



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
UNIDADE ACADÊMICA DO CABO DE SANTO AGOSTINHO
BACHARELADO EM ENGENHARIA ELÉTRICA

ISADORA RODRIGUES DE MELO

**Aplicação de Aprendizado de Máquinas na Detecção de Anomalias em
Componentes de Linhas de Transmissão**

Cabo de Santo Agostinho – PE

2025

ISADORA RODRIGUES DE MELO

**Aplicação de Aprendizado de Máquinas na Detecção de Anomalias em
Componentes de Linhas de Transmissão**

Monografia apresentada ao Curso de Graduação em Engenharia Elétrica da Unidade Acadêmica do Cabo de Santo Agostinho da Universidade Federal Rural de Pernambuco para obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Prof. Felipe Alberti Barbosa Simão Ferreira.

Cabo de Santo Agostinho – PE

2025

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema Integrado de Bibliotecas da UFRPE
Biblioteca da UACSA, Cabo de Santo Agostinho - PE, Brasil.
Bibliotecária – Rosimeri Gomes Couto – CRB-4/1395

M528a Melo, Isadora Rodrigues de.
Aplicação de aprendizado de máquinas de detecção de anomalias em componentes de linhas de transmissão. / Isadora Rodrigues de Melo. – Cabo de Santo Agostinho, 2025.
58 f. : il.

Orientador: Felipe Alberti Barbosa Simão Ferreira.
Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal Rural de Pernambuco. Unidade Acadêmica do Cabo de Santo Agostinho, 2025.
Inclui referência.

1. Sistemas Elétricos de Potência. 2. YOLOv5. 3. Linhas Elétricas Aeréas. 4. Detecção de Anomalias. 5. ResNet I. Ferreira, Felipe Alberti Barbosa Simão, orient. II. Título.

CDD 621.3

ISADORA RODRIGUES DE MELO

Aplicação de Aprendizado de Máquinas na Classificação e Detecção de Anomalias em Componentes de Linhas de Transmissão

Monografia apresentada ao Curso de Graduação em Engenharia Elétrica da Unidade Acadêmica do Cabo de Santo Agostinho da Universidade Federal Rural de Pernambuco para obtenção do título de Bacharel em Engenharia Elétrica.

Aprovado em: 21 de março de 2025.

Banca Examinadora

Prof. Dr. Felipe Alberto Barbosa Simão Ferreira
Universidade Federal Rural de Pernambuco, UFRPE

Prof. Dr. Fernando Goncalves de Almeida Neto
Universidade Federal Rural de Pernambuco, UFRPE

Prof. Dr. Joao Marcus Pereira Lima e Silva
Universidade Federal Rural de Pernambuco, UFRPE

AGRADECIMENTOS

Agradeço, em primeiro lugar, à minha mãe, Claudicia Arôxa, por ser minha maior inspiração. Mulher forte, batalhadora, que nunca deixou de estar presente, de me apoiar e de garantir que eu tivesse as oportunidades que ela talvez não teve. Tudo o que conquistei tem um pedaço dela, porque sem seu amor, apoio e ensinamentos, eu não teria chegado até aqui. Mãe, eu te amo, e essa conquista também é sua.

Agradeço também ao meu pai, por sempre acreditar em mim.

Ao meu noivo, Heitor Santiago, por estar ao meu lado em todos os momentos, acreditar nos meus sonhos e me apoiar incondicionalmente, assim como toda a sua família, que esteve presente durante essa jornada.

Minha profunda gratidão à minha tia Claudete e toda minha família, por me incentivar a nunca desistir e persistir na caminhada.

À minha fiel companheira, minha yorkshire Tiana Maria, que esteve ao meu lado todos os dias durante a escrita deste TCC, me fazendo companhia e tornando esse processo mais leve. Te amo para sempre.

Aos meus amigos de faculdade, que estiveram comigo nos momentos difíceis e compartilharam essa caminhada, em especial Valdomiro Ferreira e Guilherme Alves.

Ao meu orientador, Felipe Alberto Barbosa Simão Ferreira, por sua paciência e valioso direcionamento ao longo do curso e durante a elaboração deste trabalho.

E, acima de tudo, agradeço a Deus, cuja força sustenta meu caminho e cujas bênçãos são constantes em minha vida. Sou grata por essa conquista e por todas as pessoas que Ele colocou ao meu lado para iluminar minha jornada.

RESUMO

O avanço da tecnologia ao longo dos anos mudou bastante o Sistema Elétrico de Potência (SEP) e a indústria, melhorando a segurança na entrega de energia para todos. A inspeção de linhas de transmissão é um processo essencial que garante o funcionamento do sistema elétrico, mas apresenta desafios. Tradicionalmente, as inspeções são realizadas por equipes que se deslocam até locais de difícil acesso, que envolve altos riscos e custos financeiros. Com os novos recursos de inteligência artificial, usar aprendizado de máquina tem se mostrado uma solução viável para otimizar o processo na identificação de problemas estruturais nas linhas de transmissão. Neste projeto, foi desenvolvido um sistema baseado em aprendizado de máquina para detectar e analisar equipamentos nas linhas de transmissão. O sistema usa o modelo YOLOv5 para encontrar as peças e identificar onde elas estão na imagem. Em seguida, a rede neural convolucional ResNet, que permite uma análise eficiente das imagens, classifica cada peça identificada, determinando se existe avaria ou não. Os componentes da linha de transmissão sem avaria possuem uma caixa delimitadora da cor verde, e as com avarias da cor vermelha. Nos testes feitos, o sistema acertou 90,6% das vezes ao encontrar as peças e 81% ao dizer se tinham defeito. No entanto foi constatado alguns desafios, como a falta de certas amostras do próprio banco de dados, o que pode impactar o desempenho do modelo para determinados componentes. Assim, obter um conjunto de dados com mais imagens e robusto é fundamental para melhorar a eficácia do sistema. Este trabalho ajuda na modernização da manutenção das linhas de transmissão usando técnicas avançadas de aprendizado de máquina. Quando usado junto com sistemas de monitoramento remoto, pode diminuir gastos e riscos das inspeções feitas por pessoas. Além disso, permite a identificação de problemas previamente, tornando o sistema elétrico mais confiável e eficiente.

Palavras-chave: aprendizado de máquina, detecção de anomalias, linhas de transmissão, ResNet, YOLOv5.

ABSTRACT

The advancement of technology over the years has significantly transformed the Power System (SEP) and the industry, enhancing the safety and reliability of energy delivery for everyone. Transmission line inspection is a crucial process that ensures the proper functioning of the electrical system, but it presents several challenges. Traditionally, inspections are carried out by teams traveling to hard-to-reach locations, which involves high risks and financial costs. With the latest advancements in artificial intelligence, machine learning has proven to be a viable solution for optimizing the process of identifying structural issues in transmission lines. In this project, a machine learning-based system was developed to detect and analyze equipment in transmission lines. The system utilizes the YOLOv5 model to locate and identify components within images. Then, a convolutional neural network, ResNet, performs an efficient analysis of the images, classifying each identified component and determining whether it is damaged or not. Transmission line components without defects are highlighted with a green bounding box, while those with defects are marked in red. During testing, the system achieved 90.6% accuracy in detecting components and 81% accuracy in identifying defective parts. However, some challenges were identified, such as the lack of specific samples in the dataset, which could impact the model's performance for certain components. Therefore, acquiring a more extensive and robust dataset is essential to improve the system's effectiveness. This work contributes to the modernization of transmission line maintenance using advanced machine learning techniques. When combined with remote monitoring systems, it can reduce costs and risks associated with human inspections. Additionally, it enables the early identification of issues, making the power system more reliable and efficient.

Keywords: machine learning, anomaly detection, transmission lines, ResNet, YOLOv5.

LISTA DE FIGURAS

Figura 1: Sistema Interligado Nacional (SIN).....	17
Figura 2: Sistema Elétrico de Potência (SEP)	18
Figura 3: Matriz de Energia Elétrica	19
Figura 4: Torres de transmissão.....	22
Figura 5: Tipo estrutural de torres metálicas	23
Figura 6: Tipos de isoladores	24
Figura 7: Cadeia de isoladores.....	24
Figura 8: Manilha.....	25
Figura 9: Tipos de amortecedores.....	25
Figura 10: Conjunto de Fixação	26
Figura 11: Configuração do Espaçador Losangular e do Espaçador Quadrangular	27
Figura 12: Pinça de suspensão ou amarra balancim	27
Figura 13: Amarra Para-Raios	28
Figura 14: Suspensão Para-Raios	28
Figura 15: Tipos de sinalização	29
Figura 16: Cegonhas sentam no ninho construído na torre de transmissão de energia	30
Figura 17: O uso do helicóptero para de inspeção na linha de transmissão.....	30
Figura 18: Inteligência artificial, Aprendizado de Máquina e Aprendizado profundo.....	33
Figura 19: Esquema de um projeto completo de Machine Learning	34
Figura 20: Rede Neural	35
Figura 21: Neuronio artificial	36
Figura 22: Arquitetura de CNNs totalmente conectada	38
Figura 23: Modelo de sistema YOLO	39
Figura 24: versões do YOLO	40
Figura 25: Informações sobre a memória da GPU no Google Colab	42
Figura 26: Comando Inicial de treinamento.....	44
Figura 27: Curva de Precisão em Função do Recall da arquitetura da YOLOv5.....	49
Figura 28: Curva de F1-Score em Função da Confiança da arquitetura da YOLOv5	50
Figura 29: Detecção de componentes elétricos da linhas de transmissão com YOLO.....	51
Figura 30: Matriz de confusão da Rede Neural ResNet.....	53
Figura 31: Amostras de Classificação com ResNet.....	53
Figura 32: Classificação e detecção com Yolo e ResNet.....	54

LISTA DE TABELAS

Tabela 1: Resultados de cada componente identificado pela YOLO	52
--	----

LISTA DE SIGLAS E ABREVIATURAS

ANAC	Agência Nacional de Aviação Civil
ANEEL	Agência Nacional de Energia Elétrica
CNNs	Convolutional neural network
IA	Inteligência Artificial
ONS	Operador Nacional do Sistema Elétrico
SEP	Sistema Elétrico de Potência
SIN	Sistema Interligado Nacional
UACSA	Unidade Acadêmica do Cabo de Santo Agostinho
UFRPE	Universidade Federal Rural de Pernambuco
YOLO	<i>You Only Look Once</i>

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVO GERAL.....	15
1.2	OBJETIVOS ESPECÍFICOS	15
1.3	ESTRUTURA DO TRABALHO.....	15
2	LINHAS DE TRANSMISSÃO	16
2.1	SISTEMA DE TRANSMISSÃO BRASILEIRO	20
2.2	COMPONENTES DAS LINHAS DE TRANSMISSÃO	21
2.2.1	Cabos Condutores	21
2.2.2	Torres De Sustentação.....	22
2.2.3	Isoladores.....	23
2.2.4	Componentes de Conexão e Suspensão	26
2.2.5	Componentes de Proteção Contra Descargas Atmosféricas	27
2.2.6	Outros componentes.....	28
2.3	MANUTENÇÃO DE LINHAS DE TRANSMISSÃO.....	29
3	CONCEITOS FUNDAMENTAIS DE APRENDIZADO DE MÁQUINA	32
3.1	REDES NEURAIIS.....	35
3.2	VISÃO COMPUTACIONAL E REDES CONVOLUCIONAIS.....	36
3.3	TREINAMENTO DA REDE NEURAL.....	38
3.4	YOLO (<i>YOU ONLY LOOK ONCE</i>).....	39
4	METODOLOGIA DO PROCEDIMENTO	41
4.1	BASE DE DADOS.....	41
4.2	GOOGLE COLAB	42
4.3	ESTRUTURA DO MODELO YOLO	42
4.4	TREINAMENTO DO MODELO YOLO	44
4.5	ESTRUTURA E TREINAMENTO DO MODELO DE CLASSIFICAÇÃO	45
4.6	INTEGRAÇÃO YOLOV5 E RESNET.....	45

4.7	MÉTRICAS DE AVALIAÇÃO	47
5	RESULTADOS E DISCUSSÕES	49
5.1	DESEMPENHO DA YOLOV5 NA DETECÇÃO	49
5.2	DESEMPENHO DA RESNET NA CLASSIFICAÇÃO	53
5.3	AVALIAÇÃO DA INTEGRAÇÃO YOLOV5 E RESNET	54
6	CONCLUSÃO	55
	REFERÊNCIAS	56

1 INTRODUÇÃO

Os Sistemas Elétricos de Potência (SEP) são organizações extensivas que abrangem a produção, transporte e distribuição energética. O principal obstáculo encontrado nessas estruturas está na manutenção constante do fornecimento, evitando interrupções e instabilidades.

As falhas nos processos de transmissão e distribuição resultam em perdas econômicas significativas para consumidores e fornecedores. Por este motivo, torna-se essencial estabelecer um sistema de fornecimento energético resistente e consistente em todos os seus estágios.

No contexto brasileiro, a transmissão energética ocupa papel central no Sistema Elétrico de Potência, estabelecendo conexões por todo território nacional. O ONS (2025) indica que o Sistema Interligado Nacional (SIN) estabelece ligações entre zonas de consumo e centros geradores, permitindo administração efetiva da produção e distribuição elétrica.

A estrutura de transmissão incorpora elementos diversos de proteção e supervisão em sua extensão. Estes sistemas, formados por estruturas metálicas e condutores, atravessam extensões consideráveis e permanecem expostos às variações atmosféricas, incluindo exposição solar, precipitações, correntes de ar e fenômenos elétricos (ANEEL, 2025).

As redes de transmissão, submetidas a condições meteorológicas adversas e uso ininterrupto, necessitam verificações regulares para assegurar distribuição segura. O acompanhamento regular dos equipamentos mostra-se fundamental para estender a vida útil dos elementos transmissores. É essencial para prolongar a durabilidade dos componentes de transmissão.

Vier (2019) ressalta que a manutenção das linhas de transmissão garante a segurança e confiabilidade do sistema, evitando interrupções no fornecimento que possam comprometer a estabilidade da rede. A manutenção preventiva representa um serviço essencial em diversos setores para garantir a segurança e o funcionamento eficiente esperado do serviço ou equipamento utilizado. Estas práticas também ajudam a evitar problemas inesperados, o que torna o sistema elétrico mais seguro e estável para todos os consumidores.

Vier (2019) ainda observa que a manutenção preventiva das linhas requer procedimentos elaborados, frequentemente custosos e arriscados, demandando técnicas específicas e equipamentos apropriados para proteger trabalhadores e instalações. Diante destes desafios, este trabalho explora o uso de tecnologias computacionais modernas, especificamente

aprendizado de máquina e visão computacional, para automatizar a identificação de componentes e detectar anomalias como oxidação, danos físicos ou interferências externas.

A detecção de objetos é um problema clássico na área de visão computacional, tendo como principal característica a localização de objetos que existem em uma imagem estática ou em movimento, além de classificar o objeto (Li *et al.*, 2021). Na detecção pode-se determinar quantos objetos de uma classe estabelecida podem existir na imagem, e determinar onde este objeto está localizado. Ao contrário da classificação de imagens, que apenas indica a presença de um objeto em uma imagem específica, a detecção revela a localização desse objeto utilizando uma caixa retangular de delimitação.

O progresso tecnológico nas redes neurais artificiais, as quais sustentam as técnicas modernas de detecção de objetos, possibilitou a ampla aplicação dessas abordagens a partir dos anos 2000. Isso ocorreu devido ao desenvolvimento de métodos mais eficazes e, em paralelo, ao avanço tecnológico que proporcionou aos hardwares maior velocidade e capacidade para empregar esses métodos.

O sistema desenvolvido combina duas estruturas: YOLOv5 e a Rede Neural Convolutiva (CNN) denominada ResNet. Esta integração busca aprimorar as inspeções automáticas, oferecendo maior rapidez, segurança e eficiência. A arquitetura YOLO permite detecção instantânea de objetos com alta precisão, destacando-se em aplicações de visão computacional (Redmon *et al.*, 2016). Além disso, as redes neurais convolucionais demonstram excelente desempenho na classificação de imagens e reconhecimento de padrões visuais (Zhao *et al.*, 2019).

Os experimentos práticos atingiram 90,6% de acerto na detecção de componentes e 81% na identificação de defeitos. Foram identificadas limitações relacionadas à distribuição desigual de amostras e necessidade de aperfeiçoamento na detecção de elementos específicos, como certos isoladores, indicando a importância de expandir a base de dados. Esta pesquisa contribui ao aplicar técnicas de aprendizado de máquina na manutenção do sistema transmissão. A integração com sistemas remotos reduz custos e riscos nas inspeções, permitindo identificar falhas e aumentar a confiabilidade do sistema elétrico.

1.1 OBJETIVO GERAL

O objetivo principal deste trabalho é desenvolver e avaliar um modelo baseado em aprendizado de máquina para detecção e classificação de anomalias em componentes de linhas de transmissão de energia elétrica.

1.2 OBJETIVOS ESPECÍFICOS

- Implementar um modelo baseado na arquitetura YOLOv5 para detecção de componentes das linhas de transmissão;
- Treinar e avaliar uma Rede Neural Convolutacional (ResNet) para classificação de anomalias nos componentes detectados;
- Integrar os dois modelos para criar um sistema automatizado de inspeção de linhas de transmissão;
- Avaliar a precisão e a eficiência do sistema proposto por meio de experimentos com imagens de inspeções reais;
- Identificar limitações e melhorias para aperfeiçoar o desempenho do modelo.

1.3 ESTRUTURA DO TRABALHO

O presente trabalho está dividido em 6 capítulos. No primeiro capítulo, apresentamos a contextualização dos motivos e objetos do estudo sobre detecção de anomalias dos componentes na linha de transmissão, destacando a importância do tema e a estrutura do trabalho. O segundo capítulo apresenta os conceitos teóricos sobre linhas de transmissão, seus componentes e como é realizada a manutenção. No terceiro capítulo, apresentamos uma fundamentação teórica, destacando o embasamento necessário para aplicação de técnicas de aprendizado de máquina e visão computacional. No quarto capítulo detalhamos a metodologia, procedimentos de coleta, análise de dados e métricas de avaliação. No quinto capítulo, apresentamos uma análise do desempenho dos modelos aplicados separadamente e os resultados obtidos com integração das técnicas aplicadas para a detecção e classificação dos componentes do sistema de transmissão. No sexto e último capítulo concluímos este trabalho apresentando uma síntese geral dos resultados obtidos ao longo do estudo.

2 LINHAS DE TRANSMISSÃO

O Sistema Elétrico de Potência (SEP) é um conjunto de equipamentos e instalações com o objetivo de gerar, transmitir e distribuir energia para o consumidor, seja ele pequeno ou grande, no momento em que é solicitado e com qualidade adequada.

O setor elétrico brasileiro deu início em 1879 quando Dom Pedro II permitiu a Thomas Edison a implantação dos seus equipamentos no Brasil para fins de iluminação pública. Dessa forma, a utilização da energia era basicamente para a finalidade de iluminação e só podia ser realizada nas imediações da usina geradora de energia.

Com a construção de Paulo Afonso I, a primeira grande usina do Brasil, com 180 MW de potência e com a implantação do Sistema Interligado Nacional, o sistema elétrico brasileiro deu um salto significativo, pois a interligação do sistema proporciona maior qualidade e confiabilidade para o usuário final. Além disso, o sistema elétrico brasileiro interligado torna viável a utilização de diversas fontes de geração de energia de maneira integrada. Isso permite otimizar o uso dessas fontes de acordo com melhor custo-benefício, seja ela termoelétrica, hidroelétrica ou de energia renováveis.

O Sistema Interligado Nacional é um sistema complexo e de grande porte para transmissão e produção de energia elétrica, cuja operação está sob controle do Operador Nacional do Sistema Elétrico (ONS), que é regulado e fiscalizado pela Agência Nacional de Energia Elétrica (ANEEL).

Atualmente, o Brasil possui um dos maiores sistemas interligados no mundo com mais de 170 mil km de extensão de linhas de transmissão com tensões de 230 à 800 kV em corrente alternada e frequência de 60 Hz que conectam diferentes usinas hidrelétricas como Belo Monte, Itaipu, Jirau e diversas Usinas eólicas de Energias e Usinas solares pelo território brasileiro. Na Figura 1 é possível observar o Sistema Interligado Nacional e como ele integra as Regiões Norte, Nordeste, Sul, Sudeste-Centro e Oeste através de linhas de transmissão que conectam as usinas de geração de energia aos mais distantes dos centros de carga.

Figura 1: Sistema Interligado Nacional (SIN)



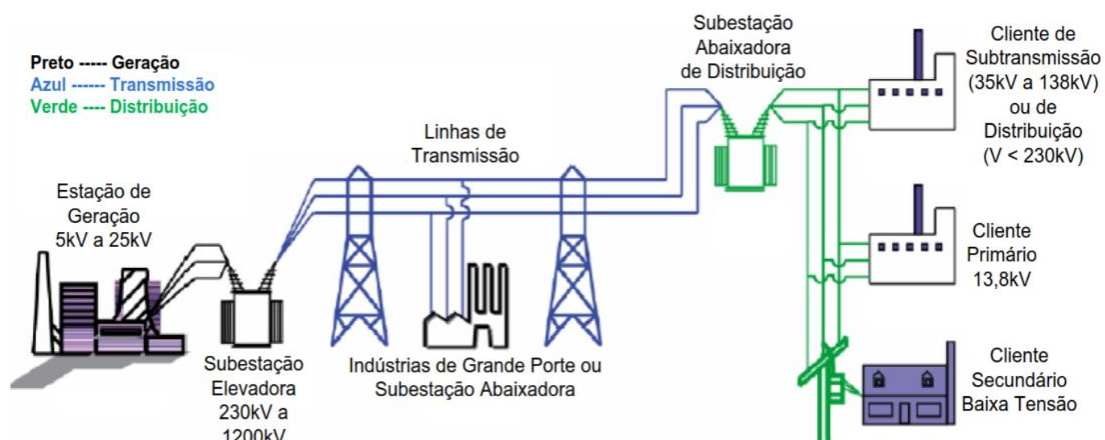
Fonte: Operador Nacional do Sistema Elétrico, 2025.

Os sistemas elétricos de potência, como o SIN, podem ser subdivididos em três grandes etapas: Geração, transmissão e Distribuição. Cada uma das etapas do SEP desempenha um papel fundamental para garantir que a energia produzida esteja sendo entregue com eficiência e qualidade ao consumidor final. A Figura 2 mostra a estrutura do Sistema Elétrico de Potência.

A geração de energia é a etapa inicial do SEP, responsável por realizar o abastecimento energético para os grandes centros. Nessa etapa ocorre a transformação de diversas formas de energia em energia elétrica, utilizando fontes renováveis ou renováveis.

Segundo dados da ANEEL (2025), a produção de energia é predominante hidrelétrica que representa mais de 50% da matriz elétrica nacional (Figura 3). O país é considerado uma das grandes potências hidráulicas do mundo por ser composta por quadro grandes bacias hidrográficas: Bacia Amazônica, Bacia do São Francisco, Bacia do Tocantins, Bacia do Paraná.

Figura 2: Sistema Elétrico de Potência (SEP)



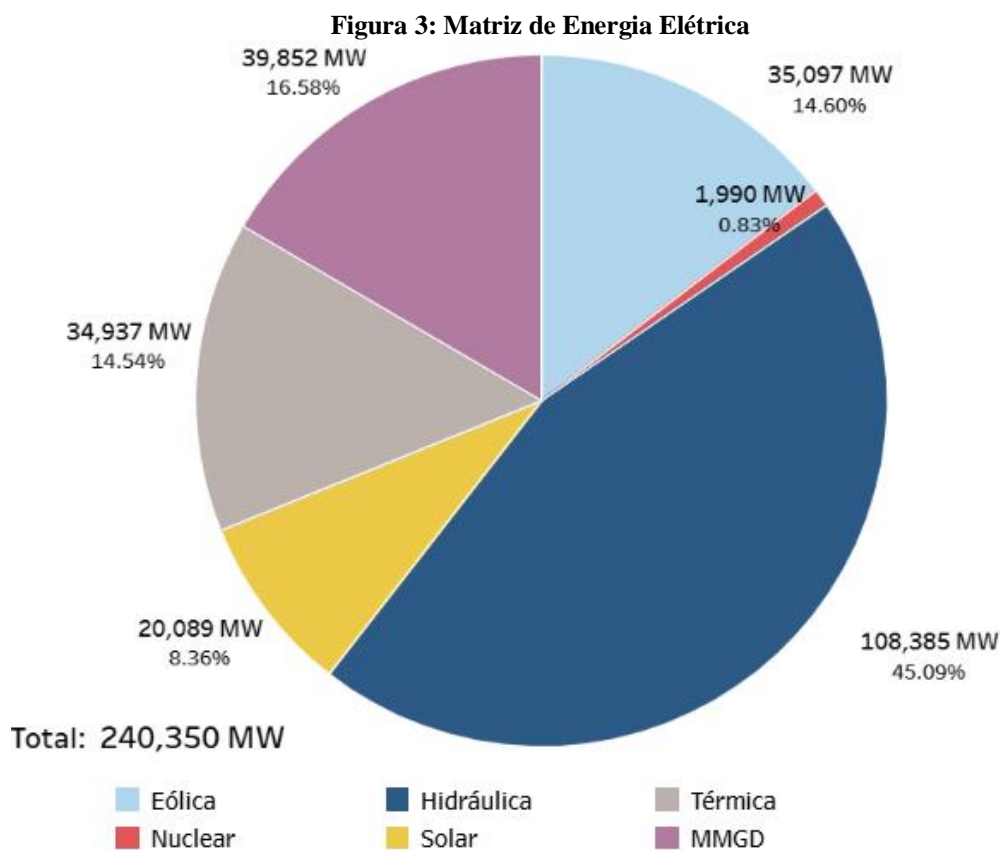
Fonte: Energês, 2021.

No cenário brasileiro além da geração por hidrelétricas existem outras fontes de energias renováveis que se destacam, como a energia eólica e solar. Complementando a matriz energética, a energia termoeletrica desempenha um papel importante no completo da matriz energética brasileiro, principalmente em períodos de estiagem, quando a principal fonte de energia do país enfrenta limitações.

Na Figura 3 é apresentada a matriz energética brasileira em 2025 que mostra a diversidade na sua geração de energia. Essa diversidade permite o ONS operar o sistema com segurança e sustentabilidade tornando o Brasil como referência em matriz de geração limpa e renovável.

A etapa de transmissão de energia tem o papel crucial na interligação entre os sistemas de geração de energia e o sistema de distribuição de energia, ou seja, é a etapa responsável pelo transporte de energia demandada. Nessa etapa os valores de tensão são elevados por causa das perdas de energia por efeito Joule, desse modo é estabelecido um valor de tensão de transmissão de acordo com a quantidade de energia a ser transportada e a distância que possui a linha.

As linhas de transmissão são formadas por diversos equipamentos como torres, cabos, para-raios e isoladores que necessitam uma inspeção periódica por operarem em tensões elevadas. Nessa etapa do SEP a identificação de problemas na linha de transmissão, que é o ponto principal desse trabalho, pode evitar eventuais falhas no sistema de transmissão.



Fonte: Operador Nacional do Sistema Elétrico, 2025.

A etapa final do sistema elétrico de potência é o sistema de distribuição que consiste em distribuir a energia elétrica aos consumidores finais. Nesse sistema existe um processo de redução das tensões de transmissão para níveis seguros de utilização segura em equipamentos elétricos.

No Brasil o sistema de distribuição é regulado por um conjunto de normas dispostas em Resoluções da ANEEL e pelo documento chamado Procedimentos de Distribuição (PRODIST), no qual são classificados os níveis de tensão de distribuição como:

- Alta tensão de distribuição (AT): tensão entre fases cujo valor eficaz é igual ou superior a 69kV e inferior a 230kV;
- Média tensão de distribuição (MT): tensão entre fases cujo valor eficaz é superior a 1kV e inferior a 69kV;
- Baixa tensão de distribuição (BT): tensão entre fases cujo valor eficaz é igual ou inferior a 1kV.

2.1 SISTEMA DE TRANSMISSÃO BRASILEIRO

O sistema elétrico brasileiro é um dos maiores sistemas interligados do mundo, com uma extensão de cerca de 4.000 km no eixo norte-sul. E essa distância seria equivalente a interligar as cidades de Lisboa e Helsinque, na Europa (Araújo, 2009). O sistema de transmissão brasileiro possui uma grande rede de linhas de transmissão que transporta energia pelo país todo. Com os dados fornecidos pelo Operador Nacional do Sistema (ONS) de 2023, atualmente o sistema de transmissão brasileiro possui 170.640 km de extensão, com previsão de expansão para 200.015 km até 2028.

A característica mais interessante do sistema brasileiro é a sua interconexão que permite que a geração que é realizada no norte do país abasteça as regiões no sul, sudeste ou nordeste do país. Isso mostra o quanto o fornecimento de energia ao consumidor final depende significante do sistema de transmissão.

De acordo com Araújo (2009), o sistema de linhas de transmissão faz um papel similar a um reservatório “ambulante”, o que reflete como o sistema de transmissão permite a utilização de reservatórios de água das usinas de forma estratégica. Um exemplo prático que mostra a importância do sistema interligado brasileiro é quando há chuvas intensas que fazem com os reservatórios das hidrelétricas atinjam níveis elevados, exigindo a liberação de água para evitar transbordamentos. Dessa forma, é aproveitado esse excedente hídrico para geração de energia. Essa energia gerada pode ser enviada para uma outra região através de linhas de transmissão garantindo fornecimento e eficiência no sistema.

De modo geral as características geográficas e climáticas do país têm o papel crucial para essa configuração especial e para aproveitar toda a energia que o sistema pode gerar, o Brasil investe muito na construção e manutenção das linhas de transmissão. Embora existam muitos sistemas interligados pelo mundo somente o sistema elétrico de transmissão do Brasil investe tanto em linhas de transmissão, essa “estranha” decisão faz sentido pelo potencial hidráulico do país que reflete em uma geração de energia barata e renovável.

No Brasil, o sistema de transmissão é uma parte essencial do Sistema Elétrico de Potência que garante o fornecimento e a geração de energia. Se o sistema de transmissão falhar ou for limitado, todo país ou partes dele podem ser afetados com a redução da capacidade do sistema. De modo geral as características geográficas e climáticas do país tem o papel crucial para interconexão do sistema de transmissão brasileiro e são fundamentais para aproveitar toda a energia que o sistema pode gerar. Além disso, os investimentos na construção e manutenção

das linhas de transmissão garantem ao máximo a confiabilidade, sustentabilidade e o fornecimento de energia.

2.2 COMPONENTES DAS LINHAS DE TRANSMISSÃO

De acordo com Fuchs (1977), as linhas transmissão dependem exclusivamente da sua geometria, ou seja, das suas características físicas sendo responsáveis pelo regime normal de operação do sistema. Para desenvolver a detecção tanto do componente quanto a sua classificação é necessário conhecer a composição de uma linha de transmissão. Os componentes de uma linha de transmissão são cabos condutores, torres de sustentação, isoladores, componentes de conexão, suspensão e proteção contra descargas atmosféricas.

2.2.1 Cabos Condutores

Os cabos condutores são os elementos ativos do sistema de transmissão que devem apresentar alta condutividade elétrica, baixo custo, alta resistência à oxidação e à corrosão, além de uma boa resistência mecânica para garantir a integridade e continuidade do serviço.

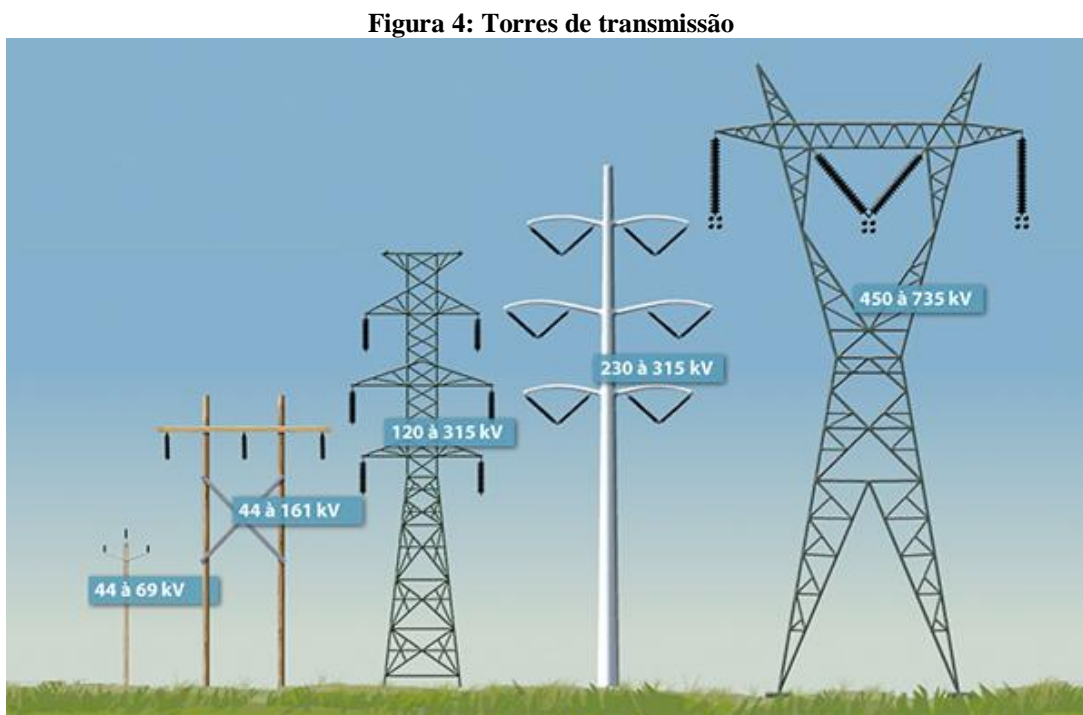
Por muito tempo, os cabos de cobre eram utilizados nas linhas de transmissão por possuir preços baixos e uma boa resistência mecânica, mas com a invenção dos cabos de alumínio (CCA ou ACSR - Aluminum Conductor Steel Reinforced) em 1908 e a evolução dessa tecnologia, o cobre foi sendo desconsiderado para construção de linhas de transmissão.

As vantagens da utilização do alumínio em relação ao cobre nas linhas de transmissão estão principalmente relacionadas ao seu menor peso e menor custo, apesar de sua maior resistividade elétrica. Considerando uma corrente elétrica I (A) constante ao longo de uma mesma distância, um condutor de alumínio com a mesma seção transversal que o de cobre apresentará aproximadamente 1,6 vezes mais perdas por efeito Joule, devido à sua maior resistividade. No entanto, para compensar essa diferença e igualar a resistência elétrica dos dois condutores, o diâmetro do condutor de alumínio precisa ser cerca de 1,261 vezes maior que o do condutor de cobre. Ainda assim, o alumínio continua sendo vantajoso em aplicações de transmissão por ser significativamente mais leve e econômico, permitindo a utilização de cabos mais espessos sem comprometer a viabilidade estrutural e financeira.

No Brasil as linhas de transmissão percorrem longas distancias e o peso dos cabos é um fator crítico na estrutura afetando diretamente os custos do projeto. Por isso, o alumínio passou a ser mais utilizado, na maioria dos projetos de transmissão.

2.2.2 Torres De Sustentação


As torres de sustentação têm um papel importante na estrutura do sistema pois são elas que sustentam os cabos, as chaves e os isoladores, além de manter a isolação, os cabos ali conectados. A Figura 4 mostra a relação das configurações das torres de transmissão de acordo com a classe de tensão e do local que elas são instaladas. É possível notar que o quanto o maior o nível da tensão ao qual a torre é submetida, maior é o espaçamento entre os seus condutores.



Fonte: Jielian Steel Structure, 2025.

As torres possuem uma estrutura metálica e podem ser classificadas com autoportantes e estaiadas. As torres autoportantes possuem estrutura de concreto e são instaladas e sustentadas pela sua própria base. A estaiada são sustentados por meio de cabos conectadas ao solo. Na Figura 5 são apresentados os tipos estruturais de torres metálicas.

Figura 5: Tipo estrutural de torres metálicas



Fonte: Engetower Engenharia, 2022.

2.2.3 Isoladores


Os isoladores são equipamentos responsáveis por suportar os cabos das linhas de transmissão além de resistir às solicitações mecânicas e elétricas do sistema. Além disso deve manter os cabos isolados das torres de transmissão.

Os materiais utilizados na fabricação de isoladores são a porcelana vitrificada e o vidro temperado. Os isoladores empregados nas linhas de transmissão podem ser classificados de acordo com o material, a aplicação e a forma que possuem. Os principais isoladores utilizados são os isoladores de polímero e os isoladores de vidro.

O isolador de polímero é utilizado em linhas de transmissão por ser leve e possuir alta resistência à corrosão, o que leva a ser uma opção viável em ambientes sujeitos a poluição atmosférica. Já o isolador de vidro tem um grande destaque pela facilidade de inspeção por

apresentarem falhas visíveis quando danificados, facilitando a manutenção preventiva. A Figura 6 mostra os tipos de isoladores.

Figura 6: Tipos de isoladores




Isolador de polímero

ISOLADOR DE VIDRO

Fonte: Elaborado pela própria autora, 2025.

Um arranjo muito utilizado no sistema de transmissão é conhecido como cadeia de isoladores em que diversos cabos estão conectados entre si e suspensos acima do solo sustentado pelos isoladores, mostrado na Figura 7. A cadeia de isoladores deve suportar valores acima da tensão nominal do sistema além de resistir surtos atmosféricos.

Figura 7: Cadeia de isoladores



Fonte: Freep!k, 2025.

As cadeias de isoladores realizam a ligação mecânica e o isolamento elétrico entre a estrutura e os cabos condutores. Na sua estrutura deve haver uma peça de ligação que liga a estrutura que geralmente é uma manilha. A manilha, é responsável por conectar os isoladores

às torres ou condutores, garantindo segurança mecânica das linhas de transmissão e podem ser classificadas de acordo com o material e a localização. Figura 8 mostra uma manilha utilizada na linha de transmissão.

Figura 8: Manilha



Fonte: Insplad, 2023.

Os cabos das linhas de transmissão estão sujeitos à ação de ventos que resultam em vibrações que podem levar a sua ruptura. Para reduzir os efeitos das vibrações são empregados amortecedores como o de Espiral e *Stockbridge*.

O amortecedor Espiral é instalado nos cabos reduzindo as vibrações mecânicas por meio da sua interação física com o condutor de energia. Já o amortecedor *Stockbridge*, realiza a dissipação de energia provocada pelo vento, protegendo os cabos e prologando a sua vida útil. Esses dispositivos são instalados ao longo das linhas de transmissão e podem ser observados na Figura 9.

Figura 9: Tipos de amortecedores

Amortecedor Stockbridge



Amortecedor Espiral



Fonte: Elaborado pela própria autora, 2025.

Outro elemento importante nas cadeias de suspensão de isoladores é o conjunto de fixação que deve ser dimensionado para resistir aos esforços mecânicos que pode ser submetido garantindo a estabilidade e segurança das linhas de transmissão. Um exemplo de conjunto de fixação é mostrado na Figura 10.

Figura 10: Conjunto de Fixação



Fonte: Insplad,2023.

2.2.4 Componentes de Conexão e Suspensão

Nas linhas de transmissão existem vários componentes que realizam a conexão e suspensão dos cabos e outros equipamentos, como o espaçador Losangular, quadrangular e pinças de suspensão. Os espaçadores têm a função manter os cabos múltiplos de cada fase separados garantindo o funcionamento da linha de transmissão e prevenindo vibrações eólicas e de rotação que podem ocasionar rompimentos ao longo da linha.

No mercado podem ser encontrados, além de espaçadores simples com a única função de separar, os modelos de espaçador-amortecedor que atuam na redução de oscilações excessivas. Os tipos mais comuns de espaçadores são o Espaçador Losangular e o Espaçador Quadrangular. A diferença entre suas configurações pode ser vista na Figura 11.

Já as pinças de suspensão, popularmente conhecido como “amarra balancim”, são responsáveis por atuar sobre os cabos criando uma tensão mecânica que é transmitida aos suportes. A sua estrutura multiarticulada, observada na Figura 12, deve permitir que os cabos se mantenham estáveis, sem balançar, para que a linha de transmissão não sofra impactados ou rompimentos.

Figura 11: Configuração do Espaçador Losangular e do Espaçador Quadrangular



Espaçador Losangular



Espaçador Quadrangular

Fonte: Elaborado pela própria autora, 2025.

Figura 12: Pinça de suspensão ou amarra balancim



Fonte: Insplad,2023.

2.2.5 Componentes de Proteção Contra Descargas Atmosféricas

As torres de transmissão são sujeitas a descargas atmosféricas e necessitam de dispositivos que permita o escoamento dessas descargas para terra sem afetar o sistema de transmissão. As componentes de proteção contra descargas atmosféricas têm a função de proteger os equipamentos da linha e desviar as descargas atmosféricas para o solo. Um dos componentes utilizado é a manilha Para-Raios e a suspensão Para-Raios

A manilha Para-Raios, ou, amarra Para-raios tem a função de fixar o para-raios à torre ou à linha. Já Suspensão Para-Raios suporta o para-raios, garantindo sua funcionalidade e conexão ao sistema. Essas peças podem ser vistas nas Figura 13 e Figura 14, respectivamente.

Figura 13: Amarra Para-Raios



Fonte: Insplad,2023.

Figura 14: Suspensão Para-Raios



Fonte: Insplad,2023.

2.2.6 Outros componentes

Ao longo das linhas de transmissão, existem sinalizadores com a finalidade de chamar a atenção para possíveis obstáculos e realizar a sinalização para evitar com acidentes aviões e helicópteros.

A sinalização na linha de transmissão ocorre por meio de placas de identificação de torre, que contêm informação de identificação e localização da torre, e esferas. De acordo com Agência Nacional de Aviação Civil (ANAC), as esferas ao longo da linha devem ter uma única cor: branca, vermelha ou Laranja.

A definição da cor depende do meio que a linha de transmissão está localizada. Em relação à sua constituição, são fabricadas de fibra de vidro ou poliéster, com cerca de 50 cm de diâmetro e pesando 5kg. Os tipos de sinalização mencionados podem ser observados na Figura 15.

Figura 15: Tipos de sinalização



Placas de identificação



Esferas

Fonte: Elaborado pela própria autora, 2025.

2.3 MANUTENÇÃO DE LINHAS DE TRANSMISSÃO

A responsabilidade para realização de manutenções nas linhas é atribuída à própria transmissora e a não realização da manutenção das linhas pode causar muitos problemas não só aos componentes das linhas como pode levar à interrupção do fornecimento de energia.

As linhas de transmissão são inseridas em ambientes externos e não controlados expostos a fatores da natureza e humanos como chuvas, maresia, poluição, sol intenso e pássaros que contribuem para a corrosão, rachaduras, curtos-circuitos entre outros distúrbios no sistema. Um exemplo disso é mostrado na Figura 16.

Figura 16: Cegonhas em um ninho construído na torre de transmissão de energia



Fonte: Patrick Seeger, 2013.

A inspeções nas linhas de transmissão são realizadas de diversas maneiras, mas existem algumas que se destacam como a inspeção visual, a inspeção Ultrassônica e a inspeção Termográfica.

A inspeção visual é um método utilizado para monitorar as linhas de transmissão no qual técnicos especializados com binóculos, drones ou helicópteros monitoram as linhas de transmissão para detectar anomalias como danos mecânicos ou corrosão nos componentes da linha. O uso do helicóptero para realização de inspeções visuais é bastante utilizado e pode ser visto na Figura 17.

Figura 17: O uso do helicóptero para de inspeção na linha de transmissão.



Fonte: Helisul. 2025.

A inspeção termográfica é uma técnica de monitoramento das linhas de transmissão que utiliza câmeras infravermelhas que auxiliam na identificação da temperatura dos componentes

da linha de transmissão que obteve um aumento na temperatura causado por conexões danificadas ou soltas.

A inspeção ultrassônica é uma técnica que contribui para uma análise avançada em relação a integridade mecânica dos equipamentos e estrutura das linhas de transmissão utilizando ondas sonoras de alta frequência.

Portanto, de forma geral as metodologias tradicionais realizam a inspeção nas redes de energia por meio de pesquisas de campo e aéreas, nas quais equipes realizam o monitoramento da rede visualmente utilizando câmeras infravermelhas ou binóculos. Esse tipo de abordagem é bastante cara, lenta e potencialmente perigosa, pois expõem os inspetores a condições perigosas, especialmente em situações de emergências.

3 CONCEITOS FUNDAMENTAIS DE APRENDIZADO DE MÁQUINA

De acordo com Russell (2021), a Inteligência Artificial (IA) vem se tornando a tecnologia mais transformadora do século XXI, revolucionando setores como saúde, transporte, energia e comunicação. A Inteligência Artificial permite que máquinas realizem tarefas complexas e aprendam com dados para tomar decisões inteligentes. Atualmente, a Inteligência Artificial é bastante difundida no cotidiano através de *chatbots*, assistentes virtuais e sistemas de recomendação.


Além disso, o aprendizado de máquina (AM), subárea da IA, tem se destacado em aplicações como diagnósticos médicos, no reconhecimento da fala, na detecção de fraudes na internet e na detecção de objetos, que é o foco desse trabalho. Essa revolução tecnológica é possível por que vivemos em uma era digital, onde todos estamos cada vez mais conectados com celulares, tablets e computadores por meio da internet. Nesse contexto, dados são coletados diariamente em uma proporção gigantesca, permitindo que empresas de grande porte tenham acesso a preferências, buscas e comportamentos dos usuários.

O avanço tecnológico que vivemos atualmente, especialmente do aprendizado de máquina, tornou-se possível por causa do aumento da capacidade de armazenamento de dados, da capacidade computacional e processamento de computadores. Esses avanços tornam a aplicação de modelos de aprendizagem de máquinas cada vez mais acessíveis e relevantes. A Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo são conceitos essenciais para compreender o modelo YOLO (*You Only Look Once*) utilizado nesse trabalho.

A Inteligência Artificial é o conceito mais amplo que engloba o aprendizado de máquina e o aprendizado profundo. Na Figura 18 é apresentada, a hierarquia existente sobre esses conceitos em que a Inteligência Artificial é representada como o conjunto mais amplo, no qual se encontra o aprendizado de máquina, que, por sua vez, contém o aprendizado profundo.

O termo Inteligência Artificial foi citado pela primeira vez na década de 50 durante um Workshop de Dartmouth. Cientistas como Newell, Simon e John McCarthy estiveram presentes e contribuíram para o início do avanço intelectual que está em andamento até hoje. A inteligência artificial surgiu a partir da ideia de automatizar tarefas, executadas por humanos, nas máquinas. Os estudos iniciais na área se baseavam em pesquisas sobre como tornar as máquinas capazes de manipular dados e utilizar métodos para resolver problemas complexos. Isso era realizado por meio de programas e bancos de dados capazes de armazenar as regras especificamente desenvolvidas para resolver problemas lógicos bem definidos.

Figura 18: Inteligência artificial, Aprendizado de Máquina e Aprendizado profundo.



Fonte: François Chollet, 2021.

Com o tempo, os problemas enfrentados pela humanidade ficaram cada vez mais complexos, como a necessidade de classificação de imagens, transcrição de texto e reconhecimento de fala. Esses desafios impulsionaram o surgimento do aprendizado de máquina que é uma subárea da IA capaz de realizar previsões a partir de dados.

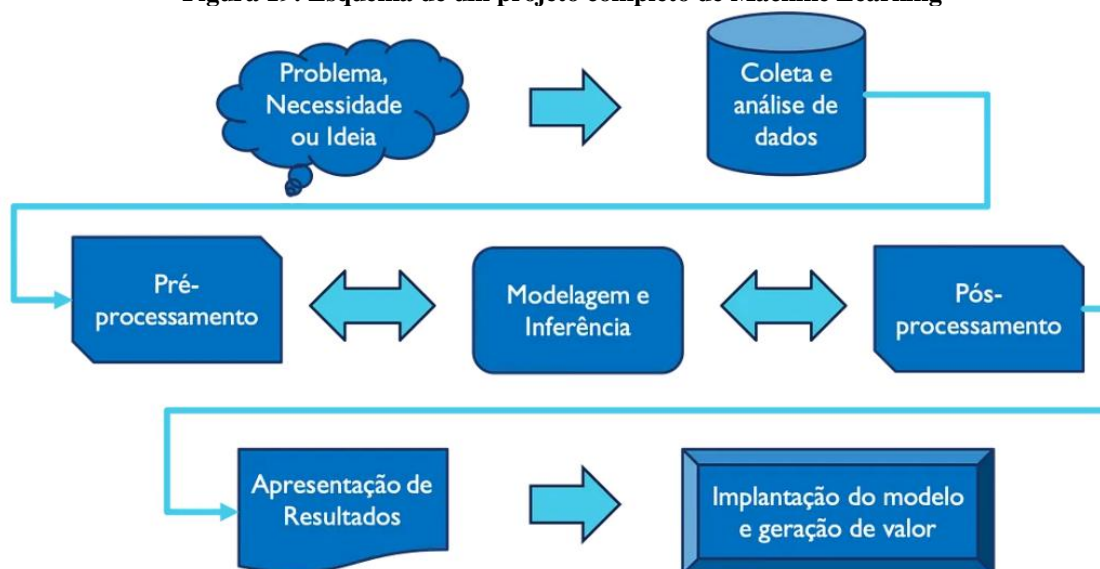
O aprendizado de máquina é baseado na estatística e matemática simulando o comportamento humano por meio de grandes quantidades de dados, ou seja, ao analisar um conjunto de dados, o aprendizado de máquina tenta identificar padrões existentes que seriam impossíveis para humanos detectarem.

O aprendizado de máquina pode ser dividido em três categorias de algoritmos: supervisionado, não-supervisionado e por reforço. No aprendizado supervisionado o modelo é treinado com um conjunto de dados rotulados, ou seja, com respostas conhecidas capaz de realizar previsões, com novos dados não vistos, utilizando o conhecimento adquirido durante o processo de treinamento. Já no aprendizado não-supervisionado, o modelo é treinado com um conjunto de dados não rotulados, ou seja, sem respostas conhecidas e é capaz de identificar padrões de agrupamentos por meio das estruturas presentes nos dados. Por fim, no aprendizado por reforço o modelo é treinado por meio de um sistema de recompensas, ou seja, ele é recompensado ao tomar uma decisão certa e punido ao tomar uma decisão errada, ajustando suas ações com base nos resultados obtidos.

Para o desenvolvimento de um modelo de aprendizado de máquina, é necessário compreender muito bem o problema a ser resolvido. Essa etapa inicial é fundamental para definir os dados que deverão ser coletados e os critérios que devem ser avaliados. Muitas vezes

os dados coletados não são suficientes ou são inconsistentes, o que leva à construção de um novo modelo. Na Figura 19 são apresentadas as principais etapas envolvidas no desenvolvimento de um aprendizado de máquina, desde a identificação do problema até a implantação do modelo e a geração de valor.

Figura 19: Esquema de um projeto completo de Machine Learning



Fonte: Escovedo & Koshiyama, 2020.

O aprendizado profundo é um subconjunto específico do aprendizado de máquina que possui uma estrutura matemática para aprender representações a partir dos dados. Ele se baseia no uso de camadas hierárquicas, conhecido como Redes Neurais, que permite aprender representações significativas de forma contínua.

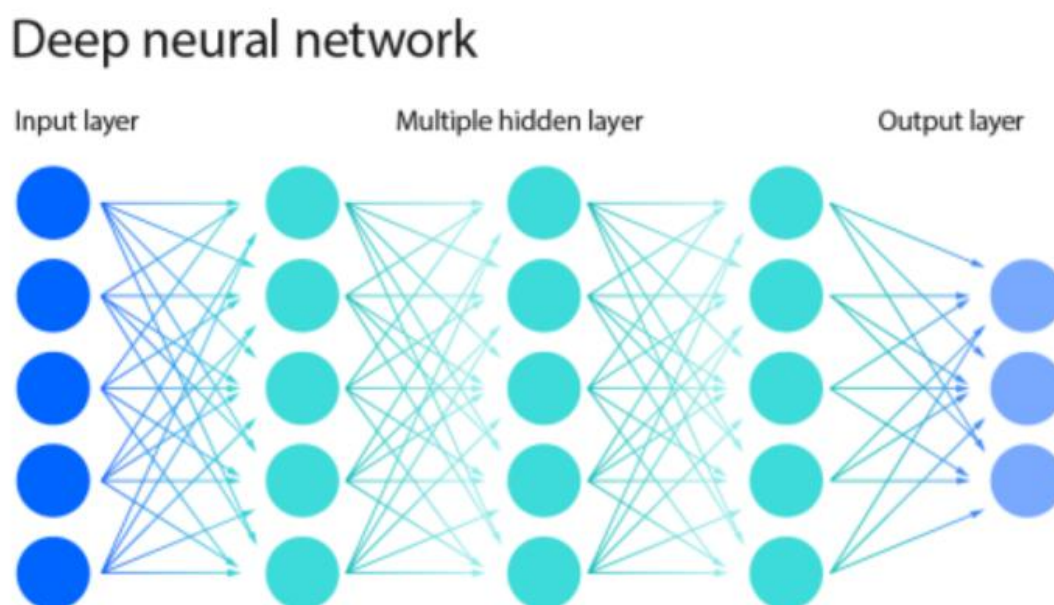
As redes neurais são treinadas para aprenderem com os dados e identificar padrões por meio de processos de treinamento. Essa abordagem é bastante utilizada em aplicações como visão computacional, processamento de linguagem natural e reconhecimento de fala, devido à sua capacidade de lidar com dados não estruturados.

O aprendizado profundo tem um papel fundamental neste trabalho por ser utilizado para a detecção de componentes de linhas de transmissão. Por meio de redes neurais convolucionais (CNNs) e do uso da arquitetura do YOLO (*You Only Look Once*), será possível identificar e categorizar componentes e anomalias em imagens de linhas de transmissão de forma eficiente e automatizada. A abordagem que será apresentada nesse trabalho não apenas aumenta a precisão na detecção, mas também reduz o tempo necessário para a análise mostrando assim a sua relevância no setor elétrico.

3.1 REDES NEURAIAS

As redes neurais, também conhecidas como Redes Neurais Artificiais (ANNs), são compostas por camadas interconectadas inspirado na neurobiologia. Ela são compostas por três níveis de camadas: a camada de entrada, uma ou mais camadas ocultas e uma camada de saída, como representado na Figura 20. Essas camadas são conectadas por meio de nós, conhecidos como neurônios artificiais, que possuem a capacidade de aprender e resolver um problema como um neurônio real do organismo humano.

Figura 20: Exemplo da estrutura em camadas de uma rede neural simples.

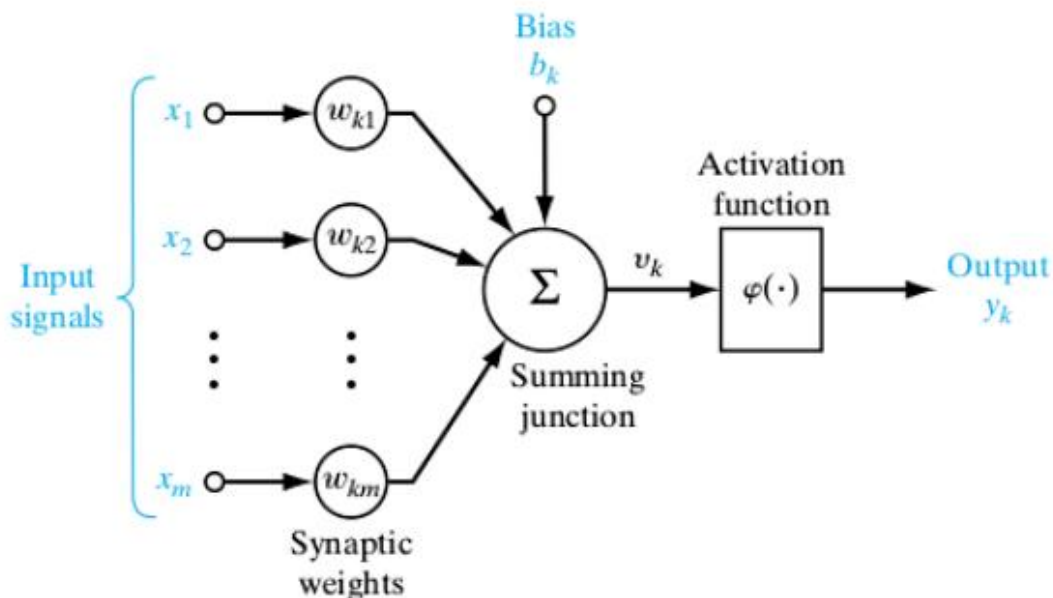


Fonte: IBM, 2025.

Os neurônios da rede neural são associados a pesos sinápticos que servem como parâmetros de aprendizagem do modelo. Os pesos sinápticos determinam a força entre as conexões de cada neurônio e são ajustados durante o processo de aprendizado da rede neural.

A Figura 21 representa o neurônio artificial, em que x_m representa os sinais de entrada do neurônio, w_{km} são os pesos sinápticos do neurônio. O b_k , refere-se ao Bias, que são valores que ajudam a calibrar as ativações dos neurônios para melhorar a performance do modelo.

Figura 21: Neurônio artificial



Fonte: Matheus coelho, 2022.

Os neurônios artificiais são ativados através de funções de ativação, que desempenham um papel central na estrutura de uma rede neural. Essas funções decidem se as informações recebidas por um neurônio são relevantes e devem ser processadas e transmitidas para os próximos neurônios ou ignoradas.

O aprendizado em redes neurais ocorre por meio de dois processos principais: *Forward Propagation* e *Backpropagation*. O aprendizado por *Forward Propagation* consiste no processamento dos dados por meio das camadas da rede, da entrada até a saída, gerando uma previsão com base nos pesos e Bias. Já o aprendizado por *Backpropagation* é utilizado algoritmos, como o gradiente descendente, para ajustar os pesos e Bias para minimizar os erros na rede. Esse processo é realizado por uma função de custo, que mede a disparidade entre as previsões e os valores reais.

As redes neurais artificiais são fundamentais para a implementação do YOLO que utiliza uma extensão das ANNs, conhecida como Redes Neurais Convolucionais, projetadas especificamente para lidar com imagens. Dessa forma, a arquitetura do YOLO e o funcionamento das redes neurais estão conectados ao objetivo deste trabalho.

3.2 VISÃO COMPUTACIONAL E REDES CONVOLUCIONAIS

A visão computacional é uma área que lida com aquisição, processamento e análise de imagens e vídeos. Atualmente, a sociedade está imersa em modelos de visão computacional

como filtros de vídeos em redes sociais, sistemas de pesquisa de imagens, aplicativos de organização de fotos, reconhecimento facial em smartphones, diagnósticos médicos e entre outras funcionalidades.

Somente em 2012, com desenvolvimento da rede neural convolucional AlexNet, por Alex Krizhevsky, a visão computacional obteve um grande avanço. A AlexNet demonstrou a capacidade de diminuir a taxa de erro em tarefas de classificação de imagens. Esse avanço possibilitou que as Redes Neurais Convolucionais (CNNs) se tornassem a base para aplicações em modelos de visão computacional. Isso levou ao surgimento de bibliotecas como TensorFlow e Pytorch, que foram e continuam sendo cruciais para a popularização da CNNs.


De acordo com Chollet (2021), a visão computacional pode ser dividida em três ramos principais:

- **Classificação de imagem:** tem o objetivo de atribuir um ou mais rótulos a uma imagem. Essa classificação pode ser de rótulo único ou de vários rótulos. Por exemplo, quando pesquisamos uma palavra-chave no aplicativo Google Fotos na realidade estamos consultando um modelo de classificação de vários rótulos, com mais de 20.000 classes diferentes, treinada em milhões de imagens;
- **Segmentação de imagem:** tem o objetivo de segmentar uma imagem em diferentes áreas, sendo cada área representada por uma categoria. Por exemplo, quando o Google Meet exibe um plano de fundo personalizado em uma chamada de vídeo, ele está usando um modelo de segmentação de imagem para diferenciar o rosto do background escolhido, com precisão de pixels;
- **Deteção de objetos:** tem o objetivo de localizar objetos específicos em uma imagem ao desenhar retângulos, chamados de caixas delimitadoras, em torno deles associando cada retângulo a uma classe. Por exemplo, usar um modelo de deteção de objetos para monitorar e identificar equipamentos nas linhas de transmissão, como é foco deste trabalho.

A visão computacional funciona processando dados por meio de redes neurais convolucionais que são modelos de aprendizado profundo programados para identificar padrões visuais, como bordas, texturas e formas. O processo tem início com a divisão da imagem em pixels, que são analisados e rotulados. À medida que o modelo é treinado com conjuntos de dados, ele se torna capaz de identificar e classificar objetos em novas imagens com alta precisão.

Na Figura 22 é apresentada a estrutura de uma CNN composta por diferentes camadas cada uma com uma função específica. A camada de convolução realiza a extração de padrões e características capturadas na imagem. A camada de *pooling* tem o papel fundamental de destacar essas características a fim de que as classes possam ser reconhecidas. Já na camada localizada no final da rede neural, chamada de rede totalmente conectada (ou rede densa), é realizada a classificação após os dados serem transformados em um vetor de números que são conectados por uma ou mais camadas totalmente conectadas.

Figura 22: Arquitetura de CNNs totalmente conectada



Fonte: Pedro Ney Stroski, 2018.

3.3 TREINAMENTO DA REDE NEURAL

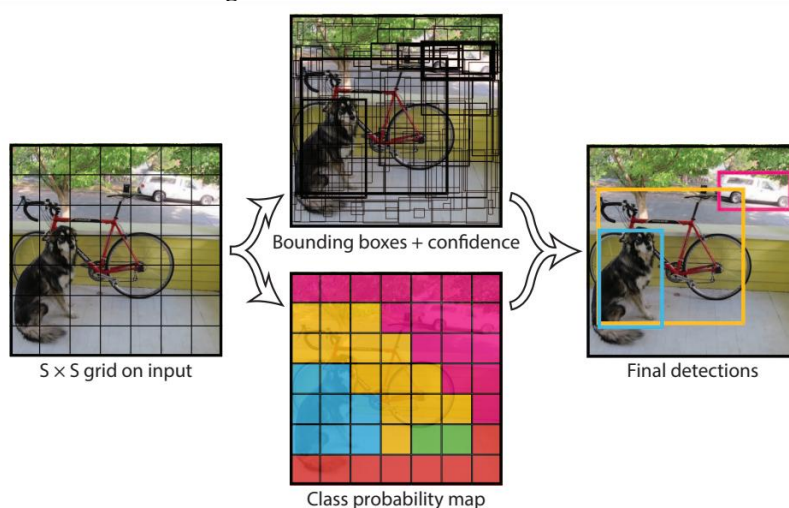
O processo de treinamento de uma CNN é o que torna o modelo confiável e deve ser feito quantas vezes seja necessário. Esse processo envolve a utilização de conjuntos de dados rotulados que geralmente, são divididos em três partes:

- **Dados para treinamento:** É o conjunto de dados usados durante o treinamento para ensinar o modelo e ajustar os parâmetros;
- **Dados para validação:** É o conjunto de dados de exemplos utilizado para avaliar o desempenho do modelo durante o treinamento e ajustar parâmetros por meio de comparação de modelos diferentes;
- **Dados para teste:** É o conjunto de dados usado para verificar a precisão do modelo com dados que ele nunca viu antes.

3.4 YOLO (*YOU ONLY LOOK ONCE*)

A YOLO é uma das arquiteturas mais famosas para detecção de objetos, criada por Joseph Redmon em 2015. Essa arquitetura consiste em uma estrutura de detecção em uma única passada, diferente dos métodos tradicionais que envolvem múltiplos estágios. A YOLO trata o problema de detecção como um problema de regressão, fracionando a imagem de entrada em uma grade com $S \times S$ células como representado na Figura 23. Cada célula da grade realiza a predição de caixas delimitadoras, ou em inglês *bounding boxes*, e atribui valores de confiança a elas.

Figura 23: Modelo de sistema YOLO



FONTE: Redmon, 2016.

A arquitetura também associa cada caixa a uma classe específica. Essa abordagem permite identificar objetos em tempo real, combinando simultaneamente a localização das caixas delimitadoras e a classificação das classes.


Desde sua criação foram desenvolvidas diversas versões incluindo YOLOv1, YOLOv2, YOLOv3, YOLOv4, YOLOv5, e a mais recente, como YOLOv11. Essas evoluções trouxeram melhorias significativas em termos de precisão, velocidade e eficiência, como mostrada na Figura 24. Na versão inicial do YOLO, cada célula pode prever no máximo duas caixas e apenas uma classe por caixa. Isso limita o desempenho em casos em que há muitos objetos próximos ou pequenos ou com muitos detalhes complexos em uma imagem.

A YOLOv2 é um modelo de classificação que introduziu a utilização de camadas convolucionais para facilitar a localização precisa de objetos. Já a YOLOv3 aumentou a

precisão de classificação ao usar classificadores logísticos independentes, o que permitiu a detecção de múltiplos objetos de diferentes classes em uma mesma imagem.

A versão YOLOv4 trouxe inovações como o aumento automático da quantidade de dados de treinamento, por meio de mosaicos compostos por imagens existentes, e ajustes no modelo para melhorar a precisão e o desempenho.

Figura 24: versões do YOLO



Fonte: Ultralytics, 2025.

A YOLOv5, utilizada neste trabalho, é uma versão que possui uma maior eficiência e rapidez tanto no treinamento quanto na detecção. Com sua estrutura otimizada e suporte a melhorias implementadas nas versões anteriores, ela apresenta excelente desempenho em aplicações práticas.

4 METODOLOGIA DO PROCEDIMENTO

Neste capítulo, são apresentados os métodos, ferramentas e procedimentos utilizados para a identificação de componentes em linhas de transmissão. O objetivo é detalhar as etapas aplicadas, desde a seleção do conjunto de dados até o treinamento e validação do modelo.

4.1 BASE DE DADOS

Para esse trabalho, buscou-se um conjunto de dados que representasse os ativos de linhas de transmissão de energia em um contexto real. Dessa maneira, foi selecionada base de dados InsPLAD (*Inspection of Power Line Assets DataSet*) que é o primeiro grande conjunto público de dados preparado para classificação, segmentação e detecção de componentes de linhas de transmissão em grande escala. Esse conjunto de dados compreende um total de 10.607 imagens, organizadas de maneira a facilitar o treinamento e a avaliação de modelos de aprendizado de máquina em aplicações no setor elétrico.

Com isso, foram selecionadas 10.561 imagens de 18 classes diferentes de componentes de linhas de transmissão, disponibilizada pelo InsPlad. Para realização da classificação do equipamento como defeituoso ou não, só foi possível utilizar 5 classes das 18. Isso se deve ao fato de que as outras classes não possuíam imagens suficientes para um treinamento eficiente do modelo.

As 18 classes que foram selecionadas para realizar a detecção são: espaçador losangular, amarra balancim, espaçador quadrangular, amortecedor *stockbridge*, amarra para-raios, suspensão para-raios, isolador de polímero, isolador de vidro, placa de identificação da torre, conjunto de fixação, manilha inferior do isolador de polímero, manilha superior do isolador de polímero, manilha da torre do isolador de polímero, manilha grande do isolador de vidro, manilha pequeno do isolador de vidro, manilha da torre do isolador de vidro, amortecedor espiral e esfera. As 5 classes para as quais possível realizar a classificação foram: isolador de vidro, suspensão para-raios, manilha superior do isolador de polímero, conjunto de fixação e amarra balancim.

A escolha desse *DataSet* foi fundamental para garantir o desenvolvimento do modelo de detecção de componentes, dado que ele apresenta uma ampla diversidade de cenários que refletem situações reais encontradas em inspeções de linhas de transmissão.

4.2 GOOGLE COLAB

Todo desenvolvimento do modelo de aprendizagem de máquina para detecção de componentes de linhas de transmissão deste trabalho foi realizado no ambiente do Google Colab (*Google Colaboratory*), uma plataforma baseada em nuvem que oferece recursos gratuitos para o desenvolvimento de aplicações de aprendizagem de máquina e aprendizado profundo. O Colab é utilizado por causa da sua facilidade de uso e da possibilidade de acesso remoto a unidades de processamento gráfico (GPUs), essenciais para tarefas de treinamento intensivo.

Para uso das GPUs, o Colab seleciona automaticamente a GPU a ser utilizada para os experimentos. No contexto deste trabalho, foi disponibilizada a Tesla T4, uma placa de vídeo com 15 GB de memória RAM como pode ser observado na Figura 25. Esse recurso permite um processamento eficiente dos dados, com uma média de tempo de uso diário de até 12 horas, com exceção de situações em que o limite de memória do ambiente for excedido.

Além disso, no ambiente do Colab foram importadas bibliotecas fundamentais para o funcionamento da rede YOLO, como o Google Drive, Ultralytics e a OpenCV (cv2), garantindo a compatibilidade do modelo e o suporte às funções necessárias para treinamento e detecção.

Figura 25: Informações sobre a memória da GPU no Google Colab

```

Wed Jan 22 02:31:31 2025
+-----+
| NVIDIA-SMI 535.104.05                Driver Version: 535.104.05   CUDA Version: 12.2   |
+-----+-----+-----+-----+-----+-----+
| GPU  Name          Persistence-M   Bus-Id        Disp.A   Volatile Uncorr. ECC |
| Fan  Temp           Perf             Pwr:Usage/Cap     Memory-Usage   GPU-Util  Compute M. |
|                                           MIG M.         |
+-----+-----+-----+-----+-----+-----+
|  0   Tesla T4      Off              00000000:00:04.0 Off           |
| N/A   33C           P8              9W / 70W      0MiB / 15360MiB      0%      Default |
|                                           N/A         |
+-----+-----+-----+-----+-----+
+-----+
| Processes:                               |
| GPU  GI    CI           PID  Type  Process name                               GPU Memory |
| ID   ID   ID                                 Name                               Usage       |
+-----+-----+-----+-----+-----+
| No running processes found              |
+-----+

```

Fonte: Elaborado pela própria autora, 2025.

4.3 ESTRUTURA DO MODELO YOLO

A versão da YOLO escolhida para realização deste trabalho foi a YOLOv5. Essa versão é conhecida pela sua simplicidade de uso e eficiência, que são essenciais para aplicações como

a análise de componentes de linhas de transmissão, em que a velocidade e a precisão são fundamentais.

Para personalização do modelo de detecção em linhas de transmissão foram realizadas algumas modificações em alguns arquivos de configuração do algoritmo YOLOv5. Foram modificados os arquivos “train.txt”, “val.txt”, “VOC_custom.yaml” e “yolov5s.yaml”.

Os arquivos “train.txt” e o “val.txt” são arquivos de texto gerados na etapa de preparação do conjunto de dados que contêm os caminhos para cada imagem de treinamento e validação, permitindo que o modelo localize corretamente os dados durante o treinamento.

O arquivo “VOC_custom.yaml” define os caminhos para os conjuntos de dados de treinamento, validação e teste, além de especificar as classes utilizadas no projeto. Neste trabalho, o arquivo foi alterado para possuir 18 classes que foram definidas para a análise de componentes das linhas de transmissão do conjunto de dados.

O conjunto de dados de treinamento, validação e teste foram organizadas em pastas específicas de tal maneira que cada imagem do *dataset* possuísse um arquivo no formato txt correspondente às anotações no formato YOLO. Esse formato consiste na especificação das coordenadas das caixas delimitadoras e as suas classes associadas.

Já o arquivo “yolov5s.yaml” abrange a arquitetura da rede neural, incluindo o número de camadas, filtros e a estrutura da rede. A modificação nesse arquivo consistiu em ajustar o parâmetro referente ao número de classes, para garantir que a última camada da rede correspondesse às 18 classes definidas no arquivo “VOC_custom.yaml”.

Após a preparação dos arquivos de configuração, foi realizada a customização do a customização da rede neural e compilação da biblioteca do modelo YOLOv5. A biblioteca oficial foi clonada do repositório “Ultralytics” por meio do comando “git clone”, e os arquivos personalizados, juntamente com as imagens e anotações, foram copiados para os diretórios apropriados da biblioteca.

Com a estrutura configurada, o treinamento do modelo foi iniciado com o comando mostrado na Figura 26. Nesse comando, são especificados os principais parâmetros necessários para o treinamento:

- **--data:** Indica o arquivo yaml que neste trabalho foi configurado no arquivo “VOC_custom.yaml”;
- **--cfg:** Define o arquivo que descreve a arquitetura da rede neural, neste caso, o yolov5s.yaml;

- **--weights:** Define os pesos do treinamento. Como é o treinamento inicial do modelo este parâmetro utiliza os pesos iniciais yolov5s.pt, fornecidos pela Ultralytics, para acelerar o processo de aprendizado;
- **--batch-size (batch):** Configurado como 16, para equilibrar eficiência computacional e precisão durante o treinamento, considerando as limitações de memória da GPU utilizada;
- **--epochs (épocas):** Definido como 100, número suficiente para garantir que o modelo convergisse de forma adequada, permitindo ajustes contínuos nos pesos durante o processo;
- **--img-size:** Especifica o tamanho das imagens processadas pela rede neural, estabelecido como 608x608 pixels, uma configuração comumente utilizada para alcançar um desempenho de qualidade do modelo.

Após a conclusão do treinamento, os pesos gerados foram salvos automaticamente como backup em uma pasta do *Google Drive*. Esse backup inclui os pesos das diferentes etapas do treinamento, além de informações detalhadas sobre a evolução da perda e da precisão ao longo das épocas fundamentais para análises dos resultados deste trabalho.

Figura 26: Comando Inicial de treinamento

```
!python train.py --data /content/yolov5/data/VOC_custom.yaml --cfg /content/yolov5/models/yolov5s.yaml --weights yolov5s.pt --batch-size 16 --epochs 50 --img-size 608
```

Fonte: Elaborado pela própria autora, 2025.

4.4 TREINAMENTO DO MODELO YOLO

Para o treinamento da rede YOLOv5, os dados foram estruturados entre o conjunto treinamento (70%), de validação (15%) e de teste (15%). Essa divisão é uma prática padrão em aprendizado de máquina, permitindo que o modelo seja treinado, ajustado e avaliado de maneira eficiente.

O conjunto de treinamento foi utilizado para atualizar os pesos da rede durante as iterações, enquanto o conjunto de validação serviu para monitorar o desempenho do modelo ao longo do treinamento. Por fim, o conjunto de teste foi utilizado para avaliação final do modelo, garantindo uma análise confiável do desempenho.

Durante o processo de treinamento, a YOLOv5 gera *backups* automáticos dos pesos após cada época. Esses backups foram salvos em uma pasta específica no *Google Drive*, permitindo a retomada do treinamento e a análise dos resultados parciais.

4.5 ESTRUTURA E TREINAMENTO DO MODELO DE CLASSIFICAÇÃO

Para a realização do treinamento de classificação foi escolhida uma Rede Neural Convolutacional (CNN) profundo chamada de ResNet (*Residual Network*). Essa CNN possui várias versões, a escolhida para esse trabalho foi a ResNet-18 por possuir uma menor complexidade de execução e treinamento rápido. Além disso, essa versão possui um uso de memória menor em relação as outras, sendo ideal para aplicabilidade no *Google Colab* com GPU limitada.

A estrutura de treinamento do modelo consistiu na organização do conjunto de dados separados entre treinamento e validação, aonde para cada conjunto de dados foi necessária a classificação das imagens entre componentes defeituosos ou não. Com o conjunto de imagem anotado, as imagens foram passadas para o modelo de classificação ResNet-18.

O processo de treinamento do modelo foi realizado utilizando PyTorch configurado para executar até 30 épocas, ativação da função de perda, duas classes (*bad* e *good*) e com o tamanho do *batch* de 16. Com a finalização do treinamento, foram armazenados o melhor modelo encontrado durante o treinamento com menor erro na validação e o último estado do treinamento.

4.6 INTEGRAÇÃO YOLOV5 E RESNET

A combinação do YOLOv5 com a ResNet é fundamental para identificar e avaliar como estão os componentes nas linhas de transmissão. O YOLOv5 trabalha encontrando e marcando onde exatamente os equipamentos estão nas fotos, e a ResNet, que é uma rede neural que processa imagens em camadas, analisa se esses equipamentos estão "bad" ou "good".

O YOLOv5 é rápido em identificar as peças nas imagens e recorta bem as partes importantes para a ResNet analisar. A ResNet então olha com cuidado cada detalhe dessas imagens recortadas, conseguindo perceber até pequenos sinais de problemas que poderiam passar despercebidos.

Na Figura 27 é apresentado o fluxograma desenvolvido para representar o funcionamento do modelo proposto, que integra as etapas de detecção e classificação em um processo contínuo e automatizado.

A imagem inicia com a entrada da imagem bruta, capturada diretamente da linha de transmissão. Embora o exemplo apresentado contenha apenas um componente visível, o sistema é capaz de processar imagens com múltiplos componentes simultaneamente.

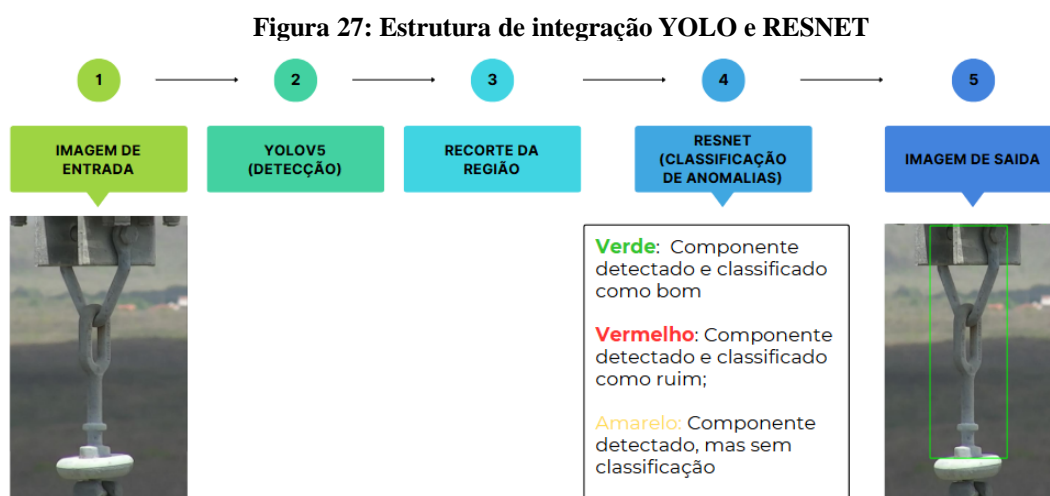
Na segunda etapa, ocorre a detecção utilizando o modelo YOLOv5. Esse modelo identifica os componentes presentes na imagem e retorna caixas delimitadoras ao redor de cada objeto detectado, juntamente com a probabilidade de acerto para cada detecção. Essa etapa é responsável por localizar os elementos de interesse na imagem.

Com base nessas detecções, é realizada a extração e recorte das regiões de interesse. Cada componente detectado é isolado em uma nova imagem, de modo que se reduza interferência de fundo e se concentre a análise apenas no item relevante. Esse recorte é essencial para garantir uma classificação mais precisa na etapa seguinte.

As imagens recortadas são, então, enviadas à rede neural ResNet, previamente treinada para classificar o estado dos componentes. O modelo analisa cada imagem individualmente e retorna uma das seguintes classificações:

- **Verde:** Componente detectado e classificado sem avaria (good);
- **Vermelho:** Componente detectado e classificado com avaria (bad);
- **Amarelo:** Componente detectado, mas sem classificação devido à falta de dados suficientes para treinar o modelo de classificação para essas classes específicas.

Por fim, a imagem de saída é gerada com todas as caixas delimitadoras, agora coloridas de acordo com a classificação realizada. Esse resultado facilita a visualização, interpretação e posterior tomada de decisão pela equipe técnica responsável pela inspeção.



4.7 MÉTRICAS DE AVALIAÇÃO

A avaliação de desempenho do modelo treinado foi realizada através de métricas convencionais de aprendizado de máquina, com destaque para a matriz de confusão, o que permite uma análise detalhada da capacidade de detecção e classificação da rede Yolov5.

A matriz de confusão é uma ferramenta para avaliar o desempenho do modelo de forma visual e quantitativa. Esse método consiste em comparar os valores previstos em relação aos valores reais do conjunto de dado, mostrando a diferença entre a expectativa e a realidade.

A matriz de erro, como também é conhecida, é representada por uma tabela que é dividida em quatro categorias:

- **Verdadeiro Positivo (TP):** Quando o modelo classifica certo para uma classe Positiva;
- **Falso positivo (FP):** Quando o modelo classifica errado uma classe Negativa como Positiva;
- **Verdadeiro Negativo (TN):** Quando o modelo classifica certo para uma classe Negativa;
- **Falso Negativo (FN):** Quando o modelo classifica errado uma classe Positiva como Negativa.

A partir dessas informações é possível definir diversas equações para avaliar o desempenho do modelo como precisão, recall, F1-score e acurácia. A precisão mede a proporção de quantas previsões de classe Positiva foram realizadas no modelo, incluindo a taxa de falsos positivos. Essa métrica é calculada como,

$$precisão = \frac{TP}{TP + FP}.$$

O *recall* mede a capacidade do modelo de identificar as classes Positivas com relação a taxa de falsos negativos, ou seja, avalia a sensibilidade do modelo. Essa métrica é calculada como

$$recall = \frac{TP}{TP + FN}.$$

A F1-Score é a combinação da precisão e do recall em uma única métrica. Essa métrica é calculada como

$$\text{F1Score} = 2 * \frac{\text{precisão} * \text{recall}}{\text{precisão} + \text{recall}}$$

A acurácia indica o quão bem foi feita a identificação do modelo. Essa métrica é calculada como

$$\text{acurácia} = \frac{TP + TN}{TP + VN + FP + FN}$$

Outra métrica utilizada para avaliar a capacidade do modelo de detectar e classificar corretamente os componentes das linhas de transmissão, servindo como um indicador global de desempenho é a métrica Mean Average Precision (mAP). O cálculo da mAP é baseado na Precisão Média (AP) e pode ser expresso da seguinte forma:

$$\text{mAP} \equiv \frac{1}{N} \sum_{i=1}^N \text{AP}_i$$

Na prática, são utilizadas diferentes variações da métrica mAP, dependendo dos critérios de avaliação:

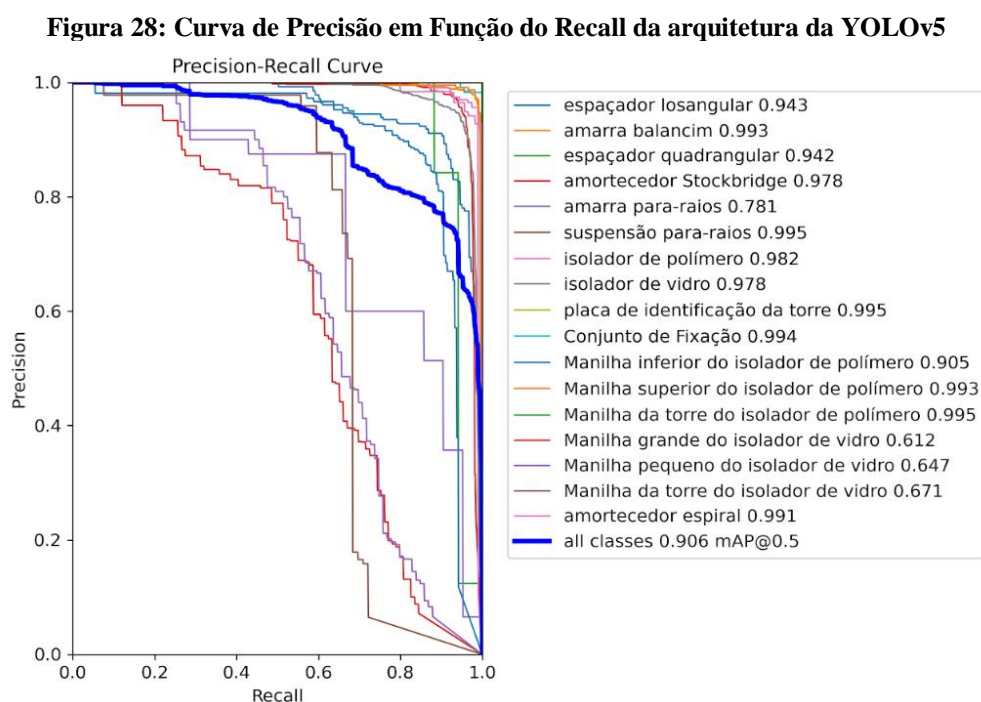
- **mAP@0.5:** Considera uma predição correta quando a interseção sobre a união entre a predição e a anotação real é maior que 0.5;
- **mAP@0.5:0.95:** Representa a média da precisão média calculada em múltiplos limiares, variando de 0.5 a 0.95 em incrementos de 0.05. Essa versão fornece uma avaliação mais rigorosa do desempenho do modelo.

5 RESULTADOS E DISCUSSÕES

Nessa sessão serão apresentados os resultados das métricas de avaliação utilizadas para avaliar o desempenho da YOLOv5 na tarefa de detecção de componentes das linhas de transmissão, bem como o desempenho da ResNet na classificação de algumas classes detectadas. As métricas de avaliação consistem na matriz de confusão, na Curva de F1-Score em função da confiança e a Curva de Precisão em função do Recall, com os resultados dessas métricas é possível entender a qualidade das previsões.

5.1 DESEMPENHO DA YOLOV5 NA DETECÇÃO

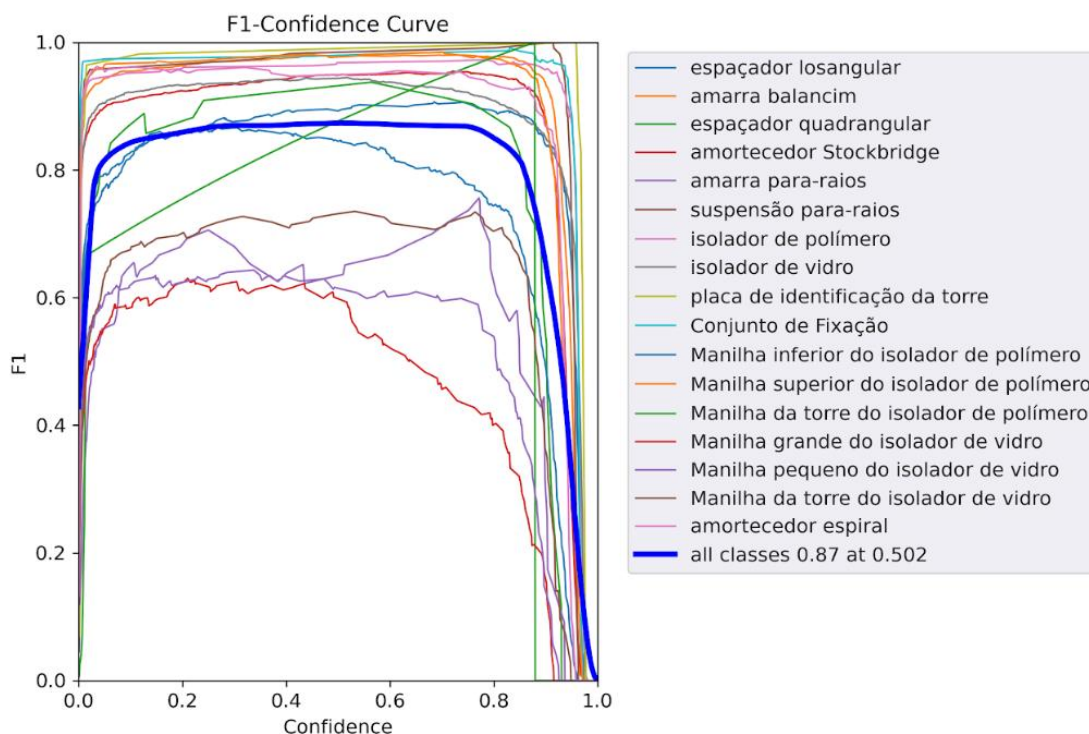
Na Figura 28 é possível observar a curva de Precisão em Função do Recall da arquitetura da YOLOv5, em que analisando individualmente cada curva, podemos notar que ao aumentar o recall, a precisão diminui o que indica que o modelo inclui mais falsos positivos em diferentes limiares. Para o nosso modelo, o limiar de confiança utilizado foi de 50% que é onde o modelo possui um valor médio de precisão de 0,906 o que indica um bom desempenho na detecção dos componentes das linhas de transmissão.



A Figura 29 mostra a pontuação F1 de 0,87 para todas as classes com um limiar de confiança de 0,502 que demonstra que o modelo de detecção é altamente eficaz na tarefa para

a qual foi projetado. Na Figura 30 é possível visualizar exemplos visuais da detecção realizada com base nos dados de validação.

Figura 29: Curva de F1-Score em Função da Confiança da arquitetura da YOLOv5



Fonte: Elaborado pela própria autora, 2025.

A Tabela 1 apresenta os resultados obtidos para cada classe de componente identificado na linha de transmissão, como precisão (P), recall (R) e mAP (*mean Average Precision*) nos limites de 50% e 50-95%.

Observa-se que a maioria das classes obteve um desempenho satisfatório, com valores de mAP50 acima de 90% para a maioria dos componentes. Por outro lado, algumas classes tiveram desempenho inferior, como a manilha da torre do isolador de polímero e a manilha pequena do isolador de vidro, que apresentaram mAP50 inferiores a 70% o que indica a necessidade de um maior refinamento no treinamento e um maior número de amostras para essas classes.

Figura 30: Detecção de componentes elétricos da linhas de transmissão com YOLO



Fonte: Elaborado pela própria autora, 2025.

Tabela 1: Resultados de cada componente identificado pela YOLO


Classe	Instâncias	Precisão (P)	Recall (R)	mAP50	mAP50-95
Todas	3889	0,901	0,861	0,906	0,702
Espaçador losangular	182	0,877	0,912	0,943	0,853
Amarra balancim	734	0,971	0,988	0,993	0,875
Espaçador quadrangular	17	0,989	0,882	0,942	0,483
Amortecedor Stockbridge	764	0,943	0,955	0,978	0,839
Amarra para-raios	21	0,607	0,667	0,781	0,499
Suspensão para-raios	56	0,97	1	0,995	0,911
Isolador de polímero	199	0,947	0,99	0,982	0,959
Isolador de vidro	919	0,944	0,945	0,978	0,879
Placa de identificação da torre	27	0,981	1	0,995	0,956
Conjunto de Fixação	113	0,961	1	0,994	0,943
Manilha inferior do isolador de polímero	223	0,908	0,793	0,905	0,637
Manilha superior do isolador de polímero	231	0,972	0,983	0,993	0,867
Manilha da torre do isolador de polímero	1	0,784	1	0,995	0,299
Manilha grande do isolador de vidro	109	0,811	0,472	0,612	0,326
Manilha pequena do isolador de vidro	99	0,816	0,492	0,647	0,312
Manilha da torre do isolador de vidro	79	0,868	0,633	0,671	0,432
Amortecedor espiral	115	0,969	0,93	0,991	0,86

Fonte: Elaborado pela própria autora, 2025.

5.2 DESEMPENHO DA RESNET NA CLASSIFICAÇÃO

A Figura 31 mostra a matriz de confusão para o modelo de classificação da ResNet que classificou corretamente 81% das previsões em relação aos dados de validação. Para a classe *bad*, o modelo possui um recall de 83% e precisão de 69%, o que significa que detecta bem, mas não é tão preciso. Para a classe *good*, o modelo possui um recall de 81% e precisão de 90% que demonstra bem o equilíbrio bem das previsões corretas e falsos positivos.

Na Figura 32 é possível visualizar exemplos visuais da classificação realizada com base nos dados de validação da Rede Neural Convolutiva (CNN).



Fonte: Elaborado pela própria autora, 2025.


5.3 AVALIAÇÃO DA INTEGRAÇÃO YOLOV5 E RESNET

A YOLOv5 foi responsável pela detecção dos componentes, enquanto a ResNet foi integrada ao modelo para classificar 5 das 18 classes detectadas como "*bad*" ou "*good*". Assim, essa integração permite identificar os componentes e avaliar sua condição. Nesse contexto, na Figura 33, são exibidos exemplos visuais que ilustram as detecções e a classificação de alguns componentes utilizando a integração desses dois modelos.

A abordagem visual destaca a precisão da YOLO na identificação dos componentes e a capacidade da ResNet na classificação dos equipamentos como bons ou ruins. Na prática os resultados são mostrados visualmente com cores deferentes nas *bounding boxes* de acordo com a classificação da rede neural:

- **Caixa verde:** Componente detectado e classificado como bom;
- **Caixa vermelha:** Componente detectado e classificado como ruim;
- **Caixa amarela:** Componente detectado, mas sem classificação.

Figura 33: Classificação e detecção com Yolo e ResNet



Fonte: Elaborado pela própria autora, 2025.

6 CONCLUSÃO

Este trabalho teve como objetivo desenvolver um algoritmo de aprendizagem de máquina para identificação de componentes da estrutura de linhas de transmissão, além de classificar esses componentes em casos de anomalias, como ferrugem, presença de ninhos de pássaros ou peças quebradas. Esses problemas podem afetar negativamente tanto a segurança quanto eficiência do sistema elétrico por isso é fundamental desenvolver soluções automatizadas para manutenção preventiva.

Inicialmente, foi realizado um estudo sobre os fundamentos de aprendizado de máquina, bem como as ferramentas utilizadas para parametrização e aplicação dos modelos preditivos, como a arquitetura YOLOv5 para detecção dos componentes e a utilização da Rede Neural Convolutiva (CNN), ResNet, para classificação de alguns elementos defeituosos em linhas de transmissão.

Os resultados alcançados ao combinar as duas técnicas de aprendizado de máquina indicam que a utilização desse tipo de tecnologia pode tornar a supervisão das linhas de transmissão mais eficiente e segura, reduzindo a necessidade de inspeções manuais e permitindo uma detecção precoce de problemas.

De forma geral, o sistema de detecção de anomalias apresentou bons resultados em termos de tempo e precisão nos experimentos realizados. No entanto, foram identificadas algumas limitações, como as variações nos fundos das imagens no conjunto de dados, a quantidade limitada de dados para classificação de componentes com defeitos e o desequilíbrio das classes na ResNet. Atualmente, apenas 5 dos 18 componentes detectáveis são classificados como defeituosos ou não pelo modelo, indicando a necessidade de melhorias no equilíbrio e na quantidade de dados disponíveis.

REFERÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO (Brasil). **Sistema Interligado Nacional**. Brasília: ANA, s.d. Disponível em: <https://www.ana.gov.br/sar/sin>. Acesso em: 11 jan. 2025.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **ANEEL 25 anos**: conheça os caminhos da regulação e a história do setor elétrico brasileiro. Brasília: ANEEL, 2022. Disponível em: <https://www.gov.br/aneel/pt-br/assuntos/noticias/2022/aneel-25-anos-conheca-os-caminhos-da-regulacao-e-a-historia-do-setor-eletrico-brasileiro>. Acesso em: 11 jan. 2025.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Caminhos da regulação**. Brasília: ANEEL, 2022. Disponível em: <https://caminhosregulacao.aneel.gov.br/caminhos3.asp>. Acesso em: 10 jan. 2025.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Matriz elétrica teve aumento de 10,9 GW em 2024, maior expansão da série histórica**. Brasília: ANEEL, 2025. Disponível em: <https://www.gov.br/aneel/pt-br/assuntos/noticias/2025/matriz-eletrica-teve-aumento-de-10-9-gw-em-2024-maior-expansao-da-serie-historica>. Acesso em: 10 jan. 2025.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **PRODIST**: procedimentos de Distribuição de Energia Elétrica. Brasília: ANEEL, 2023. Disponível em: https://www2.aneel.gov.br/cedoc/aren2018842_prodinst_modulo_1_v10.pdf. Acesso em: 10 jan. 2025.
- ARAÚJO, Roberto Pereira d'. **O setor elétrico brasileiro**: uma aventura mercantil. Rio de Janeiro: Paz e Terra, 2009
- BICHELS, Arlei. **Sistemas elétricos de potência**: métodos de análise e solução. Curitiba: EDUTFPR, 2018.
- CARVALHO, Geraldo. **6 tipos de isoladores elétricos que você precisa conhecer**. AAS Abrasivos, 2023. Disponível em: <https://www.aasabrasivos.com.br/blog/categorias/artigos/6-tipos-de-isoladores-eletricos-que-voce-precisa-conhecer>. Acesso em: 12 jan. 2025.
- CHOLLET, François. **Deep learning with Python**. 2. ed. Shelter Island: Manning, 2021.
- DIFERENÇA entre linha de distribuição e transmissão. **Energes**, 2023. Disponível em: <https://energes.com.br/diferenca-entre-linha-de-distribuicao-e-transmissao/>. Acesso em: 12 jan. 2025.
- DIFFERENCES between transmission tower lines and distribution tower lines. **Steel Tower CHN**, 2023. Disponível em: <https://www.steeltowerchn.com/en/differences-between-transmission-tower-lines-and-distribution-tower-lines/>. Acesso em: 12 jan. 2025.
- ESCOVEDO, Tatiana; KOSHIYAMA, Adriano S. **Introdução a data science**: algoritmos de machine learning e métodos de análise. São Paulo: Casa do Código, 2020.

ESCOVEDO, Tatiana. **Machine learning: conceitos e modelos parte 1: aprendizado supervisionado.** Medium, 2020. Disponível em: <https://tatianaesc.medium.com/machine-learning-conceitos-e-modelos-f0373bf4f445>. Acesso em: 12 jan. 2025.

FLORES, Sebastián. **Inspeção de linhas de transmissão de forma automatizada: como fazer?** Pixforce, 19 mar. 2024. Disponível em: <https://pixforce.ai/pt-br/como-a-inspecao-de-linhas-de-transmissao-tem-sido-aprimorada-com-a-inteligencia-artificial/>. Acesso em: 12 jan. 2025.

FLORES, Sebastián. **Visão computacional: um guia completo para tirar suas dúvidas.** Pixforce, 24 abr. 2024. Disponível em: <https://pixforce.com/pt-br/visao-computacional-um-guia-completo-para-tirar-suas-duvidas/>. Acesso em: 12 jan. 2025.

GOMES, Gabriel Ribeiro. **Detecção e classificação de falhas em linhas de transmissão aéreas utilizando técnicas de aprendizado de máquina.** Projeto de Graduação (Engenharia Elétrica) – Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2022. Disponível em: <http://www.repositorio.poli.ufrj.br/monografias/projpoli10038966.pdf>. Acesso em: 12 jan. 2025

GOMES, João Vitor Esteves. **Detecção de objetos com a arquitetura YOLO.** Trabalho de Conclusão de Curso (Graduação em Sistemas de Informação) – Instituto de Ciências Exatas e Aplicadas, Universidade Federal de Ouro Preto, João Monlevade, 2022. Disponível em: https://www.monografias.ufop.br/bitstream/35400000/4746/6/MONOGRAFIA_Detec%a7%a3oObjetosArquitetura.pdf. Acesso em: 12 jan. 2025

JAMES, G. *et al.* **An introduction to statistical learning.** New York: Springer, 2013.

KAMADO, Lucas Mity; SILVA, Murilo Vargas da. Detecção automática de placas veiculares utilizando aprendizado de máquina profundo. In: CONGRESSO DE INOVAÇÃO, CIÊNCIA E TECNOLOGIA DO IFSP, 12., 2021, São Paulo. **Anais [...]**. São Paulo: Instituto Federal São Paulo, Campus Cubatão - IFSP, 2021. Disponível em: <https://ocs.ifsp.edu.br/conict/xiiconict/paper/viewFile/7762/2333>. Acesso em: 15 jan. 2025.

LEMOS, Rafael. *et al.* Visão computacional: identificação de contêineres e pessoas através da YOLO CNN. In: MOSTRA DA PRODUÇÃO UNIVERSITÁRIA, 22., 2023, Rio Grande. **Anais [...]**. Rio Grande: Universidade Federal do Rio Grande – FURG, 2023. Disponível em: https://www.researchgate.net/publication/375086321_Visao_Computacional_Identificacao_e_Conteineres_e_Pessoas_atraves_da_YOLO_CNN. Acesso em: 15 jan. 2025.

LI, Z. *et al.* A survey of convolutional neural networks: analysis, applications, and prospects. **IEEE Transactions on Neural Networks and Learning Systems**, v. 32, n. 1, p. 1-21, 2021. Disponível em: <https://ieeexplore.ieee.org/document/9451544> . Acesso em: 20 jan. 2025

MATTEDE, Henrique. **Um pouco mais sobre o Sistema Elétrico de Potência (SEP).** Mundo da Elétrica, 2022. Disponível em: <https://www.mundodaeletrica.com.br/um-pouco-mais-sobre-o-sistema-eletrico-de-potencia-sep/>. Acesso em: 09 jan. 2025.

O que é uma rede neural? **IBM.** Disponível em: <https://www.ibm.com/br-pt/topics/neural-networks>. Acesso em: 12 jan. 2025.

O que é sep (sistema elétrico de potência)? **Tecnogera**, 2022. Disponível em: <https://blog.tecnogera.com.br/blog/o-que-e-sep-sistema-eletrico-de-potencia>. Acesso em: 08 jan. 2025.

OLIVEIRA, Cláudia Almerinda de Souza; *et al.* Aplicação de uma rede neural artificial YOLO para controle de estoque por imagens em uma revenda de autopeças. **REGRASP – Revista Para Graduandos / IFSP-Câmpus São Paulo**, v. 8, n. 2, p. 21-43, jul. 2023. Disponível em: <https://regrasp.spo.ifsp.edu.br/index.php/regrasp/article/view/1132/878>. Acesso em: 15 jan. 2025.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO (Brasil). **O sistema em números**. [S.l.]: ONS, [s.d.]. Disponível em: <https://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>. Acesso em: 06 jan. 2025.

REDMON, J. *et al.* You only look once: unified, real-time object detection. **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, 2016. Disponível em: https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Redmon_You_Only_Look_CVPR_2016_paper.pdf. Acesso em: 15 jan. 2025.

SABINO, João Vitor. *et al.* Utilizando processamento de imagens e YOLO para a construção de um sistema de navegação de um drone com aplicação em uma indústria. **Colloquium Exactarum**. ISSN: 2178-8332, [S. l.], v. 13, n. 4, p. 42–53, 2022. Disponível em: <https://journal.unoeste.br/index.php/ce/article/view/4098>. Acesso em: 20 jan. 2025.

SILVA, André Luiz Buarque Vieira e. *et al.* InsPLAD: a dataset and benchmark for power line asset inspection in UAV images. **International Journal of Remote Sensing**, v. 44, n. 23, p. 1–27, 2023. Disponível em: https://www.researchgate.net/publication/376015075_InsPLAD_A_Dataset_and_Benchmark_for_Power_Line_Asset_Inspection_in_UAV_Images. Acesso em: 20 jan. 2025.

YOLO models documentation. **Ultralytics**, 2024. Disponível em: <https://docs.ultralytics.com/models/yolo11/>. Acesso em: 20 jan. 2025.

VIER, Gustavo Bystronski. **Manutenção de linhas de transmissão: metodologia multicritério para priorização da correção de defeitos em linhas de transmissão**. 2019. 68 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade do Vale do Rio dos Sinos, São Leopoldo, RS, 2019. Disponível em: <https://repositorio.jesuita.org.br/handle/UNISINOS/9271>. Acesso em: 20 jan. 2025.

XAVIER, Leonardo Mendes Sousa. **Aplicações de aprendizado de máquina na detecção de anomalias em sistemas eólicos**. 2024. 102 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Pernambuco, Recife, 2024. Disponível em: <https://repositorio.ufpe.br/handle/123456789/56306>. Acesso em: 10 jan. 2025.

ZHAO, Z.-Q. *et al.* Object detection with deep learning: a review. **IEEE Transactions on Neural Networks and Learning Systems**, v. 30, n. 11, p. 3212–3232, 2019. Disponível em: <https://www.semanticscholar.org/reader/7998468d99ab07bb982294d1c9b53a3bf3934fa6>. Acesso em: 08 jan. 2025.