



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

LAIS DE MOURA COSTA

**VISÃO COMPUTACIONAL APLICADA A IDENTIFICAÇÃO DE RISCOS EM
REDES DE DISTRIBUIÇÃO DE ENERGIA**

Caruaru
2022

LAIS DE MOURA COSTA

**VISÃO COMPUTACIONAL APLICADA A IDENTIFICAÇÃO DE RISCOS EM
REDES DE DISTRIBUIÇÃO DE ENERGIA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Engenharia de Produção.

Área de concentração: Otimização e Gestão da Produção.

Orientador: Prof. Dr. Rodrigo Sampaio Lopes

Caruaru
2022

Catálogo na fonte:
Bibliotecária – Paula Silva - CRB/4 - 1223

C837v Costa, Lais de Moura.
Visão computacional aplicada a identificação de riscos em redes de distribuição de energia. / Lais de Moura Costa. – 2022.
69 f.; il.: 30 cm.

Orientador: Rodrigo Sampaio Lopes.
Dissertação (Mestrado) – Universidade Federal de Pernambuco, CAA, Mestrado em Engenharia de produção, 2022.
Inclui Referências.

1. Visão por computador – Caruaru (PE). 2. Redes neurais (Computação) – Caruaru (PE). 3. Manutenção. 4. Energia elétrica – Distribuição – Caruaru (PE). I. Lopes, Rodrigo Sampaio (Orientador). II. Título.

CDD 658.5 (23. ed.) UFPE (CAA 2022-005)

LAIS DE MOURA COSTA

**VISÃO COMPUTACIONAL APLICADA A IDENTIFICAÇÃO DE RISCOS EM
REDES DE DISTRIBUIÇÃO DE ENERGIA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Engenharia de Produção.

Área de concentração: Otimização e Gestão da Produção.

Aprovada em: 21/02/2022.

BANCA EXAMINADORA

Prof. Dr. Rodrigo Sampaio Lopes (Orientador)

Universidade Federal de Pernambuco

Prof.^a Dr.^a Marcele Elisa Fontana (Examinadora Interna)

Universidade Federal de Pernambuco

Prof. Dr. Thiago Poletto (Examinador Externo)

Universidade Federal do Pará

Aos meus avós, Maria Aparecida (*In memoriam*) e José Félix, que apesar de não terem tido acesso à educação, sempre reconheceram seu valor e incentivaram para que seus netos o tivessem.

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me dado o dom da vida, saúde e persistência para concluir mais esta etapa.

À minha família: pais e irmão, por todo apoio, esforço, incentivo e por estarem sempre ao meu lado, nunca medindo esforços para me apoiar.

Ao meu orientador, professor Dr. Rodrigo Sampaio Lopes, pela disposição em orientar-me e presteza para o desenvolvimento do presente trabalho.

A todos os professores que contribuíram para minha formação profissional até aqui e a todos os amigos que pude fazer durante esse período, com os quais compartilhei os melhores e mais difíceis momentos durante essa jornada.

À Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco – FACEPE, pelo apoio e incentivo na disponibilização da bolsa de pesquisa, a qual foi fundamental para a realização deste trabalho.

Aos demais que direta ou indiretamente contribuíram para a aquisição de novos conhecimentos e desenvolvimento desta pesquisa.

“Ninguém nasce feito, é experimentando-nos no mundo que nós nos fazemos”.
(FREIRE, 2001, p. 40).

RESUMO

O gerenciamento de falhas em sistemas de energia é um dos principais desafios enfrentados pelas concessionárias de energia elétrica, à medida que se esforçam para garantir maior eficiência e confiabilidade, usando várias abordagens e métodos científicos que alavancam os avanços em informação, comunicação e tecnologia. Pelo fato desses sistemas estarem expostos ao ambiente atmosférico, as chances de ocorrência de falhas acabam sendo maiores, logo, devido as suas características, essas redes apresentam vários obstáculos técnicos, já que os sistemas a serem monitorados são distribuídos, muitas vezes em locais remotos, e dessa forma, a detecção rápida de falhas nas linhas de transmissão e distribuição permite o rápido isolamento da linha defeituosa e, portanto, protege-a dos efeitos prejudiciais da falha. Analisando esse cenário, foram utilizadas técnicas de visão computacional para auxiliar a gestão da manutenção, por meio de um método de identificação de riscos na rede de distribuição que potencialmente prejudicariam o fornecimento de energia aos consumidores, através do processamento de imagens e detecção de riscos por meio de redes neurais convolucionais. O método proposto consiste na coleta das imagens, que foi realizada em áreas de zona urbana da cidade de Caruaru-PE, criação de um banco de dados e posterior divisão das imagens em classes de acordo com as características de riscos que podem afetar a distribuição de energia, classificação das imagens através de CNNs (*Convolutional Neural Networks*), escolha da melhor rede, detecção dos riscos pela CNN e priorização dos riscos identificados. Foi comparado o desempenho de cinco redes pré-treinadas, LeNet, AlexNet, ResNet, GoogLeNet e VGG19, e também foi comparado o desempenho de três otimizadores, Adam, SGD, RMSprop. Após o treinamento das redes foi possível observar que a rede neural que apresentou os melhores resultados foi a VGG19, treinada com o algoritmo de otimização SGD, atingindo uma acurácia de 94% e valor de perda de 0,15, sendo, portanto, a rede escolhida. Também foi possível identificar os riscos que necessitam de priorização através da matriz de risco, e por meio dela indicar ações de manutenção que evitem que o risco evolua até uma falha na rede elétrica. Dessa forma, a precisão da análise computacional pode trazer uma grande economia de tempo e melhorias de qualidade para a empresa, uma vez que, com tal conhecimento prévio dos riscos identificados, os gestores podem direcionar melhor suas equipes de manutenção.

Palavras-chave: visão computacional; CNN; manutenção; redes de distribuição.

ABSTRACT

Failure management in power systems is one of the key challenges facing electric utilities as they strive to ensure greater efficiency and reliability using various scientific approaches and methods that leverage advances in information, communication and technology. Because these systems are exposed to the atmospheric environment, the chances of failures end up being higher, so, due to their characteristics, these networks present several technical obstacles, since the systems to be monitored are distributed, often in remote locations, and in this way, the rapid detection of faults in transmission and distribution lines allows fast isolation of the faulty line and therefore protects it from the harmful effects of the fault. Analyzing this scenario, computer vision techniques were used to assist maintenance management, through a method of identifying risks in the distribution network that could potentially harm the supply of energy to consumers, through image processing and risk detection by through convolutional neural networks. The proposed method consists of collecting the images, which was carried out in urban areas of the city of Caruaru-PE, creating a database and later dividing the images into classes according to the characteristics of risks that can affect the distribution of energy, classification of images through CNNs (Convolutional Neural Networks), choice of the best network, detection of risks by CNN and prioritization of identified risks. The performance of five pre-trained networks, LeNet, AlexNet, ResNet, GoogLeNet and VGG19, was compared, and the performance of three optimizers, Adam, SGD, RMSprop, was also compared. After training the networks, it was possible to observe that the neural network that presented the best results was the VGG19, trained with the SGD optimization algorithm, reaching an accuracy of 94% and a loss value of 0.15, being, therefore, the network chosen. It was also possible to identify the risks that need prioritization through the risk matrix, and through it indicate maintenance actions that prevent the risk from evolving into a failure in the electrical network. In this way, the precision of the computational analysis can bring great time savings and quality improvements to the company, since, with such prior knowledge of the identified risks, managers can better direct their maintenance teams.

Keywords: computer vision; CNN; maintenance; distribution networks.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Hierarquia da Inteligência Artificial, Aprendizagem de Máquina e Aprendizagem Profunda	22
Figura 2 –	Exemplos de arquiteturas de uma Rede Neural Artificial e de Aprendizado Profundo.....	24
Figura 3 –	Arquitetura da LeNet-5, uma Rede Neural Convolutacional (CNN) para reconhecimento de dígitos	27
Figura 4 –	Ilustração da arquitetura AlexNet	27
Figura 5 –	Configurações de VGG em <i>Torchvision</i>	29
Quadro 1 –	Descrição dos critérios de impacto	34
Quadro 2 –	Descrição dos critérios de probabilidade	34
Quadro 3 –	Matriz de risco 4x4	35
Fluxograma 1 –	Esquema da metodologia aplicada neste trabalho	36
Fluxograma 2 –	Esquema da metodologia aplicada para classificação de imagens com CNNs.....	37
Quadro 4 –	Imagens pertencentes a cada classe de risco	39
Fotografia 1 –	Imagens geradas artificialmente	40
Quadro 5 –	Arquitetura da rede AlexNet utilizada para a classificação das imagens	41
Quadro 6 –	Fatores de risco das classes abordadas	44
Figura 6 –	Matriz de Risco para priorização de ações	45
Figura 7 –	Matriz de confusão para a rede AlexNet, otimizador: SGD	47
Gráfico 1 –	Acurácia das redes GoogLeNet e VGG19 – Adam	49
Gráfico 2 –	Loss das redes GoogLeNet e VGG19 – Adam	49
Gráfico 3 –	Acurácia das redes GoogLeNet e VGG19 – SGD	50
Gráfico 4 –	Loss das redes GoogLeNet e VGG19 – SGD	51
Gráfico 5 –	Acurácia das redes GoogLeNet e VGG19 – RMSprop	51
Gráfico 6 –	Loss das redes GoogLeNet e VGG19 – RMSprop	52
Figura 8 –	Matriz de confusão para a rede VGG19	53
Gráfico 7 –	Métricas da rede VGG19 com otimizador SGD	54
Fotografia 2 –	Riscos obtidos através da classificação de imagens	55
Quadro 7 –	Nível dos riscos para a classe Contato com Árvores	56
Quadro 8 –	Nível dos riscos para a classe Contato com Postes Inclinados	57
Quadro 9 –	Nível dos riscos para a classe Postes próximos a Residências	57
Quadro 10 –	Nível dos riscos para a classe Postes Sobrecarregados	58

LISTA DE SIGLAS

Acc	<i>Accuracy</i> (Acurácia)
Adam	<i>Adaptive Moment Estimation</i> (Estimativa de Momento Adaptativo)
ANEEL	Agência Nacional de Energia Elétrica
AP	Aprendizagem Profunda
CHI	Cliente Hora Interrompido
CNN	<i>Convolutional Neural Network</i> (Rede Neural Convolutacional)
DEC	Duração Equivalente de Interrupção por Unidade Consumidora
DL	<i>Deep Learning</i> (Aprendizado Profundo)
EUA	Estados Unidos da América
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora
FFNN	<i>Feedforward Neural Network</i> (Rede Neural Feedforward)
FN	<i>False Negative</i> (Falso Negativo)
FP	<i>False Positive</i> (Falso Positivo)
GPS	<i>Global Positioning System</i>
GPUs	Unidade de Processamento Gráfico
GRUs	Unidades <i>Gatedsgd</i>
IA	Inteligência Artificial
IoT	<i>Internet of Things</i> (Internet das Coisas)
LSTM	Memória de Longo Prazo
NERC	<i>North American Electric Reliability Corporation</i>
RGB	Sistema de Cores – <i>Red – Green – Blue</i>
RELU	Unidade Linear Retificada
ResNet	Modelo de Rede Residual
RMSprop	<i>Root Mean Square Root</i>
RNAs	Redes Neurais Artificiais
RNN	Redes Neurais Recorrentes
SDN	<i>Secondary Distribution Network</i> (Rede de Distribuição Secundária)
SGD	<i>Stochastic Gradient Descent</i>
SVR	<i>Support Vector Regression</i> (Regressão Vetorial de Suporte)
TN	<i>True Negative</i> (Verdadeiro Negativo)
TP	<i>True Positive</i> (Verdadeiro Positivo)
VGG	<i>Visual Geometry Group</i>

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	JUSTIFICATIVA	15
1.2	OBJETIVOS	16
1.2.1	Objetivos específicos	16
1.3	ESTRUTURA DO TRABALHO	16
2	FUNDAMENTAÇÃO TEÓRICA.....	18
2.1	REDES DE DISTRIBUIÇÃO DE ENERGIA	18
2.2	MANUTENÇÃO ASSISTIDA POR COMPUTADOR	20
2.3	APRENDIZADO PROFUNDO	21
2.4	REDES NEURAIIS	23
2.4.1	Redes pré-treinadas	26
2.5	MÉTODOS DE OTIMIZAÇÃO	30
2.5.1	SGD - <i>Stochastic Gradient Descent</i>.....	30
2.5.2	RMSprop - <i>Root Mean Square Root</i>	31
2.5.3	ADAM - <i>Adaptive Moment Estimation</i>	31
2.6	ANÁLISE DE RISCO EM REDES DE DISTRIBUIÇÃO DE ENERGIA.....	32
3	METODOLOGIA.....	36
3.1	AQUISIÇÃO DE IMAGENS E PRÉ-PROCESSAMENTO	37
3.2	CONJUNTO DE DADOS	38
3.3	CLASSIFICAÇÃO DOS RISCOS PELA CNN E ESCOLHA DA MELHOR REDE	40
3.4	PRIORIZAÇÃO DOS RISCOS	42
3.4.1	Probabilidade de ocorrência	42
3.4.2	Impacto.....	44
4	RESULTADOS E DISCUSSÃO.....	46
4.1	CLASSIFICAÇÃO DOS RISCOS PELA CNN E ESCOLHA DA MELHOR REDE	46
4.2	PRIORIZAÇÃO DAS OCORRÊNCIAS	54
4.3	DISCUSSÕES GERENCIAIS	59

5	CONCLUSÕES.....	61
5.1	CONSIDERAÇÕES FINAIS	61
5.2	LIMITAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS	62
	REFERÊNCIAS.....	63

1 INTRODUÇÃO

Redes de distribuição secundária (SDN) de sistemas de energia elétrica fornecem conectividade para os clientes finais (ZIDAN *et al.*, 2017). Sua principal função é garantir um fornecimento seguro e eficiente de energia aos consumidores (PALFI, 2016).

Estas redes podem ser divididas em aéreas ou subterrâneas de acordo com o tipo de instalação de cabos e demais componentes ao longo de sua extensão. As chances de ocorrência de falhas em uma linha de transmissão aérea são maiores em comparação com linhas subterrâneas, uma vez que a mesma está exposta ao ambiente atmosférico (DAVIS, 2013). Conseqüentemente, o gerenciamento de falhas em sistemas de energia é um dos principais desafios enfrentados pelas concessionárias de energia elétrica à medida que se esforçam para garantir maior eficiência e confiabilidade, usando várias abordagens e métodos científicos que alavancam os avanços em informação, comunicação e tecnologia (DOE, 2015 *apud* MNYANGHWALO *et al.*, 2020).

Vários fatores podem gerar falhas no fornecimento que afetam a distribuição de energia para os consumidores finais, como: sobrecarga do sistema em função de um elevado consumo, curto-circuito na rede de distribuição em função de equipamentos sem a devida manutenção, árvores que forçam a rede fazendo com que os cabos se toquem ocasionando curto-circuito, ou até rompimento dos cabos em função de agentes externos, como árvores, caminhões etc. (HEUBER *et al.*, 2015).

Uma vez que as falhas ocorrem, elas podem resultar em baixa qualidade de energia, fonte de alimentação elétrica não confiável, menos conforto para o consumidor, danos ao equipamento ou risco potencial para as pessoas com base em sua gravidade e na duração da falha (ARMENDARIZ *et al.*, 2016). De acordo com os dados contidos no anuário estatístico de acidentes de origem elétrica no ano de 2021, no Brasil, os casos de mortes envolvendo acidentes elétricos mostrou uma redução no número total de acidentes de origem elétrica, mas ainda é um número pouco significativo, dentre esses acidentes, podemos citar mortes por choques realizando podas de árvores, colocação de antenas, choques por fios rompidos em calçadas, etc., (ABRACOPEL, 2021).

Normalmente, a equipe de atendimento ao cliente deve designar uma equipe de manutenção para solucionar problemas e restaurar os serviços elétricos. Todo o processo consome grande tempo e esforço gerencial para detectar as falhas. Geralmente os clientes relatam as falhas por meio de telefones, o atraso na eliminação dessas falhas é causado muitas

vezes por relatos manuais de falhas, dificuldade da equipe técnica em localizar áreas onde as falhas foram relatadas pelos consumidores, técnicas de resolução de problemas ineficazes e ferramentas inadequadas para identificar e classificar falhas, o que conseqüentemente gera um aumento nas reclamações de clientes e perdas significativas de receita tanto para os clientes quanto para a empresa (MNYANGHWALO *et al.*, 2019).

Para diminuir tais problemas, seria interessante desenvolver métodos preventivos que auxiliem na identificação dos defeitos apresentados pelas redes de distribuição de energia. Avanços recentes nas tecnologias de processamento de informações e sensores levaram à possibilidade de implantar tecnologias de automação inteligente, inteligência artificial, controle hierárquico, redes de comunicação híbridas e Internet das Coisas (*IoT*) na rede elétrica para melhorar seu desempenho e eficiência (MOTLAGH *et al.*, 2020). Nesse sentido, o uso de visão computacional pode auxiliar, uma vez que as tecnologias de inteligência artificial proporcionam à gestão da manutenção mais ferramentas para monitorar os ativos nas empresas.

Na literatura são encontrados artigos que utilizam a visão computacional em gestão da manutenção, através de algoritmo proposto para verificar um conjunto de imagens de peças de engenharia (SUN, XING *et al.*, 2018), segmentação de defeitos em tubos (WANG, CHENG, 2020), para detectar danos estruturais (CHA, CHOI, 2018), fios elétricos rompidos (SONG, WANG, ZHANG, 2014), sistema de inspeção automática em linha de distribuição de energia (ZHANG, WEI *et al.*, 2018) e aplicação de CNN (*Convolutional Neural Network*) para reconhecimento de placas de trânsito (PALANISAMY, SADAYAN, PATHINETAMPADIYAN, 2019).

A proposta desse trabalho é apresentar um método de identificação de riscos que potencialmente prejudicariam a rede de distribuição de energia através do processamento de imagens e utilização de algoritmos de visão computacional. Onde o propósito é obter as imagens da rede dos próprios consumidores, tendo em vista que se tratam de sistemas distribuídos, muitas vezes em locais remotos, fazendo com que as equipes de manutenção precisem percorrer longas distâncias de um ponto a outro, principalmente em grandes centros urbanos, exigindo uma infraestrutura e demanda maior de equipes de coleta de dados e manutenção nessas áreas, considerando ainda, que os custos de manutenção constituem uma parcela significativa, pois desempenha um papel substancial na manutenção da confiabilidade do sistema dentro dos limites desejáveis e não pode ser negligenciado (GHARAKHEILI *et al.*, 2018).

Portanto, pretende-se propor um método que consiga melhor utilização dos recursos, de forma a identificar com mais rapidez questões de manutenção auxiliando na gestão da equipe

de manutenção, além de apresentar um baixo custo e possibilidade de replicação do algoritmo em várias localizações, assegurando uma maior disponibilidade e se mantendo de acordo com as regulamentações do setor elétrico.

1.1 JUSTIFICATIVA

Atualmente, as linhas de distribuição de energia são inspecionadas principalmente manualmente pelos trabalhadores, que acaba gerando alta intensidade de trabalho e custa muito tempo (ZHANG *et al.*, 2018). Além disso, as distribuidoras de energia são avaliadas em diversos aspectos no fornecimento de energia elétrica.

A qualidade percebida pelo consumidor de uma concessionária ou permissionária de serviço público de distribuição de energia elétrica deve ser avaliada a partir de três grandes aspectos: a qualidade do “produto” energia elétrica (relacionada à conformidade da tensão em regime permanente e à ausência de perturbações na forma de onda), a qualidade do “serviço” (relacionada à continuidade na prestação do serviço) e a qualidade do atendimento ao consumidor (ANEEL, 2021).

Portanto, a satisfação do cliente está se tornando um fator considerável no novo ambiente regulatório e melhorar a satisfação do cliente e seu fornecimento de energia elétrica é muito importante. Além disso, de acordo com o planejamento estratégico do governo de Pernambuco, pretende-se melhorar a qualidade de distribuição de energia no estado até o ano de 2035, de forma a melhorar a qualidade com redução da frequência e do tempo médio de interrupção (GOVERNO DE PERNAMBUCO, 2021). Então, coletar e classificar as causas de possíveis riscos no sistema de maneira rápida e correta pela gestão da manutenção é primordial para atingir esses objetivos.

Para garantir a disponibilidade dos sistemas, a gestão da manutenção passou a integrar novos recursos tecnológicos como a inteligência artificial (IA) para ampliar a capacidade de resolução de problemas cada vez mais complexos. Abordagens como reconhecimento de padrões, visão computacional, diagnósticos de processamento de imagens, robótica e automação são alguns dos exemplos das aplicações difundidas que buscam auxiliar o gestor na tomada de decisão (PATEL *et al.*, 2021).

Diante do exposto, entende-se que este estudo possui uma grande relevância à sociedade e aos setores público e privado, em virtude dos impactos que os riscos podem causar nas redes de distribuição, causando transtornos e interrupção do serviço aos consumidores, danos e custos às concessionárias e a terceiros e até mortes. A partir disso, vê-se a importância de identificar

e planejar ações de manutenção e a utilização de visão computacional nesse processo fornece às concessionárias uma ferramenta de gerenciamento eficiente, que auxilia nas decisões técnicas e financeiras de forma mais rápida e precisa.

1.2 OBJETIVOS

Este trabalho teve como objetivo propor um método para implementação de redes neurais convolucionais para classificação de riscos que potencialmente prejudicariam a rede de distribuição através de imagens de redes de distribuição de energia, proporcionando à gestão da manutenção uma ferramenta que auxilie na identificação dos defeitos apresentados pelas redes com pouca interferência humana.

1.2.1 Objetivos específicos

Para alcançar o objetivo geral desse trabalho, foram traçados alguns objetivos específicos:

- Gerar um banco de dados de imagens de redes de distribuição de energia para treino da rede;
- Adaptar redes neurais convolucionais e realizar o treinamento para classificar e identificar falhas em imagens de redes de distribuição de energia;
- Identificar o desempenho de redes neurais pré-treinadas;
- Selecionar o melhor algoritmo de otimização para o treinamento;
- Selecionar a melhor rede neural para a classificação das imagens;
- Identificar a priorização do risco a ser gerenciado.

1.3 ESTRUTURA DO TRABALHO

Para cumprir os objetivos descritos, esta dissertação foi dividida em 5 capítulos. O capítulo 1 apresenta a introdução, composta pelas considerações iniciais, justificativa, objetivo geral, objetivos específicos e a presente estrutura do trabalho. No capítulo 2 encontra-se o referencial teórico, onde são apresentadas as redes de distribuição de energia e explicações sobre manutenção assistida por computador. Também são inseridos conceitos de aprendizagem

profunda, redes neurais, métodos de otimização e análise de riscos a fim de facilitar a compreensão do estudo e a interpretação dos resultados obtidos.

No capítulo 3 é exposta a metodologia, que é dividida em aquisição das imagens, geração de um banco de dados, classificação das imagens através de CNNs e escolha da melhor rede a partir do treinamento e priorização dos riscos.

No capítulo 4, serão apresentados os resultados obtidos, onde será apresentado os gráficos com os resultados das redes treinadas, e posteriormente feita a escolha da rede com as melhores métricas. Após detectados os riscos, também é mostrado o resultado da matriz de risco para priorização das ações de manutenção. Por fim, no capítulo 5 encontram-se as considerações finais e algumas sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é apresentado uma abordagem dos conceitos, dentro da literatura, relacionado às redes de distribuição de energia, à manutenção assistida por computador e às técnicas de aprendizado profundo utilizadas para auxiliar a gestão da manutenção. Além de explorar também a análise de riscos em redes de distribuição de energia, de modo a fornecer um embasamento teórico necessário ao trabalho, facilitando a compreensão do objeto de estudo e a interpretação dos resultados obtidos.

2.1 REDES DE DISTRIBUIÇÃO DE ENERGIA

A evolução tecnológica e o elevado desenvolvimento industrial tornam a nossa sociedade fortemente dependente de energia. Esta necessidade, aliada aos padrões de qualidade de serviço atualmente impostos, se repercute nos sistemas elétricos de energia, originando um acréscimo de complexidade e dimensão destes, assim como um aumento da sua importância (MNYANGHWALO *et al.*, 2020).

O sistema de distribuição de energia é a parte do sistema mais próxima da unidade consumidora, responsável por reduzir o nível de tensão e distribuir a energia até o consumidor final, como residências, comércios ou indústrias (ALDABÓ, 2001). Portanto, estabelece-se a necessidade de que a prestação do serviço de transmissão de energia seja realizada com qualidade e associada a altíssimos níveis de disponibilidade das instalações.

A rede de energia elétrica de distribuição é composta por cabos condutores, transformadores e equipamentos diversos de medição, controle e proteção (BROWN, 2009). Essas redes podem ser divididas quanto ao tipo de instalação de cabos e demais componentes ao longo de sua extensão:

- Rede de Distribuição Aérea Convencional: Esse tipo de rede utiliza os condutores nus, ou seja, não possuem qualquer tipo de proteção ao longo da extensão do cabo, e são montadas em cruzetas, mantendo um espaço considerável entre condutores, o que implica em uma grande área de restrição entorno ao condutor. Essas características tornam este tipo de rede muito susceptível à ocorrência de falhas, principalmente provocadas por vegetação. Apresenta baixo custo de implantação (ROCHA, 2018; ABNT, 2012).

- Rede de Distribuição Aérea Compacta: Nesse tipo de rede os condutores dos alimentadores possuem uma camada de proteção que permite uma menor geometria entre as

fases, caracterizados por condutores cobertos, deixando o alimentador menos suscetível a falhas (ROCHA, 2018).

- Rede de Distribuição Aérea Isolada: Esse tipo de rede é pouco utilizado devido ao custo superior às redes convencionais ou compactas e utiliza condutores multiplexados isolados. Normalmente utiliza-se este tipo de instalação em trechos que necessitam da aplicação de um grande número de alimentadores por poste, como saída de subestações ou em situações em que a rede convencional (cabos nus) e a rede compacta (cabos protegidos por uma camada que não garante a isolação) oferecem situações de risco (ROCHA, 2018; ABNT, 2012).

- Rede de Distribuição Subterrânea: Este tipo de rede proporciona o maior nível de confiabilidade e também o melhor resultado estético, pois os cabos ficam acomodados em galerias subterrâneas. Apresenta custo de implantação elevado em comparação com as demais soluções, sendo utilizada apenas em regiões densamente ocupadas ou com restrições às redes aéreas (ROCHA, 2018).

As redes de distribuição aéreas convencionais e compactas são as de maior empregabilidade no Brasil, onde o tipo de rede a ser utilizada depende da região, pois leva-se em consideração questões climáticas, arborização, confiabilidade desejada, etc. Verifica-se que devido ao alto nível de tensão de transmissão e os comprimentos das linhas de transmissão e distribuição se tornando cada vez mais longos e o ambiente mais complexo, a possibilidade e o número de falhas são aumentados, inevitavelmente, necessitando ser corrigidos antes que evoluam para falhas (XI, FEILAI, *et al.*, 2017).

Esse crescimento do sistema elétrico de energia se reflete em todos os seus componentes, que representam vários elementos complexos, inter-relacionados e dinâmicos, que geralmente são suscetíveis a falhas elétricas. Devido aos seus impactos críticos, as falhas no sistema de energia elétrica na rede de distribuição secundária devem ser imediatamente detectadas, classificadas e eliminadas com urgência (MNYANGHWALO *et al.*, 2020).

Como as redes encontram-se desprotegidas contra as influências do meio ambiente, vários danos podem ser causados, como veículos que atingem postes, descargas atmosféricas, chuvas, poluição, podas de árvores não realizadas, objetos estranhos na rede, proximidade das redes com marquises, varandas, janelas, andaimes, que possam facilitar o contato acidental de pessoas, acarretando em descargas elétricas e acidentes graves (BROWN, 2009).

As concessionárias de energia utilizam planos de manutenção para evitar a ocorrência de falhas nessas redes, porém algumas questões fogem do padrão, um exemplo disso são as podas das árvores, onde na maioria das vezes as árvores encontram-se nas calçadas e nas estações chuvosas a força dos ventos pode forçar galhos contra os cabos causando curto

circuitos e provocando desligamentos, além da possibilidade de quedas dessas árvores. Em geral, o serviço de poda se dá através de cortes programados, geralmente ao iniciar a estação chuvosa, porém, a equipe precisa percorrer a rede em busca de possíveis problemas. A presença de objetos estranhos também pode levar a falhas e a retirada desses objetos da rede, tais como pipas, calçados, galhos de árvores soltos, etc., deve ser realizada, também resultando em um trabalho manual, que gera um gasto de tempo, recursos e equipes. Postes sobrecarregados de cabos é fruto do crescimento e diversificação dos serviços de telecomunicações, que tem o direito de utilização dos postes, mas o fazem sem o consentimento das distribuidoras de energia e a fiscalização precária acaba trazendo problemas para as concessionárias e consumidores do serviço.

Nas redes, quando ocorre uma falha, o equipamento de proteção inicia a operação dos disjuntores, para desenergizar a parte com falha. Geralmente, os disjuntores atuam como um dos dispositivos primários no esquema de proteção da rede contra falhas. Esta ação de proteção deve ser realizada antes que correntes e tensões excessivas causem danos aos equipamentos conectados, como transformadores (SOWAH *et al.*, 2018 *apud* MARTIN, AGUADO, 2003). Logo, devido as suas características, essas redes apresentam vários obstáculos técnicos, já que os sistemas a serem monitorados são distribuídos, muitas vezes em locais remotos, conseqüentemente, a detecção rápida de falhas nas linhas de transmissão e distribuição permite o rápido isolamento da linha defeituosa e, portanto, protege-a dos efeitos prejudiciais da falha. A classificação dessas falhas significa a identificação do tipo de falha, e esta informação é necessária para a localização da mesma e acessar a extensão do trabalho de reparo a ser executado (ROY, BHATTACHARYA, 2015).

2.2 MANUTENÇÃO ASSISTIDA POR COMPUTADOR

O crescente aumento estrutural das empresas vem trazendo demasiada quantidade de informações, fazendo com que seja vital a utilização de computadores e *softwares* para uma melhor gestão de dados e informações, o que pode trazer uma melhor utilização dos recursos disponíveis na gestão da manutenção, além disso, uma decisão tomada apoiada em informações técnicas atualizadas, consiste em decisões corretas e conseqüentemente mais eficientes.

Falhas em sistemas de energia elétrica são condições irregulares imprevisíveis que podem ser causadas por mudanças nas condições climáticas, erros humanos, incêndio e falhas de *hardware* elétrico e agentes externos (MNYANGHWALO *et al.*, 2020).

Nas redes de distribuição secundárias, as falhas devem ser detectadas primeiro e, em seguida, classificadas de acordo para outros processos. Uma vez conhecida a ocorrência das falhas e quais linhas estão afetadas, é fácil acionar os processos de liberação adequados para restaurar os serviços às suas condições normais ou evitá-los (MNYANGHWALO *et al.*, 2020). Atualmente, as linhas de distribuição são principalmente inspecionadas manualmente pelos trabalhadores, o que pode causar alta intensidade de trabalho e custa muito tempo.

A fim de diminuir problemas e melhorar o desempenho das redes, seria interessante métodos preventivos que auxiliem na identificação dos defeitos apresentados pelas redes de distribuição de energia. O avanço no aprendizado de máquina atualmente mostra o desempenho do aprendizado profundo e da arquitetura de aprendizado de máquina, como Redes Neurais Convolucionais (CNN), Redes Neurais Recorrentes (RNN), Unidades Recorrentes *Gated* (GRUs), Memória de Longo Prazo (LSTM), *Neural Feed Forward Rede* (FFNN) e abordagens de regressão vetorial de suporte (SVR) para ter melhor desempenho do que as abordagens tradicionais, fornecendo um novo método técnico para pesquisas em linhas de energia (LI, 2017).

Nesse sentido, o uso de visão computacional pode auxiliar, uma vez que as tecnologias de inteligência artificial proporcionam à gestão da manutenção mais ferramentas para monitorar os ativos nas empresas. Assim, a adoção desse processo poderá auxiliar a equipe de gestão da manutenção, otimizando seus recursos, de forma a identificar com mais rapidez questões de manutenção, onde a técnica de classificação de falhas precisa, rápida e confiável é um requisito operacional importante nos sistemas de distribuição de energia, já que sua principal função é assegurar o fornecimento ininterrupto de energia aos seus clientes, de acordo com padrões de qualidade previamente estabelecidos.

2.3 APRENDIZADO PROFUNDO

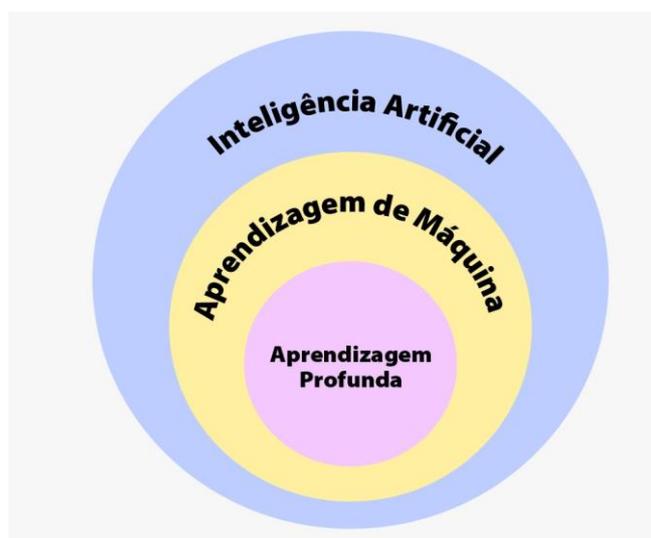
Entre as décadas de 1960 e 1970 surgiram os primeiros sistemas precursores das técnicas de Aprendizagem Profunda (AP) (do inglês *Deep Learning* - DL), porém a expressão “*Deep learning*” só foi criada em 2006 (SCHMIDHUBER, 2015).

O aprendizado profundo vem fazendo grandes avanços na solução de problemas sendo aplicável a muitos domínios da ciência, negócios e governo. Bateu recordes em reconhecimento de imagem (KRIZHEVSKY *et al.*, 2017; FARABET *et al.*, 2013; TOMPSON, 2014) e reconhecimento de fala (MIKOLOV *et al.*, 2011; HINTON *et al.*, 2012), superou outras técnicas de aprendizado de máquina na previsão da atividade de potenciais moléculas de

drogas (MA *et al.*, 2015), reconstruindo circuitos cerebrais (HELMSTAEDTER *et al.*, 2013) e prevendo os efeitos de mutações no DNA não codificante na expressão gênica e na doença (LEUNG *et al.*, 2014).

O aprendizado profundo é um subcampo específico de aprendizado de máquina que por sua vez é um campo da inteligência artificial (IA), Figura (1), que representa uma nova abordagem das representações de aprendizado a partir de dados. Nessa abordagem, é enfatizado o aprendizado através de camadas sucessivas (GUO, et al 2016). O termo aprendizado profundo se refere ao número de camadas que um modelo tem, quanto mais camadas, mais profundo é o modelo. No aprendizado profundo, essas representações em camadas são geralmente Redes Neurais Artificiais (CHOLLET, 2017).

Figura 1 - Hierarquia da Inteligência Artificial, Aprendizagem de Máquina e Aprendizagem Profunda



Fonte: A Autora (2021).

Deep learning oferece métodos que podem ser empregados de forma supervisionada e não supervisionada, ou até mesmo as duas formas juntas (SCHMIDHUBER, 2015). No aprendizado supervisionado, uma medida de resposta está disponível para cada observação das medidas do preditor e o objetivo é ajustar um modelo que preveja com precisão a resposta das observações futuras. Mais especificamente, na aprendizagem supervisionada, os valores da entrada x e da saída y correspondente estão disponíveis e o objetivo é aprender uma função f que se aproxime com uma margem de erro razoável da relação entre a entrada e a saída correspondente. Por outro lado, na aprendizagem não supervisionada, as variáveis de resposta não estão disponíveis e o objetivo da aprendizagem é compreender as características subjacentes às observações. A aprendizagem não supervisionada, portanto, tenta aprender com

a distribuição dos dados as características distintivas e as associações nos dados (GAMBELLA *et al.*, 2020).

2.4 REDES NEURAIAS

Redes neurais artificiais (RNAs) são modelos de processamento de dados que buscam inspiração na forma de funcionamento das redes neurais biológicas, lembrando o cérebro humano na forma como funcionam. Elas simulam um conjunto de neurônios conectados que são organizados em camadas, onde cada camada faz o processamento da informação e passa para a camada seguinte, dessa forma, são capazes de realizarem tarefas como reconhecer objetos, classificar imagens, aprender padrões, etc. (HAYKIN, *et al.*, 2009).

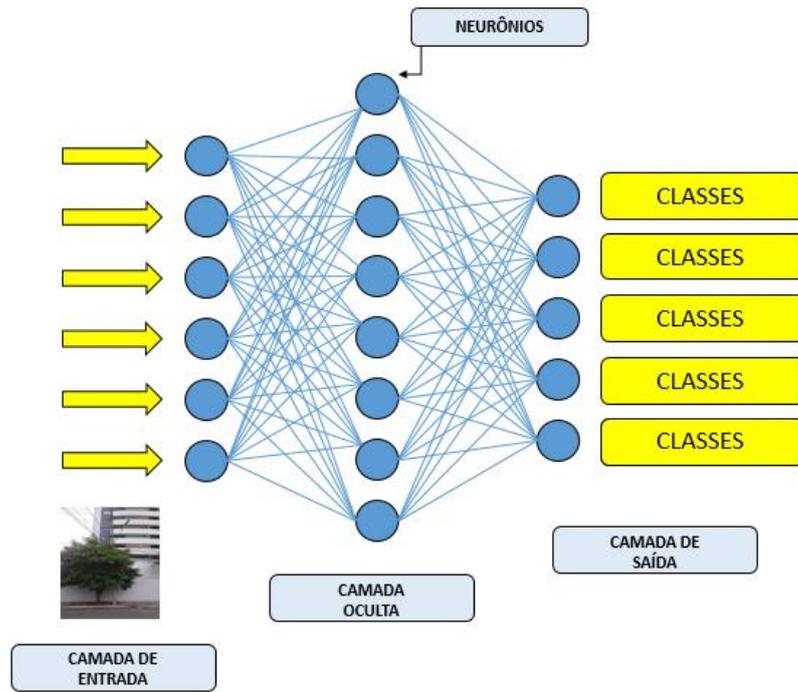
Entretanto, Chollet (2017), deixa claro que não há evidências de que o cérebro implemente algo como os mecanismos de aprendizagem usados em RNAs, e prefere definir aprendizagem profunda como sendo uma estrutura matemática para aprender representações a partir de dados.

O que diferencia uma RNA de uma arquitetura de aprendizado profundo é o número de camadas ou a profundidade da rede (SCHMIDHUBER, 2015). Em uma RNA geralmente encontramos apenas uma camada oculta, ou *hidden*, que está contida entre as camadas de entrada e saída. Já no aprendizado profundo podemos encontrar “n” camadas ocultas, como pode ser visto na Figura (2), que ilustra a classificação de uma imagem de rede de distribuição (LECUN, BENGIO, HINTON, 2015; KAVITHA, *et al.*, 2018).

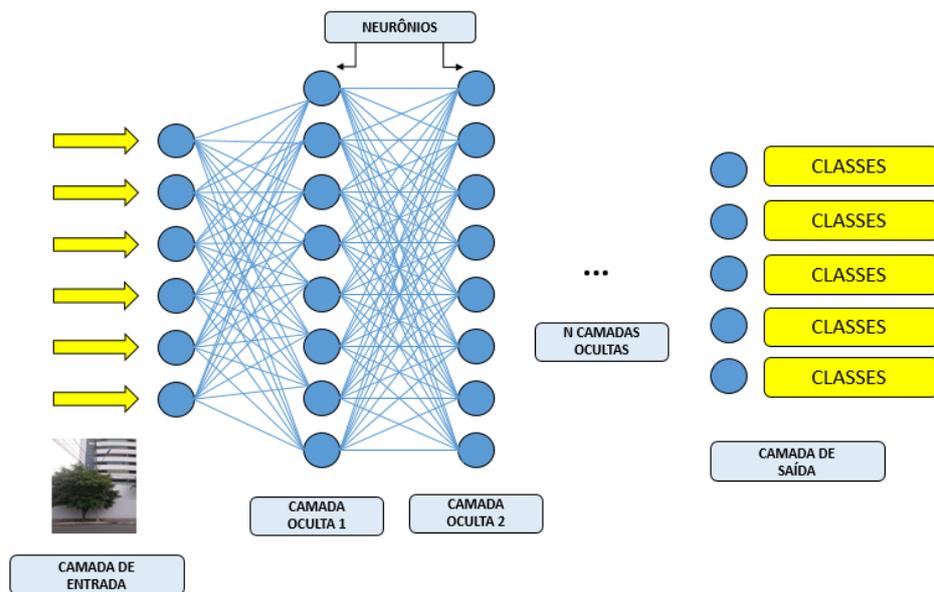
As Redes Neurais Convolucionais (CNNs) são uma classe das Redes Neurais Artificiais e são usadas para classificar imagens, realizar reconhecimento de objetos ou até mesmo o reconhecimento de áudios, são uma das técnicas mais proeminentes usadas na detecção de imagens e sistemas de percepção de computador, e são historicamente válidas no campo da ciência de dados. Além disso, as redes convolucionais (ConvNets) tiveram um grande sucesso no reconhecimento de imagem e vídeo em grande escala (KRIZHEVSKY *et al.*, 2012; ZEILER, FERGUS, 2014; SERMANET *et al.*, 2014; SIMONYAN, ZISSERMAN, 2015) que se tornou possível devido aos grandes repositórios de imagens públicas, como *ImageNet* (DENG *et al.*, 2009), e sistemas de computação de alto desempenho, como GPUs ou clusters distribuídos em grande escala (DEAN *et al.*, 2012).

Figura 2 - Exemplos de arquiteturas de uma Rede Neural Artificial e de Aprendizado Profundo

(a) Arquitetura de uma Rede Neural Artificial



(b) Arquitetura de uma Aprendizagem Profunda



Fonte: A Autora (2021).

Nota: Adaptado de LECUN, BENGIO, HINTON (2015); KAVITHA, *et al.* (2018).

A CNN se tornou uma das mais importantes no campo da classificação de padrões, pois a rede evita o pré-processamento das imagens e podemos inserir diretamente a imagem original (KAVITHA *et al.*, 2018).

Uma CNN simples é composta por uma sequência de camadas, e cada camada de uma CNN transforma um volume de ativações em outro através de uma função diferenciável. Além da camada de entrada, que normalmente é composta por uma imagem com largura, altura e profundidade (sistema de cores RGB (*Red, Green, Blue*)), são utilizados alguns tipos de camadas para criar arquiteturas CNN: *Convolutional Layer, Flatten Layer, Dropout Layer, Pool Layer* e *Fully Connected Layer* (GOODFELLOW *et al.*, 2016). Além disso, após uma camada de convolução é comum uma camada de ativação (normalmente uma função ReLu). Essas camadas, quando colocadas em sequência (ou empilhadas), forma a arquitetura de uma CNN.

A camada de convulação tem como objetivo aprender de forma eficiente características importantes sobre a imagem. Nela é realizada a parte mais pesada do processamento computacional (GONZALEZ, WOODS, 2007).

É uma camada que é composta por um conjunto de filtros (ou *kernels*) capazes de aprender de acordo com um treinamento e cada filtro é convolvido com a imagem de entrada. Os filtros são matrizes pequenas (por exemplo, $5 \times 5 \times 3$) compostas por valores reais que podem ser interpretados como pesos. A tarefa do filtro é processar a imagem ou a camada anterior, realizando a soma do produto de todos os valores de seu campo receptivo. Essa tarefa é executada em todas as posições de sua entrada, sendo possível detectar características independente de sua posição na imagem, graças ao fato que todos os neurônios formando o campo visual utilizam o mesmo filtro (KAVITHA *et al.*, 2018; VENKATESH, SUGUMARAN, 2021).

Nas matrizes resultados da convolução é aplicado a função de ativação. RELU (Unidade Linear Retificada), é a camada que atribuirá uma função de ativação do elemento, que é simplesmente aplicar a função $\max(0, x)$ em cada elemento do resultado da convolução. Assim, essa camada ajuda a truncar o número de parâmetros no sistema e torna o cálculo eficiente (KAVITHA *et al.*, 2018).

A camada de *pooling* é outro bloco de construção da rede CNN. É muito comum após uma camada de convolução existir uma camada de *pooling*. A técnica de *pooling* é utilizada com objetivo de reduzir o tamanho espacial das matrizes resultantes da convolução. Conseqüentemente, essa técnica reduz a quantidade de parâmetros a serem aprendidos na rede, contribuindo para o controle de *overfitting*. A técnica mais utilizada é a que usa o valor máximo encontrado na região como resultado, conhecida como *max pooling*, onde o valor do *pixel* que está tendo o valor máximo dentro de cada bloco é obtido. Além do *max pooling*, pode ser utilizadas outras funções, como por exemplo a média dos valores (CHUNJING *et al.*, 2017).

A camada totalmente conectada ligará todos os neurônios, finalmente, no final do CNN, e é completamente conectada com a camada anterior. Nesse caso, os neurônios têm conexões completas com todas as ativações nas camadas anteriores, sendo capaz de juntar informações para que uma visão geral da imagem possa ser obtida. Nas unidades de saída, é utilizado uma função *softmax* para se obter a probabilidade de dada entrada pertencer a uma classe (KAVITHA *et al.*, 2018).

2.4.1 Redes pré-treinadas

Um grande número de conjuntos de dados com rotulagem adequada é necessário para treinar um modelo CNN a partir do zero, portanto, treinar uma nova rede pode ser uma tarefa desafiadora. Por isso, o uso de modelos pré-treinados é considerado vantajoso e útil para superar essas desvantagens (GOODFELLOW *et al.*, 2016).

A principal razão para adotar modelos pré-treinados é devido à sua capacidade de treinar rapidamente em grandes conjuntos de dados com baixo erro de treinamento e exibir melhores propriedades de extração de recursos. Vários estudos recomendaram e demonstraram com sucesso o uso de modelos de rede pré-treinados (VENKATESH, SUGUMARAN, 2021). Neste trabalho foram utilizadas cinco arquiteturas de CNNs renomadas como LeNet, AlexNet, GoogLeNet, ResNet e VGG19 que foram selecionadas para serem comparadas. O critério de escolha dessas redes foi baseado em resultados de competições, como *ImageNet*, visto que, essas redes foram criadas pelos principais grupos de estudos de redes neurais do mundo, além disso, também se encontram disponíveis publicamente, em plataformas de códigos como *Github*, facilitando a adaptação para o problema deste estudo. Abaixo são apresentados mais detalhes sobre elas.

2.4.1.1 LeNet

Foi desenvolvida por LeCun *et al.*, (1998), sendo a primeira aplicação de CNN que obteve sucesso. Foi utilizada para classificar dígitos e por conta disso é muito utilizada em tarefas como leitura de códigos postais e afins.

A estrutura do modelo é dividida em uma camada de entrada, uma camada de convolução, uma camada de *pool*, uma camada totalmente conectada e uma camada de saída. Uma camada de entrada é removida e um total de 7 camadas são incluídas, como visto na Figura (3) (TAN, TAN, 2019).

2.4.1.3 GoogLeNet

GoogLeNet é uma rede de 22 camadas que foi proposta por Szegedy *et al.*, (2015) no ILSVRC 2014 e resolvia tarefas como detecção de objetos e classificação de imagens. GoogLeNet usa um modelo de CNN inspirado no modelo LeNet, mas implementou um novo conceito: o módulo de injeção, por isso também é comumente conhecido com *Inception V1*. O módulo de injeção é baseado em várias convoluções pequenas com o objetivo de drasticamente reduzir o número de parâmetros e facilitar o treinamento.

Nove módulos iniciais acompanhados por quatro camadas de convolução e *pooling* máximo, três camadas de *pooling* média, cinco totalmente conectadas seguidas por três camadas *softmax* são organizadas para completar a arquitetura de rede. As camadas totalmente conectadas são ativadas usando a função de ativação ReLU e são fornecidas com *dropouts* de proporção 0,4 para resistir ao sobreajuste (VENKATESH, SUGUMARAN, 2021).

2.4.1.4 ResNet – Modelo de Rede Residual

O modelo de rede residual (ResNet) é uma rede neural convolucional da Microsoft, desenvolvido por HE *et al.* (2016), que ganhou prêmios na competição ILSVRC 2015. A arquitetura dos modelos ResNet é profunda, exibindo características de alta convergência com precisão atraente, foi construída usando várias unidades residuais empilhadas e são construídas com um número variável de camadas (18, 34, 50, 101, 152 e 1202). De acordo com HE *et al.* (2016), ResNets de 50/101/152 camadas são mais precisas do que os de 34 camadas por margens consideráveis.

A ResNet é composta por blocos residuais, onde cada um é composto de várias camadas convolucionais empilhadas e como outros modelos pré-treinados, é composto de camadas de convolução, *pooling* e totalmente conectadas. Essa arquitetura é cerca de 20 vezes mais profunda que a AlexNet e 8 vezes mais profunda que a VGG (GU *et al.*, 2018).

No presente estudo é utilizado ResNet com 50 camadas (ResNet50), que contém 49 convoluções e uma camada totalmente conectada.

2.4.1.5 VGG - Visual Geometry Group

A arquitetura VGG (*Visual Geometry Group*) utiliza camadas convolucionais 3 x 3 empilhadas umas sobre as outras com profundidade crescente, venceu as tarefas de identificação e classificação da competição ILSVRC 2014 desenvolvido por (SIMONYAN, ZISSERMAN, 2015).

Existem algumas variações do modelo VGG, como vista na Figura (5), mas foi constatada boa precisão para o reconhecimento de imagens utilizando redes de 16-19 camadas. Essa rede possui similaridade com a AlexNet, mas utiliza apenas convoluções 3x3 e as compensa com muitos filtros. Neste trabalho considerou-se apenas a arquitetura VGG-19, devido à sua boa performance e facilidade de uso.

Figura 5 - Configurações de VGG em *Torchvision*

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Fonte: Simonyan, Zisserman (2015).

2.5 MÉTODOS DE OTIMIZAÇÃO

Com o propósito de fazer com que o modelo funcione melhor no processo de classificação, deve-se modificar de alguma forma as variáveis para todas as camadas da rede, ou seja, com uma função de custo definida, precisa-se então ajustar os parâmetros para que o custo seja reduzido.

Primeiramente, é importante saber o quão bom é o desempenho do modelo, comparando a saída prevista do modelo com a saída desejada. Uma das medidas de desempenho mais importantes é a entropia cruzada. A entropia cruzada é uma função contínua sempre positiva e torna-se zero quando a saída prevista do modelo corresponde exatamente à saída desejada (TAQI *et al.*, 2018).

Portanto, o principal objetivo da otimização é minimizar a entropia cruzada, para que chegue o mais próximo possível de zero, para isso, geralmente usa-se o algoritmo do gradiente descendente, visando minimizar a discrepância entre a saída desejada e a saída real (LECUN, KAVUKCUOGLU, FARABET, 2010).

O gradiente descendente é uma forma de minimizar uma função objetivo $J(\theta)$ parametrizado pelos parâmetros de um modelo $\theta \in \mathbb{R}^d$ atualizando os parâmetros na direção oposta do gradiente da função objetivo $\nabla_{\theta} J(\theta)$ wrt para os parâmetros. A taxa de aprendizagem η determina o tamanho das etapas que executamos para atingir um mínimo (local) (TAQI *et al.*, 2018).

No presente trabalho, foram utilizados três algoritmos de otimização: SGD, Adam e RMSprop, discutidos abaixo, com o objetivo de se extrair o melhor aproveitamento de treinamento para as CNNs estudadas.

2.5.1 SGD - *Stochastic Gradient Descent*

Segundo Ruder (2016), o gradiente descendente é um dos algoritmos mais populares para realizar a otimização e, de longe, a forma mais comum de otimizar redes neurais. SGD provou ser um método de otimização eficiente e eficaz que foi fundamental em muitas histórias de sucesso de aprendizado de máquina, como avanços recentes no aprendizado profundo (DENG *et al.*, 2013; KRIZHEVSKY *et al.*, 2012; HINTON, SALAKHUTDINOV, 2006; HINTON *et al.*, 2012 ; GRAVES *et al.*, 2013).

Existem três variantes do gradiente descendente, esse trabalho utiliza uma delas, a variante SGD. O método de otimização SGD realiza uma atualização de parâmetro para cada exemplo de treinamento $x(i)$ e rótulo $y(i)$:

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)}) \quad (1)$$

O SGD executa atualizações frequentes com uma alta variação que faz com que a função objetivo flutue fortemente, dessa forma, permite que ele pule para mínimos locais novos e potencialmente melhores (RUDER, 2016; SUTSKEVER *et al.*, 2013).

2.5.2 RMSprop - *Root Mean Square Root*

RMSprop significa *Root Mean Square Root* e é um método de taxa de aprendizagem adaptativa, que funciona muito bem com redes neurais (HINTON *et al.*, 2012). O algoritmo calcula médias da magnitude dos gradientes mais recentes para cada parâmetro e as usa para modificar a taxa de aprendizado individualmente antes de aplicar os gradientes. O objetivo do RMSProp é manter a média móvel dos gradientes quadrados para cada peso, e após isso é dividido o gradiente pela raiz quadrada do quadrado médio (RUDER, 2016). Segundo Taqi (2018), a média de execução $E[g^2]_t$ num tamanho de passo t depende da média anterior e do gradiente atual sendo:

$$E[g^2]_t = 0,9E[g^2]_{t-1} + 0,1g_t^2 \quad (2)$$

e

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_{t+\epsilon}}} g_t \quad (3)$$

2.5.3 ADAM - *Adaptive Moment Estimation*

Adaptive Moment Estimation (Adam) é outro método que calcula taxas de aprendizagem adaptativa individuais para diferentes parâmetros de estimativas de primeiro e segundo momentos dos gradientes (KINGMA, BA, 2014).

Além de armazenar uma média exponencialmente decadente de gradientes quadrados anteriores v_t como RMSprop, Adam também mantém uma média exponencialmente decadente de gradientes anteriores m_t , onde:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (4)$$

e

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (5)$$

sendo m_t e v_t estimações do primeiro momento, a média, e o segundo momento, a variação não centralizada, os gradientes β_1 e β_2 são as taxas de decaimento. Adam é um algoritmo que concatena RMSprop e momentum juntos (TAQI *et al.*, 2018).

2.6 ANÁLISE DE RISCO EM REDES DE DISTRIBUIÇÃO DE ENERGIA

De acordo com a ISO 31000 (2009), risco é o efeito da incerteza nos objetivos, ou seja, o desvio em relação ao esperado, que se dá tanto positivamente quanto negativamente. Ele é caracterizado pela referência aos eventos e às consequências, ou até mesmo uma combinação destes fatores. Podendo ser expresso em termos das consequências de um evento e sua probabilidade.

Procurando atender as necessidades e anseios dos consumidores, as empresas concessionárias de energia vêm implantando práticas de intervenção da manutenção na rede de distribuição a fim de evitar que o risco evolua até uma falha. Atualmente são mais de 3,9 milhões de quilômetros de redes de distribuição no Brasil, as quais estão sujeitas a todo o tipo de intempéries e adversidades, mais ou menos previsíveis (ANEEL, 2019).

A identificação das causas de interrupção nas redes de distribuição de energia elétrica é uma tarefa desafiadora, já que na maioria dos casos, ao haver uma interrupção do serviço não é possível saber com exatidão a causa da falha, o que exige análise de dados coletados pelas equipes de campo e pelos sistemas automatizados de diagnóstico de falhas. Em alguns casos, infere-se causas mais prováveis de terem originado o problema, baseado em medições, inspeções e/ou reclamações dos consumidores, o que acelera o processo de diagnóstico e manutenção. Assim, o processo proposto através da classificação de riscos em imagens, enviadas pelos próprios usuários do serviço, auxiliam no processo de identificação de fatores que podem gerar a interrupção de energia.

Porém, após a análise dos riscos, têm-se a dificuldade em decidir qual medida deve ser tomada primeiro. Geralmente, há um número limitado de equipes disponíveis para atividades de manutenção e reparo, não podendo atender a todas as demandas de uma única vez, sendo considerável concentrar recursos na priorização das medidas urgentes e mais importantes. Diante desta situação de impasse, coloca-se em prática a Matriz de Risco, também conhecida como Matriz de Priorização, que se trata de uma ferramenta que visa a tomada de decisão através da priorização de problemas, como visto abaixo.

2.6.1 Matriz de Risco

A matriz de risco é um método gráfico utilizado no processo de análise de risco, onde o resultado pode ser um guia para decidir a prioridade do risco a ser gerenciado. A matriz utiliza como eixos: probabilidade de ocorrência do risco (que pode ser relatada como alta, média e baixa) e impacto do risco, caso ele venha a ocorrer (que pode ser relatado como insignificante, moderado e alto) (XIAOSONG *et al.*, 2009).

O risco pode ser sério quando é provável que aconteça ou, quando acontecer, haverá uma grande perda, por isso, a dificuldade de gerenciamento deve ser levada em consideração na avaliação dos níveis de gravidade dos riscos (ZHANG *et al.*, 2016). Dessa forma, a classificação quantitativa do impacto e da probabilidade do risco é julgada por especialistas de acordo com uma experiência mais intuitiva e, em seguida, os fatores de risco são classificados, bem como a avaliação de risco é realizada, possibilitando a tomada de decisões e a realização de medidas preventivas para tratar esses riscos (XU *et al.*, 2018). Além disso, por ser uma ferramenta de fácil entendimento e por dispor informações de forma clara e precisa, colabora com engajamento da equipe no processo de gestão de riscos.

A matriz criada deve ser adaptada para a realidade da empresa. Após a classificação e identificação dos riscos, deve ser atribuído várias características aos mesmos. O conhecimento sobre o risco identificado é fundamental para que a avaliação seja realista e precisa, por exemplo, a probabilidade de ocorrência de um risco típico é a avaliação da equipe sobre a probabilidade de um risco acontecer. Estimar essa probabilidade de ocorrência pode ser difícil na prática, por isso as atribuições devem ser baseadas em dados de ocorrência e as discussões geradas ajudarão a entender e esclarecer qual é o nível real de impacto e probabilidade do risco sob avaliação (XIAOSONG *et al.*, 2009). Os Quadros (1) e (2) mostram a descrição dos critérios de impacto e probabilidade.

Quadro 1 – Descrição dos critérios de impacto

Impacto	Descrição dos critérios de impacto
Baixo	Os riscos possuem pequenas consequências em curto prazo. Os requisitos mínimos aceitáveis serão atendidos
Moderado	Os riscos possuem consequências reversíveis em curto e médio prazo, e podem apresentar custos adicionais
Alto	Os riscos possuem consequências altas, grande aumento de custo e alguns requisitos podem não ser atendidos
Severo	Os riscos possuem consequências muito altas e grande aumento de custos

Fonte: A Autora (2021).

Nota: Adaptado de XIAOSONG *et al.* (2009).

Quadro 2 - Descrição dos critérios de probabilidade

Probabilidade		Descrição dos critérios de probabilidade
Numérica	Descritiva	
1% a 25%	Insignificante	Muito improvável que o risco ocorra
26% a 50%	Baixa	Improvável que o risco ocorra
51% a 75%	Moderada	Probabilidade de o risco ocorrer
76% a 100%	Alta	Provavelmente o risco ocorrerá

Fonte: A Autora (2021).

Nota: Adaptado de XIAOSONG *et al.* (2009).

Após a definição dos níveis de impacto e probabilidade é feito o cálculo dos níveis dos riscos, localizados em blocos da matriz identificados por cores, como visto no Quadro (3).

Quadro 3 – Matriz de risco 4x4

Probabilidade	Alta	Moderado	Elevado	Extremo	Extremo
	Média	Moderado	Elevado	Elevado	Extremo
	Baixa	Baixo	Moderado	Elevado	Elevado
	Insignificante	Baixo	Baixo	Moderado	Moderado
		Baixo	Moderado	Alto	Severo
Impacto					

Fonte: A Autora (2021).

Ao se estabelecer os níveis de riscos, cada um deles irá apresentar diferentes métodos de tratamento dos riscos identificados. O nível de risco extremo indica que a atividade é crítica e demanda imediata atenção. O risco elevado significa que a atividade é de grande importância, mas não demanda urgência, o que sugere que pode ser incluído em metas e programações, a fim de que sejam priorizadas para que não se tornem urgentes. Já o nível de risco moderado indica que a atividade é importante, mas não urgente, podendo ser feito o monitoramento ou a realização de procedimentos específicos necessários. E por fim, o nível de risco baixo indica que a atividade é de pouca importância, podendo ser gerenciada através de procedimentos de rotina (LUEJAI, *et al.*, 2021; BASU, 2017).

Assim, a matriz de risco pode ser utilizada no processo de priorização dos riscos e pode ajudar a reduzir a reincidência de falhas, uma vez que pode ser melhor visualizadas as classes mais vulneráveis, gerando uma maior transparência ao informar os riscos de maior urgência e melhorando assim os padrões de gerenciamento.

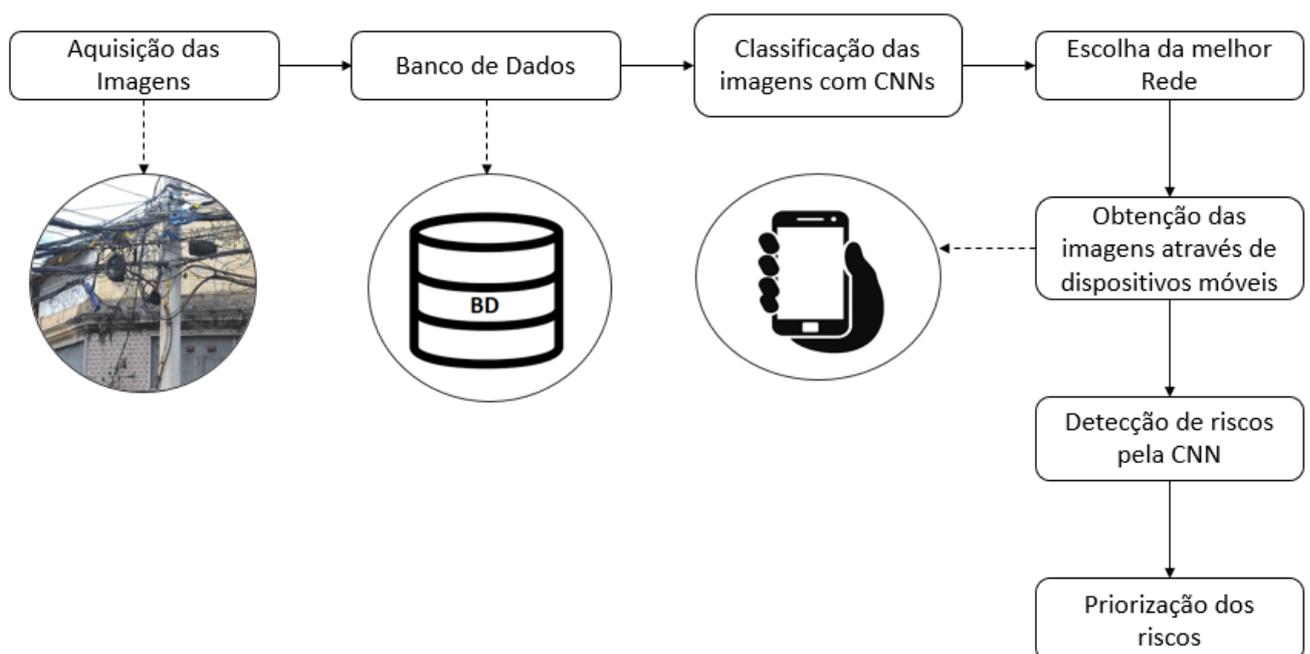
3 METODOLOGIA

Este capítulo apresenta as etapas na qual foi desenvolvido este trabalho. Além disso, também é apresentado a metodologia da ferramenta de classificação dos riscos utilizada nesta dissertação, bem como a ferramenta para priorização dos riscos identificados.

Esta pesquisa tem caráter aplicado, pois pretende aplicar soluções baseada na revisão da literatura realizada. É considerada qualitativa, pois busca estabelecer uma relação entre a aplicação da manutenção assistida por computador com a redução de falhas e redução de gastos da empresa. Também é classificada como exploratória por pretender ampliar as informações na área do estudo e promover o avanço científico na área de manutenção e inteligência artificial e é definida como um estudo de caso uma vez que utilizará o contexto atual das redes de distribuição de energia da cidade de Caruaru - PE para desenvolver os resultados desta pesquisa, onde o estudo foi conduzido em uma empresa que presta serviços de manutenção para uma companhia de distribuição de energia.

O método proposto para identificação e classificação de riscos em imagens de redes de distribuição é composto por: aquisição das imagens, geração de um banco de dados, classificação das imagens através de CNNs pré-treinadas, escolha da melhor rede a partir do treinamento, obtenção das imagens através de dispositivos móveis, detecção de riscos pela CNN e priorização dos riscos, como visto no Fluxograma (1).

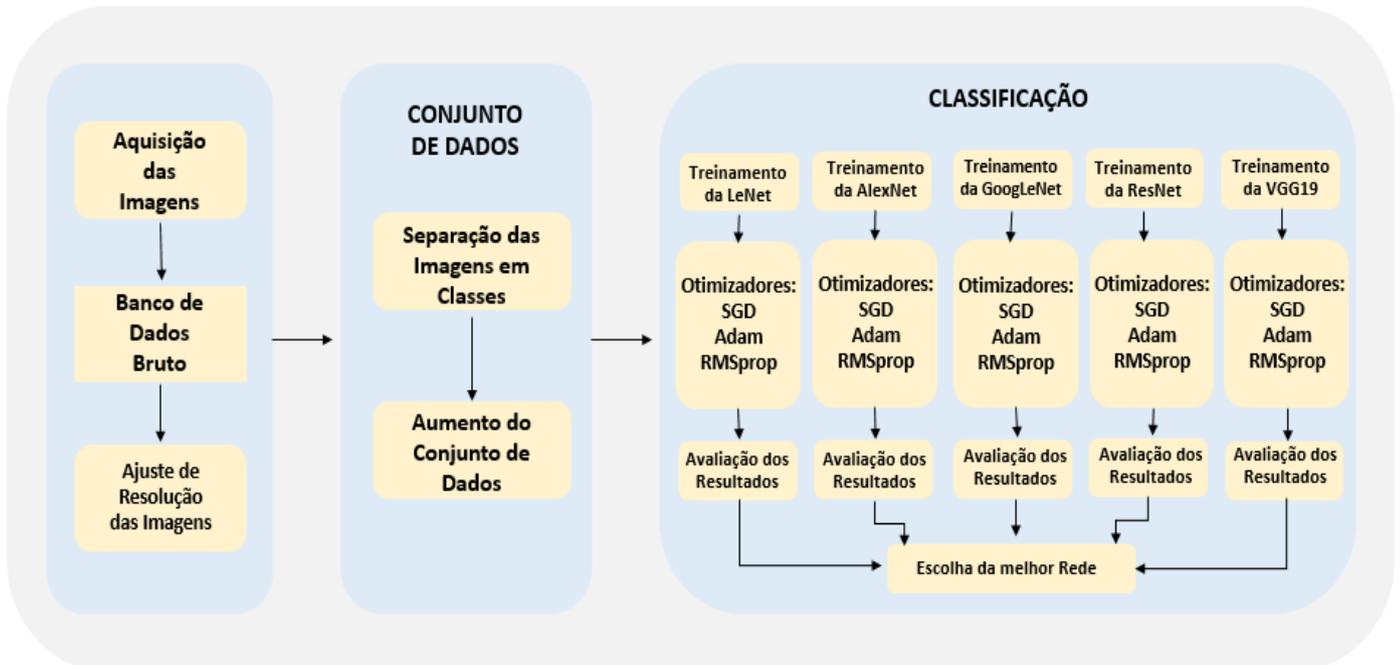
Fluxograma 1 - Esquema da metodologia aplicada neste trabalho



Fonte: A Autora (2021).

A classificação das imagens pelas CNNs, por sua vez, consiste em três etapas principais: aquisição de imagens e pré-processamento, criação de um conjunto de dados e classificação ou detecção de riscos pela CNN, como pode ser visto no Fluxograma (2).

Fluxograma 2 - Esquema da metodologia aplicada para classificação de imagens com CNNs



Fonte: A Autora (2021).

As etapas são descritas nas seguintes subseções.

3.1 AQUISIÇÃO DE IMAGENS E PRÉ-PROCESSAMENTO

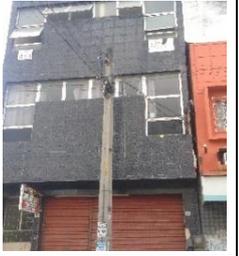
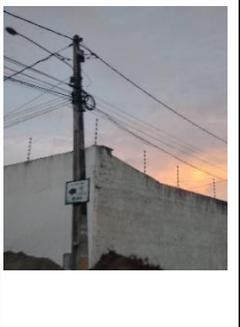
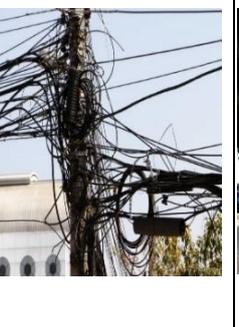
Obter imagens dos postes de distribuição de energia é a premissa para a identificação de riscos por meio de CNNs. Algumas plataformas disponibilizam conjuntos de dados para treinamentos de redes neurais, porém não foi encontrado nenhum conjunto de imagens que pudesse ser aplicado à problemática desse trabalho. Nesse caso, a obtenção das imagens foi feita pela autora por meio de câmeras de dispositivos móveis, inicialmente em áreas de zona urbana que continham problemas a serem identificados na rede de distribuição, na cidade de Caruaru – PE. O conjunto de dados inicial consistiu em 155 imagens em RGB. Porém, o objetivo futuro é que essas imagens possam ser obtidas através de aplicativos fornecidos pelas companhias de energia, em que a própria população pode fazer o envio das imagens, localização e informações complementares, tendo em vista a alta disseminação na internet atualmente.

Após a aquisição, o pré-processamento é uma das etapas aplicada na imagem para obter um melhor resultado. Como dito anteriormente, a CNN se tornou uma das técnicas mais importantes no campo da classificação de padrões, pois a rede evita o pré-processamento das imagens e podemos inserir diretamente a imagem original. Nesse caso, foi feito apenas o pré-processamento da resolução das imagens, que nada mais é do que uma matriz de valores de *pixels*, que originalmente continham 3456x4608 *pixels* e serão utilizadas com resoluções de 64x64 e 224x224 *pixels*. As imagens podem apresentar diversas dimensões, porém, esse pré-processamento foi feito levando em consideração as redes estudadas a fim de evitar que as mesmas sofram *overfitting* considerável, ou seja, evitar que o modelo aprenda muito bem no treinamento, mas se mostre ineficaz para prever novos resultados.

3.2 CONJUNTO DE DADOS

Uma base de imagens foi criada especificamente para o treinamento das redes neurais desse trabalho, como exposto no tópico anterior. Foi gerado um banco de dados de imagens, onde as mesmas posteriormente foram separadas em classes pelas características de riscos que podem afetar a distribuição de energia para os consumidores finais, sendo essas classes definidas juntamente com a empresa a qual é realizado esse estudo de caso. Dessa forma, o conjunto que apresenta originalmente 155 imagens foi separado em 5 classes, sendo elas: árvores que forcem a rede, fios muito próximos a residências, postes sobrecarregados e inclinação de postes. Além disso, também foi criada uma classe que possui imagens da rede em perfeito funcionamento e sem interferências, para que dessa forma possa ser feita a classificação se a imagem possui ou não algum risco que necessite de manutenção. A identificação das classes de riscos também será uma contribuição desse estudo, tendo em vista que a partir dessa identificação poderá ser estabelecido as classes que mais apresentam riscos de interrupção de energia, e, dessa forma, a gestão da manutenção pode fazer redimensionamentos de equipes para as classes que apresentarem níveis de risco extremo. Imagens de cada classe podem ser vistas no Quadro (4). Porém, vale ressaltar que o modelo de rede identifica apenas um risco por imagem, mesmo que a imagem apresente vários riscos sobrepostos.

Quadro 4 - Imagens pertencentes a cada classe de risco

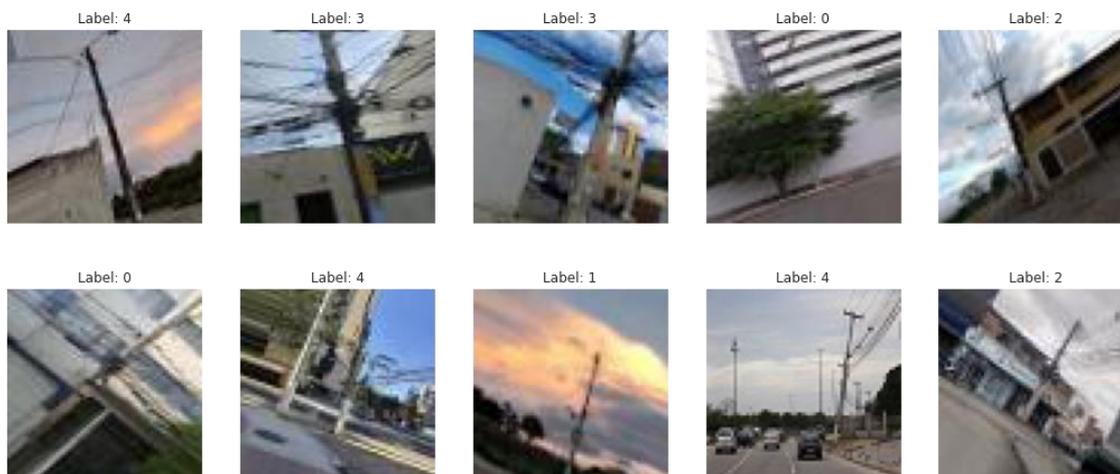
Classe 0 (Contato com Árvores)	Classe 1 (Postes Normais)	Classe 2 (Postes próximos a Residências)	Classe 3 (Postes Sobrecarregados)	Classe 4 (Postes Inclinados)
				
				

Fonte: A Autora (2021).

Destaca-se também que o número de imagens inicial do conjunto de dados é relativamente pequeno para problemas de classificação de imagens por meio de técnicas de aprendizado profundo. Assim, o aumento de dados é uma forma comumente usada para diminuir o *overfitting* causado pelo pequeno conjunto de dados e aumentar o desempenho do modelo.

Portanto, após a divisão das imagens em classes, procede-se à leitura destas e aumento do conjunto de dados, utilizando uma técnica de gerar novas imagens a partir das existentes, aplicando transformações aleatórias: distorção, rotação e *zoom*. Esse processo aumenta artificialmente o número de segmentos, com o objetivo de melhorar o procedimento de aprendizagem e o desempenho, treinando o modelo com dados variados (KAMILARIS, PRENAFETA-BOLDÚ, 2018). A partir desse processo, o conjunto de dados passou a apresentar 1250 imagens. A Fotografia (1) mostra algumas imagens geradas através dessa técnica.

Fotografia 1 - Imagens geradas artificialmente



Fonte: A Autora (2021).

3.3 CLASSIFICAÇÃO DOS RISCOS PELA CNN E ESCOLHA DA MELHOR REDE

Após a realização das etapas mostradas anteriormente, é feito o treinamento com as CNNs. Dentre os modelos de redes existentes e utilizadas para reconhecimento de objetos em imagens, foram selecionadas cinco redes pré-treinadas com base em seus desempenhos em trabalhos e classificação de imagens. Neste trabalho serão comparadas as redes: LeNet, AlexNet, GoogLeNet, ResNet50 e VGG19. Os algoritmos das redes pré-treinadas foram aplicados através da linguagem de programação em *Python* para classificar as imagens da rede de distribuição.

Cada arquitetura de rede inicial foi modificada a fim de se adequar ao classificador de imagens de redes de distribuição de energia. Foram adaptadas as entradas de forma que fosse aceito as imagens em cores do conjunto de treinamento com forma (64, 64, 3) para as redes neurais LeNet, ResNet e VGG19 e (224, 224, 3) para as redes AlexNet e GoogLeNet, que correspondem a resolução das imagens e aos canais de cores (RGB), respectivamente. Também foi modificado o número de saídas para que se encaixasse em 5 rótulos exclusivos no conjunto de treinamento, que se refere as classes identificadas. Nas camadas convolucionais foram explorados dois hiperparâmetros, o número de filtros e o tamanho do *kernel*. Nas camadas *Max Pooling* foi explorado o tamanho do *kernel*. Nas camadas totalmente conectadas foram explorados os números de unidades. Também foi escolhido o algoritmo de otimização utilizado no treinamento. Dos sete algoritmos de otimização disponíveis no *Keras* (Interface de programação de aplicação de AP escrita em *Python*) foram selecionados três algoritmos que são mais utilizados em problemas de classificação de imagens e cada rede foi treinada com os

otimizadores SGD, Adam e RMSprop, a fim de identificar qual otimizador se adequa melhor a cada rede. Após isso, foram escolhidos os parâmetros de treinamento como número de épocas e tamanho dos lotes (*batch size*) para fazer o treinamento. O Quadro (5) mostra como exemplo a arquitetura de uma das redes treinadas, AlexNet, utilizada para a classificação das imagens deste trabalho.

Quadro 5 - Arquitetura da rede AlexNet utilizada para a classificação das imagens

CAMADA	DESCRIÇÃO
Entrada	(224, 224, 3)
Convulação 11x11	4x4 stride, valid padding
Ativação	ReLu
Max Pooling	2x2 stride, valid padding
Batch Normalization	-
Convulação 11x11	1x1 stride, valid padding
Ativação	ReLu
Max Pooling	2x2 stride, valid padding
Batch Normalization	-
Convulação 3x3	1x1 stride, valid padding
Ativação	ReLu
Batch Normalization	-
Convulação 3x3	1x1 stride, valid padding
Ativação	ReLu
Batch Normalization	-
Max Pooling	2x2 stride, valid padding
Batch Normalization	-
Flatten	256
Dense	4096
Ativação	ReLu
Dropout	4096
Dense 1	4096
Ativação	ReLu
Dropout 1	4096
Dense 2	1000
Ativação	ReLu
Dropout 2	1000

Camada Totalmente Conectada	5
Ativação	Softmax

Fonte: A Autora (2021).

Ao fim do treinamento das redes estudadas, são analisadas as métricas utilizadas na literatura em avaliações e técnicas de aprendizagem para classificação de imagens, onde através dessas métricas é possível avaliar se a rede apresentou um bom desempenho ou não, a fim de selecionar a melhor rede para detecção de riscos em imagens.

3.4 PRIORIZAÇÃO DOS RISCOS

Ao receber as imagens classificadas pela CNN contendo a localização do risco através do aplicativo, a empresa poderá direcionar a demanda a uma de suas equipes através da priorização do mesmo. Essa priorização é feita levando em consideração a probabilidade de ocorrência do risco e o impacto que ele pode causar caso venha a ocorrer como mostra a Equação (6). Essa priorização é importante pois promove um atendimento mais rápido da demanda de manutenção, evitando que a falha venha ocorrer na rede e direcionando melhor suas equipes aos locais de risco, tendo em vista que dependendo da localização do risco, esses fatores podem ocorrer de forma mais alta ou mais baixa (LIAO, *et al.*, 2020).

$$R = P \times I \quad (6)$$

Para a priorização dos serviços de manutenção através dos riscos identificados nas imagens, o método proposto pode ser apoiado por registros dos eventos de falhas e interrupção de energia em bancos de dados e posterior análise dos indicadores de continuidade do serviço de distribuição de energia elétrica quanto à duração e frequência de interrupção, conforme os conceitos de qualidade de serviço de energia elétrica do módulo 8 do PRODIST, proposto pela ANEEL.

3.4.1 Probabilidade de ocorrência

A partir dos dados de interrupção, podem ser calculados os indicadores de qualidade de serviço DEC e FEC (ANEEL, 2021):

$$FEC = \frac{\sum Ca(i)}{c} \quad (7)$$

$$DEC = \frac{\sum Ca(i)*t}{c} \quad (8)$$

Onde: DEC = Duração Equivalente de Interrupção por Unidade Consumidora

FEC = Frequência Equivalente de Interrupção por Unidade Consumidora

Ca(i) = consumidores atingidos

C = número de consumidores

t = total de interrupções

Avaliando esses indicadores podem ser verificadas as principais causas de interrupções nos indicadores de qualidade DEC e FEC e assim analisar a probabilidade de ocorrência de cada classe de risco. Analisando trabalhos na área, Richard (2009), cita causas mais frequentes de desligamentos em redes de distribuição de energia em três distribuidoras de energia dos EUA, sendo as causas equipamentos defeituosos, contato com árvores, descarga atmosférica e animais, as mais frequentes nessa análise. O autor ainda cita que é importante levar em consideração a taxa de crescimento de cada tipo de planta que divide espaço com a rede, tendo em vista que a causa mais frequente (chegando em 30% de causas de interrupções) é contato com árvores, perdendo apenas para equipamentos defeituosos (chegando em 50% das causas de interrupções).

Hazan (2020) analisou os dados de interrupção de energia de uma concessionária de energia elétrica, registrados pela empresa nos anos de 2015 a 2018. A partir dos dados de interrupção, foram calculados os indicadores de qualidade de serviço DEC e FEC utilizando-se a quantidade de horas interrompidas por cliente consumidor, a quantidade de clientes interrompidos e a quantidade total de clientes consumidores. E partir disso, foram analisadas por meio de gráficos e tabelas as principais causas de interrupção de energia elétrica. Foi observado que das causas que compõem o DEC, tem-se 13% das causas relacionadas a árvores e 11% relacionados a ações externas, causas não relacionadas diretamente a problemas nas instalações. E, para as causas relacionadas diretamente as interrupções temos 1% relacionados a causas operacionais.

Também foi analisado a composição do indicador FEC por causas, apresentando 11% relacionados a contato de árvores, 15% relacionados a ações externa e 4% operacionais. Para esse indicador, as causas se apresentam mais equivalentes, tanto as relacionadas diretamente a problema nas instalações como as não relacionadas.

3.4.2 Impacto

Outro indicador que pode ser calculado através das informações disponíveis no banco de dados da empresa é a variável Consumidor Hora Interrompido (CHI), expressa por (ANEEL, 2021):

$$CHI = \frac{(x*t)}{60} \quad (8)$$

Onde: x = número de unidades afetadas com a interrupção de energia;

t = tempo em minutos da duração de interrupção de energia.

Através do CHI podem ser avaliados os impactos que determinada falha pode causar a rede, uma vez que envolve a quantidade de consumidores atingidos na ocorrência das falhas gerando descontentamento ao consumidor final. Em seu trabalho, Fernandes (2014) cita as causas de maior influência nas interrupções, relativos aos consumidores hora interrompidos e frequência das falhas ou número de eventos, para o período de 01 a 03/2012. Segundo ele, danos em postes depreciados apresentam a maior causa de CHI, seguidos por causas ligadas a vegetação. Com relação a frequência das falhas, as causas ligadas a vegetação aparecem em terceiro lugar, seguido por animais/pássaros, representando ações externas.

O Quadro (6) foi elaborado a fim de estabelecer os fatores de risco de cada classe em concordância com a equipe de colaboradores da empresa. Dessa forma, os impactos que esses riscos podem causar caso a falha ocorra se tornam mais visíveis, a fim de facilitar o estabelecimento do nível de impacto.

Quadro 6 – Fatores de risco das classes abordadas

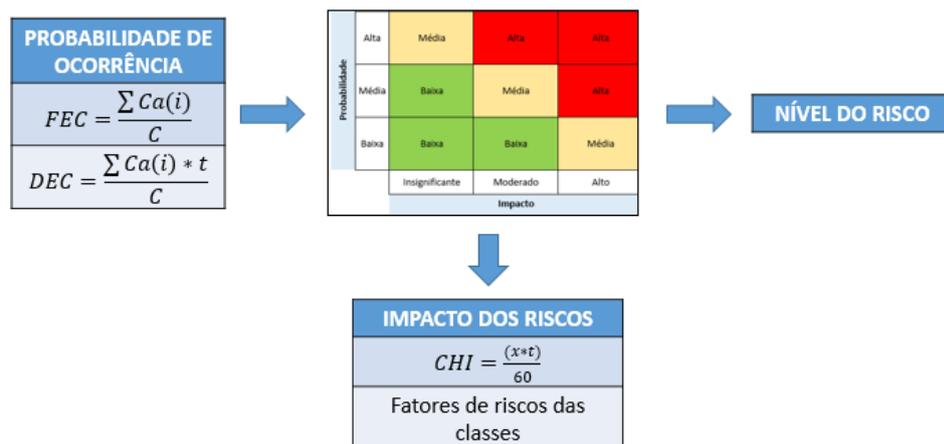
RISCO	FATORES DE RISCO
Contato com Árvores	Curto-circuito e interrupção do fornecimento de energia; Queda de árvores sobre a rede energizada; Rompimento de cabos; Acidentes envolvendo terceiros.
Postes próximos a Residências	Curto-circuito por objetos jogados na rede; Acidentes domésticos – choques elétricos; Risco com animais.
Postes Sobrecarregados	Rompimento de cabos; Acidentes envolvendo terceiros;

	Comprometimento da segurança.
Postes Inclinados	Risco de ceder, causando acidentes; Rompimento de cabos; Interrupção do serviço.

Fonte: A Autora (2021).

Ao final dessa análise e identificados os riscos que mais contribuem para as causas de interrupções, pode, então, ser examinado os elementos que compõem esses riscos e sua probabilidade de ocorrência e impacto gerado podem ser estimados, e, seu gerenciamento bem-sucedido. Dessa forma, de acordo com a definição de nível de risco, o nível é a combinação da probabilidade e impacto correspondente, como visto na Figura (6) (LIAO, *et al.*, 2020).

Figura 6 – Matriz de Risco para priorização de ações



Fonte: A Autora (2021).

Os dados utilizados nessa etapa representam a realidade, mas para preservar a empresa na qual está sendo realizado o estudo, os mesmos foram integrados com os resultados. Dessa forma, a priorização das ações será analisada através de outros trabalhos relacionados a área como exposto nessa metodologia, através da análise de ocorrências das causas e em concordância com colaboradores da empresa.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta a análise dos resultados encontrados, baseado na metodologia apresentada no Capítulo III, assim como, na fundamentação teórica apresentada no Capítulo II.

4.1 CLASSIFICAÇÃO DOS RISCOS PELA CNN E ESCOLHA DA MELHOR REDE

De acordo com a metodologia apresentada anteriormente, foi feito o treinamento das redes pré-treinadas. O conjunto de dados foi dividido em treino e teste, com 1000 e 250 imagens respectivamente.

Nesta etapa, são passados como parâmetro à rede neural o número de épocas, onde uma época é uma iteração passando por todos os dados do conjunto de treino, o *batch size* que é o número de dados utilizados para atualização dos pesos e os dados de treino e teste. Feito isso, são coletados os resultados por meio da função *history* do *Keras*, e em seguida são as feitas as previsões para o conjunto de teste, coletando todas as métricas para serem analisadas.

Destarte, é possível avaliar qual rede consegue atingir os melhores resultados para o problema de classificação da rede de distribuição de energia, onde, são utilizadas como métricas a matriz de confusão, acurácia, *loss*, sensibilidade e especificidade.

A matriz de confusão compara as previsões de um modelo com o padrão verdadeiro. A diagonal da matriz representa classes que foram corretamente previstas (*True Positive* - TP), enquanto elementos fora da diagonal representam imagens que foram classificados de forma errada (*False Positive* - FP). A Figura (7) mostra a matriz de confusão obtida através do treinamento da rede AlexNet com o otimizador SGD, onde, analisando a diagonal da mesma, pode ser visto que a rede acertou bastante em suas previsões.

A partir da matriz de confusão, algumas métricas podem ser calculadas, como sensibilidade, especificidade, acurácia e erro, a fim de avaliar se o algoritmo está ou não conseguindo bons resultados. Dessa forma, temos:

$$\text{Sensibilidade} = \frac{TP}{TP+FN} \quad (9)$$

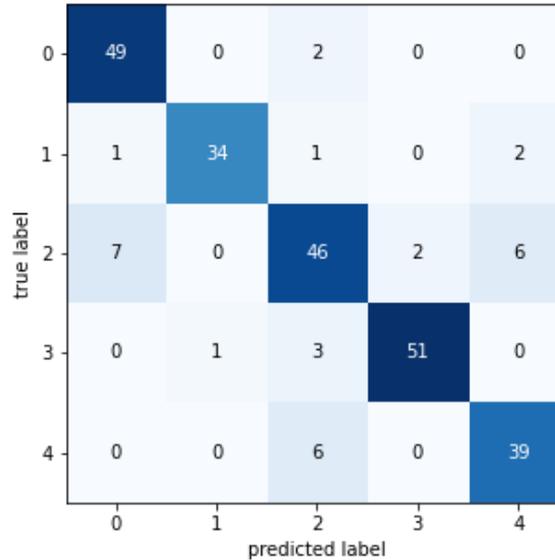
$$\text{Especificidade} = \frac{TN}{TN+FP} \quad (10)$$

$$\text{Acurácia} = \frac{TP+TN}{TP+TN+FP+FN} \quad (11)$$

$$\text{Erro} = 1 - \text{Acurácia} \quad (12)$$

Sendo, TP: verdadeiro positivo, FN: falso negativo, TN: verdadeiro negativo, FP: falso positivo.

Figura 7 - Matriz de confusão para a rede AlexNet, otimizador: SGD



Fonte: A Autora (2021).

A métrica sensibilidade avalia a proporção de verdadeiros positivos sobre o total de imagens com problemas existentes. Já a especificidade avalia a proporção de verdadeiros negativos sobre o total de imagens normais existentes. A acurácia significa a proporção de imagens classificadas corretamente sobre o total de imagens, portanto, uma métrica que nos dá uma visão geral do resultado. Assim, essas métricas podem representar uma ferramenta para melhorar a tomada de decisão, uma vez que através delas pode-se verificar o melhor resultado possível para um treinamento, e consequentemente obter-se um resultado mais assertivo através das técnicas de visão computacional.

Na Tabela (1) é possível observar os valores extraídos a partir do treinamento das redes estudadas.

Tabela 1 – Valores obtidos após o treinamento das redes neurais convolucionais

	Adam			
	Acc	Loss	Especificidade	Sensibilidade
LeNet	0,4720	3,5138	0,9032	0,7895
AlexNet	0,7400	1,0190	0,9535	1,0000
GoogLeNet	0,9039	0,4003	1,0000	1,0000
ResNet	0,8479	0,4809	0,9809	0,9172
VGG19	0,9079	0,3227	1,0000	0,9714
SGD				

	Acc	Loss	Especificidade	Sensibilidade
LeNet	0,2280	1,6022	0,3115	0,2901
AlexNet	0,8759	0,4202	1,0000	0,9714
GoogLeNet	0,9079	0,4496	1,0000	1,0000
ResNet	0,8360	1,0914	0,9783	0,9062
VGG19	0,9399	0,1520	1,0000	1,0000

RMSprop				
	Acc	Loss	Especificidade	Sensibilidade
LeNet	0,4799	7,1824	0,9125	0,7981
AlexNet	0,6639	1,7596	0,8780	1,0000
GoogLeNet	0,8119	0,8404	0,9756	0,9688
ResNet	0,6919	1,7489	1,0000	0,8571
VGG19	0,9319	0,2525	1,0000	1,0000

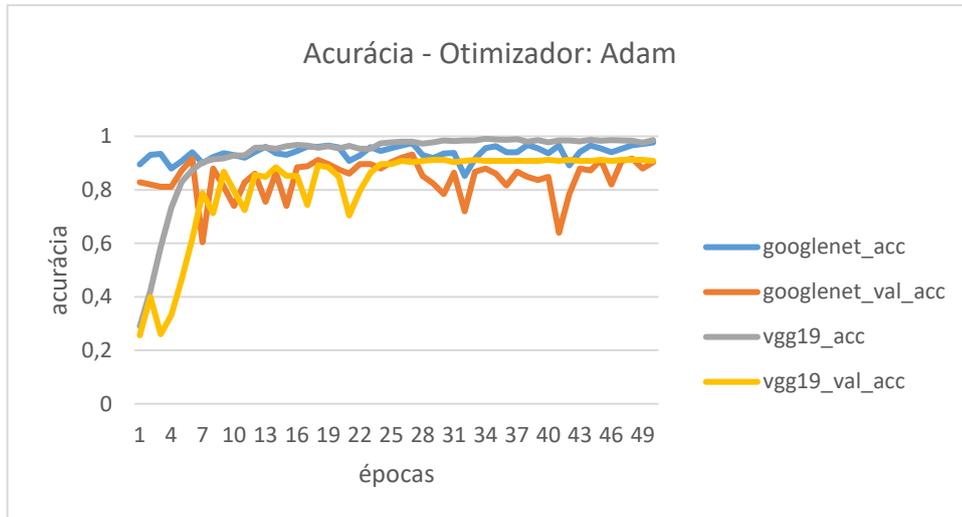
Fonte: A Autora (2021).

A partir da Tabela (1), é possível verificar que as redes com as melhores métricas são a GoogLeNet e VGG19, em relação a todas as outras. A rede que apresentou as piores métricas foi a LeNet, com acurácias abaixo de 50%, isso pode ser justificado pelo fato de que essa rede foi uma das primeiras implementadas, sua aplicação inicial foi para identificação de dígitos, e, dessa forma, as imagens não apresentam tantas características de formas e cores para classificação como as utilizadas nesse trabalho, uma vez que a quantidade de informações presente nas imagens dificulta o processamento e a identificação dos riscos.

As redes neurais convolucionais podem apresentar desempenhos diversos de acordo com o conjunto de dados treinados, dessa forma, apesar de serem redes renomadas, para alguns conjuntos de dados as mesmas podem não apresentar bons desempenhos.

Os resultados das duas melhores redes serão avaliados, e, abaixo, podemos observar os gráficos das métricas (acurácia e *loss*) das redes GoogLeNet e VGG19 para os otimizadores Adam, SGD e RMSprop.

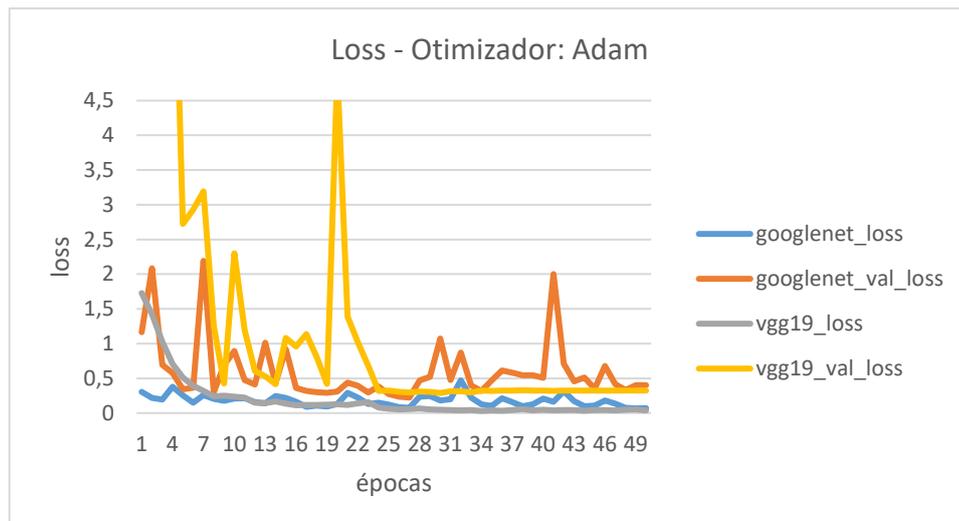
Gráfico 1 – Acurácia das redes GoogLeNet e VGG19 - Adam



Fonte: A Autora (2021).

No Gráfico (1), é possível ver os valores de acurácia em cada época por rede com o otimizador Adam, onde é possível verificar que a rede com maior valor de acurácia foi a VGG19 que apresentou valores mais baixos de acurácia no início do treinamento, mas evoluiu para valores muito próximos a 1 ou 100%, tanto para acurácia de treino como para acurácia de validação, ao final das 50 épocas de treinamento. A rede GoogLeNet também finalizou o treinamento com valores próximos de 100%, mas não chegou a ultrapassar a rede VGG19.

Gráfico 2 – Loss das redes GoogLeNet e VGG19 - Adam

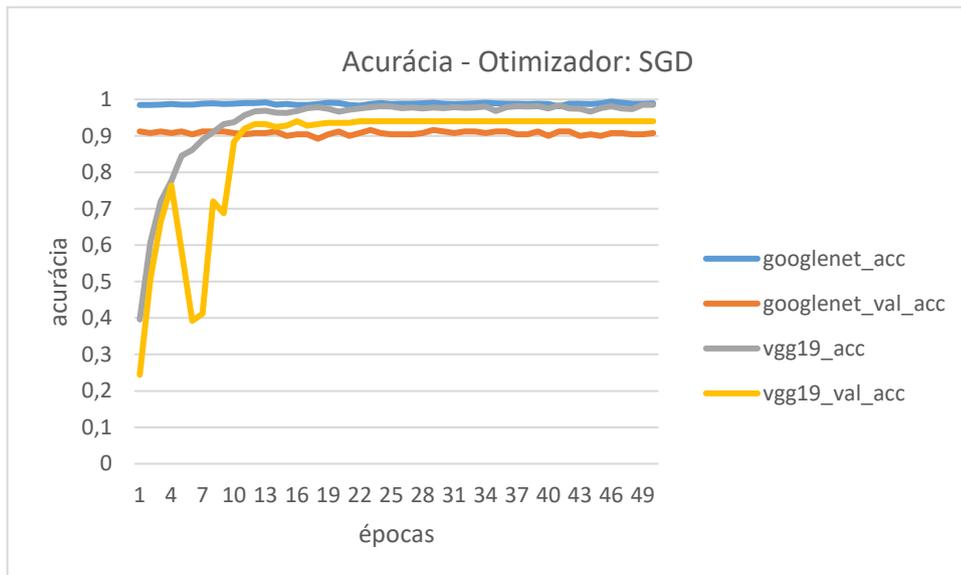


Fonte: A Autora (2021).

No Gráfico (2) tem-se o acompanhamento dos valores de perda (*loss*) das CNNs ao longo das épocas do treinamento. Algumas variações são observadas no decorrer das épocas para validação do GoogLeNet e VGG19, porém, com o avanço do treinamento os valores de perda tornaram-se próximos de zero, esse padrão é uma evidência importante de que não houve *overfitting* durante o treinamento. Ao final do treinamento foi obtido valores muito próximos de zero para VGG19 *loss*, superando a rede GoogLeNet.

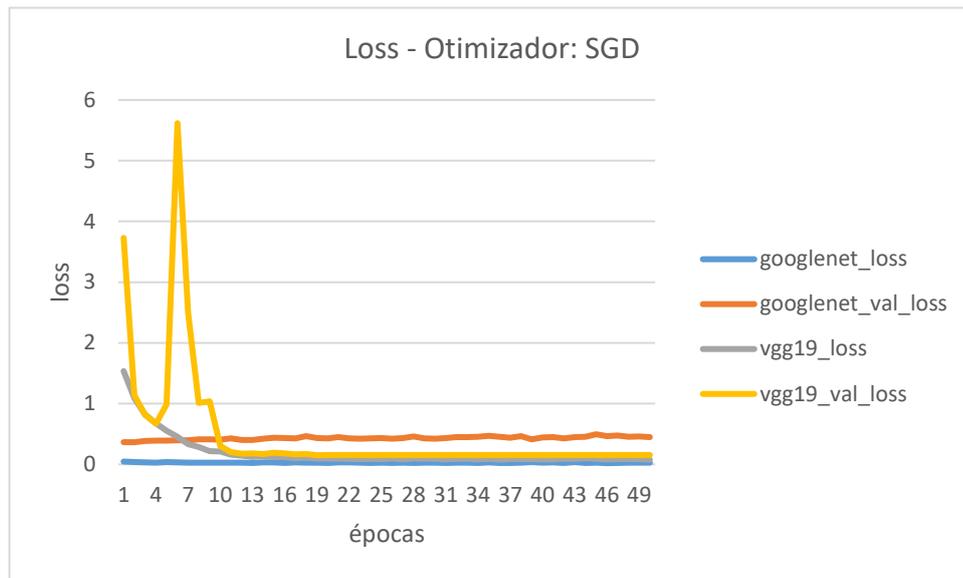
O próximo Gráfico (3), mostra a acurácia para as redes com o otimizador SGD. A partir do mesmo, é possível verificar valores bem mais estáveis de treinamento que os comparados ao otimizador Adam. As redes GoogLeNet e VGG19 apresentaram valores muito próximos de 1 ou 100% de acurácia, como visto nas linhas azul e cinza. A acurácia de validação apresentou valores maiores para a rede VGG19.

Gráfico 3 - Acurácia das redes GoogLeNet e VGG19 - SGD



Fonte: A Autora (2021).

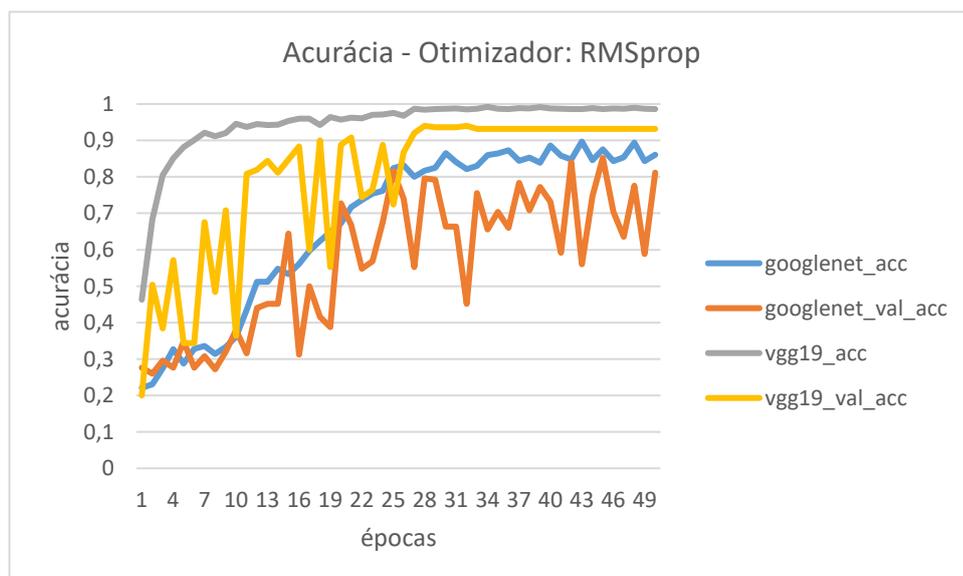
Gráfico 4 - Loss das redes GoogLeNet e VGG19 - SGD



Fonte: A Autora (2021).

Observa-se no Gráfico (4) os valores de perda para o otimizador SGD, que inicialmente apresentou uma partida de *loss* mais alta para validação do VGG19, porém com o avanço do treinamento os valores de perda tornaram-se próximos de zero, e muito próximo de zero para VGG19 *loss*, superando também a rede GoogLeNet. Portanto, a CNN treinada conseguiu obter resultados satisfatórios de acurácia e *loss*, como foi demonstrado nos Gráficos (3) e (4).

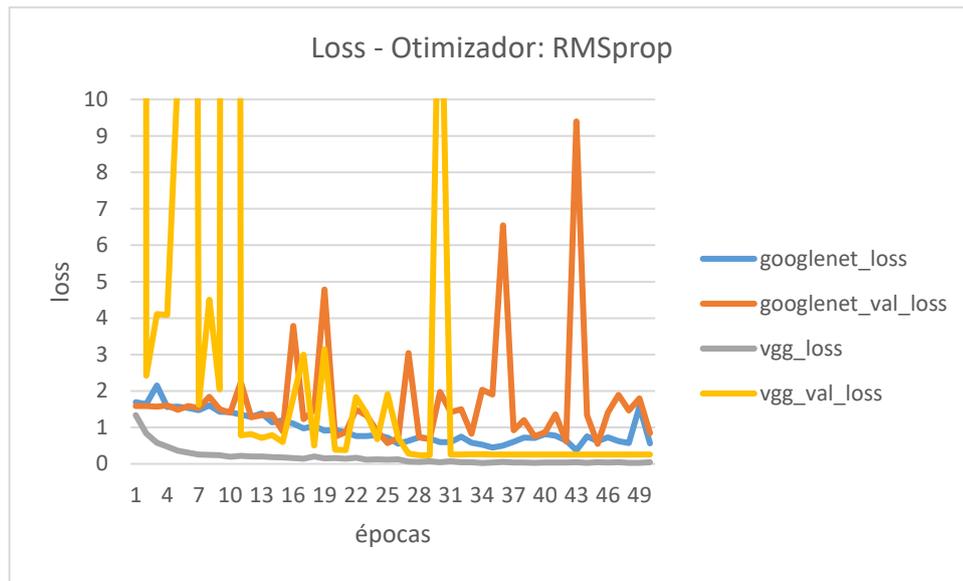
Gráfico 5 - Acurácia das redes GoogLeNet e VGG19 - RMSprop



Fonte: A Autora (2021).

Para o otimizador RMSprop, a rede GoogLeNet apresentou valores de acurácia inferiores aos outros otimizadores mostrados acima. A rede VGG19, apesar de ter se apresentado mais instável no início do treinamento apresentou valores de acurácia e validação superiores a 90% ao final das 50 épocas de treinamento, como visto no Gráfico (5).

Gráfico 6 - Loss das redes GoogLeNet e VGG19 - RMSprop



Fonte: A Autora (2021).

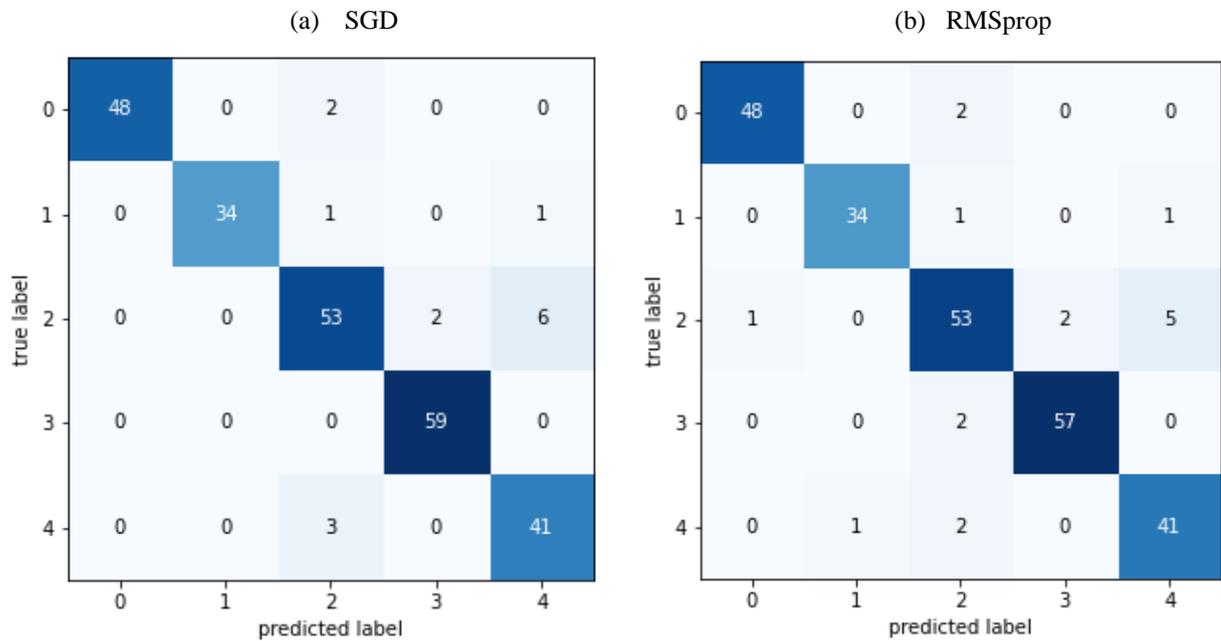
Os valores de perda expostos no Gráfico (6) apresentaram percentuais muito altos quando comparados com os otimizadores Adam e SGD para a rede GoogLeNet. O fato de o RMSprop utilizar taxas de aprendizagem adaptativas faz com que redes muito profundas, que é o caso da rede GoogLeNet, tenham mais dificuldade de convergir para os melhores pesos. Já a rede VGG19 apresentou valores de *loss* próximos a zero durante o treinamento, indicando que apresentou bom desempenho.

Portanto, como avaliado nos gráficos acima a rede VGG19 apresentou os melhores resultados comparados com a GoogLeNet e os otimizadores SGD e RMSprop apresentaram as melhores métricas para a rede destacada. Como dito anteriormente, foram coletadas as matrizes de confusão para as redes estudadas. Abaixo podemos ver as matrizes da rede VGG19, Figura (8), para os otimizadores SGD e RMSprop.

É possível observar que, em ambos os otimizadores, as diagonais principais apresentam números mais altos, isso indica que a rede acertou bastante, tendo em vista que estas diagonais representam as predições corretas feita pela rede. Apesar das matrizes apresentarem resultados

muito próximos, podemos notar que para o otimizador SGD a rede apresentou um número maior de predições.

Figura 8 – Matriz de confusão para a rede VGG19

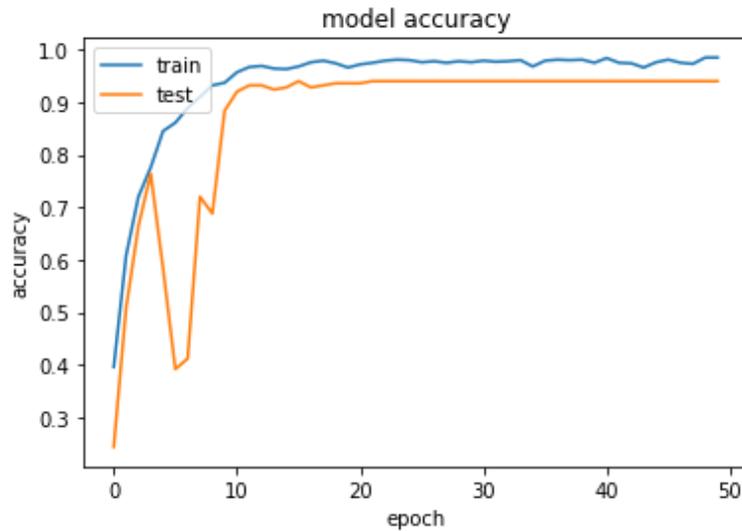


Fonte: A Autora (2021).

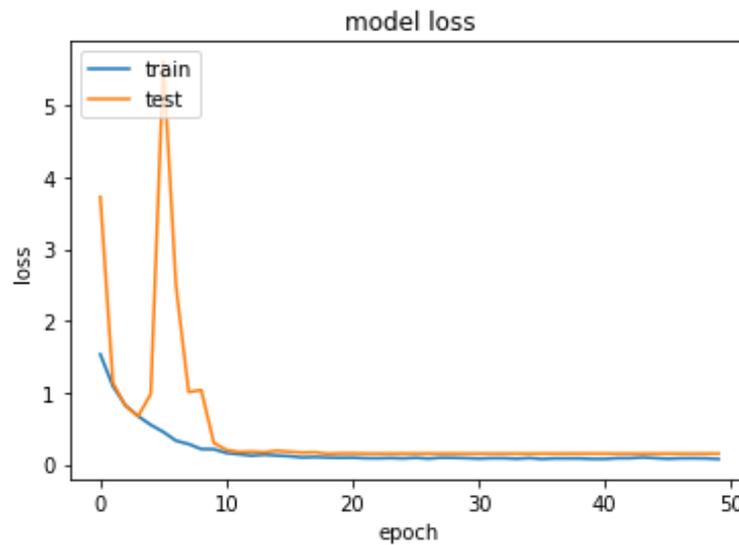
Diante do exposto, conclui-se, a rede que apresentou maior desempenho foi a VGG19 e a rede treinada com o otimizador SGD conseguiu resolver de maneira mais eficiente a classificação, sendo a escolha do otimizador crucial para resolver um problema de classificação de imagens. Abaixo pode ser visto os gráficos obtidos com as métricas da rede que apresentou maior desempenho dentre as treinadas.

Gráfico 7 – Métricas da rede VGG19 com otimizador SGD.

(a) Acurácia



(a) Loss



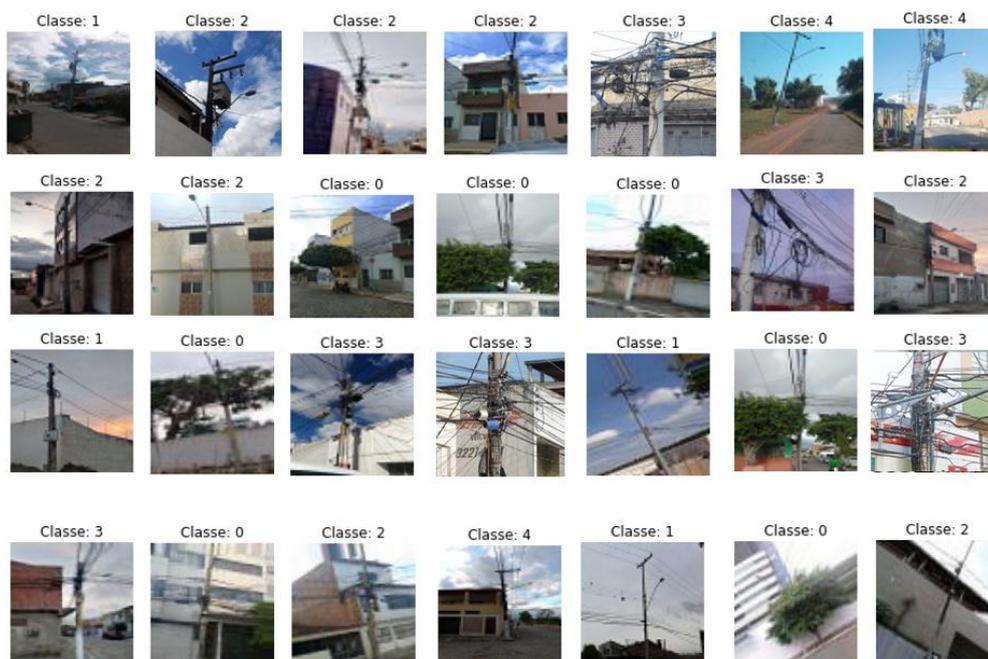
Fonte: A Autora (2021).

4.2 PRIORIZAÇÃO DAS OCORRÊNCIAS

Ao se obter as imagens classificadas pela CNN de acordo com os riscos, as ações de manutenção podem seguir a priorização das ocorrências a partir da matriz de risco, como proposto na metodologia deste trabalho. Dessa forma, para compreender o modelo proposto, analisaremos uma situação hipotética, em que são recebidos imagens de possíveis riscos, essas imagens foram registradas pela autora, e foram classificadas de acordo com o risco de

interrupção do serviço, Fotografia (2), onde 0: representa a classe contato com árvores, 1: postes normais, ou seja, que não representam riscos, 2: postes próximos a residências, 3: postes sobrecarregados e 4: postes inclinados.

Fotografia 2 – Riscos obtidos através da classificação de imagens



Fonte: A Autora (2021).

Foi feito uma análise para cada tipo de classe, tendo em vista que as equipes de manutenção são divididas de acordo com o serviço de manutenção a ser realizado, dessa forma, há uma equipe especializada em cada classe de risco abordada. O número de equipes de manutenção por classe varia de acordo com a quantidade de ocorrência dos riscos. Dessa forma, foi proposto juntamente com a equipe da empresa que a matriz de risco de cada classe seria elaborada em função da localização do risco, considerando o deslocamento da equipe de um ponto a outro e os impactos que o mesmo pode causar dependendo da localização em que se encontra, interferindo no aumento dos cliente hora interrompidos, no aumento de acidentes envolvendo terceiros e satisfação dos consumidores. Assim, os riscos foram separados por áreas (que serão informadas no momento do envio das imagens através do aplicativo), sendo: Zona Urbana, Zona Rural e Zona Industrial.

Ao ser recebidos os riscos classificados de acordo com sua classe de risco, pode ser utilizada a matriz de risco a fim de identificar a priorização desses riscos. Levando em consideração essas informações é definido os níveis dos riscos das imagens classificadas, de

acordo com os critérios de probabilidade e impacto dos Quadros (1) e (2), citados anteriormente:

Quadro 7 – Nível dos riscos para a classe Contato com Árvores

RISCO	PROBABILIDADE	IMPACTO	NÍVEL
Contato com Árvores em Zona Urbana	80%	Alto	Extremo
Contato com Árvores em Zona Rural	55%	Alto	Elevado
Contato com Árvores em Zona Industrial	30%	Moderado	Elevado

Fonte: A Autora (2021).

De acordo com a Fotografia (2), sete imagens foram classificadas como contato com árvores, dessa forma, considerando-se que quatro dessas imagens estão localizadas em zona urbana, duas em zona rural e uma em zona industrial e analisando a matriz de risco para a classe árvores, como mostra o Quadro (7), o contato com árvores em zona urbana apresenta níveis de risco extremo, enquanto para as zonas rural e industrial o nível de risco é elevado. Dessa forma as imagens que foram classificadas como risco extremo devem receber atenção imediata e devem ser direcionadas equipes aos locais. Já os outros riscos identificados devem ser incluídos nas programações de manutenção da equipe. Principalmente ao se iniciar a estação das chuvas, deve ser priorizado ações de manutenção relacionadas a causas por árvores, compreendendo o corte ou poda de árvore que, pelo seu porte ou pela ação de agentes externos, tais como ventos, erosão, etc., possam atingir a estrutura e/ou cabos e interferir na operação da rede de distribuição de energia. Reitera-se que a aplicação das atividades que requeiram poda e/ou corte de árvores deve obedecer a todas as orientações dos órgãos ambientais competentes. Locais com alto índice de vegetação podem requerer maior frequência de limpezas de faixa ou podas, ou mesmo, em casos extremos, o emprego de outras tecnologias de rede (rede compacta).

Quadro 8 – Nível dos riscos para a classe Postes Inclinados

RISCO	PROBABILIDADE	IMPACTO	NÍVEL
Postes Inclinados em Zona Urbana	55%	Severo	Extremo
Postes Inclinados em Zona Rural	25%	Moderado	Baixo
Postes Inclinados em Zona Industrial	30%	Alto	Elevado

Fonte: A Autora (2021).

Na Fotografia (2) foram identificadas três imagens indicando postes inclinados, considerando-se dois em zona urbana e um em zona industrial, são encontrados riscos de nível extremo e elevado, de acordo com o Quadro (8). Para os riscos de nível extremo, medidas devem ser tomadas de imediato, pois o risco apresenta urgência. E para o nível de risco elevado, é sugerido que seja incluído em metas e programações de manutenção.

Quadro 9 - Nível dos riscos para a classe Postes próximos a Residências

RISCO	PROBABILIDADE	IMPACTO	NÍVEL
Postes Próximos a Residências em Zona Urbana	65%	Alto	Elevado
Postes Próximos a Residências em Zona Rural	45%	Moderado	Moderado
Postes Próximos a Residências em Zona Industrial	10%	Moderado	Baixo

Fonte: A Autora (2021).

Também foram identificadas oito imagens que foram classificadas como postes próximos a residências, e considerando-se cinco em zona urbana e três em zona rural temos os níveis de risco elevado e moderado, respectivamente, como observado no Quadro (9). Dessa forma, como representam riscos que não demandam urgência podem ser incluídos nas programações de manutenção e monitorados para que não evoluam para falhas na rede.

As ações de manutenção ligadas a postes inclinados e próximos a residências, dependem da probabilidade de ocorrência dos eventos e a ocorrência das falhas provém de fatores externos, como falhas operacionais, objetos na rede, colisões em postes, etc., em alguns casos podem levar a um número maior de consumidores hora interrompidos, devendo ser realizado o reparo ou troca dos postes no local, para riscos com postes inclinados, e a ação pertinente ao risco relacionado com postes próximos a residências.

Quadro 10 - Nível dos riscos para a classe Postes Sobrecarregados

RISCO	PROBABILIDADE	IMPACTO	NÍVEL
Postes			
Sobrecarregados em Zona Urbana	60%	Alto	Elevado
Postes			
Sobrecarregados em Zona Rural	20%	Baixo	Baixo
Postes			
Sobrecarregados em Zona Industrial	20%	Moderado	Baixo

Fonte: A Autora (2021).

E, por fim, seis imagens foram classificadas como postes sobrecarregados, considerando-se três em zonas urbanas, um em zona rural e dois em zona industrial, temos os níveis de risco elevado, baixo e baixo, Quadro (10). Assim, como já dito para as outras classes, os níveis de risco elevado devem ser incluídos nas programações de manutenção, não necessitando de uma ação imediata tendo em vista que embora importantes não apresentam urgência. E os riscos de nível baixo podem ser gerenciados através de procedimentos de rotina no local.

As ações relacionadas a postes sobrecarregados consistem na identificação e retirada de cabos inativos e equipamentos instalados à revelia da concessionária, além da coordenação e monitoramento das ações de regularização das situações de desorganização do cabeamento, com emaranhados de fios, exposição de riscos de acidentes e poluição visual, além de providenciar o aprumo ou a substituição de postes, se necessário.

Portanto, a partir da matriz de risco podem ser geradas notas de inspeção e manutenção dos riscos identificados através de algoritmos de visão computacional, a fim de mitigar causas não permanentes e execução de outros serviços pertinentes. Além de auxiliar a equipe na

tomada de decisões, realizações de medidas básicas, práticas e de baixo custo, sobretudo, de forma rápida, identificando padrões e encontrando respostas para problemas complexos com pouca interferência humana. E assim, teremos a otimização dos recursos que serão direcionados à execução de serviço para os riscos prioritários, o que conseqüentemente trará uma redução dos indicadores de continuidade e menor custo atrelados à eliminação ou manutenção do risco.

4.3 DISCUSSÕES GERENCIAIS

Um programa de manutenção eficaz é fundamental em qualquer área, de forma a atuar evitando falhas e considerando as limitações dos recursos disponíveis (equipes, materiais e equipamentos). As empresas de energia elétrica podem se beneficiar do uso de métodos de descoberta de conhecimento e aprendizado de máquina para manutenção preventiva.

O bom funcionamento e manutenção dos equipamentos da rede de distribuição é indispensável para garantir a saúde dos ativos da rede de distribuição e realizar a operação de forma confiável. Está relacionado ao consumo contínuo e confiável de energia dos usuários e à operação segura e confiável da rede elétrica (WANG, YANG, *et al.*, 2019).

Zhang *et al.* (2018) cita que atualmente os estudos de linhas de distribuição encontram-se em defasagem e que métodos automáticos são extremamente necessários para inspeção em linhas de distribuição. Uma pesquisa de 2007 do NERC (*North American Electric Reliability Corporation*) afirma que a “infraestrutura obsoleta e novas construções limitadas” é o maior desafio para a confiabilidade da rede elétrica de todos os desafios considerados pela pesquisa (RUDIN *et al.*, 2012). Sendo assim, a confiabilidade será uma questão fundamental à medida que as redes elétricas se transformam ao longo dos próximos anos, e a manutenção da rede se tornará ainda mais crítica do que é atualmente.

A manutenção inteligente utiliza inspeções inteligentes com base em tecnologias de análise de *big data*, dispositivos inteligentes para coletar os dados, serviços inteligentes, gerenciamento de ativos e outras técnicas para tomar decisões de manutenção preventiva. Dessa forma, a rede inteligente tornará as operações e a manutenção mais online, movendo a indústria de operações reativas para proativas.

Os benefícios associados à utilização desses sistemas são vários, como a redução dos custos de operação e manutenção, calendarização de ações de manutenção com informações precisas e utilizáveis a nível de planejamento e manutenção, detecção mais rápida de defeitos e falhas, além de apresentar melhorias na qualidade do serviço prestado.

Assim, ao se utilizar a metodologia proposta nesse trabalho, a equipe de manutenção pode identificar antecipadamente casos que devem ser solucionados, tendo a oportunidade de gerir como e qual caso exige rapidez e, assim, direcionar a equipe de manutenção para esses casos antes que a falha ocorra. Contribuindo, dessa forma, para uma melhor utilização de tempo, equipe e disponibilidades do sistema. Além disso, apresenta um baixo custo, uma vez que a empresa receberia todos os dados da própria população e os algoritmos podem ser replicados em várias localizações.

Dessa forma, fica evidente a importância do uso de inteligência artificial, visão computacional, entre outras abordagens, no setor elétrico e em grandes setores da economia como saúde, indústria, educação, tendo em vista que essas soluções trazem ganhos efetivos de eficiência, reduzem custos e, se somadas a uma série de outros esforços em termos de investimentos em processos, são capazes de resolverem problemas complexos e permite a automatização de tomada de decisões.

5 CONCLUSÕES

Esta seção encerra a dissertação, apresentando conclusões sobre os resultados encontrados, assim como limitações e sugestões para trabalhos futuros.

5.1 CONSIDERAÇÕES FINAIS

As concessionárias de energia utilizam planos de manutenção para evitar a ocorrência de falhas nas redes de distribuição, porém algumas questões fogem do padrão e o gerenciamento de falhas em sistemas de energia é um dos principais desafios enfrentados pelas concessionárias de energia elétrica à medida que se esforçam para garantir maior eficiência e confiabilidade. Este trabalho apresentou um processo de identificação de riscos que potencialmente prejudicariam a rede de distribuição de energia através do processamento de imagens e utilização de algoritmos de visão computacional.

Para isso foram utilizadas redes neurais convolucionais para realizar o treinamento das imagens da rede de distribuição, e a fim de identificar qual rede apresenta o melhor treinamento foi feita uma análise comparativa entre cinco redes pré-treinadas e também foram explorados três otimizadores, com o objetivo de se extrair o melhor aproveitamento de treinamento para as CNNs estudadas. Ao realizar uma análise comparativa, verificou-se que as redes GoogLeNet e VGG19 alcançaram resultados muito próximos. Comparando as métricas entre as duas melhores redes, a VGG19 treinada com o otimizador SGD apresentou as melhores métricas, atingindo uma acurácia de 0,94% e valores de perda de 0,15, sendo, portanto, a rede escolhida.

Após a classificação das imagens e identificação dos riscos, foi aplicado uma ferramenta de análise de risco denominada Matriz de Risco, e com o uso desta ferramenta foi possível quantificar e conseqüentemente priorizar, dentro dos riscos identificados, quais necessitam de ações de intervenção urgentes, ajudando a reduzir a reincidência de falhas, uma vez que pode ser melhor visualizadas as classes mais vulneráveis, gerando uma maior transparência ao informar os riscos de maior urgência e melhorando assim os padrões de gerenciamento.

Apesar da manutenção não está diretamente ligada a composição dos riscos, já que vários outros fatores externos podem interferir, como efeitos sazonais ou eventos climáticos, picos de tensão, acidentes, etc., a realização de atividades de manutenção auxilia significativamente na eliminação de falhas na rede.

Portanto, este trabalho contribui para demonstrar a potencialidade de pesquisa presente no campo da área de visão computacional para a identificação e classificação de riscos em

diversos setores da gestão da manutenção, otimizando recursos de forma a identificar com mais rapidez questões de manutenção, e, nesse caso, assegurando um fornecimento de energia ininterrupto a seus clientes.

5.2 LIMITAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Como limitações desse trabalho destaca-se:

- Ausência de imagens para gerar um banco de dados mais robusto permitindo um maior aprendizado de treinamento das redes neurais com dados variados;
- A falta de dados para avaliar o impacto econômico das interrupções do serviço e custos da manutenção.

Algumas sugestões para trabalhos futuros são:

- Aumentar o conjunto de dados a fim de proporcionar uma maior aprendizagem à rede treinada e ampliar as aplicações da visão computacional;
- Testar outras estratégias de aumento de dados, considerar a otimização de mais hiperparâmetros e outros algoritmos de otimização;
- Identificar riscos sobrepostos nas imagens;
- Identificar outras classes de riscos que podem interferir na interrupção do fornecimento de energia;
- Repensar como tratar as prioridades de riscos urgentes em zonas afastadas ou de difícil acesso;
- Desenvolver uma ferramenta computacional SAD (Sistema de Apoio à Decisão) para gerir informações e fornecer conhecimento para o processo de tomada de decisão, proporcionando mais dinamismo ao modelo para auxiliar o planejamento e acompanhamento das ações de manutenção;
- Desenvolver um aplicativo móvel que possa ser utilizado pelos consumidores do serviço, para que assim, os mesmos possam enviar suas imagens de possíveis riscos de interrupção na rede de distribuição.

REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **ISO 31000 - Gestão de Riscos - Princípios e Diretrizes**, p.32, 2009.

ABNT – Associação Brasileira de Normas Técnicas. **Redes de distribuição aérea de energia elétrica com condutores nus**, 2012.

ABRACOPEL – Associação Brasileira de Conscientização para os Perigos da Eletricidade. **Anuário Estatístico de Acidentes de Origem Elétrica**, São Paulo. Disponível em: <<https://www.crea-al.org.br/2021/04/anuario-estatistico-da-abracopel-mostra-recuo-em-acidentes-eletricos/#:~:text=A%20Associa%C3%A7%C3%A3o%20Brasileira%20de%20Conscientiza%C3%A7%C3%A3o,segmentados%20em%20diversos%20temas%20como>>. Acesso em: 16/10/2021.

ANEEL – Agência Nacional de Energia Elétrica. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST Módulo 8 – Qualidade da Energia Elétrica**. Disponível em: <https://www2.aneel.gov.br/cedoc/aren2021956_prodist_modulo_8_v13.pdf>. Acesso em: 15/09/2021.

ANEEL – Agência Nacional de Energia Elétrica. **Qualidade na distribuição**. <<https://www.aneel.gov.br/qualidade-na-distribuicao>>. Acesso em 06/12/2021.

ARMENDARIZ, M., BABAZADEH, D., NORDSTRÖM, L., & BARCHIESI, M. A method to place meters in active low voltage distribution networks using BPSO algorithm. **Paper presented at the Power Systems Computation Conference (PSCC)**, Genoa, Italy, 2016.

ALDABÓ, R. **Qualidade na Energia Elétrica**. São Paulo: Artliber, 252 p., 2001.

BARROS, André Felipe Antunes. **Análise das Principais Causas de Descontinuidade no Fornecimento de Energia elétrica e de seus Impactos nos Indicadores de Qualidade**. Rio de Janeiro: UFRJ/ Escola Politécnica, 2020. Projeto de Graduação – UFRJ/ Escola Politécnica/ Curso de Engenharia Elétrica, 2020.

BASU, S. Basics of hazard, risk ranking, and safety systems. **Plant Hazard Analysis and Safety Instrumentation Systems**, p. 1-81, 2017.

BROWN, Richard E. **Electric Power Distribution Reliability**. Second Edition. **New York: Taylor & Francis Group**, 2009.

CHA, Y. J., CHOI, W. et al. Autonomous Structural Visual Inspection Using Region-Based Deep Learning for Detecting Multiple Damage Types. **Special Issue: Health Monitoring of Structures**, volume 33, Issue 9, p. 731-747, 2018.

CHUNJING, Y., YUEYAO, Z., YAXUAN, Z. and LIU, H. Application of convolutional neural network in classification of high resolution agricultural remote sensing images. **The International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences**, pp. 18-22, September 2017.

CHOLLET, F. Deep learning with python. [S.l.]: **Manning Publications Co.**, 2017.

DAVIS, W.P. Analysis of faults in overhead transmission lines. **Project (M.S., Electrical and Electronic Engineering)** - California State University, Sacramento, 2013.

DOE, U. Enabling modernization of the electric power system. **Quadrennial Technology Review**, 22, p. 54-59, 2015.

GOVERNO DE PERNAMBUCO. **Estratégia de Desenvolvimento e Carteira de Projetos Públicos de Pernambuco**. Disponível em: <<https://www.seplag.pe.gov.br/pe-2035>>. Acesso em: 20/06/2021.

FARABET, C., COUPRIE, C., NAJMAN, L. & LECUN, Y. Learning hierarchical features for scene labeling. **IEEE Trans. Pattern Anal. Mach. Intell.** 35, 1915–1929, 2013.

FERNANDES, L. **Ferramenta de Apoio à Decisão para Priorização de Obras de Manutenção em Redes de Distribuição de Energia Elétrica**. Dissertação-Mestrado. Universidade Federal do Rio Grande do Sul. Escola de Engenharia. Programa de Pós-Graduação em Engenharia de Produção, 2014.

FREIRE, P., 1921 – 1997. **Política e educação: ensaios/ Paulo Freire**. – 5. Ed. – São Paulo, (Coleção Questões de Nossa Época; v.23) Cortez, 2001.

GHARAKHEILI, M. A., FOTUHI-FIRUZABAD, M. & DEGHANIAN, P. A New Multiattribute Decision Making Support Tool for Identifying Critical Components in Power Transmission Systems, **in IEEE Systems Journal**, vol. 12, no. 1, pp. 316-327, March 2018.

GONZALEZ, R., & WOODS, R. **Digital Image Processing**. Pearson, 3 edition, 2007.

GOODFELLOW et al. Deep Convolutional Networks. **Deep Learning**, cap. 9, 2016.

HAYKIN, S. S.; HAYKIN, S. S.; HAYKIN, S. S.; HAYKIN, S. S. Neural networks and learning machines. [S.l.]: **Pearson Upper Saddle River**, NJ, USA: v. 3, 2009.

HE, K., ZHANG, X., REN, S., *et al.* Deep residual learning for image recognition. **In: Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, Las Vegas, NV, 27–30, pp.770–778, June 2016.

HELMSTAEDTER, M., *et al.* Connectomic reconstruction of the inner plexiform layer in the mouse retina. *Nature* **500**, 168–174, 2013.

HINTON, G. *et al.* Deep neural networks for acoustic modeling in speech recognition. **IEEE Signal Processing Magazine**, vol 29, p. 82–97, 2012.

HINTON, G., SRIVASTAVA, N., & SWERSKY, K. Neuralnetworks for machine learning lecture 6a overview of mini-batch gradient descent. **Cited on**, volume 14, Issue 8, 2012.

KAMILARIS, A., PRENAFETA-BOLDÚ, F.X., 2018. Deep Learning in Agriculture: A Survey. **Comput. Electron. Agric.** 147, p. 70–90, 2018.

KAVITHA, D., HEBBAR, R., VINOD, P. *et al.* CNN based technique for systematic classification of field photographs. **Proceedings - 2018 International Conference on Design Innovations for 3Cs Compute Communicate Control, ICDI3C 2018**, p. 59-63, 2018.

KINGMA, D. P., BA, J. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.

KRIZHEVSKY, A., SUTSKEVER, I., & HINTON, G., E. ImageNet classification with deep convolutional neural networks. **Commun ACM** **2017**; 60: 84–90.

LECUN, Y., BENGIO, Y. & HINTON, G. Deep learning. *Nature* **521**, 436–444, 2015.

LECUN, Y., BOTTOU, L., BENGIO, Y., HAFFNER, P. Gradient-Based Learning Applied to Document Recognition. **PROC. OF THE IEEE**, 1998.

LECUN, Y., KAVUKCUOGLU, K., & FARABET, C. Convolutional networks and applications in vision. **Proceedings of 2010 IEEE International Symposium on Circuits and Systems**, pp. 253-256, 2010.

LEUNG, MK, XIONG, HY, LEE, LJ & FREY, BJ. Deep learning of the tissue-regulated splicing code. *Bioinformatics*, vol 30, i121–i129, 2014.

LIAO, Y., HUI, B. e WEI, Y. Risk Assessment of High-voltage Cable System Based on Cable Failure Probability and Failure loss. **IEEE 3rd International Conference on Automation, Electronics and Electrical Engineering (AUTEEE)**, pp. 143-146, 2020.

LIMA, H. G. F., COSTA, R. M. *et al.* Reconhecimento de árvores usando visão computacional para prevenir interrupções no sistema de distribuição de energia elétrica. **XI Brazilian Symposium on Information System**, Goiania, GO, May 26-29, 2015.

LUEJAI, W.; SUWANASRI, T.; SUWANASRI, C. D-distance Risk Factor for Transmission Line Maintenance Management and Cost Analysis. **Sustainability**, 13, 8208, 2021.

MA, J., SHERIDAN, R. P., LIAW, A., DAHL, G. E. & SVETNIK, V. Deep neural nets as a method for quantitative structure-activity relationships. **J. Chem. Inf. Model.** **55**, 263–274, 2015.

MIKOLOV, T., DEORAS, A., POVEY, D., BURGET, L. & CERNOCKY, J. Strategies for training large scale neural network language models. **In Proc. Automatic Speech Recognition and Understanding**, 196–201, 2011.

MNYANGHWALO, D., KAWAMBWA, S. *et al.* Fault Detection and Monitoring in Secondary Electric Distribution Network Based on Distributed Processing. **2018 20th International Middle East Power Systems Conference, MEPCON 2018 – Proceedings**, p. 84-89, 2019.

MNYANGHWALO, D., KUNDAELI, H. *et al.* Deep learning approaches for fault detection and classifications in the electrical secondary distribution network: Methods comparison and recurrent neural network accuracy comparison. **Cogent Engineering**, volume 7, Issue 1, 2020.

MARTIN, F. e AGUADO, J.A. Wavelet-based ANN approach for transmission line protection. **IEEE Transactions on Power Delivery**, volume 18, Issue. 4, pp. 1572-1574, 2003.

MOTLAGH, N. H., MOHAMMADREZAEI, M., HUNT, J., *et al.* Internet of Things (IoT) and the energy sector. **Energies** **13**, Issue 2: 494, 2020.

OPRISAN, M., FILIPPELLI, F., CLARK, I. M., BILLINTON, R. A reliability data system for the reporting of forced outages of distribution equipment. **[Proceedings] WESCANEX '91**, pp. 267-270, 1991.

PALFI, J. Localization of Faults in Low Voltage Networks by Graph Method. **IEEE Int. Symp. Appl. Comput. Intell. Informática**, volume 11, pp. 397-400, 2016.

PATEL, A. R. *et al.* **Artificial Intelligence: Prospect in Mechanical Engineering Field—A Review**. [s.l.] Springer Singapore, vol. 52, 2021.

Relatório de Avaliação de Resultado Regulatório nº 0001/2019-SRD/ANEEL. **Superintendência de Regulação dos Serviços de Distribuição – SRD**, Versão Pré-Participação Pública - Brasília, 2019.

RUDIN, C. *et al.*, Machine Learning for the New York City Power Grid. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, volume 34, Issue 2, pp. 328-345, 2012.

ROCHA, J. F. **Priorização da manutenção em redes de distribuição aéreas com premissas de melhoria dos indicadores de continuidade e da sustentabilidade econômico-financeira.** Dissertação (Mestrado) – Instituto de Tecnologia para o Desenvolvimento, Institutos Lactec – Programa de Pós-Graduação em Desenvolvimento de Tecnologia, 2018.

ROY, N. & BHATTACHARYA, K. Detection, Classification, and Estimation of Fault Location on an Overhead Transmission Line Using S-transform and Neural Network. **Electric Power Components and Systems**, Volume 43, Issue 4, 461-472, 2015.

RUDER, S. An overview of gradient descent optimization algorithms. **arXiv preprint arXiv:1609.04747**, 2016.

SAMIR, S., EMARY, E., EL-SAYED, K., ONSI, H. Optimization of a pre-trained AlexNet model for detecting and localizing image forgeries. **Information (Switzerland)**, Volume 11, Issue 5, 2020.

SERMANET, P., FROME, A., REAL, E. Attention for Fine-Grained Categorization. **Computer Vision and Pattern Recognition ICLR**, Workshop, 2014.

SOWAH, R.A., *et al.* Design of Power Distribution Network Fault Data Collector for Fault Detection, Location and Classification using Machine Learning. **IEEE 7th International Conference on Adaptive Science & Technology (ICAST)**, pp. 1-8, 2018.

SIMONYAN, K., ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **In: 3rd International Conference on Learning Representations, (ICLR) - Conference Track Proceedings**, San Diego, CA, 7–9 May 2015, pp.1–14, 2015.

SUN, L., XING, J. C., WANG, Z. *et al.* Virtual reality of recognition technologies of the improved contour coding image based on level set and neural network models. **Neural Computing and Applications**, volume 29, Issue 5, p. 1311-1330, 2018.

SONG, Y., WANG, H., ZHANG, J. A vision-based broken strand detection method for a power-line maintenance robot. **IEEE Transactions on Power Delivery**, volume 29, Issue 5, p. 2154-2161, 2014.

SUTSKEVER, I., MARTENS, J., DAHL, G., & HINTON, G. On the importance of initialization and momentum in deep learning. **In International conference on machine learning**, pp. 1139-1147, 2013.

TAN, S., & TAN, Z. Improved LeNet-5 Model Based On Handwritten Numeral Recognition. **Chinese Control And Decision Conference (CCDC)**, pp. 6396-6399, 2019.

TAQI, A. M., AWAD, A., AL-AZZO, F. e MILANOVA, M. The impact of multi-optimizers and data augmentation on TensorFlow convolutional neural network performance. **In IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)**, pp. 140-145, 2018.

TOMPSON, J., JAIN, A., LECUN, Y. & BREGLER, C. Joint training of a convolutional network and a graphical model for human pose estimation. **In Proc. Advances in Neural Information Processing Systems**, vol. 27, 1799–1807, 2014.

VENKATESH, S. N., & SUGUMARAN, V. A combined approach of convolutional neural networks and machine learning for visual fault classification in photovoltaic modules. **Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability**, 2021.

WANG, L., YANG, F., WANG, Z., WANG, Y., ZENG, X., WANG, M. State-evaluation & Risk-assessment based Maintenance Resource Allocation Method for Distribution Networks. **IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)**, pp. 1930-1935, 2019.

WANG, M., CHENG, J.C.P. A unified convolutional neural network integrated with conditional random field for pipe defect segmentation. **Computer-Aided Civil and Infrastructure Engineering**, volume 35, Issue 2, p. 162-177, 2020.

XU, W., TAO, C., YUJIE, W., QINRUI, G., YANGXIN, T. Risk Assessment of Power Information Risk Security Based on Risk Matrix. **IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)**, pp. 1494-1498, 2018.

XIAOSONG, L., SHUSHI, L., WENJUN, C., SONGJIANG, F. The Application of Risk Matrix to Software Project Risk Management. **International Forum on Information Technology and Applications**, pp. 480-483, 2009.

XI, P., FEILAI, P., YONGCHAO, L., ZHIPING, L. e Long, L. Fault Detection Algorithm for Power Distribution Network Based on Sparse Self-Encoding Neural Network. **International Conference on Smart Grid and Electrical Automation (ICSGEA)**, pp. 9-12, 2017.

ZEILER, M. D., FERGUS, R. Visualizing and Understanding Convolutional Networks. **In: Fleet D., Pajdla T., Schiele B., Tuytelaars T. (eds) Computer Vision – ECCV**. Lecture Notes in Computer Science, vol. 8689. Springer, Cham, 2014.

ZHANG, D., HAN, J., SONG, J., YUAN, L. A risk assessment approach based on fuzzy 3D risk matrix for network device. **2nd IEEE International Conference on Computer and Communications (ICCC)**, pp. 1106-1110, 2016.

ZHANG, X., XU, W., LI, J., WANG, H., SUN, Y. An automatic acquisition algorithm for power distribution line based on vehicle-mounted system. **Tenth International Conference on Digital Image Processing (ICDIP 2018)**, Shanghai, China, 2018.

ZIDAN, A. et al. Fault Detection Isolation and Service Restoration in Distribution Systems: State-of-the-Art and Future Trends. **IEEE Trans. Smart Grid**, Volume 8, Issue 5, pp. 2170-2185, 2017.