção 2.1 elenca as categorias de manutenção, com ênfase nas técnicas preditivas e análise termográfica. Concluindo, a Seção 2.2 aborda os fundamentos de análise e processamento de imagens, abordagem clássica de processamento e análise de imagens, bem como os métodos utilizando *Deep Learning* empregados no presente trabalho.

2.1 Manutenção

Um determinado item ou sistema pode ser categorizado como em estado de falha quando esse não está apto a exercer a sua finalidade, ou é categorizado como em estado de defeito quando o mesmo apresenta um desvio nas suas características básicas de operação, porém ainda exercendo sua finalidade. De modo a corrigir e/ou evitar estados de falha ou defeito, pode-se aplicar uma manutenção centrada na confiabilidade, a qual, conforme a NBR-5462 (1994), é a combinação de ações técnicas e de gerenciamento para manter ou recolocar qualquer item ou sistema para exercer a função destinada.

2.1.1 Manutenção Corretiva

Segundo Dhillon (2002), apesar da engenharia projetar equipamentos visando a confiabilidade, todo sistema ou item é suscetível a falha. Assim, a manutenção corretiva entra como uma ferramenta importante; sendo grande parte do esforço da manutenção dedicada à ação corretiva.

De acordo com Kardec e Nascif (2009), a manutenção corretiva é a atuação para corrigir uma falha ou defeito do equipamento que afete a operação esperada do mesmo. Dessa forma, a manutenção corretiva não é necessariamente uma ação de emergência para todos os casos, podendo, nos casos de defeito, ser realizada somente para reparar ou restabelecer o padrão de funcionamento de um determinado item.

2.1.2 Manutenção Preventiva

A NBR-5462 (1994) define a manutenção preventiva como sendo ações efetuadas em intervalos de tempo definidos, com base em critérios planejados previamente, para reduzir a falha ou degradação do equipamento ou sistema. Ainda, Kardec e Nascif (2009) argumentam que a manutenção preventiva atua através do estabelecimento de um plano elaborado, considerando cada instalação como um caso específico.

2.1.3 Manutenção Preditiva

A NBR-5462 (1994) aponta que a manutenção preditiva ou controlada é aquela que garante a qualidade do serviço, utilizando de técnicas de análise de maneira que

ocasiona a redução máxima do suporte preventivo e corretivo.

Utiliza-se de ferramentas para efetuar o diagnóstico de um equipamento antes que a falha ou defeito ocorra de modo a prever uma provável avaria e permitir o uso do item pelo maior tempo possível.

A intervenção preditiva é feita com o item em funcionamento integral, ou seja, não é necessária uma parada do processo produtivo para realizar os procedimentos.

Segundo Dhillon (2002), a manutenção preditiva (também chamada monitoramento de condições) utiliza de métodos e equipamentos para aquisição de dados de um item ou sistema para diagnosticar a condição do mesmo. Quando utilizado continuamente com o auxílio da análise de tendências e reconhecimento de padrões, pode-se determinar a situação de um equipamento de maneira a prever falhas.

A condição do equipamento é monitorada segundo Cezar (2012) pelo cruzamento de vias não intrusivas como imagem sonora, imagem térmica, harmônicos elétricos, vibrações e outras técnicas. De acordo com Kardec e Nascif (2009), as condições para se utilizar a manutenção controlada são:

- Possibilidade de implantação de método de monitoramento do item.
- Análise de custo para implantação de monitoramento para equipamento.
- Falha com origem em que se permite monitorar de maneira progressiva.
- Planejamento de programas de monitoramento, análise e diagnóstico sistematizado.

2.1.4 Análise Termográfica

A análise termográfica é um caso particular de manutenção preditiva, o qual será tratado em detalhes nesta seção. A NBR-15572 (2013) estipula que as anomalias que geram aquecimentos em componentes elétricos geralmente são oriundas de elevação das perdas por efeito "joule", seja pelo aumento da resistência gerada por conexões mal feitas, sistemas deteriorados ou instalados de forma inadequada. Além disso, falhas podem ser ocasionadas por problemas mecânicos como a falta de lubrificação que, por atrito, provoca elevação de temperatura nos mancais, por exemplo. Logo, a investigação termográfica fornece informações confiáveis sobre as condições do item e as causas das irregularidades, sugerindo assim ações corretivas.

A empresa Fluke (2009) aponta que a inspeção termográfica é uma ciência que trabalha com equipamentos ópticos com o objetivo de detectar a radiação e correlacionar com a temperatura da superfície do equipamento em análise, definindo radiação como fluxo de calor com propagação de energia radiante na presença de um meio direto de transferência.

2.2 Análise e Processamento de Imagens

De acordo com Pedrini e Schwartz (2008), uma imagem pode ser representada como uma função vetorial sobre o \mathbb{R}^2 , a qual mapeia cada ponto $(x, y) \in \mathbb{R}^2$ (x e y são ditas as coordenadas espaciais) para um vetor, o qual representa as informações captadas no ponto em questão. Na prática, somente uma quantidade finita de pontos são armazenados e os valores dos vetores correspondentes são discretizados. Nesse caso, diz-se tratar de uma imagem digital. O termo de processamento de imagens se refere, usualmente, ao processamento de imagens digitais realizado por um computador.

Gonzalez e Woods (2009) discutem sobre os sentidos humanos, com ênfase na visão. Nesse contexto, as imagens, limitadas à gama de visão dos nossos olhos, desempenham um papel de extrema relevância. Diversos equipamentos eletrônicos, no que lhes concerne, permitem produzir informações não só a partir do comprimento de onda da luz visível, mas também a partir de outras faixas, as quais cobrem praticamente todo o espectro eletromagnético. Especificamente, imagens podem ser produzidas por fontes tais como raios-X, ultrassom, microscopia eletrônica e infravermelho, viabilizando inúmeras aplicações práticas de engenharia.

Segundo Gonzalez e Woods (2009), as imagens de raios-X, por exemplo, são as fontes de imagens mais antigas e mais conhecidas, devido à ampla utilização no meio médico, em diagnósticos de saúde, imagens estas provenientes de energia em forma de radiação de raios-X. Imagens na banda ultravioleta possuem diversas aplicações, sendo uma delas na microscopia, que funciona onde uma luz de excitação é utilizada para irradiar um elemento preparado e depois separa-se a luz fluorescente da irradiante, de um modo que as áreas fluorescentes resultantes brilham em contraste com um fundo escuro para permitir a detecção. Imagens da banda visível e banda de rádio também podem ser utilizada assim como todo espectro eletromagnético.

Gonzalez e Woods (2009) cita que atualmente a gama de aplicações de processamento de imagens é extremamente ampla, abordando diversas áreas de empreendimentos, desta forma necessitando de uma maneira de organização que inclua todas as finalidades do processamento digital de imagens. A maneira mais transparente de se compreender as aplicações do processamento é categorizar imagens segundo a sua fonte. Usualmente a banda infravermelha é utilizada em conjunção com a banda visível na formação de imagens.

Além disso, Jaahne (2004) propõe que as imagens na faixa de infravermelho e micro-ondas podem ser usadas para medir a temperatura de objetos remotamente. Esta aplicação de imagem é conhecida como termografia. Nas Figuras 1, 2 e 3 podem ser observadas imagens térmicas de equipamentos.

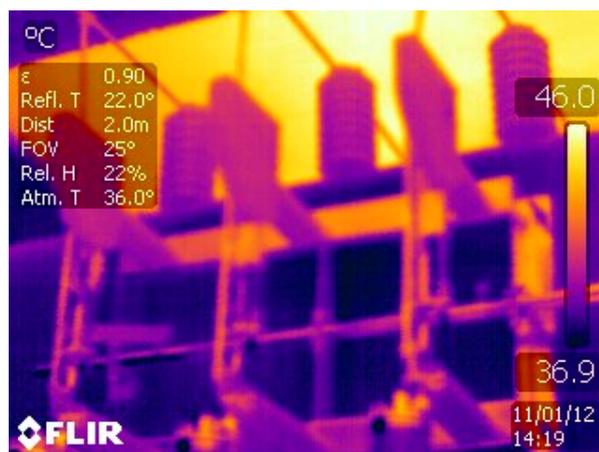


Figura 1 – Termografia eletromagnética, exemplo 1

Fonte: Cezar, 2012

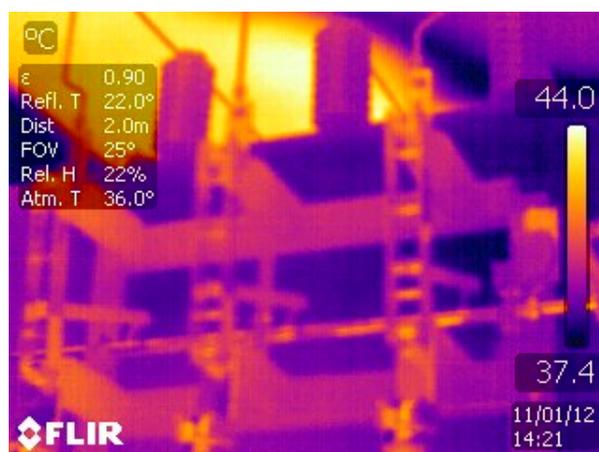


Figura 2 – Termografia eletromagnética, exemplo 2

Fonte: Cezar, 2012

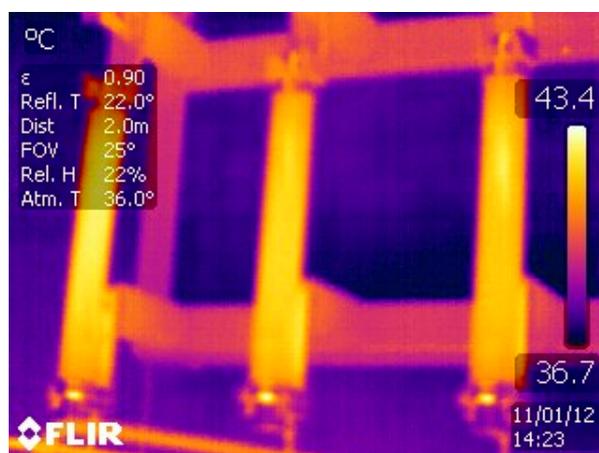


Figura 3 – Termografia eletromagnética, exemplo 3

Fonte: Cezar, 2012

2.2.1 Abordagem Clássica de Processamento e Análise de Imagens

Conforme Russ (2011) afirma, o processamento e análise de imagens trata de estabelecer critérios que possam ser usados para identificar ou diferenciar diferentes categorias de objetos que podem aparecer nas imagens. Esses critérios podem variar em forma e sofisticação. Segundo Dougherty (2012), no caso de uma imagem, utiliza-se do processo de segmentação para isolar objetos do fundo, onde os diferentes elementos da imagem estão rotulados. Um sistema convencional de reconhecimento de padrões conta com procedimento de pré-processamento que ocorre antes da segmentação, contando também com mecanismo de extração de características e por fim com auxílio de um grupo de exemplos já classificados utilizando de técnicas de classificação. A Figura 4 ilustra o *pipeline* clássico de processamento e análise de imagens.

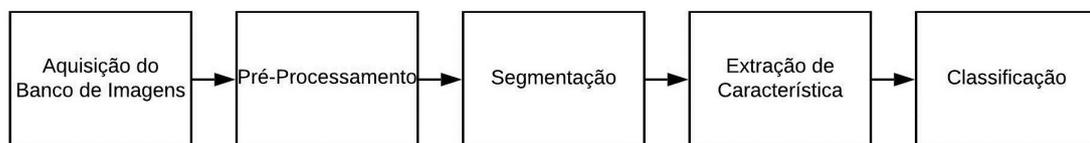


Figura 4 – Fluxograma da abordagem clássica de processamento e análise de imagens

Fonte: o Autor.

a) Pré-processamento: Dougherty (2012) apresenta o pré-processamento de maneira geral utilizando-o para adequar uma imagem para o processo de segmentação, através de técnicas para diminuição do ruído, brilho, sombra e entre outros.

b) Segmentação: Gonzalez e Woods (2009) cita que a segmentação subdivide uma imagem em grupos, com o intuito específico de detectar regiões de interesse. Seja R o conjunto composto por todos os pixels da imagem, a segmentação atua como processo de subdivisão desse subconjunto em n subconjuntos, também denominados regiões, R_1, R_2, \dots, R_n , onde tipicamente o objetivo é separar o objeto de interesse do restante da cena. Dougherty (2012) argumenta que existem duas abordagens principais para a segmentação, a saber, os métodos com base em agrupamento de regiões onde são detectadas semelhanças, e os métodos baseados em detecção de bordas, onde as arestas das regiões são detectadas e ligadas para formar fronteiras contínuas.

c) Extração de características: De acordo com Dougherty (2012), características são propriedades específicas de objetos, onde os valores de extração devem ser semelhantes em elementos de uma mesma classe. Tais características devem ser representadas através de estrutura de dados compatíveis com o algoritmo de classificação.

d) Classificação: Segundo Dougherty (2012), a classificação é a etapa final de um processo geral que envolve atribuir um rótulo de classe para um dado objeto conforme as características do mesmo.

2.2.2 Processamento e Análise de Imagens Utilizando *Deep Learning*

O processamento e análise de imagens com o auxílio de *deep learning*, utiliza-se de redes convolucionais para realizar diretamente a classificação, sem as etapas de pré-processamento, segmentação e extração de características tipicamente presentes em um sistema clássico de processamento e análise de imagens. Contudo, para serem treinadas de maneira adequada, redes convolutivas exigem uma quantidade significativa de amostras de treinamento. Quando a quantidade de amostras não é significativa, uma abordagem possível é utilizar uma rede pré-treinada. Outra dificuldade relacionada à escassez de amostras é a possível questão dos dados apresentarem desbalanceamento entre classes. Esta seção é organizada pelas seguintes etapas:

- Utilização de redes neurais convolucionais (Subseção 2.2.2.1);
- Balanceamento do número de amostras (Subseção 3.2.2);
- Classificação (Subseção 3.2.3).

2.2.2.1 Redes Neurais Convolucionais

Os primeiros modelos de rede convolucionais a gerarem resultados foram registrados por volta de 2012, no segmento de reconhecimento de fala (DAHL et al., 2011).

Já Krizhevsky, Sutskever e Hinton (2012), desenvolveram em sua pesquisa o primeiro modelo de rede convolucional capaz de gerar resultados atrativos utilizando imagens, modelo este denominado AlexNet. Atualmente redes neurais convolucionais são amplamente utilizadas em reconhecimento de padrões, seja na detecção e localização de objetos em imagens e vídeos, até em tarefas mais complexas como segmentação, sendo aplicados em diversos segmentos da engenharia. Um dos modelos de redes neurais convolucionais utilizadas neste trabalho é a VGG16, ilustrada abaixo.

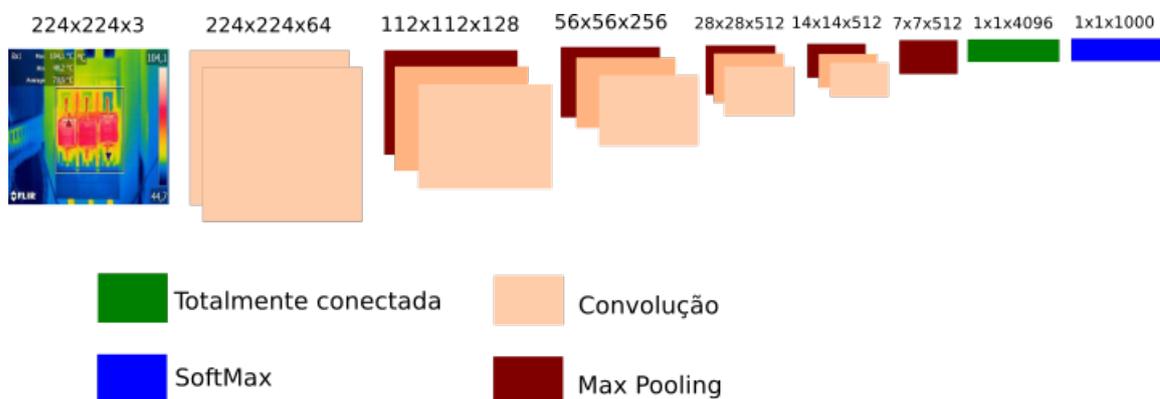


Figura 5 – Arquitetura básica da rede neural convolucional VGG16.

Fonte: o Autor.

Como é observado na Figura 5, a VGG16, bem como outras redes convolucionais utilizadas no trabalho, conta com as camadas de convolução, *max pooling*, totalmente conectada, e transferência (por exemplo, *softmax*).

A principal operação realizada por tais CNNs é a convolução e visa preservar a estrutura principal da imagem, no caso do trabalho em questão, representado por uma matriz $224 \times 224 \times 3$. Desta forma aplica-se um filtro g sobre toda a extensão da imagem f , conforme descrito na Eq. (2.1) e ilustrado na Figura 6.

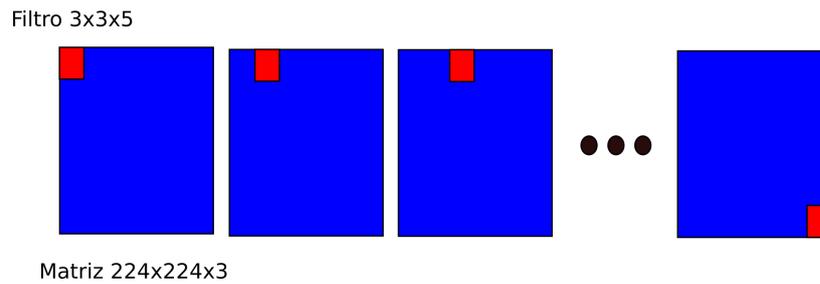


Figura 6 – Ilustração genérica do processo de convolução efetuado através da rede convolucional.

Fonte: o Autor.

$$f[x, y] * g[x, y] = \sum_{n_1=-\infty}^{\infty} \sum_{n_2=-\infty}^{\infty} f[n_1, n_2].g[x - n_1, y - n_2] \quad (2.1)$$

A etapa de *Pooling*, por sua vez, procura diminuir a dimensão espacial da matriz, e pode ser efetuada através do método *Max pooling*, retirando o valor máximo de cada porção da matriz inicial, ilustrado na Figura 7, ou através do *Average pooling*, que efetua o mesmo procedimento, porém retirando o valor médio de cada fração da matriz inicial.

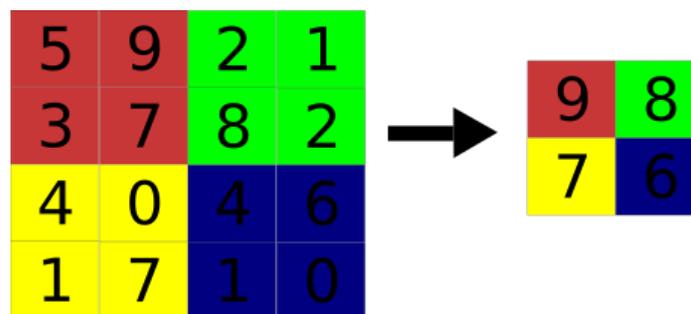


Figura 7 – Exemplo de funcionamento do método Maxpooling.

Fonte: o Autor.

2.2.2.2 Balanceamento de Dados

Classificação de dados desbalanceados em aprendizado máquina é considerado uma tarefa árdua, pois sistemas apresentam tendência a favorecer dados da classe com maior quantidade de informações (FACELI et al., 2011). Para solucionar tal empecilho são

empregadas técnicas não supervisionadas (*clustering*). Métodos supervisionados trabalham com conjuntos de dados rotulados utilizando-os como referência para fazer previsões sobre dados inéditos. O *clustering*, entretanto, trabalha apenas com dados “desconhecidos” (não rotulados), podendo assim ser aplicado em tarefas de classificação, onde dados com características semelhantes apresentam tendência a formar agrupamentos semelhantes, e em operações de balanceamento de dados, onde são agrupados elementos de uma mesma classe de tal maneira que todas as classes pertencentes ao problema apresentem a mesma quantidade de dados.

No presente trabalho, tal método é utilizado para efetuar o balanceamento entre as classes da base de dados. Segundo Jain (2010), técnicas de *clustering* são amplamente utilizadas em inúmeros campos da ciência para análise de dados. O autor afirma que o algoritmo mais conhecido e amplamente utilizado é o *k-means*. Tal algoritmo consiste em encontrar aglomerações (*clusters*) em um conjunto de dados, dado um grupo de vetores (i.e., observações) $\mathbf{x}^{(i)}$, tal que, $X = \{\mathbf{x}^{(i)}\}, i = 1, \dots, n - 1$, onde $(n - 1)$ denota a quantidade de observações de treinamento em uma mesma classe $y^{(i)}$ a serem agrupados em $C = \{c_k\}, k = 1, \dots, K$, sendo μ_k a média de um determinado *cluster* C_k (i.e., subgrupo).

O algoritmo encontra as K partições de maneira que o erro quadrático total entre médias μ_k e dados $x^{(i)}$ de cada subgrupo C_k seja mínimo, expresso como $J(c_k) = \sum_{\mathbf{x}^{(i)} \in C_k} \|\mathbf{x}^{(i)} - \mu_k\|^2$ para cada subgrupo, e $J(C) = \sum_{k=1}^K \sum_{\mathbf{x}^{(i)} \in C_k} \|\mathbf{x}^{(i)} - \mu_k\|^2$ entre os k subgrupos.

2.2.2.3 Classificação

Com o objetivo de atribuir rótulos aos vetores de características provenientes das redes convolucionais empregam-se técnicas de classificação. O método KNN (K vizinhos mais próximos) é, segundo Gonçalves et al. (2016), uma técnica que atribui um rótulo a um vetor de teste ainda não identificado (desconhecido) com base nos rótulos dos K vizinhos mais próximos (vetores de treinamento), utilizando-se do cálculo da distância euclidiana ilustrada na Eq. (2.2) para a determinação da proximidade.

$$d(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \sqrt{\sum_{k=1}^n (x_k^i - x_k^j)^2}. \quad (2.2)$$

Onde $\mathbf{x}^{(i)}$ e $\mathbf{x}^{(j)}$ são vetores no \mathbb{R}^d provenientes do algoritmo de balanceamento de dados; $x_k^{(i)}$ denota a k -ésima característica de $\mathbf{x}^{(i)}$ e $x_k^{(j)}$ denota a k -ésima característica de $\mathbf{x}^{(j)}$.

Consideramos $\mathbf{x}^{(i)}$ um vetor de treinamento, com $i \in [0, q - 1]$ e $\mathbf{x}^{(q)}$ denominado vetor de teste, de forma que o intervalo de $[0, q]$ retrata o número total de vetores. A técnica KNN classifica a imagem através da distância euclidiana Eq. (2.2), entre vetores de forma que $\mathbf{x}^{(q)}$ será atribuído ao rótulo do vetor mais votado, através da moda de $(\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^{(q-1)})$.

A classificação utilizando o método SVM (support Vector Machines), segundo Faceli et al. (2011) é fundamentada pela teoria de aprendizado estatístico, onde estabelece princípios que devem ser seguidos em classificadores que apresentam alta capacidade de generalização. Faceli et al. (2011) continua, afirmando que SVMs lineares tem eficácia com dados que são facilmente representados linearmente. Caso dados não seja facilmente separáveis o referido método utiliza de núcleos (i.e., *Kernel*), mapeando os dados em um espaço de alta dimensionalidade, buscando a melhor separação entre classes.

Dada um hiperplano com as classes linearmente separáveis.

$$f(x) = \beta_0 + \beta_1 \mathbf{x}_1^{(i)} + \beta_2 \mathbf{x}_2^{(i)} + \dots + \beta_p \mathbf{x}_p^{(i)} = 0 \quad (2.3)$$

se $f(x) > 0$, então, $\mathbf{x}^{(i)}$ está de um lado do hiperplano, se $f(x) < 0$, então, $\mathbf{x}^{(i)}$ está do outro lado do hiperplano, de forma que $f(x^{(i)}) > 0 \therefore y_{(i)} = +1$ e $f(x^{(i)}) < 0 \therefore y_{(i)} = -1$.

O conceito de *kernel*, visa mapear os dados em planos de alta dimensionalidade encontrando um determinado plano que melhor separe os dados entre classes. Neste trabalho utiliza-se da *Radial Basis Function*.

$$K(x, x') = \exp(-\gamma \|x - x'\|^2) \quad (2.4)$$

Onde γ é um hiperparâmetro definido no modelo do sistema proposto, responsável por ponderar a distância euclidiana entre as amostras x e x' .

2.2.3 Métricas de Desempenho

Segundo Dougherty (2012) existem inúmeras métricas para se quantificar o desempenho de um classificador. Para o sistema proposto em específico foram utilizados: acurácia, precisão, *recall* e *F-score*. Para melhor entender as referidas denominações, deve-se entender os conceitos de verdadeiro positivo, falso positivo, falso negativo e verdadeiro negativo, oriundos da tabela de confusão.

É denominado Verdadeiro Positivo, VP, quando o modelo prediz a amostra como pertencente a uma determinada classe e ela, de fato, pertence ao rótulo. O falso positivo, FP, representa o evento contrário, ou seja, prediz uma amostra como falso positivo. Falso negativo FN acontece quando casos positivos são diagnosticados como negativos. Verdadeiro negativo VN quando a amostra é determinada negativa e de fato o é.

a) Acurácia: Responsável por revelar o desempenho do sistema, retorna o número de acertos em relação a todas as interações do sistema. No trabalho proposto, ela representa o quociente entre o número de imagens classificadas corretamente e o número total de imagens (N_{img}).

$$Acuracia = \frac{Acertos}{Numero_{Imagens}} \quad (2.5)$$

b) Precisão: Revela o quociente de verdadeiros positivos entre soma dos itens diagnosticados como verdadeiro positivo e falso positivo.

$$Precisao = \frac{VP}{VP + FP} \quad (2.6)$$

c) Recall: Calcula o quociente entre verdadeiros positivos e o total de amostras consideradas verdadeiras que o modelo não conseguiu prever.

$$Recall = \frac{VP}{VP + FN} \quad (2.7)$$

d) F-Score: Dada pela média harmônica entre a precisão e o *recall*.

$$F - Score = 2 \frac{Precisao \ recall}{Precisao + recall} \quad (2.8)$$

3 MATERIAIS E MÉTODOS

Neste capítulo serão apresentadas as metodologias utilizadas para a realização deste trabalho. Na Seção 3.1 é apresentado o processo de aquisição da base de imagens. A Seção 3.2 apresenta os métodos que serão utilizados para o desenvolvimento do sistema proposto. Por fim a metodologia para a avaliação e seleção de hiperparâmetros do sistema, descrito na Seção 4.1.

3.1 Aquisição do Banco de Imagens

Devido a impossibilidade de desenvolver experimento próprio para aquisição de imagens, surgiu a necessidade de compilar um banco de dados de imagens adequado para tarefas de classificação. Para a montagem da base, consideraram-se imagens termográficas originárias de relatórios de inspeção expostos em (ARESPCJ, 2015).

Tendo em vista que os referidos relatórios disponíveis em (ARESPCJ, 2015) apresentam uma abordagem diversificada de sistemas e itens elétricos, foi observado que determinados itens não poderiam ser representados em todas as suas condições de temperatura, ou seja, itens abordados única e exclusivamente em condições severas de temperatura, ou por vezes itens que foram apenas abordados em uma única inspeção, entre outros casos dos quais não era possível caracterizar as diversas condições de temperatura do equipamento. Desta forma, foi selecionado um subconjunto de imagens que melhor representasse as condições de um determinado item, durante toda a sua vida útil. Logo, foi estabelecida a utilização de termogramas de fusíveis tipo D e tipo NH para compor o banco de imagens, pois as representações das condições térmicas do item em questão conseguem ser abordadas por completo pela base de imagens disponível, portanto a base de dados atual conta com 82 imagens termográficas. Termogramas dos demais equipamentos foram descartados do experimento.

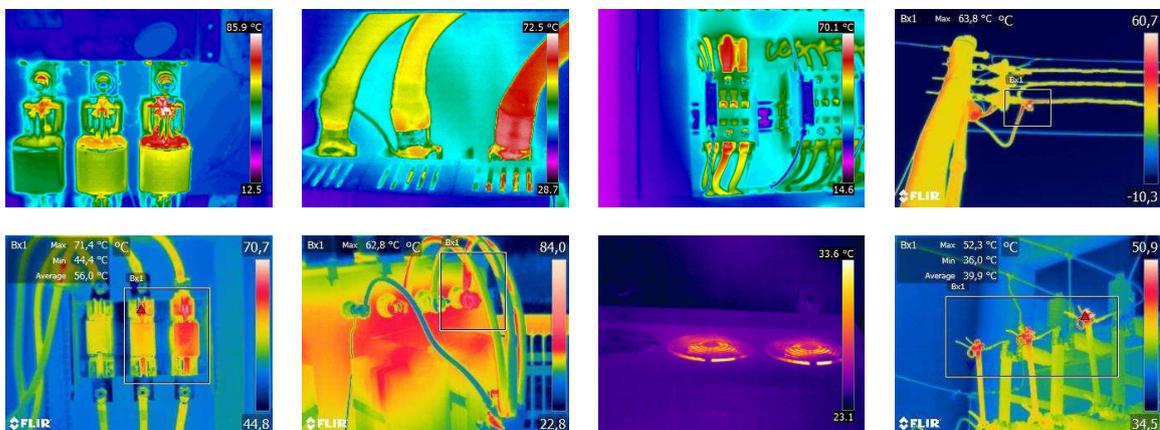


Figura 8 – Imagens contidas nos relatórios de inspeção termográfica.

Fonte: ARESPCJ, 2015.

Conforme os relatórios expostos em (ARESPCJ, 2015), um rótulo de classificação foi atribuído para cada imagem termográfica, com base na variação da temperatura corrigida (TC) do item em questão, a qual depende da temperatura máxima admissível (TMA) para o mesmo que, no que lhe concerne, é obtida através da tabela do fabricante. A Tabela 1 especifica o critério adotado para a atribuição dos rótulos. Na primeira coluna são exibidos os rótulos, e na segunda coluna são apresentados os intervalos de temperatura. Cabe mencionar que a temperatura corrigida (TC) do componente se dá para condição de 100% da carga e velocidade do vento igual a 1m/s.

Tabela 1 – Avaliação da condição dos equipamentos de acordo com a variação de temperatura.

Rótulo	Variação	Qtd. Imagens
Classe A: Pouco aquecido	$0,3 \text{ TMA} < \text{TC} < 0,7 \text{ TMA}$	17
Classe B: Aquecido	$0,7 \text{ TMA} < \text{TC} < 1,1 \text{ TMA}$	25
Classe C: Muito Aquecido	$1,1 \text{ TMA} < \text{TC}$	40

Fonte: o Autor.

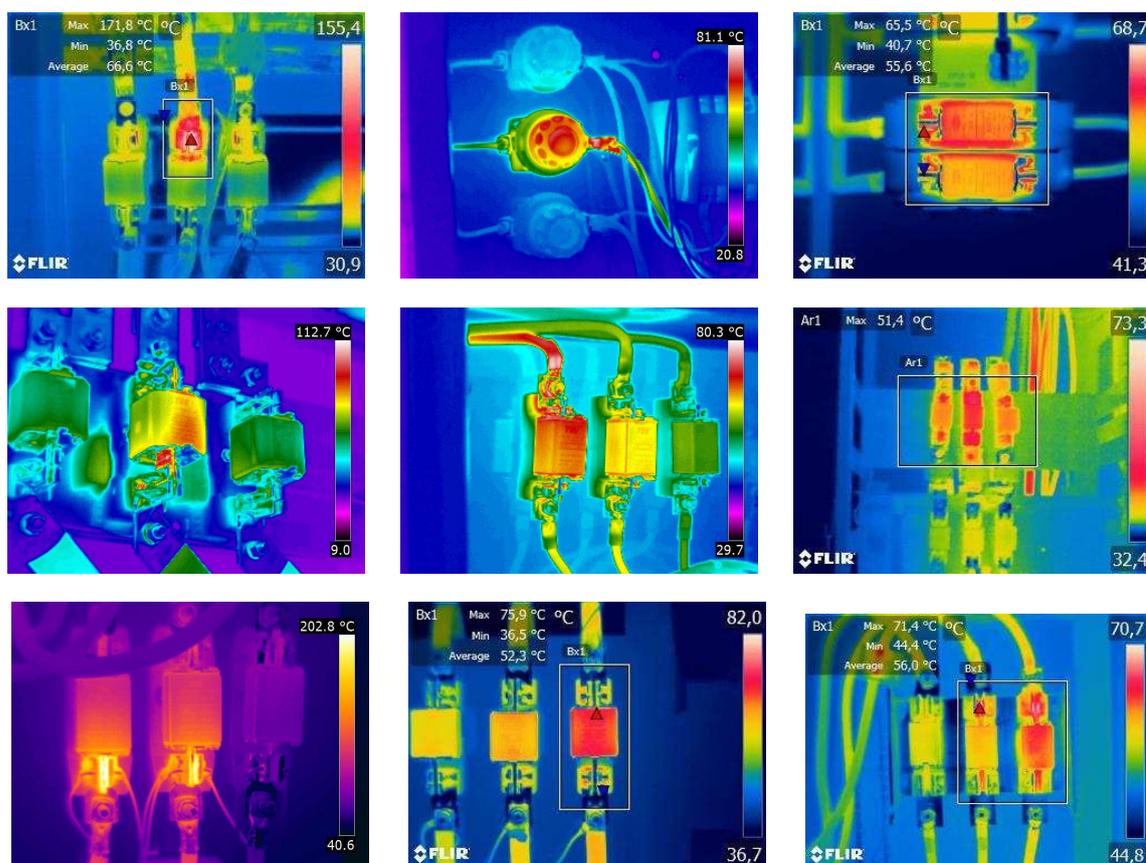


Figura 9 – Imagens termográficas contidas no novo banco de dados.

Fonte: ARESPCJ, 2015.

Com base neste critério, o subconjunto com as 82 imagens termográficas de fusíveis do tipo D e tipo NH provenientes da (ARESPCJ, 2015) foram subdivididos em 3 classes:

Classe A, denominada “pouco aquecido”; classe B, denominada “aquecido”, e classe C, denominada “muito aquecido”. A Figura 9 apresenta exemplos de termogramas contidos no novo banco de dados, onde na primeira coluna à esquerda estão as imagens da classe “muito aquecido”, na coluna central termografias da classe “aquecido” e, por último, na última coluna à direita, estão as imagens da classe “pouco aquecido”.

3.2 Sistema Proposto

Nesta seção é detalhado o sistema proposto, o qual é composto pelas seguintes etapas:

- Extração de características (Subseção 3.2.1);
- Balanceamento do número de amostras por classe usando *k-means* (Subseção 3.2.2);
- Classificação (Subseção 3.2.3).

O Sistema proposto, ao contrário dos sistemas clássicos de processamento e análise de imagens (ver Subseção 2.2.1) realiza a extração de características da imagem através de redes convolucionais pré-treinadas (Subseção 2.2.2.1). A Figura 10 ilustra o fluxo de trabalho do sistema proposto.

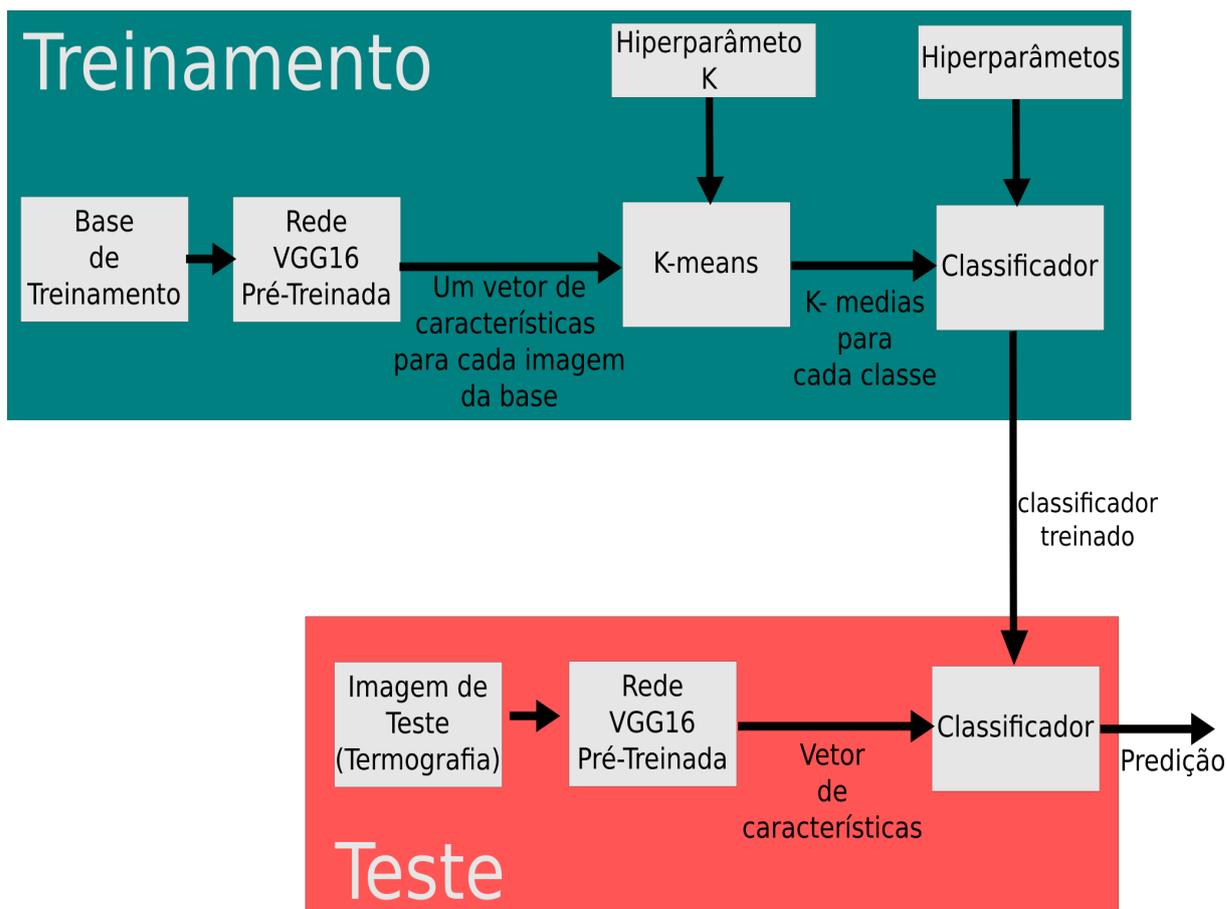


Figura 10 – Fluxo de trabalho do sistema de processamento e análise de imagens proposto.

Fonte: o Autor.

3.2.1 Extração de Características

Para a realização da extração de características foram examinadas diversas redes convolucionais encontradas na literatura (Subseção 2.2.2.1). O sistema utilizou de redes convolucionais pré-treinadas, com base de dados provenientes da *Imagenet* (KRIZHEVSKY; SUTSKEVER; HINTON, 2012). As imagens foram redimensionadas para que atendessem os requisitos de dimensionalidade da rede, usualmente 224×224 pixels, exceto para a rede InceptionV3 onde a entrada deve ser 331×331 . Especificamente para a rede VGG16, os procedimentos de convolução e *pooling* foram aplicados até se atingir a camada *maxpooling* com dimensão $7 \times 7 \times 512$, onde é feita a extração de características de cada matriz 7×7 , gerando assim um vetor com 512 característica para cada imagem da base. A Figura 11 ilustra a extração de características através da rede VGG16.

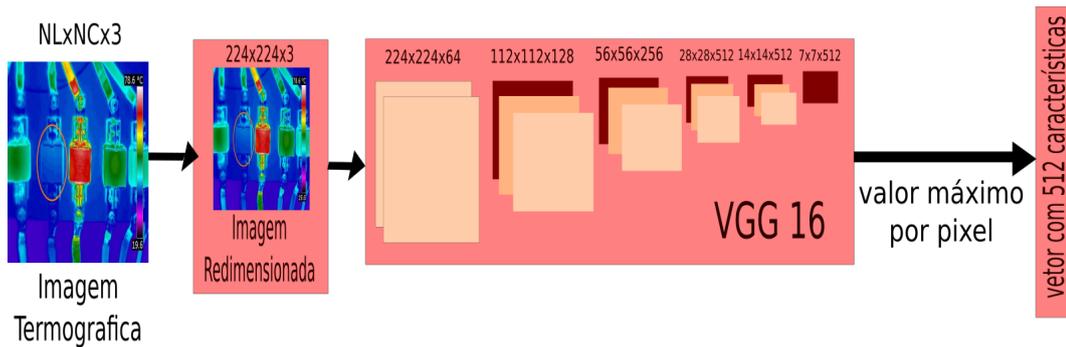


Figura 11 – Uso da rede VGG16 pré-treinada para extração de características.

Fonte:O Autor.

3.2.2 Balanceamento do Número de Amostras por Classe Usando *k-means*

Aplica-se o algoritmo *k-means* separadamente em cada classe no conjunto de treinamento de modo a balancear o número de amostras, pois como pode ser observado na Tabela 1, a distribuição do banco de imagens é desbalanceada.

O número de observações resultante do *k-means* será igual a *k* médias produzidas para cada classe. O conjunto composto pelas referidas médias contém *kxC* (número de médias *x* número de classes) amostras, sendo elas utilizadas para treinar o classificador do modelo. Portanto, a distribuição de dados se torna balanceada.

As Figuras 12 até 14 ilustram a aplicação do *k-means* nos vetores destinados ao treinamento para cada classe. É importante ressaltar que as amostras aqui ilustradas sofreram redução de dimensionalidade única e exclusivamente para que pudessem ser apresentadas como figuras em duas dimensões. A metodologia não efetua tal procedimento.

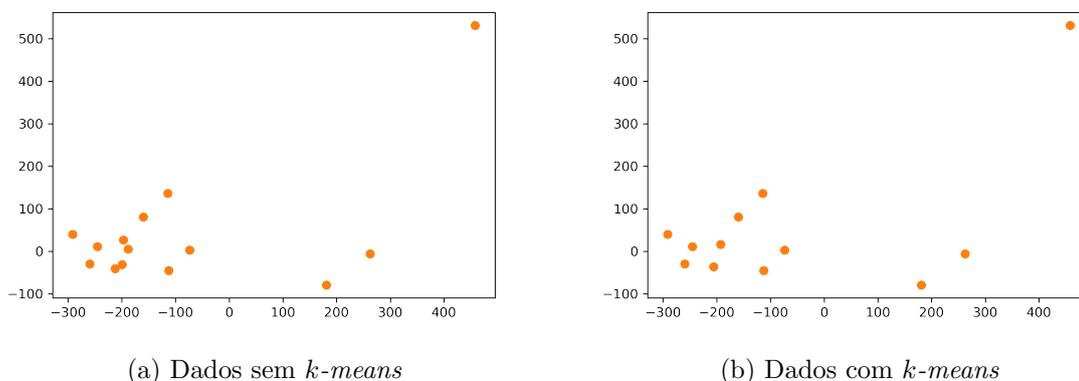


Figura 12 – Representação dos vetores de características de treino da classe “pouco aquecido”, antes e após o procedimento de balanceamento de amostras.

Fonte: o Autor.

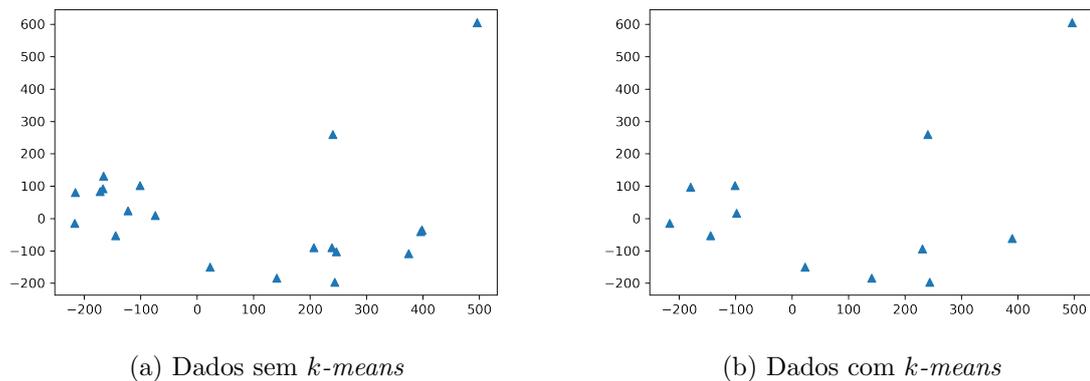


Figura 13 – Representação dos vetores de características de treino da classe “aquecido”, antes e após o procedimento de balanceamento de amostras.

Fonte: o Autor.

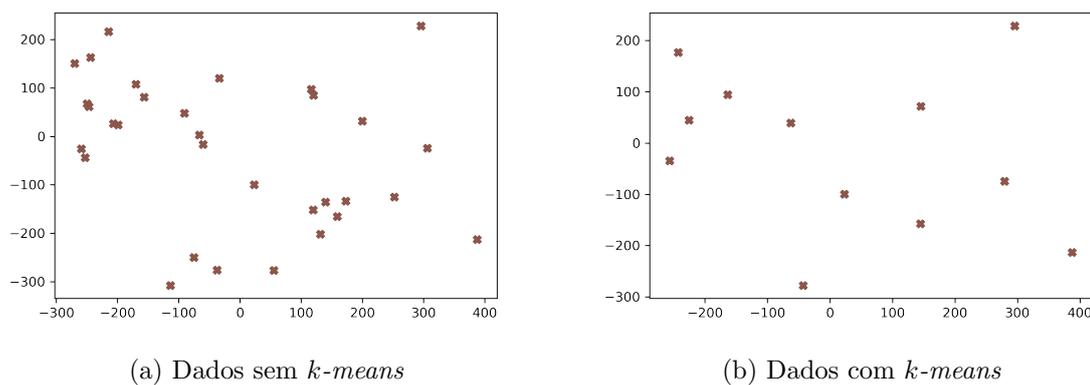


Figura 14 – Representação dos vetores de características de treino da classe “muito aquecido”, antes e após o procedimento de balanceamento de amostras.

Fonte: o Autor.

Nas Figuras 12 até 14 as bases de dados se tornam balanceadas contendo $k = 12$, produzindo k amostras em cada classe, portanto o total de amostras geradas pelo algoritmo *k-means* é definido conforme o valor do hiperparâmetro k . Na Figura 12 é possível observar a representação no plano dos vetores de características referente à classe “pouco aquecido” que, antes da aplicação do algoritmo continha 14 representações e, após o *k-means*, formam um conjunto com 12 amostras. Na Figura 13, observa-se a classe “aquecido”, antes da aplicação do algoritmo contendo 20 representações e, após o procedimento gera-se o conjunto com 12 amostras. Por fim, na Figura 14 a classe “muito aquecido” é apresentada com 32 representações e, após o algoritmo, gera-se um conjunto com 12 amostras.

3.2.3 Classificação

Esta etapa consiste em treinar um modelo de classificação tornando-o capaz de atribuir um rótulo (isto é, uma classe) a um vetor de característica cuja classe é desconhecida. Portanto, em posse das amostras de treinamento é então desenvolvido um modelo para o classificador. Os vetores de características do teste provenientes da rede convolucional são então introduzidas no classificador sem as informações de seus respectivos rótulos, para que assim possam ser classificadas conforme o modelo gerado pelas amostras de treino. O procedimento ocorre para avaliar o desempenho de alguns dos métodos de classificação convencionais encontrados na literatura de aprendizagem de máquina (FACELI et al., 2011) (DOUGHERTY, 2012).

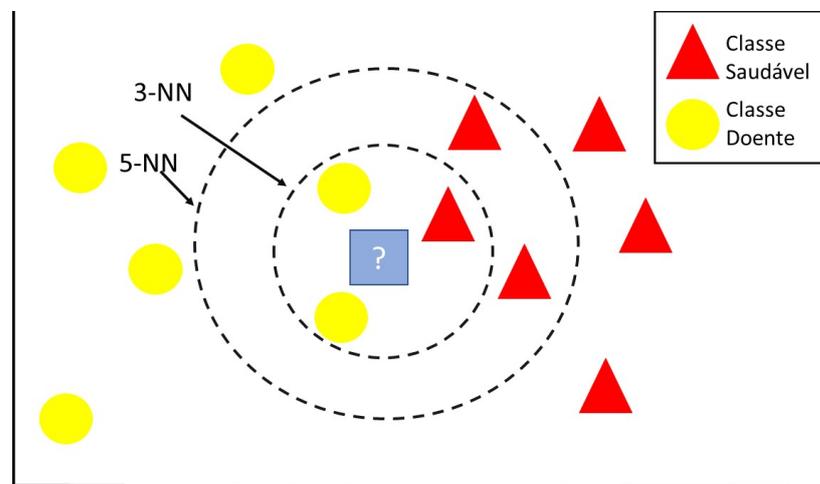


Figura 15 – Exemplo da aplicação do classificador KNN.

Fonte: FACELI et al., 2011.

A Figura 15 ilustra o procedimento de classificação para o classificador KNN, onde o objetivo é procurar os k vizinhos mais próximos do vetor de características de teste desconhecido (vide Subseção 2.2.2.3). Através da moda entre os vizinhos o vetor é rotulado, e o hiperparâmetro k é responsável por definir a quantidade de vizinhos presentes na moda. Neste caso, o hiperparâmetro $k=3$ define a amostra desconhecida como “Doente”, mas para o hiperparâmetro $k=5$ o rótulo atribuído será “Saudável”.

Os métodos de classificação utilizados no trabalho podem ser considerados como uma função que se ajusta segundo os parâmetros de entrada, sendo que tal ajuste é executado visando o melhor desempenho na predição. Para o caso exemplificado na Figura 15, caso a amostra desconhecida fosse pertencente à classe “Saudável”, o melhor ajuste seria utilizando $k=5$.

4 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados e discutidos os resultados dos experimentos realizados. Na Seção 4.1 é apresentado o procedimento empregado para particionar o conjunto de dados em subconjuntos de treinamento, validação e teste, bem como os recursos computacionais utilizados. Na Seção 4.2, por sua vez, são apresentados os experimentos realizados para avaliar os melhores hiperparâmetros de configuração do sistema proposto, com base no subconjunto de validação. Por fim, na Seção 4.3, é avaliado o desempenho do sistema proposto, com base no subconjunto de teste.

4.1 Particionamento do Conjunto de Dados e Recursos Computacionais Utilizados

Inicialmente o conjunto de dados (isto é, base de dados) foi distribuído em dois subconjuntos, treinamento e teste, aplicando a prática comum em sistemas de aprendizado de máquina. O primeiro subconjunto de dados foi designado ao treinamento, possuindo 80% das imagens oriundas de cada classe. O segundo subconjunto foi destinado ao teste e possui 20% das imagens provenientes de cada classe.

A divisão da base de dados conta também com o subconjunto de validação. Porém, como a base contém pequena quantidade de imagens disponíveis para o experimento, o subconjunto de validação se deu através de técnica de amostragem com origem nos dados de treinamento. A Figura 16 ilustra como se deu o referido subconjunto de validação.



Figura 16 – Divisão do base de dados em conjunto de treino, validação e teste.

Fonte: o Autor.

A validação do sistema aconteceu através da técnica de amostragem *Leave-one-out* onde o treinamento do modelo foi efetuado com $n - 1$ vetores, de modo que $\{\mathbf{x}^{(1)}, \dots,$

$\mathbf{x}^{(j-1)}, \mathbf{x}^{(j+1)}, \dots, \mathbf{x}^{(n)}$, por sua vez o modelo foi validado utilizando o vetor $\mathbf{x}^{(j)}$. O processo é repetido n vezes, selecionando-se em cada iteração um vetor de características diferente. A taxa de acerto do modelo em validação é dada pela média entre os resultados das n iterações. Na Figura 17 ilustra-se o procedimento de validação cruzada empregado no treinamento e validação.

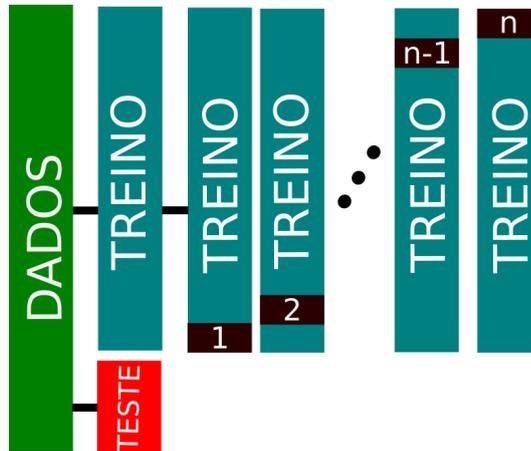


Figura 17 – Esquema de validação cruzada *leave-one-out* utilizado na etapa de treino e validação do sistema proposto.

Fonte: o Autor.

Os experimentos foram realizados e desenvolvidos com processador intel i3 com 6Gb de memória RAM sem nenhum tipo de GPU, através da linguagem *Python*, utilizando como recurso as bibliotecas *TensorFlow* e *Keras* empregadas para executar todas as etapas do sistema proposto. As bibliotecas em questão contam com ferramentas de pré-processamento de imagens e com modelos pré-treinados através da base de dados *Imagenet*.

4.2 Ajuste dos Hiperparâmetros com o Subconjunto de Validação

Esta seção lida com os critérios empregados para ajustar os hiperparâmetros do sistema proposto, com base no desempenho obtido no subconjunto de validação. Os métodos utilizados no trabalho disponibilizam diversos hiperparâmetros que podem ser ajustados em inúmeros níveis, desde a arquitetura da rede convolucional, profundidade da rede convolucional, método de pooling, critérios de ajuste do classificador, métodos de agrupamento, entre outros.

No experimento, tais ajustes existem em duas etapas. A primeira, corresponde ao ajuste do hiperparâmetro do algoritmo *k-means*. O mesmo procedimento ocorre para os classificadores, onde no classificador SVM em particular, o hiperparâmetro é composto por duas variáveis: C e γ . No classificador KNN ajusta-se o número de K vizinhos, enquanto no *Random Forest*, ajusta-se a profundidade máxima da árvore. Ademais, de forma semelhante é selecionada a arquitetura da rede convolucional.

Os hiperparâmetros avaliados na validação do sistema proposto foram os seguintes:

- Número de amostras gerados pelo algoritmo *k-means*: 3, 4, ..., 12;
- Número de vizinhos para o KNN: 1, 3, 5, 7, 9;
- Hiperparâmetros do SVM: $C = 2^{-5}, 2^{-3}, \dots, 2^{15}$ e $\gamma = 2^{-15}, 2^{-13}, \dots, 2^3$ (HSU et al., 2003);
- Profundidade máxima do *Random Forest*: 0.1, 0.2, ..., 0.9.

As redes convolucionais avaliadas na validação e teste do sistema proposto foram:

- DenseNet169 (HUANG et al., 2017);
- InceptionV3 (SZEGEDY et al., 2015);
- MobileNet (HOWARD et al., 2017);
- ResNet50 (HE et al., 2016);
- VGG16 (SIMONYAN; ZISSERMAN, 2015);
- VGG19 (SIMONYAN; ZISSERMAN, 2015).

Os classificadores avaliados na validação e teste do sistema proposto foram:

- KNN (Subseção 2.2.2.3);
- SVM (Subseção 2.2.2.3);
- *Random Forest* (Subseção 2.2.2.3).

A avaliação e seleção de hiperparâmetros do sistema proposto foi realizada durante a mencionada etapa de treinamento e validação, onde cada conjunto de hiperparâmetros passa pela validação cruzada *leave-one-out* retornando um valor de acurácia. O processo ocorre até que todas as combinações de hiperparâmetros sejam treinadas e validadas pelo sistema proposto. Dado que todas as combinações apresentam um resultado de acurácia, o melhor desempenho do conjunto denominará os hiperparâmetros que serão empregados na etapa de teste do sistema proposto.

A Figura 18 apresenta o fluxograma do processo de avaliação e seleção de hiperparâmetros para uma iteração de validação, onde a cada iteração o sistema retorna um resultado, sendo 0 para erro de predição e 1 para acerto de predição. A validação *Leave-one-out* acontece até que todos os dados de treino sejam utilizados como dado de validação (vide Figura 17), ao final a média dos resultados determina a acurácia do sistema submetida ao conjunto de hiperparâmetros em avaliação. Neste ponto um novo conjunto de hiperparâmetros é inserido e o processo de validação e teste é reiniciado. O procedimento se repete até que todas as combinações de hiperparâmetros sejam treinadas e validadas

em conjunto com cada uma das redes convolucionais. O objetivo nesta etapa é avaliar os conjuntos de hiperparâmetros, que somado a determinada rede convolucional, apresente o melhor desempenho (i.e., acurácia) na predição, os quais serão utilizados no teste do sistema proposto.

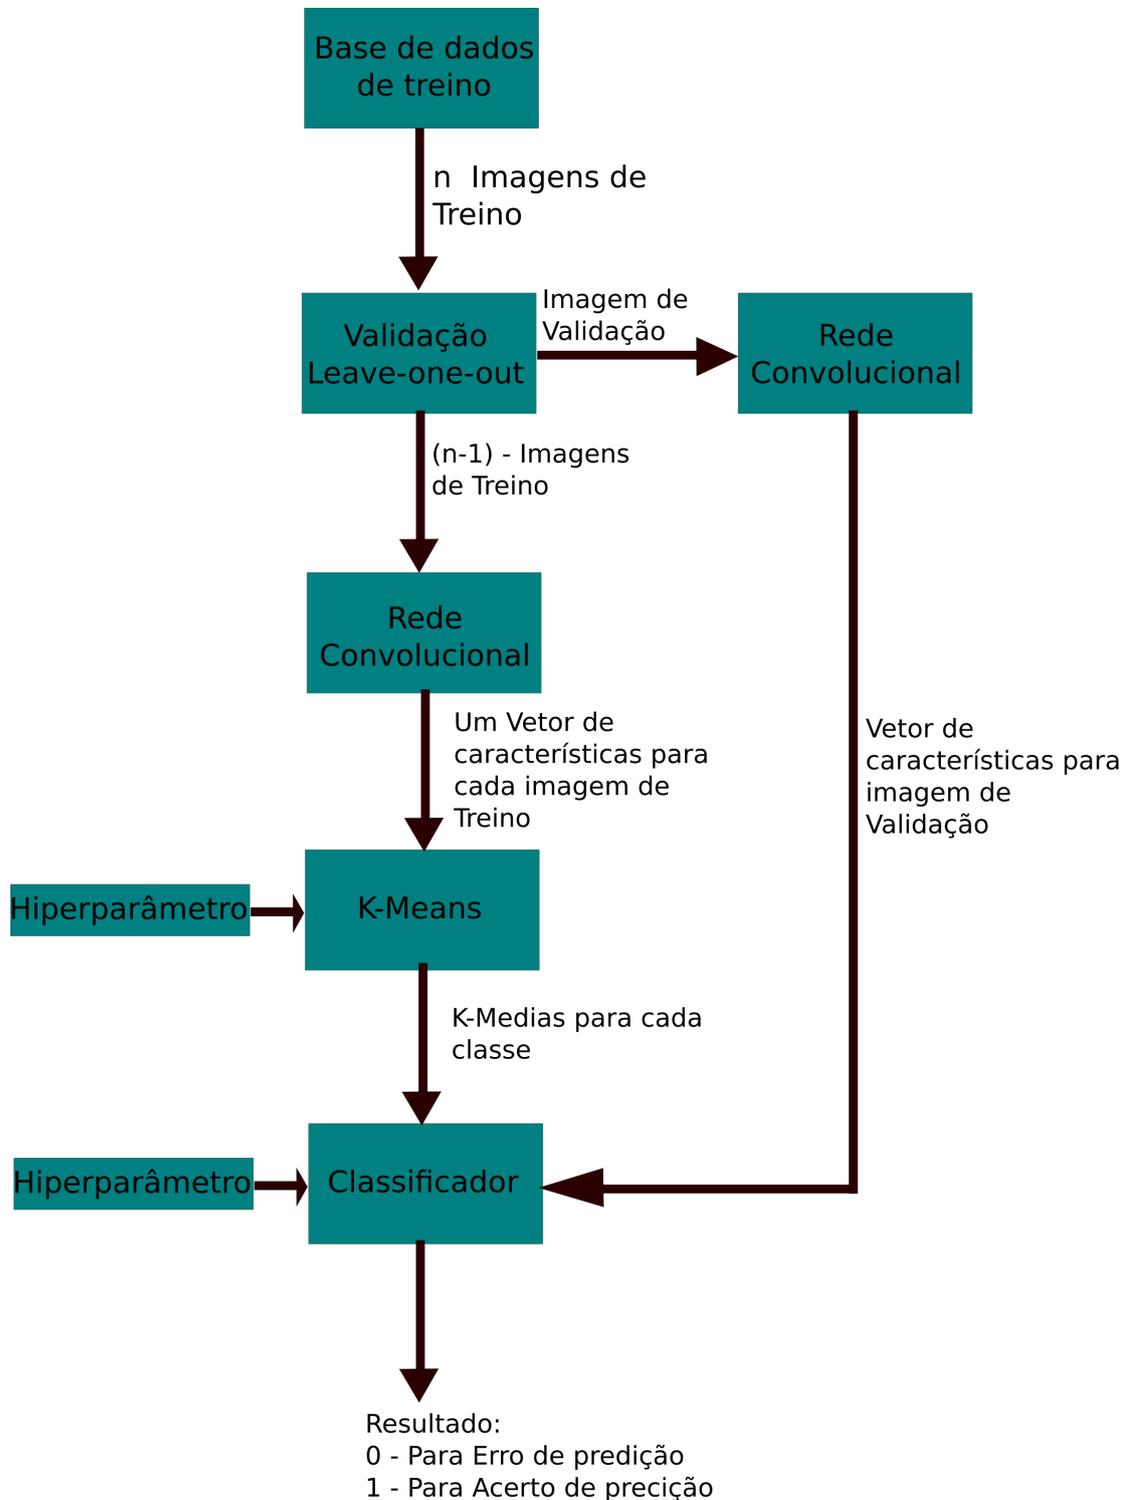


Figura 18 – Fluxograma do processo de avaliação de hiperparâmetros para uma iteração de validação.

Fonte: o Autor.

4.3 Avaliação do Desempenho do Sistema com o Subconjunto de Teste

Neste seção são apresentados os resultados dos experimentos realizados com o subconjunto de teste. Nas Subseções 4.3.1 até 4.3.3 são avaliados respectivamente os desempenhos do sistema proposto com o subconjunto de teste utilizando os classificadores KNN, *Random Forest* e SVM.

4.3.1 Sistema Proposto Utilizando KNN

O melhor desempenho para o classificador KNN foi de 62,5% utilizando MobileNet. Foram calculadas métricas de precisão, *recall* e *f1-score*. Ademais, utiliza-se da matriz de confusão para analisar as referidas métricas, conforme observado na Tabela 2 e na Figura 19.

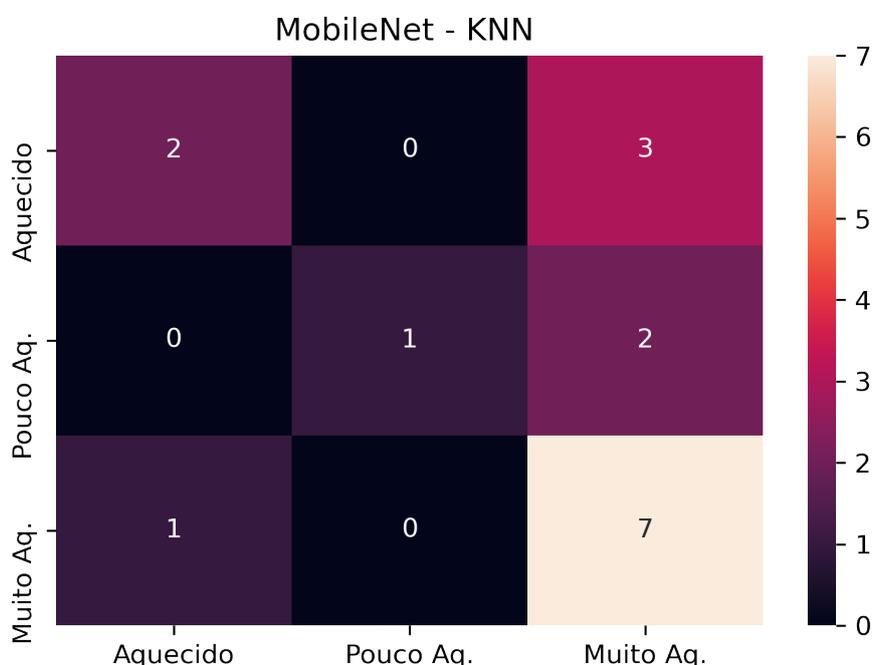


Figura 19 – Matriz de confusão apresentando o desempenho da rede convolucional MobileNet em conjunto com o classificador KNN.

Fonte: o Autor.

Na Figura 19 as classes apresentadas na vertical representam a condição real do item, enquanto as classes ilustradas na horizontal representam a predição do sistema proposto. Dos 5 itens em condição “aquecido”, 2 foram corretamente rotulados enquanto 3 foram rotulados como “muito aquecido” pelo sistema. Já para os 3 itens em condição “pouco aquecido”, 1 foi corretamente rotulado enquanto 2 foram classificados como “muito aquecido”. Para os 8 itens em condição “muito aquecido”, 7 foram corretamente classificadas, em contrapartida, 1 imagem foi rotulada como “aquecido”. Portanto, é possível observar que

o sistema apresenta tendência a classificar as imagens como “muito aquecido” justificando a precisão de 58% para tal rótulo.

Tabela 2 – Desempenho rede convolucional MobileNet em conjunto com o classificador KNN

Classes	Precisão	Recall	F1-Score
Aquecido	67%	40%	50%
Pouco Aquecido	100%	33%	50%
Muito Aquecido	58%	88%	70%
Média	75%	54%	57%

Fonte: o Autor.

Conforme apresentado na Tabela 2, o rótulo “pouco aquecido” apresenta precisão de 100%, porém é possível observar que termografias de itens “pouco aquecido”, quando submetidas ao sistema proposto, mostram tendência a serem classificadas como “muito aquecido”, reforçando o observado na Figura 19.

4.3.2 Sistema Proposto Utilizando *Random Forest*

O melhor desempenho para classificador *Random Forest* foi de 62,5% para as redes convolucionais VGG19 e InceptionV3.

Foram calculadas métricas de precisão, *recall* e *f1-score*. Ademais utiliza-se da matriz de confusão para analisar as referidas métricas, conforme observado nas Tabelas 3 e 4, e nas Figuras 20 e 21.

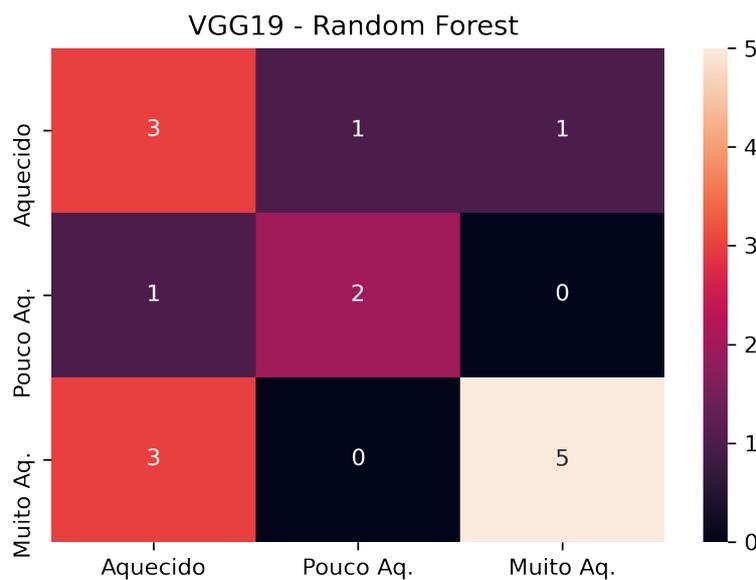


Figura 20 – Matriz de confusão apresentando o desempenho da rede convolucional VGG19 em conjunto com o classificador Random Forest.

Fonte: o Autor.

Na Figura 20 as classes apresentadas na vertical representam a condição real do item, enquanto as classes ilustradas na horizontal representam a predição do sistema proposto. Dos 5 itens em condição “aquecido”, 3 foram corretamente rotulados enquanto os demais foram rotulados como “pouco aquecido” e “muito aquecido” pelo sistema. Já para os 3 itens em condição “pouco aquecido”, 2 foram corretamente rotulados enquanto 1 foi classificado como “aquecido”. Por fim, para os 8 itens em condição “muito aquecido”, 5 foram corretamente classificados, em contrapartida, 3 imagens foram rotuladas como “aquecido”.

Tabela 3 – Desempenho rede convolucional VGG19 em conjunto com o classificador Random Forest

Classes	Precisão	<i>Recall</i>	F1-Score
Aquecido	43%	68%	50%
Pouco Aquecido	67%	67%	67%
Muito Aquecido	83%	62%	71%
Média	63%	63%	64%

Fonte: o Autor.

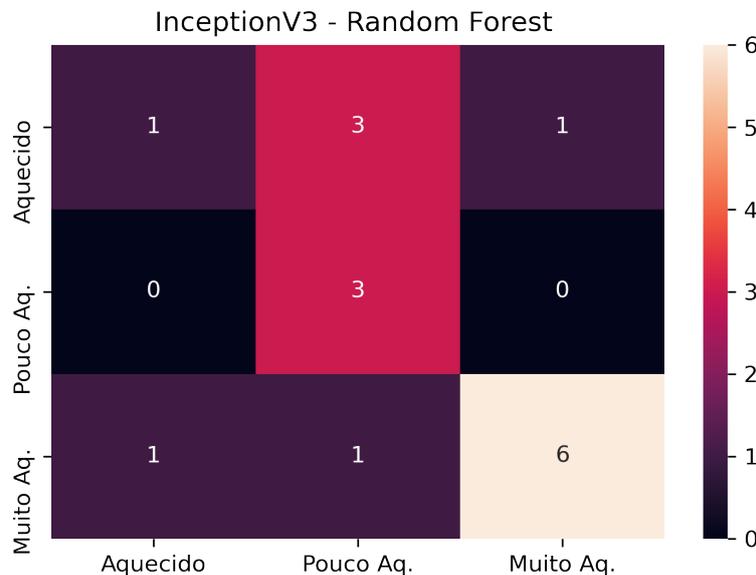


Figura 21 – Matriz de confusão apresentando o desempenho da rede convolucional InceptionV3 em conjunto com o classificador Random Forest.

Fonte: o Autor.

Na Figura 21, dos 5 itens em condição “aquecido”, 1 foi corretamente rotulado, enquanto 3 foram rotulados como “pouco aquecido” e 1 como “muito aquecido”. Já para os 3 itens em condição “pouco aquecido”, todos foram corretamente rotulados pelo sistema proposto. Para os 8 itens em condição “muito aquecido”, 7 foram corretamente classificados. Em contrapartida, 1 imagem foi rotulada como “aquecido”.

Tabela 4 – Desempenho rede convolucional ResNet50 em conjunto com o classificador Random Forest

Classes	Precisão	Recall	F1-Score
Aquecido	43%	60%	50%
Pouco Aquecido	67%	67%	67%
Muito Aquecido	83%	62%	71%
Média	64%	63%	63%

Fonte: o Autor.

Assim, em conformidade ao que foi apresentado anteriormente, ainda que os resultados de acurácia sejam semelhantes para o VGG19 e InceptionV3, as análises dos resultados mostram as particularidades do emprego de cada uma das redes convolucionais.

4.3.3 Sistema Proposto Utilizando SVM

Os melhores desempenhos para classificador SVM foram de 93,75% utilizando VGG16 e 81,25% empregando VGG19. Ademais, foram calculadas métricas de precisão, *recall* e *f1-score*. Utiliza-se também da matriz de confusão para melhor analisar as referidas métricas. Conforme observado nas Tabelas 5 e 6 e nas Figuras 22 e 23.



Figura 22 – Matriz de confusão apresentando o desempenho da rede convolucional VGG16 em conjunto com o classificador SVM.

Fonte: o Autor.

Na Figura 22, dos 5 itens em condição “aquecido”, 4 foram corretamente rotulados,

enquanto 1 item foi rotulado como “muito aquecido” pelo sistema proposto. Já para os 3 itens em condição “pouco aquecido”, todos foram corretamente rotulados pelo sistema proposto. Para os 8 itens em condição “muito aquecido”, todos foram corretamente classificados.

Tabela 5 – Desempenho rede convolucional VGG16 em conjunto com o classificador SVM

Classes	Precisão	Recall	F1-Score
Aquecido	100%	80%	89%
Pouco Aquecido	100%	100%	100%
Muito Aquecido	89%	100%	94%
Média	96%	93%	94%

Fonte: o Autor.

Conforme apresentado na Tabela 5, apenas a severidade “muito aquecido” apresenta precisão inferior a 100%. Portanto, todos os itens classificados pelo sistema proposto com severidade “pouco aquecido” e “aquecido” também foram diagnosticados com as respectivas severidades por especialistas. Consequentemente, através da Figura 22, é possível identificar que o único item com rótulo “aquecido” foi diagnosticado como “muito aquecido”. O *Recall* de 80% para o rótulo “aquecido” se dá pela referida confusão entre as classes, ilustrada na matriz de confusão.



Figura 23 – Matriz de confusão apresentando o desempenho da rede convolucional VGG19 em conjunto com o classificador SVM.

Fonte: o Autor.

Na Figura 23, dos 5 itens em condição “aquecido”, 3 foram corretamente rotulados,

enquanto 2 foram rotulados como “pouco aquecido” e “muito aquecido”. Já para os 3 itens em condição “pouco aquecido”, todos foram corretamente rotulados pelo sistema proposto. Para os 8 itens em condição “muito aquecido”, 7 foram corretamente classificados. Em contrapartida, 1 imagem foi rotulada como “aquecido”. Além disso, a confusão entre os itens com rótulo “muito aquecido” por itens com rótulo “aquecido” é considerada de risco, pois um item considerado “muito aquecido” pode apresentar risco iminente de falha e necessitar de intervenção imediata.

Tabela 6 – Desempenho rede convolucional VGG19 em conjunto com o classificador SVM

Classes	Precisão	<i>Recall</i>	F1- <i>Score</i>
Aquecido	75%	60%	67%
Pouco Aquecido	75%	100%	86%
Muito Aquecido	88%	88%	88%
Média	79%	83%	80%

Fonte: o Autor.

Além disso, conforme apresentado na Tabela 6, a precisão média entre as classes do sistema é inferior à acurácia calculada. O classificador apresenta menor precisão em itens diagnosticados como “aquecido” e “pouco aquecido” e maior precisão em itens diagnosticados como “muito aquecido”.

5 CONSIDERAÇÕES FINAIS

A análise termográfica de itens e sistemas elétricos é considerada uma ferramenta promissora para a detecção de falhas ou defeitos. Atualmente o diagnóstico da condição de um item ocorre através da análise da imagem termográfica, executada por um especialista, seja ele um engenheiro eletricista ou técnico especializado. Porém, por vezes este é um processo que exige trabalhadores especializados, demandando um alto custo. Além disso, a possibilidade de um diagnóstico equivocado pode prejudicar a produtividade fabril, colocando em risco a segurança dos envolvidos no processo. Neste contexto, este trabalho surgiu com intuito de propor um sistema de análise de imagens termográficas, capaz de classificar a condição de itens e sistemas elétricos através de imagens provenientes da análise termográfica, de forma que tal classificação possa auxiliar profissionais na tomada de decisão quanto ao diagnóstico de condição.

Para atingir o referido objetivo foi inicialmente realizado um levantamento bibliográfico sobre como é feito o processamento e análise de imagens digitais, utilizando de redes convolucionais assim como um pequeno estudo sobre os trabalhos relacionados na literatura, para explorar quais métodos melhor se adequavam à pesquisa.

O desenvolvimento da pesquisa foi realizado em duas etapas distintas. A primeira etapa teve como objetivo compilar imagens termográficas, de itens e sistemas elétricos com o propósito de construir um banco de dados adequado para as tarefas de classificação. Portanto, foi montada uma base com 82 imagens termográficas de fusíveis do tipo D e tipo NH, distribuídas em 3 classes: classe A “pouco aquecido” contendo 17 termogramas; classe B “aquecido” contendo 25 termogramas e por fim a classe C denominada “muito aquecido”, composta por 40 imagens termográficas. Na segunda etapa desta pesquisa foi desenvolvido um experimento onde o objetivo foi classificar o referido banco de dados através de métodos supervisionados. Assim, as imagens foram separadas da seguinte forma: 80% das imagens foram destinadas ao treinamento e validação, e 20% destinadas ao teste do sistema proposto. A iteração do sistema ocorreu de maneira que pudessem ser treinados e validados inúmeros conjuntos de hiperparâmetros, de forma que os modelos que apresentaram melhores resultados para cada rede convolucional, fossem submetidos ao teste do sistema. O melhor resultado entre todos os testes realizados, foi obtido com o modelo desenvolvido através da rede convolucional VGG16, apresentando taxa de acerto de 93,75%.

Este trabalho dispõe de resultados que proporcionam um avanço ao tema da pesquisa, pois desenvolve e adequa uma pequena base de dados de imagens termográficas de itens e sistemas elétricos para serem destinadas à tarefas de classificação. Além disso, os resultados apresentados sinalizam que o sistema proposto se apresenta como uma ferramenta promissora para o auxílio na interpretação e análise de imagens termográficas.

No entanto, a principal limitação encontrada é em relação à base de dados que possui amostras com classes desbalanceadas. Apesar da aplicação da metodologia

de agrupamento de dados, que visa o balanceamento entre as classes ter se mostrado satisfatória, estima-se que o referido fator influenciou negativamente no desempenho dos classificadores. Outra limitação encontrada na base dados são as quantidades limitadas de imagens. Apesar da técnica de validação cruzada *leave-one-out*, apresentar desempenho satisfatório, tal metodologia possui custo computacional elevado. Uma possível solução para as referidas limitações, se encontra na aquisição e classificação de mais imagens termográficas, visando o desenvolvimento de base de dados robustas, visando interpretar melhor a realidade do item.

Para trabalhos futuros aconselha-se a utilização de uma base de dados com uma maior quantidade de imagens, baseadas em sistemas ou itens que apresentem condições de temperatura semelhantes, ou seja, valores de TMA e TC similares. Ademais, preconiza-se incluir itens com condições normais de temperatura, isto é, itens que não apresentem aquecimento superior à temperatura máxima admissível (TMA).

REFERÊNCIAS

- ARESPCJ. *Agência Reguladora dos Serviços de Saneamento das bacias dos Rios Piracicaba, Capivari e Jundiaí*: Base de relatórios. 2015. Disponível em: <<http://www.arespcj.com.br/arquivos/13/relatorios-de-monitoramento.aspx>>. Acesso em: 16 abr. 2021. Citado 2 vezes nas páginas 27 e 28.
- CACHADA, A. et al. Maintenance 4.0: Intelligent and predictive maintenance system architecture. In: IEEE. *2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA)*. Torino, Italy, 2018. v. 1, p. 139–146. Citado na página 14.
- CEZAR, C. L. Sistema de gestão da manutenção industrial utilizando termografia: aplicação na usina termelétrica da CAAL–Alegrete. *Universidade Federal do Pampa*, 2012. Citado 2 vezes nas páginas 15 e 18.
- DAHL, G. E. et al. Context-dependent pre-trained deep neural networks for large-vocabulary speech recognition. *IEEE Transactions on Audio, Speech, and Language Processing*, IEEE, v. 20, n. 1, p. 30–42, 2011. Citado na página 22.
- DHILLON, B. S. *Engineering Maintenance: a modern approach*. Boca Raton: CRC Press, 2002. Citado 3 vezes nas páginas 14, 17 e 18.
- DOUGHERTY, G. *Pattern Recognition and Classification: an introduction*. Camarillo CA: Springer, 2012. Citado 3 vezes nas páginas 21, 25 e 33.
- ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, Nature Publishing Group, v. 542, n. 7639, p. 115–118, 2017. Citado 2 vezes nas páginas 14 e 15.
- FACELI, K. et al. Inteligência Artificial: uma abordagem de aprendizado de máquina. *Rio de Janeiro: LTC*, v. 2, p. 192, 2011. Citado 3 vezes nas páginas 23, 25 e 33.
- FLUKE, T. S. G. *Introdução aos Princípios da Termografica*. USA: American Technical, 2009. Citado na página 18.
- GONÇALVES, J. C. et al. *Reconhecimento de dígitos em imagens de medidores de consumo de gás natural utilizando técnicas de visão computacional*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2016. Citado na página 24.
- GONZALEZ, R. C.; WOODS, R. C. *Processamento Digital de Imagens*. Brasil: Pearson, 2009. Citado 2 vezes nas páginas 19 e 21.
- HAN, W. et al. *ContextNet: Improving Convolutional Neural Networks for Automatic Speech Recognition with Global Context*. Xangai, China, 2020. 3610–3614 p. Citado na página 14.
- HE, K. et al. Identity mappings in deep residual networks. Springer, Cham, 2016. Citado na página 36.
- HOWARD, A. G. et al. *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. 2017. Citado na página 36.
- HSU, C. et al. *A practical guide to support vector classification*. Taiwan, 2003. Citado na página 36.

- HUANG, G. et al. Densely connected convolutional networks. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, Havaí: IEEE, 2017. p. 2261–2269. Citado na página 36.
- HUTCHINS, D. C. *Just in Time*. Aldershot, Hampshire, England Brookfield, Vt., USA: Gower Publishing, Ltd., 1999. ISBN 9780566077982. Citado na página 14.
- JAAHNE, B. *Practical Handbook on Image Processing for Scientific and Technical Applications*. Boca Raton, FL: CRC Press, 2004. ISBN 0-8493-1900-5. Citado na página 19.
- JAIN, A. K. Data clustering: 50 years beyond k-means. *Pattern Recognition Letters*, Elsevier, v. 31, n. 8, p. 651–666, 2010. Citado na página 24.
- KARDEC, A.; NASCIF, J. *Manutenção-Função Estratégica*. Rio de Janeiro: Qualitymark Editora Ltda, 2009. ISBN 8541403629. Citado 2 vezes nas páginas 17 e 18.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: . New York, NY, USA: Association for Computing Machinery, 2012. v. 25, p. 1097–1105. Citado 3 vezes nas páginas 14, 22 e 30.
- NBR-15572, A. 15572:2013: Ensaaios não destrutivos — termografia — guia para inspeção de equipamentos elétricos e mecânicos. *Rio de Janeiro*, 2013. Citado na página 18.
- NBR-5462, A. 5462-tb116: Confiabilidade e manutenibilidade. *Rio de Janeiro*, 1994. Citado 2 vezes nas páginas 14 e 17.
- OLIVO, R. Y.; FILHO, P. L. de P.; JUNIOR, A. C. Uma abordagem neural na identificação de objetos em imagens para auxílio na manutenção de rede elétrica. In: *Anais Estendidos do XXXIII Conference on Graphics, Patterns and Images*. Porto Alegre, RS, Brasil: SBC, 2020. p. 179–182. Citado 2 vezes nas páginas 14 e 15.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de Imagens Digitais: princípios, algoritmos e aplicações*. São Paulo: Cengage Learning, 2008. ISBN 8522105952. Citado na página 19.
- RUSS, J. C. *The Image Processing Handbook*. Boca Raton FL: CRC Press, 2011. ISBN 149874026X. Citado na página 21.
- SANTOS, L. d. *Termografia Infravermelha em Subestações de Alta Tensão Desabrigadas*. Dissertação (Mestrado) — Universidade Federal de Itajubá, 2006. Citado na página 15.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. In: *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*. California, USA: ICLR, 2015. p. 1–14. Citado na página 36.
- SZEGEDY, C. et al. Going deeper with convolutions. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015. p. 1–9. Citado na página 36.