



Monitoramento Inteligente de Manutenção em Linha Viva com Visão Computacional e Mapeamento 3D

Tema: Linhas de Distribuição até 138 Kv aéreas e subterrâneas

Autores: Grégori da Cruz Balestra; Alexandre Silva Pinto

Co-Autores: Antonio Roberto Donadon; Vitor Tosetto; Flavia Manica Siviero; Luciane Calabria; Klysman Hoentsch; Tales Brumon Medeiros de Figueiredo

Empresa: Pix Force S.A.

Resumo

A manutenção de redes elétricas energizadas, também conhecida como Linha Viva, é uma prática essencial para garantir a continuidade do fornecimento de energia elétrica, mas apresenta desafios significativos relacionados à segurança operacional e eficiência nas inspeções de componentes críticos. Este estudo apresenta o desenvolvimento e validação de um sistema automatizado para monitoramento de segurança em manutenções de Linha Viva, integrando inteligência artificial, visão computacional e mapeamento tridimensional. O sistema utiliza a arquitetura YOLOv8 para a detecção e segmentação de componentes críticos, como condutores e isolantes, com base em um dataset sintético gerado no simulador Isaac Sim, da NVIDIA. A câmera estereoscópica ZED Mini X foi empregada para capturar imagens estereoscópicas e estimar profundidade, possibilitando a reconstrução tridimensional da cena e a geração de nuvens de pontos. Além disso, keypoints humanos foram monitorados para avaliar o posicionamento do eletricitista em relação a componentes energizados, promovendo maior segurança durante as operações. Os resultados demonstraram alta precisão nas tarefas de detecção e segmentação, além de eficácia na emissão de alertas para situações de risco, indicando o potencial do sistema para aplicação prática em cenários operacionais. O estudo reforça a relevância do uso de IA e visão computacional para aumentar a segurança e a eficiência em atividades de manutenção em ambientes de alta tensão.

1. Introdução

A manutenção de redes elétricas energizadas (Linha Viva) é essencial para evitar interrupções no fornecimento de energia, garantindo continuidade operacional, maior eficiência energética e redução de impactos econômicos para concessionárias e consumidores (Gemma et al., 2022). Contudo, essa prática também representa um grande desafio para as companhias de energia, exigindo rigorosos protocolos de segurança para reduzir riscos de choques elétricos, arcos voltaicos e falhas operacionais. Uma das principais dificuldades enfrentadas nesse contexto é a inspeção eficiente e automatizada dos fios de alta tensão, identificando corretamente quais estão expostos e quais possuem isolamento adequado (Göcsei et al., 2022; Panich & Rukijkanpanich, 2024; Ramirez-Bettoni et al., 2024).

Atualmente, as inspeções são realizadas majoritariamente de forma manual, o que pode levar a erros operacionais e tempo elevado de análise. Os métodos empregados variam com base nos níveis de tensão e

nas condições operacionais, com três técnicas principais: método de contato, que utiliza roupas condutoras para equilibrar o potencial elétrico do eletricitista com a rede, sendo adequado para tensões acima de 69 kV; método à distância, que emprega ferramentas isoladas de longo alcance, como hastes telescópicas, para manipulação segura em redes de média tensão (13,8 kV a 34,5 kV); e o método com luvas isolantes, onde os eletricitistas operam componentes energizados utilizando luvas e mangas de borracha em redes de até 34,5 kV, sendo essencial para tarefas rotineiras de manutenção (Badgujar & Shirpur, 2019; Oltean et al., 2014).

Para mitigar os perigos associados a esses serviços, o uso de inteligência artificial (IA) e visão computacional tem se mostrado uma solução promissora, permitindo a identificação automática de componentes da rede elétrica, monitoramento contínuo, detecção de riscos em tempo real e suporte à tomada de decisão durante operações em redes energizadas. Os benefícios observados com o uso dessas técnicas é, principalmente, o aumento da segurança dos técnicos envolvidos e da eficiência operacional (Liu et al., 2023; Aderamo et al., 2024; Trivedi & Alqanhtani, 2024).

Em contextos onde a inspeção manual é insuficiente ou arriscada, a capacidade de modelos de Redes Neurais Convolucionais (CNN), como a YOLO e suas variantes, de realizar detecções rápidas e precisas é valiosa (Sankuri et al., 2024). Seu uso permite a identificação em tempo real de diversos componentes em redes elétricas, sendo particularmente relevante no contexto da manutenção de linhas vivas, onde a capacidade de identificar objetos de forma rápida e precisa pode prevenir acidentes e aumentar a segurança operacional (Santos et al., 2020; Wang et al., 2024).

A pesquisa de Liu et al. (2023) destaca o uso YOLO-CSM na detecção de defeitos e objetos estranhos em componentes de linhas de transmissão, utilizando drones para inspeção. O estudo indica que o uso dessa técnica não apenas diminui o custo inicial e melhora a flexibilidade na implementação, mas também aumenta a segurança ao minimizar a necessidade de inspeções manuais em áreas de risco.

Uma pesquisa realizada por Nguyen et al. (2019) propõe um sistema de detecção e classificação em múltiplas etapas que mostrou precisão na identificação de falhas comuns em componentes de linhas de energia. Esse argumento é complementado por estudos que exploram a aplicação de visão computacional em cenários de inspeção de linhas de transmissão, onde a precisão e a velocidade são fundamentais para a manutenção proativa e a prevenção de falhas (Sankuri et al., 2024). A integração de algoritmos de visão computacional em sistemas de monitoramento de redes elétricas pode transformar a abordagem de manutenção em linhas de energia, aumentando a eficiência e a segurança operacional (Lin & Kuo, 2024). Nesse contexto, o presente estudo buscou desenvolver e validar um sistema baseado em IA e visão computacional para detecção de componentes em rede elétrica e monitoramento da posição dos eletricitistas durante a manutenção em linha viva. O trabalho visa contribuir para aumentar a segurança dos trabalhadores, reduzindo riscos operacionais e permitindo uma abordagem proativa e preditiva na prevenção de acidentes.

Para isso, foram utilizadas CNNs baseadas na arquitetura YOLOv8 para a segmentação automática de fios de alta tensão expostos e isolados, com suporte de imagens sintéticas provenientes de câmeras especializadas com percepção de profundidade avançada. O desenvolvimento do modelo partiu da geração de um dataset sintético, com cenários simulados no Isaac Sim, da NVidia, utilizados para o treinamento e validação do modelo. Após, foi analisada a eficácia do modelo simulando o uso da câmera ZED para captura de imagens, considerando sua posição e ângulo de captura real, sendo possível a recriação de modelos 3D dos ativos e dos eletricitistas.

2. Desenvolvimento

A primeira etapa do estudo consistiu na criação de um ambiente virtual para gerar um dataset sintético, utilizando o Isaac Sim, um simulador de física desenvolvido pela NVidia. A utilização de simulação se beneficia da redução de custos em configurar cenários e capturar dados, bem como permite a emulação de diversos casos de forma ágil e prática. No caso de manutenções em linha viva, a simulação é uma alternativa que dispensa a visita in loco de técnicos e desenvolvedores durante a fase de desenvolvimento e validação inicial do sistema. Além disso, a escolha desta plataforma de simulação se deu pelo suporte à câmera ZED X, da Stereolabs, usada para capturas de imagens estéreis, e por possuir módulos consolidados para a geração e rotulagem de datasets sintéticos de forma automatizada, bem como, a aleatorização controlada da posição, rotação, escala e configuração de inúmeros atributos dos elementos de interesse.

Desta forma, foram modelados elementos básicos, como poste, cruzeta, isolantes de porcelana, condutores, coberturas de condutor, de pino e de cruzeta e caixa aérea, e adicionadas representações humanas, simulando a atuação dos trabalhadores no ambiente de risco. Foram criadas 5.000 imagens, contemplando diferentes condições ambientais, como variações de iluminação e ângulos de captura, além de alterações nos elementos estruturais da rede elétrica, garantindo um conjunto de dados diversificado e representativo para a tarefa de segmentação. A anotação dessas imagens foi realizada de forma automatizada utilizando a ferramenta Replicator, um módulo integrado ao Isaac Sim que permite a rotulagem eficiente e precisa dos componentes na cena.

Essa aplicação permitiu executar, aleatorizar elementos, capturar frames e gerar máscaras de segmentação, bounding boxes e mapas de profundidade. Para a detecção de elementos da linha viva, bem como coberturas e elementos de isolamento, foi definida a utilização de máscaras de segmentação, o que permitiu que algoritmos de treinamento pudessem segmentar a região da imagem onde objetos de interesse estivessem posicionados. Também, foi possível converter tais máscaras de segmentação em bounding boxes, caso fosse necessário treinar modelos somente para detectar a presença de elementos específicos da imagem.

Na Figura 1, é possível visualizar um exemplo de imagem que compôs o dataset gerado com Isaac Sim (a) e sua respectiva máscara de segmentação (b). Os condutores e os isolantes de porcelana estão representados em verde, a cruzeta em azul, a cobertura da cruzeta em rosa e a cobertura de condutor em amarelo.




Figura 1 - Cena gerada pelo replicator do Isaac Sim (a) e máscara de segmentação (b).

Esse processo possibilitou a segmentação detalhada dos fios expostos e isolados, além de outras estruturas elétricas adjacentes, sem a necessidade de intervenção humana na marcação dos elementos. Com essa abordagem, o treinamento da rede neural pôde ser realizado sobre um conjunto de dados previamente estruturado e consistente, garantindo maior confiabilidade na detecção dos componentes.

2.1. Segmentação e treinamento do modelo

Para a segmentação e treinamento do modelo, foram consideradas seis classes de interesse: condutor (fio), isolante (porcelana), cruzeta, cobertura de condutor, cobertura da cruzeta e cobertura do pino (isolante/porcelana). A arquitetura escolhida para a modelagem do sistema foi a YOLOv8-seg, que permite, além da detecção e classificação de objetos, a delimitação da forma exata dos alvos de interesse e o treinamento de redes neurais para segmentação utilizando pesos pré-treinados no conjunto de dados COCO, que contém milhões de imagens anotadas com diversos tipos de objetos reais. Isso permitiu o aprendizado de formas comuns, reduzindo o tempo e os dados necessários para treinar o modelo de segmentação. Para garantir um aprendizado robusto e eficiente, o modelo foi configurado para um total de 500 épocas de treinamento, ajustando os pesos e parâmetros iterativamente, buscando minimizar erros e otimizar a capacidade de classificação. O critério de *early stopping* (*patience*) adotado foi de 100, para evitar *overfitting*, utilizando *batch size* de 6, imagens de 1280 pixels de resolução e os pesos pré-treinados no COCO para acelerar a convergência. Apesar de serem previstas 500 épocas de execução, a rede interrompeu seu treinamento no episódio 461, depois de observar que não houve aprendizado nos últimos 100 episódios.

2.2 Validação do modelo

A validação do modelo foi realizada por meio da análise de métricas coletadas ao longo do desenvolvimento. Essas métricas contemplaram as perdas na detecção de caixas delimitadoras, na segmentação, classificação e localização focalizada, tanto na fase de treinamento quanto na validação. Além disso, foi verificado o comportamento quanto à precisão e *recall* da detecção de caixas delimitadoras e na segmentação de objetos, além da precisão média dessas mesmas tarefas para IoU (*Intersection over Union*) 0,5 e IoU entre 0,5 e 0,95. Na Figura 2 são apresentados os resultados para as perdas registradas no treinamento do modelo e na Figura 3 na validação.




Figura 2 - Perdas registradas durante o treinamento do modelo.

Os gráficos apresentados na Figura 2 mostram uma redução progressiva nas perdas ao longo das épocas, refletindo o aprendizado do modelo. Na métrica de detecção de caixas delimitadoras (a), observa-se que a perda inicial, em torno de 0,7, diminui rapidamente nas primeiras 100 épocas, estabilizando-se em valores próximos de 0,3 após cerca de 400 épocas. A curva de segmentação (b) segue um comportamento similar, partindo de valores iniciais próximos a 0,7 e convergindo para aproximadamente 0,25. Já a métrica de classificação (c) apresenta um padrão consistente, com a perda inicial mais elevada, de 0,8, e estabilização em torno de 0,2. Por fim, a perda de localização focalizada (d) começa em 0,95 e apresenta uma diminuição mais sutil, estabilizando-se em torno de 0,8.

Esses resultados indicam que o modelo foi capaz de aprender a realizar as tarefas de detecção, segmentação, classificação e localização de forma eficiente, convergindo para perdas baixas em todas as métricas avaliadas, o que reflete um bom ajuste dos parâmetros e eficácia no treinamento. A estabilização das perdas

em valores baixos é um forte indicativo de que o modelo alcançou um ponto de equilíbrio entre aprendizado e generalização, sem sinais aparentes de *overfitting*.




Figura 3 - Perdas registradas no conjunto de validação do modelo.

Na validação do modelo, as perdas diminuíram gradativamente à medida que o modelo se ajustava aos dados. No gráfico de detecção de caixas delimitadoras (a), as perdas iniciais começam em aproximadamente 0,6 e apresentam uma redução consistente, estabilizando-se em torno de 0,3 após 400 épocas. Um comportamento semelhante é observado no gráfico de segmentação (b), onde as perdas começam próximas de 0,6, estabilizando-se em torno de 0,45. As oscilações iniciais nesse gráfico indicam que o modelo realizou ajustes mais significativos nas épocas iniciais, o que é esperado devido à maior complexidade da tarefa de segmentação.

O gráfico de classificação (c) apresenta uma perda inicial de cerca de 0,45, reduzindo rapidamente e estabilizando em 0,2, evidenciando um bom ajuste do modelo para identificar corretamente as classes dos objetos. Por fim, no gráfico de localização focalizada (d), as perdas começam mais elevadas (0,84) e diminuem gradualmente até valores próximos de 0,74, indicando uma convergência mais lenta nessa métrica, possivelmente devido à precisão exigida para localizar os objetos de forma refinada.

Na Figura 4 são apresentados os gráficos obtidos para a precisão e *recall* na detecção de caixas delimitadoras e na segmentação de objetos. Para as métricas de classificação e localização focalizada não foram realizadas essas análises pelo fato dessas tarefas já estarem contempladas indiretamente pelas métricas principais. O desempenho de classificação está integrado às métricas gerais de detecção e segmentação, e a métrica de localização focalizada está avaliada através de métricas de perda contínua e refletida no mAP.

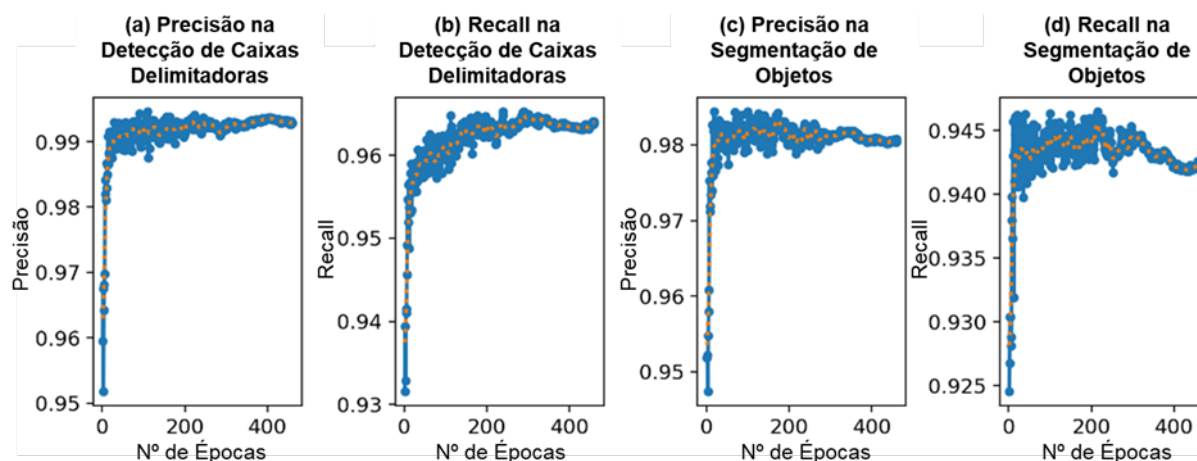


Figura 4 - Precisão e Recall do modelo.

A precisão na detecção de caixas delimitadoras, como demonstrado no gráfico da Figura 4 (a), mede a proporção de detecções corretas (verdadeiros positivos) em relação ao total de detecções realizadas. Observa-se uma estabilização da métrica em valores acima de 0,99 após aproximadamente 200 épocas, indicando que o modelo foi capaz de detectar com alta confiabilidade os objetos dentro das imagens, minimizando falsos positivos. Já o segundo gráfico, que representa o *recall* na detecção de caixas delimitadoras (b), ou seja, a capacidade do modelo de identificar corretamente os objetos presentes na imagem (verdadeiros positivos em relação ao total de objetos reais), apresentou resultados iniciando em torno de 0,93, crescendo de forma consistente e estabilizando acima de 0,96 nas épocas finais, indicando que o modelo conseguiu detectar a maior parte dos objetos reais presentes nas imagens. O gráfico da precisão na segmentação de objetos (c) apresenta os resultados da proporção de pixels segmentados corretamente em relação ao total de pixels classificados pelo modelo, foi elaborado. Essa métrica iniciou em torno de 0,95 e apresentou uma rápida elevação, estabilizando acima de 0,98 após cerca de 200 épocas, refletindo que o modelo realizou a segmentação com alta exatidão, minimizando pixels incorretamente atribuídos. Ainda, o gráfico do *recall* na segmentação de objetos (d), mediu a proporção de pixels verdadeiros corretamente identificados em relação ao total de pixels reais da classe, iniciando em torno de 0,925 e crescendo rapidamente até estabilizar em valores próximos a 0,945 após aproximadamente 200 épocas. A oscilação leve nas épocas finais pode ser atribuída à maior complexidade da tarefa de segmentação, que requer maior refinamento em comparação à detecção.

Os resultados dos gráficos mostram que o modelo alcançou altos valores de precisão e *recall* em ambas as tarefas, com desempenho consistente ao longo do treinamento. A estabilização das métricas após 200 épocas é uma evidência de que o modelo atingiu um ponto de convergência, com baixo risco de *overfitting* e alta generalização. Esses resultados confirmam a eficácia do modelo para identificar e segmentar objetos em cenários de redes elétricas, com alta confiabilidade tanto na detecção quanto na segmentação.

A Figura 5 apresenta os gráficos relacionados à precisão média (mAP) para as tarefas de detecção de caixas delimitadoras e segmentação de objetos. Os gráficos avaliaram o desempenho do modelo ao longo das 500 épocas de treinamento em dois cenários principais: mAP50, que indica a precisão a um limiar de IoU de 0,5 e mAP50-95, que demonstra a precisão média para múltiplos limiares de IoU entre 0,5 e 0,95.




Figura 5 - Precisão média (mPA) do modelo para IoU 0,5 e IoU entre 0,5 e 0,95.

Quanto à mAP50 para a detecção de caixas delimitadoras (a), os valores iniciais começaram em aproximadamente 0,955 e rapidamente aumentaram, estabilizando acima de 0,975 após cerca de 200 épocas, refletindo a alta capacidade do modelo em detectar objetos com precisão elevada, mesmo com limiares relaxados de IoU. Ainda para a detecção de caixas delimitadoras, o comportamento da precisão média

observada para o IoU entre 0,5 e 0,95 (b) foi similar, com valores iniciais em torno de 0,82 e estabilização acima de 0,94 após 200 épocas, indicando que o modelo consegue manter boa precisão em múltiplos limiares de IoU, o que demonstra sua robustez para detectar objetos de diferentes tamanhos e formas. O gráfico (c) representa o comportamento do modelo quanto à métrica mAP50 para segmentação. Os valores iniciais começaram próximos a 0,945 e aumentaram rapidamente, estabilizando acima de 0,96 após cerca de 150 épocas, o que demonstra alta eficácia em segmentar objetos com precisão elevada, garantindo que a maioria dos pixels segmentados pertence corretamente às classes identificadas. Já os resultados observados para precisão média na segmentação dos objetos com IoU entre 0,5 e 0,95 (d) refletiu um comportamento consistente com as outras métricas, com valores iniciando em torno de 0,82 e estabilizando acima de 0,86 após cerca de 200 épocas. Esse desempenho destaca que o modelo mantém boa precisão em múltiplos limiares de IoU, especialmente para objetos complexos ou pequenos.

Os resultados demonstram que o modelo obteve alto desempenho na detecção e segmentação, com precisão elevada e estabilidade das métricas após 200 épocas, indicando convergência eficiente sem overfitting. A diferença entre mAP50 e mAP50-95 era esperada, pois limiares mais rigorosos aumentam a exigência na avaliação. Esses achados confirmam a robustez do modelo para aplicações práticas, garantindo confiabilidade na manutenção e monitoramento automatizado de redes elétricas, com resultados consistentes ao longo do treinamento.

Ainda, para avaliar o desempenho do modelo em classificar diferentes categorias de objetos, foi elaborada uma matriz de confusão normalizada, apresentada na Figura 6, com valores variando de 0 a 1. A intensidade da cor reflete a magnitude desses valores (quanto mais escuro, maior a precisão). A diagonal principal da matriz contém as previsões corretas (onde a classe prevista coincide com a classe verdadeira), enquanto as células fora da diagonal representam erros de classificação (confusões entre classes).




Figura 6 - Matriz de confusão do modelo de segmentação.

A matriz reafirma que o modelo apresentou alto desempenho na classificação das classes avaliadas, com Cobertura do Pino, Cobertura do Condutor e Isolante atingindo 100% de precisão, sem qualquer erro de classificação. A Cobertura da Cruzeta também obteve excelente desempenho, com 99% de precisão e apenas 1% de confusão com o background. A classe Condutor teve 96% de acerto, com pequenas confusões (4%) com o *background*, enquanto a Cruzeta obteve a menor precisão, com 87%, apresentando confusões em 13% dos casos.

Vale ressaltar que os erros de classificação estão principalmente relacionados ao *background*, o que é esperado em cenários de visão computacional com objetos complexos ou de pequeno porte. Com relação à classe cruzeta, que teve o maior número de confusões, pode ser suposto que isso se dá devido à semelhança visual em determinadas condições, podendo ser refinada com mais dados ou ajustes no treinamento. Na Figura 7 é apresentada uma imagem gerada no conjunto de testes, segmentada a partir do treinamento realizado. O modelo demonstrou capacidade de identificar diversos elementos na cena, como condutores, cruzetas, coberturas de condutor e isolantes, utilizando *bounding boxes* com rótulos que indicam a classe do objeto e a confiança da predição, destacadas por cores distintas para facilitar a diferenciação.




Figura 7: Imagem de teste segmentada após treinamento do modelo.

A imagem também demonstra que o modelo foi capaz de realizar segmentações detalhadas, especialmente em isolantes e coberturas de cruzetas, com alta precisão e confiança atribuída à maioria das detecções, evidenciando a boa generalização em relação às classes treinadas. O eletricitista também foi claramente identificado, cercado por objetos corretamente classificados, sugerindo que o modelo pode ser utilizado para monitorar seu posicionamento em relação a componentes energizados, promovendo maior segurança durante operações em linha viva. No entanto, algumas caixas delimitadoras de condutores apresentam sobreposições ou confianças mais baixas, como "condutor 0.75", possivelmente devido à similaridade visual com o *background* ou à oclusão parcial causada por outros objetos, como cruzetas.

2.2 Mapeamento 3D e monitoramento de segurança em linha viva

O sistema de monitoramento baseia-se na captura de dados tridimensionais utilizando uma câmera especializada com percepção de profundidade avançada. A simulação contemplou a representação do cenário real de captura de imagens, composto por uma câmera estereoscópica Stereolabs ZED X, posicionada estrategicamente no topo do poste. Essa câmera, equipada com duas lentes, permite a obtenção de imagens estéreo que foram processadas para estimar a profundidade e reconstruir a posição 3D dos elementos da cena. No simulador Isaac Sim, foi modelado um protótipo que reproduziu o cenário de instalação da câmera no alto do poste, posicionada cerca de 4 cm acima da cruzeta, com inclinação de 26° e foco direcionado para a linha viva, garantindo que os elementos de interesse fossem monitorados com precisão. Esse protótipo

possibilitou a geração de dados sintéticos, usados para calibrar o sistema e verificar o desempenho da câmera em diferentes configurações.

Para realizar a reconstrução tridimensional dos elementos da linha viva foi utilizado o conjunto de ferramentas e bibliotecas SDK (*Software Development Kit*) fornecido pela Stereolabs para a câmera ZED, que oferece suporte para operações como captura de imagens estereoscópicas, estimação de profundidade, detecção e rastreamento de objetos, reconstrução 3D, monitoramento de pessoas (*keypoints*) e integração com *frameworks* de visão computacional e aprendizado de máquina. Além disso, foi possível gerar nuvens de pontos detalhadas, associando os dados de profundidade a cada objeto identificado pelo modelo, permitindo que os elementos detectados fossem segregados por classe, identificando sua posição no espaço tridimensional, bem como suas bordas, dimensões e extremidades. As nuvens de pontos geradas forneceram informações essenciais para o monitoramento, permitindo que o sistema avaliasse com precisão a interação entre os objetos e o eletricitista.

Dessa forma, foi possível gerar imagens reproduzindo o cenário real, com o eletricitista realizando o trabalho na linha viva. Na Figura 8 são apresentadas duas imagens emuladas pelo Isaac Sim, uma com a lente esquerda da câmera (a) e outra com a direita (b), capturando a cena do ângulo configurado.




Figura 8: Imagens emuladas pelo Isaac Sim no ângulo definido para câmera.

Também foi possível gerar o mapa de calor de profundidade da cena, conforme ilustrado na Figura 9 (a), onde os objetos mais próximos (como os condutores e o eletricitista) são indicados com cores quentes (vermelho e amarelo), enquanto objetos mais distantes são representados em cores frias (azul e verde). Esse tipo de informação foi crucial para estimar a profundidade dos elementos da linha viva, identificando sua posição relativa em um espaço tridimensional, o que permite que o sistema reconheça as relações espaciais entre componentes e possíveis riscos. A nuvem de pontos tridimensional gerada a partir das imagens estéreo capturadas é representada na Figura 9 (b). Cada ponto da nuvem representa uma localização específica no espaço, formando uma reconstrução detalhada dos componentes da linha viva e do eletricitista, possibilitando a identificação com precisão os contornos e a posição exata dos objetos detectados, como os condutores e as cruzetas, além de monitorar o posicionamento do eletricitista em relação a esses elementos.




Figura 9: Mapa de calor e nuvem de pontos.

Essas imagens demonstram a eficácia do uso da câmera ZED X combinada com o SDK para realizar o mapeamento 3D da linha viva e reconstruir cenas complexas em tempo real. Esse mapeamento é a base para o sistema de monitoramento de segurança, permitindo a detecção de riscos através da integração de profundidade, nuvens de pontos e informações adicionais. As representações tridimensionais viabilizam a análise do posicionamento do eletricitista, informação indispensável para análise de risco e configuração para emissão de alertas para prevenir acidentes durante operações de manutenção em linha viva.

As informações tridimensionais foram processadas por um módulo heurístico, cuja função principal foi interpretar o posicionamento e a relação espacial de cada elemento detectado pelo modelo YOLOv8 e pela câmera. Esse módulo não se limitou a identificar a posição central dos objetos, mas todas as regiões ocupadas no espaço tridimensional, considerando bordas, extremidades, dimensões e orientação de cada componente.

Para viabilizar essa análise detalhada, o SDK da ZED permite a geração de nuvens de pontos que segmentam cada objeto detectado, com base nos parâmetros intrínsecos e extrínsecos da câmera. Combinando os rótulos e as *bounding boxes* geradas pelo YOLOv8, cada nuvem de pontos pode ser segregada por classe, associando dados tridimensionais precisos a cada elemento identificado. A Figura 10 exemplifica esse processo, mostrando como os elementos da linha viva, como condutores, cruzetas e isolantes, são reconstruídos em um espaço tridimensional, com cada *cluster* de pontos representado por uma cor distinta.




Figura 10: Nuvem de pontos tridimensional.

O sistema combinou, então, as informações de profundidade, nuvens de pontos e *keypoints* humanos em uma heurística avançada que avaliou continuamente o posicionamento do eletricitista em relação aos componentes da linha viva. A integração dos dados tridimensionais permitiu a detecção de situações de risco, que podem ser utilizados para gerar alertas para prevenir acidentes e garantir a segurança operacional. Essa abordagem amplia a capacidade de monitoramento e contribui para automatizar a análise de cenários críticos em linhas energizadas.

O sistema também incorporou o monitoramento de *keypoints* humanos fornecidos pelo SDK da câmera, representando articulações e partes específicas do corpo do eletricista, como pescoço, nariz e orelhas, elementos que permanecem visíveis durante a operação e são cruciais para avaliar situações de risco. Apesar de o SDK estimar posições mesmo para membros ocluídos, o foco do monitoramento recaiu sobre as áreas expostas, especialmente a face, que são analisadas em conjunto com os objetos tridimensionais para identificar movimentações perigosas.

Na Figura 11 (a) os *keypoints*, representados por pontos azuis interligados, são estimados e sobrepostos à imagem real da cena, destacando articulações e partes específicas do corpo, permitindo monitorar o posicionamento tridimensional do eletricista em relação aos elementos energizados, como condutores e cruzetas. Essa abordagem possibilitou verificar a consistência da estimativa e sua correspondência com a realidade, assegurando a capacidade do sistema de identificar áreas expostas do corpo. Já na Figura 11 (b) os mesmos *keypoints* são representados de forma isolada, em um modelo esquelético tridimensional, o que facilita a análise detalhada do posicionamento do eletricista sem distrações visuais da cena e permite ao sistema interpretar o movimento e a postura do eletricista em relação aos componentes da linha viva, mesmo quando partes do corpo estão ocluídas.




Figura 11: *Keypoints* detectados e estimados pelo modelo.

A integração entre os dados tridimensionais gerados pela câmera ZED e os *keypoints* estimados pelo modelo fornecem dados para que um sistema de monitoramento avalie, em tempo real, o posicionamento do eletricista em relação aos componentes da linha viva. Essa abordagem possibilita identificar situações de risco com alta precisão, ao correlacionar as interações entre os objetos energizados e os pontos críticos do corpo humano, especialmente em áreas não cobertas por EPIs.

3. Conclusão

O presente estudo demonstrou a eficácia da combinação de inteligência artificial, visão computacional e mapeamento tridimensional para ser utilizado no desenvolvimento de um sistema de monitoramento para operações de manutenção em linha viva. A utilização da arquitetura YOLOv8, aliada ao suporte técnico da câmera ZED e ao ambiente de simulação Isaac Sim, permitiu a detecção precisa de componentes elétricos e o acompanhamento do posicionamento do eletricista em tempo real. Os resultados obtidos confirmam a capacidade do modelo em segmentar e monitorar elementos críticos da rede elétrica, enquanto as heurísti-

cas desenvolvidas mostraram-se promissoras na identificação de situações de risco e na geração de alertas preventivos.

O sistema proposto pode ser uma ferramenta para aumentar a segurança dos trabalhadores em cenários de alta complexidade e contribuir para a eficiência operacional, ao aumentar a confiabilidade no diagnóstico de condições perigosas. O uso de datasets sintéticos e modelos tridimensionais oferece uma abordagem inovadora, que pode ser adaptada para diversas aplicações em redes de energia, eliminando a necessidade da exposição de trabalhadores e pesquisadores para a coleta de dados em campo, principalmente em ambientes de alta periculosidade. A continuidade desse estudo visa a expansão do treinamento com dados reais em campo e a validação prática em cenários operacionais, a fim de consolidar a aplicabilidade do sistema em larga escala e explorar novas funcionalidades de monitoramento proativo.

Por fim, agradecemos à CEMIG e a todos os técnicos envolvidos pelo suporte e financiamento deste trabalho, realizado no âmbito do projeto de Pesquisa e Desenvolvimento da Aneel nº P&D-04950-0661. Esse apoio foi essencial para o desenvolvimento das soluções apresentadas, contribuindo significativamente para a inovação do setor de energia. Agradecemos também à NVIDIA pelo fornecimento do simulador Isaac Sim, que desempenhou um papel fundamental na geração de dados sintéticos e na validação do sistema.

4. Referências bibliográficas

- ADERAMO, A. T., OLISAKWE, H. C., ADEBAYO, Y. A., ESIRI, A. E. AI-Driven HSE management systems for risk mitigation in the oil and gas industry. **Comprehensive Research and Reviews in Engineering and Technology**, 2024, v. 02, n. 01, p. 001–022. DOI: <https://doi.org/10.57219/crret.2024.2.1.0059>.
- BADGUJAR, H. A. Live Line Maintenance of Transmission Lines in Indian Perspective-A Review. *International Journal of Engineering Applied Sciences and Technology*, 2019, v. 4, n. 3, p. 157-160. DOI: <http://dx.doi.org/10.33564/ijeast.2019.v04i03.026>.
- GEMMA, S. F. B.; PRIMO, R.; LIMA, F. T. DE; BERGSTROM, G. T.; FERNANDES, A. L.; FRANCO, E. S.; BRITTES, J. L. P.; MISUTA, M. S. Artefatos Tecnológicos e o Trabalho de Eletricistas de Linha Viva. **Revista Psicologia: Organizações & Trabalho (rPOT)**, 2022, v. 22, n. 3, p. 2163-2170. DOI: - <https://doi.org/10.5935/rpot/2022.3.22960>.
- GÖCSEI, G.; NÉMETH, B.; BETTONI, E. R. Arc Protection During High Voltage Live Work. **In**: 13th International Conference on Live Maintenance (ICOLIM), Turin, Italy, 2022, p. 1-6. DOI: <https://doi.org/10.1109/ICOLIM56184.2022.9840583>.
- LIN, Y. T.; KUO, C. C. Real-Time Salt Contamination Monitoring System and Method for Transmission Line Insulator Based on Artificial Intelligence. **Applied Sciences**, 2024, v. 14, n. 4, p. 1506. DOI: <https://doi.org/10.3390/app14041506>.
- LIU, C.; MA, L.; SUI, X.; GUO, N.; YANG, F.; YANG, X.; HUANG, Y.; WANG, X. YOLO-CSM based components defect and foreign object detection on overhead transmission lines. **Research Square Platform LLC**, 2023, v. 22, n. 1. DOI: <http://dx.doi.org/10.21203/rs.3.rs-3639443/v1>
- NGUYEN, V. N.; JENSSEN, R.; ROVERSO, D. Intelligent Monitoring and Inspection of Power Line Components Powered by UAVs and Deep Learning. **In**: IEEE Power and Energy Technology Systems Journal Institute of Electrical and Electronics Engineers (IEEE), 2019, .v. 6, n. 1, p. 11-21. DOI: <http://dx.doi.org/10.1109/jpets.2018.2881429>
- OLTEAN, M. N. Complete solutions for LW maintenance of high voltage OHL. **In**: 2018 IEEE International Conference on Real-time Computing and Robotics (RCAR). Budapest, Hungary, 2014, p. 1-6. DOI: <http://dx.doi.org/10.1109/ICOLIM.2014.6934333>.

PANICH N.; RUKIJKANPANICH, J. Reducing Risks in Maintenance of High-Voltage Transmission Lines. **In: 14th International Conference on Industrial Engineering and Operations Management**, 2024. DOI: <https://doi.org/10.46254/AN14.20240102>.

RAMIREZ-BETTONI, E.; EBLEN, M. L.; NEMETH, B. Analysis of Live Work Accidents In Overhead Power Lines And Other Electrical Systems Between 2010-2022, 2024. **In: IEEE IAS Electrical Safety Workshop (ESW)**, Tucson, AZ, USA, 2024, p. 1-5. DOI: <https://doi.org/10.1109/ESW52258.2024.10752775>.

SANKURI, R. S.; SRI, N. B.; KARRI, S. P. K. SYFLo: augmenting yolo for real-time health monitoring of electric assets in power transmission lines. **Springer Science and Business**, 2024. DOI: <https://doi.org/10.21203/rs.3.rs-4584579/v1>

SANTOS, M. L. Dos; SANTOS, V. N. Dos; MAURICIO, C. R. M.; PERES, F. F. F. Detecção e classificação de objetos em linhas de distribuição de energia utilizando a CNN YOLOv3. **Anais do XVII Congresso Latino-Americano de Software Livre e Tecnologias Abertas (Latinoware 2020)**. **In: Congresso Latino-Americano de Software Livre e Tecnologias Abertas**. Sociedade Brasileira de Computação - SBC, 2020. DOI: <http://dx.doi.org/10.5753/latinoware.2020.18617>

WANG, K.; ZHANG, X.; SUN, Y.; XU, T.; LI, J.; CAO, S. YOLO DFT: An object detection method based on cloud data fusion and transfer learning for power system equipment maintenance. **IET Collaborative Intelligent Manufacturing Institution of Engineering and Technology (IET)**, 2024. DOI: <http://dx.doi.org/10.1049/cim2.12104>