

Eficiência e Gestão de Inspeções de Segurança Setor Elétrico apoiada por Inteligência Artificial

Tema: Pessoas

Autores: Claunir Pavan

Co-Autores: Ana Paula do Espírito Santo Becker, Eduardo Soldateli

Empresa: Celesc Distribuição S.A

Resumo

A promoção da segurança no trabalho é amplamente debatida e requer a adoção de tecnologias inovadoras para modernizar os processos de monitoramento e garantir o cumprimento das normas regulatórias.

Neste contexto, este artigo apresenta uma plataforma tecnológica desenvolvida para monitoramento e inspeção de processos operacionais relacionados à qualidade e à segurança do trabalho em serviços de distribuição de energia elétrica. A solução integra técnicas de inteligência artificial para análise de vídeos captados em campo, possibilitando a detecção automatizada de elementos de interesse, como detectores de tensão, varas de manobra, trabalhadores com capacete e sem capacete. Essa abordagem visa agilizar os processos de inspeção e aumentar a eficiência operacional.

A plataforma tem como principal objetivo reduzir acidentes e aprimorar a segurança dos trabalhadores, oferecendo um painel de indicadores que subsidia a tomada de decisão por meio de ações corretivas, melhorias nos processos e iniciativas de capacitação. A implementação da ferramenta em uma concessionária de energia elétrica comprovou sua eficácia, evidenciando avanços significativos no estado da arte do monitoramento e inspeção de segurança no setor elétrico.

1. Introdução

A prevenção de acidentes no setor elétrico é uma preocupação constante, o que impulsiona a busca por tecnologias inovadoras que modernizem os processos de monitoramento e inspeção, e assegurem o cumprimento das normas regulamentadoras. Entre as atividades intensivas em recursos humanos e tempo está a inspeção de segurança do trabalho, tradicionalmente realizada de maneira presencial. Nesse contexto, um inspetor se desloca até o local de execução do serviço, registra dados em formulários de papel ou eletrônicos, para posterior consolidação e sistematização. Em geral esses dados não são convertidos em informações para fins de análise preditiva.

Nos últimos anos, algumas concessionárias começaram a utilizar câmeras de vídeo embarcadas em veículos ou em estruturas para permitir a inspeção remota, em tempo real ou por meio de análise de gravações. Essa abordagem trouxe benefícios para os setores de segurança do trabalho, pois reduz a necessidade de deslocamentos e amplia a capacidade de supervisão.

O uso de vídeo-monitoramento no setor elétrico já tem um histórico de mais de duas décadas. Em (Yabiku, et al., 2003) apresentaram um projeto para monitoramento de equipamentos em subestações da Companhia

de Transmissão de Energia Elétrica Paulista – CTEEP, visando a supervisão de chaves seccionadoras que apresentavam elevada taxa de falhas durante as manobras.

Em 2006, a Companhia Energética de Minas Gerais - CEMIG - iniciou um projeto para o "Desenvolvimento de Sistema Inteligente de Vídeo-Monitoramento de Subestações para Operação e Segurança Patrimonial". O objetivo era desenvolver uma ferramenta inovadora para vídeo-monitoramento de equipamentos de subestações, integrado a um sistema já existente da CEMIG, para fins de operação e segurança patrimonial (Queiroz, 2017).

Outros projetos destacam a evolução no uso de vídeo-monitoramento. Em 2013, a Endesa Brasil propôs o projeto intitulado "Monitoria Veicular, um Novo Modelo de Gestão dos Riscos e Supervisão" (Reis, 2013), com o objetivo de analisar o comportamento dos profissionais e facilitar investigações de acidentes. Neste caso, veículos eram equipados com câmeras para captação e armazenamento dos vídeos para futura inspeção, por amostragem, por uma equipe de supervisores. Seguindo essa abordagem, a Companhia Paranaense de Energia - COPEL, desenvolveu o "Sistema de vídeo-monitoramento Copel - VMC: Uma solução para a gestão de dados do processo de videomonitoramento de serviços operacionais Copel", apresentado no XXII Seminário Nacional de Distribuição de Energia Elétrica – SENDI (Araujo, 2016). Analogamente à proposta da Endesa Brasil, trata-se da instalação de câmeras nos veículos para a captura de imagens, envio para um servidor central, e análise das imagens por uma equipe de inspetores.

Ainda em 2016, a Centrais Elétricas de Rondônia – CERON, iniciou o desenvolvimento de um projeto intitulado "Sistema de Segurança e Monitoramento Remoto de Técnicos em Manutenção de Sistemas Elétricos – SAFETEC" que objetivou o desenvolvimento de um sistema composto de um dispositivo portátil de gravação e transmissão de dados, através do qual um supervisor pode ver remotamente o que um técnico está fazendo em campo (ANEEL, 2017). No mesmo período, a Companhia Energética do Maranhão – CEMAR apresentou o "Sistema de gestão de segurança – SGS", um sistema de inspeção móvel baseado em formulários eletrônicos com suporte para fotos, que otimizava o registro de dados e facilitava a geração de relatórios. (Calzavara, 2017). O projeto objetivou operacionalizar as atividades de *blitz* e inspeções de segurança com a utilização de dispositivos móveis. Trata-se de um sistema de formulário eletrônico, com recurso de inclusão de fotos, em que o inspetor verifica uma lista de itens a serem inspecionados e registra a sua situação a partir de um *smartphone* ou *tablet*. Após o registro, relatórios permitem o acompanhamento do desempenho das equipes.

Essas iniciativas ilustram a relevância e a recorrência do tema na comunidade acadêmica e empresarial, destacando os esforços contínuos para aprimorar a segurança no setor elétrico. Apesar dos avanços, as soluções existentes ainda exigem que um inspetor visualize manualmente todo o conteúdo capturado em vídeo para concluir a inspeção, o que limita a eficiência do processo.

Diante desse cenário, este artigo apresenta os resultados de um projeto finalizado em 2022 no programa de P&D da Celesc – Centrais Elétricas de Santa Catarina, intitulado "Monitoramento digital em tempo real de aspectos operacionais, de qualidade e segurança do trabalho em serviços da distribuição de energia elétrica", atualmente em operação na Celesc sob o nome de Plataforma Partner. O projeto inova ao empregar recursos de inteligência artificial, mais especificamente visão computacional, para a análise automatizada de vídeos gravados, permitindo a identificação de elementos de interesse, como pessoa com capacete, pessoa sem capacete, vara de manobra e detector de tensão, agilizando o processo de inspeção a partir de vídeos. Além disso, a plataforma coleta e organiza os dados das inspeções, e disponibiliza um painel de indicadores de conformidade que permite a análise preditiva e apoia a tomada de decisões estratégicas e operacionais.

2. Desenvolvimento

2.1 Arquitetura da Plataforma e Funcionalidades

A plataforma proposta consiste em uma infraestrutura composta por um conjunto integrado de software e hardware, projetada para suportar o registro de atividades e inspeções, bem como para gerar estatísticas sobre o desempenho de equipes e empresas. Essas informações podem subsidiar tomadas de decisão tanto estratégicas quanto operacionais. A Figura 1 apresenta a arquitetura da plataforma, que está organizada em módulos didaticamente estruturados para facilitar a compreensão.

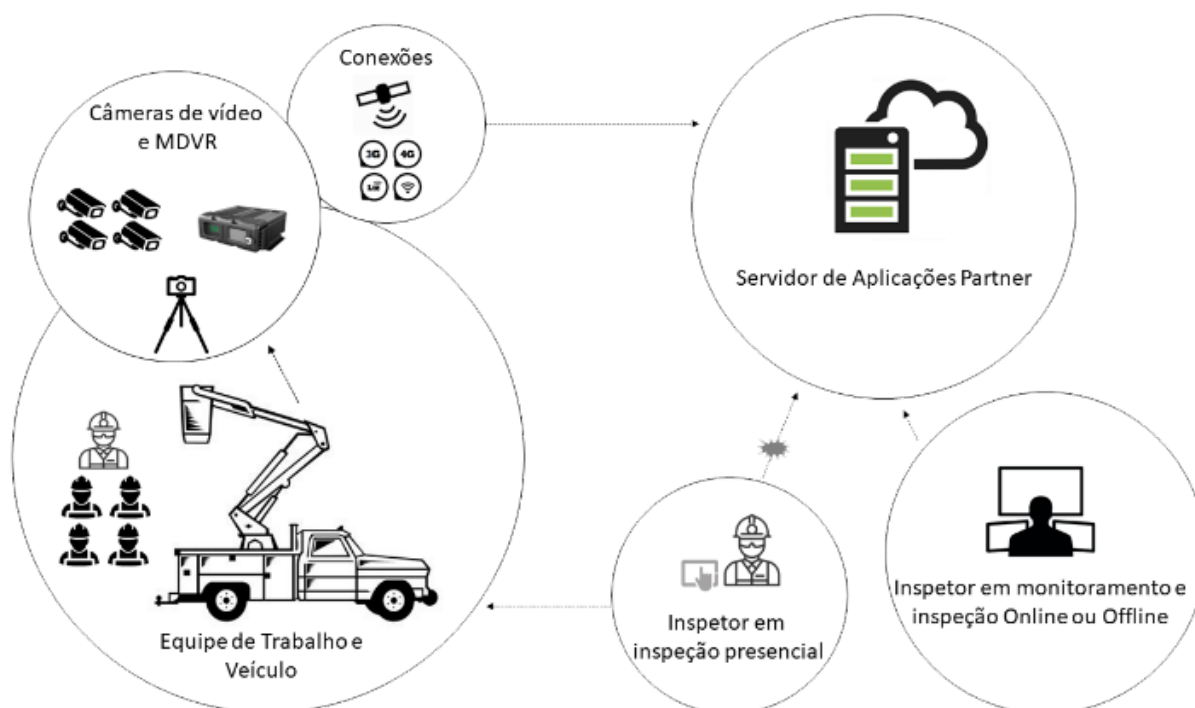


Figura 1 - Arquitetura da Plataforma Partner.

No bloco de construção “Equipe de trabalho e veículo” (ver Figura 1) demonstra-se que o veículo pode ser equipado com dispositivos de armazenamento e câmeras embarcadas fixas e portáteis, apresentados graficamente no bloco de construção “Câmeras de vídeo e MDVR”.

Em geral, o dispositivo de armazenamento é um MDVR (*Mobile Digital Vídeo Recorder*), que é um aparelho equipado com entradas/canais para câmeras de vídeo (nesta solução utilizamos modelos com 4 canais), e com recursos de *GPS* (*Global Positioning System*) para armazenar a localização da captação das imagens e com conexão de rede (e.g., 4G, 5G, Wifi) para acompanhamento das imagens em tempo real por um centro de monitoramento (ver bloco de construção “Conexões”). Pode também ser equipado com cartões de memória *flash* para permitir armazenamento local. Posteriormente o conteúdo destes cartões pode ser transferido ao servidor central para inspeção.

As câmeras empregadas na solução incluem modelos com capacidade de movimentação horizontal (pan), vertical (tilt) e de aproximação (zoom). A Figura 2 e Figura 3 exibem a posição da instalação dessas câmeras em veículos utilizados em operações de linha viva e em atividades de construção ou manutenção, respectivamente.




Figura 2 - Pontos de instalação das câmeras fixas nos veículos de linha viva.




Figura 3 - Pontos de instalação das câmeras fixas nos veículos de construção e manutenção.

O MDVR é automaticamente ativado ao ligar o veículo, iniciando a captação de imagens. A fim de evitar a geração de arquivos excessivamente grandes, o sistema é configurado para criar arquivos segmentados por intervalos regulares, como a cada 15 minutos.

A câmera instalada no pára-brisa dos veículos objetiva a obtenção de imagens do deslocamento, do ambiente de trabalho em frente ao veículo, além das atividades de planejamento da execução, Diário Diário de Segurança (DDS) e Análise Preliminar de Riscos (APR). Os trabalhadores são instruídos a executar estas tarefas na área de cobertura desta câmera. Outras duas câmeras, localizadas nas laterais, registram o ambiente adjacente ao veículo.

No caso de veículos de linha viva, uma câmera específica é destinada à captura de imagens dos eletricitistas no cesto aéreo (ver Figura 2). Já nos caminhões de construção e manutenção, uma câmera é utilizada para registrar a movimentação de cargas (ver Figura 3).

Além das câmeras fixas, também são utilizados dispositivos portáteis, como smartphones, tablets ou câmeras instaladas em cones ou tripés, que permitem uma captura mais flexível do cenário de trabalho. O armazenamento é realizado em memórias próprias, e as imagens coletadas por esses dispositivos podem ser transmitidas em tempo real, dependendo do modelo, ou enviadas posteriormente ao servidor central para inspeções offline.

A infraestrutura descrita é capaz de estabelecer conexão com um servidor de aplicações baseado na nuvem, desde que se encontre em uma área com cobertura de redes de dados móveis, como 4G, 5G, ou Wifi. Essa conexão permite o monitoramento remoto por meio de softwares específicos, conforme ilustrado no bloco "Servidor de Aplicações Partner". O acesso ao monitoramento pode ser realizado de qualquer dispositivo conectado à internet, via navegador web, embora seja recomendado o uso de centros de monitoramento com telas grandes para facilitar o acompanhamento.

O acesso e uso dos MDVRs está vinculado a três módulos: a) VMS (*Vehicle Management System*) server, que é o software instalado no servidor de aplicações para gerenciar os MDVRs e usuários que acessarão as câmeras dos veículos; b) VMS Cliente, aplicativo para visualização e gerenciamento das câmeras em dispositivos dos usuários. Pode ser dispensado se o VMS Server suportar uma versão web. É possível também, configurar alarmes para exibição no centro de monitoramento, como por exemplo, se o veículo ultrapassar uma determinada velocidade ou uma área delimitada; c) MDVR player, ferramenta para reprodução e edição de vídeos armazenados.

A interface de monitoramento online permite a visualização simultânea de todas as câmeras conectadas ao sistema, oferecendo aos profissionais da área de segurança do trabalho, fiscais de obras e profissionais de centros de operações do sistema elétrico a possibilidade de acompanhar os serviços e inspecionar equipes em tempo real, monitorando tanto as imagens captadas quanto a localização geográfica dos veículos.

É importante destacar que a plataforma Partner é independente do software utilizado para monitoramento online, ficando a escolha deste recurso a cargo da equipe de implantação, em conformidade com o modelo e o fabricante das câmeras empregadas. Geralmente, os próprios fabricantes fornecem softwares específicos para a gestão de DVRs e monitoramento, que podem ser integrados ao sistema conforme necessário. Esses softwares não foram desenvolvidos no âmbito do projeto, mas sua utilização potencializa as funcionalidades do sistema, garantindo flexibilidade e adaptação às necessidades operacionais.

O registro de atividades e de inspeções ocorre em uma aplicação web desenvolvida no âmbito do projeto (ver Figura 4). A interface permite registrar conformidades e não conformidades a partir de formulários eletrônicos configuráveis, cujas perguntas podem ser adaptadas às normas regulamentadoras aplicáveis a cada tipo de atividade. Cada resposta negativa gera uma pontuação proporcional à criticidade da pergunta, auxiliando na avaliação do desempenho das equipes e no planejamento de políticas de gestão da segurança. Para cada pergunta é esperada uma resposta entre “Sim”, “Não” e “N/A”, sendo a última usada para o caso de “Não Avaliada”.

A interface do software de registro de inspeções, intitulada 'Partner' no topo, apresenta uma barra de navegação lateral com opções como Dashboard, Atividades, Inspeções, Usuários, Veículos, Administrador e Parâmetros. A seção principal, 'Editar inspeção', contém uma barra de ferramentas com ícones para voltar, atualizar, salvar, imprimir e enviar por e-mail. Abaixo, há uma aba 'QUESTIONÁRIOS' com um botão 'ADICIONAR QUESTIONÁRIO'. O formulário em exibição é para 'Serviço Desenergizado - v.12' e contém três perguntas:

- 1) Existe ORDEM de SERVIÇO e DTD? (Resposta: SIM, 3 / 3 pontos)
- 2) O superior imediato e a equipe realizaram a APR-Análise Preliminar de Riscos? (Resposta: SIM, 1 / 1 pontos)
- 3) Todos os trabalhadores possuem e utilizam os EPIs e EPCs adequados e necessários para executar a atividade?

Na base da interface, há logotipos de parceiros como CELESC, CEECSC e ANEEL.

Figura 4 - Interface do software de registro de inspeções para Editar inspeção.

De modo a evidenciar eventuais não conformidades identificadas, o sistema permite a inclusão de mídias em diversos formatos (imagem estática, vídeo, áudio, texto). Esta imagem pode ser oriunda de várias fontes: a) do sistema de visualização de câmeras on-line, b) das câmeras portáteis (e.g. *smarthphones*) ou c) dos vídeos armazenados no MDVR e transmitidos ao servidor.

Ao finalizar a inspeção, é possível encaminhar relatório da inspeção por email, e o destinatário poderá acessar a Plataforma Partner para visualizar vídeos anexos a partir de um link apresentado em forma de QR-Code. A Figura 5 exibe a interface com a lista de inspeções, permitindo diversos filtros (por período, inspetor, vínculo, atividade, etc.), exportação e visualização.

Dashboard

Atividades

Inspeções

Usuários

Veículos

Administrador

Parâmetros

Inspeções

	Cód.	Data de Inspeção	Inspetor	Vínculo Unidade	Inspecionada	Tipo de Atividade	Data da Atividade	Situação
<input type="checkbox"/>	4078	16/12/2024	e018887	NUPLA - Núcleo Planalto		Construção LM Distribuição	01/11/2024	Finalizada ✓
<input type="checkbox"/>	4077	16/12/2024	e018887	NUPLA - Núcleo Planalto		Construção LM Distribuição	05/12/2024	Finalizada ✓
<input type="checkbox"/>	4076	16/12/2024	e018887	NUPLA - Núcleo Planalto		Operação/Emergência	30/12/2024	Finalizada ✓
<input type="checkbox"/>	4075	16/12/2024	e013802	NUSUL - Núcleo Sul		Fiscalização de Compartilhadoras	09/12/2024	Finalizada ✓
<input type="checkbox"/>	4074	16/12/2024	e018887	NUPLA - Núcleo Planalto		Operação/Emergência	11/11/2024	Finalizada ✓
<input type="checkbox"/>	4073	16/12/2024	e018887	NUPLA - Núcleo Planalto		Operação/Emergência	22/11/2024	Finalizada ✓
<input type="checkbox"/>	4072	16/12/2024	e013802	NUSUL - Núcleo Sul		Construção LM Distribuição	05/12/2024	Finalizada ✓
<input type="checkbox"/>	4071	16/12/2024	e016319	UNJSL - Unidade Jaraguá do Sul		Operação/Emergência	16/12/2024	Finalizada ✓
<input type="checkbox"/>	4070	16/12/2024	e013876	NUVAL - Núcleo Alto Vale		Poda e Roçada	16/12/2024	Finalizada ✓
<input type="checkbox"/>	4069	16/12/2024	e013876	NUVAL - Núcleo Alto Vale		Manutenção LV Distribuição	16/12/2024	Finalizada ✓

Registros por página 10 1 - 10 de 1622

CELESC

Celcsc Distribuição S.A.

FD ANEEL

+

Figura 5 - Interface do software de registro de inspeções para visualizar inspeções.

2.2 Inspeção Offline

Para o caso de inspeções offline, a partir dos vídeos gravados, o sistema conta com recurso de inteligência artificial para detectar elementos de interesse. Atualmente o sistema detecta pessoa sem capacete, pessoa com capacete, pessoa, detector de tensão e vara de manobra. A detecção de novos elementos de interesse será implementada em novas versões.




Figura 6 - Exemplo de indicação de localização de elementos de interesse via Inteligência Artificial.

Na Figura 6 podemos perceber que a linha do tempo dos vídeos exibe um conjunto de pontos coloridos, relativos à legenda que aparece ao lado esquerdo. Notem que, no menu da esquerda, há a indicação que o sistema reconheceu os elementos capacete e detector de tensão no vídeo. Assim o inspetor poderá identificar rapidamente ocorrências de interesse e proceder a inspeção mais detalhada daquele ponto, selecionando a marcação.

2.3 Inspeção Presencial

A plataforma foi projetada para unificar a base de dados dos diferentes tipos de inspeção. Reconhecendo a importância da inspeção presencial, ela visa facilitar e otimizar o trabalho dos inspetores de segurança durante as inspeções presenciais. Utilizando um tablet, o inspetor pode realizar todas as etapas necessárias da inspeção, como preencher formulários diretamente na plataforma; coletar imagens estáticas, gravar vídeos e áudios para registro da inspeção; e inserir arquivos de texto adicionais, conforme necessário.

A plataforma é equipada com a tecnologia Progressive Web App (PWA), que permite o funcionamento mesmo em locais sem cobertura de rede de dados ou Wi-Fi. Nesse modo offline, todas as informações da inspeção, incluindo mídias coletadas, são armazenadas localmente no tablet.

Assim que a conexão com a internet for restabelecida, a plataforma sincroniza automaticamente os dados e mídias armazenados localmente com a nuvem, garantindo a integridade e a centralização das informações. Essa funcionalidade oferece ao inspetor maior flexibilidade e segurança, eliminando a dependência de conectividade no momento da inspeção e assegurando a continuidade e a qualidade do processo.

2.4 Painel de Indicadores

Um painel de indicadores, implementado em Microsoft Power BI, está integrado à base de dados e permite a visualização de diversos cruzamentos de interesse. O painel responde também questões como: Qual é a não conformidade que mais ocorre em um determinado período? Qual é a gravidade das ocorrências de não conformidade por período, por empresa, por tipo de atividade, etc? Qual é a atividade com melhor desempenho (menor número de não conformidade) em determinado período? A Figura 7 exibe uma tela do painel de indicadores.



Figura 7 - Painel de indicadores em Power BI.

O painel oferece respostas a estas questões em modo gráfico, com detalhamento através da aplicação de múltiplos filtros. Esse nível de detalhamento promove uma compreensão abrangente do desempenho das equipes inspecionadas e dos processos avaliados. Na Figura 7, além de apresentar o número de inspeções realizadas e a relação conformidade/não conformidade por unidade na parte superior, o painel fornece informações detalhadas sobre o estado das inspeções conforme o filtro selecionado (finalizadas e não finalizadas), o número de incidentes registrados, a relação geral entre conformidades e não conformidades, e o número de questões inspecionadas categorizadas por gravidade (alta, média, menor). Este último indicador evidencia que a concessionária direciona maior esforço para inspecionar atividades de maior gravidade, priorizando-as sobre aquelas de gravidade média e menor. Essa abordagem demonstra um compromisso com a gestão de risco, enfatizando a segurança das atividades mais críticas e assegurando a conformidade em áreas que apresentam maior potencial de impacto.

Dessa forma, a ferramenta fornece subsídios para a identificação de padrões críticos, priorização de ações corretivas e desenvolvimento de estratégias direcionadas à mitigação de riscos, contribuindo significativamente para a gestão da segurança e a melhoria contínua das operações.

2.5 Desenvolvimento do Modelo de Inteligência Artificial para Detecção de Elementos de Interesse

O termo Inteligência Artificial é o campo de pesquisa que abrange conceitos mais especializados como aprendizado de máquina (*machine learning*) e aprendizado profundo (*deep learning*). Na prática os pesquisadores dessas áreas buscam criar algoritmos computacionais para coletar dados, aprender a partir dos dados, e depois proceder a predição sobre algo. O conceito mais especializado dos apresentados, *deep learning*, faz uso de redes neurais artificiais, que são algoritmos inspirados na biologia do nosso cérebro, incluindo o conceito de neurônios distribuídos em camadas discretas, com especificações sobre possibilidades de conexões e direções de propagação de dados. É nesse conceito que se assenta a abordagem escolhida para implementação nessa solução, para a detecção de elementos de interesse.

No contexto do setor elétrico, o problema de identificar elementos de interesse se torna dificultado por conta dos distintos cenários em que eles aparecem. Um veículo pode estar operando em um centro urbano, onde

o cenário é “poluído” com placas de identificação de comércios, pessoas que não fazem parte da equipe, outros veículos, etc. Pode também estar operando em regiões rurais, em que o cenário é “poluído” por diversos tipos de vegetações. O cenário também sofre interferências relativas à incidência de luz, e todas as variáveis precisam ser consideradas desde o princípio a fim de treinar uma rede neural para detectar um determinado elemento.

Com o avanço das redes neurais profundas, principalmente as redes neurais convolucionais (CNN do inglês Convolutional Neural Networks) é possível reconhecer um grande número de itens, como automóveis, pessoal, placas de veículos e de trânsito, após um treinamento (Ramaswamy, Gnanaraj, Sekar, & Muthukumar, 2023), (Ammar, 2023).

Existem várias arquiteturas dedicadas à tarefa de detecção de objetos e aprendizado profundo, como por exemplo YOLO (You Only Look Once), SSD (Single-Shot Detection), R-CNN (Regions with Convolutional Network), Fast-RCNN, Faster-RCNN e R-FCNN (Region-Based Convolutional Network).

Nos últimos anos a arquitetura YOLO (You Only Look Once) (Ross Girshick, 2016) (A. Bochkovskiy, 2020) tem demonstrado contribuições importantes para o avanço da detecção de objetos, em termos de precisão e velocidade de detecção, sendo possível colocá-lo atualmente como o estado da arte para o efeito (*Yolov7 Detectron2*, 2022). Por isso foi eleita a arquitetura aplicável a esta solução.

O desenvolvimento do modelo neste projeto, para a detecção de elementos do setor elétrico foi conduzido utilizando o framework YOLOv4, amplamente reconhecido por sua eficiência em tarefas de visão computacional em tempo real. O processo seguiu uma abordagem sistemática, desde a preparação dos dados até a validação do modelo.

A coleta de dados foi realizada com base em 2500 imagens, oriundas tanto de fontes públicas na internet quanto de registros próprios, capturados pela equipe do projeto em ambientes reais de trabalho no setor elétrico. Parte desse conjunto foi extraída de vídeos gravados em campo, convertendo quadros individuais (*frames*) em imagens estáticas para ampliar a diversidade do dataset. Como estratégia adicional, aplicamos *data augmentation* (uma técnica para aumentar o número de amostras na base de dados), criando variações em parâmetros como cor, brilho, saturação, exposição e ângulos das imagens. Isso permitiu simular condições operacionais reais e aumentar a representatividade do conjunto de dados. Cada imagem foi rotulada manualmente, identificando as classes-alvo: Pessoa sem Capacete, Pessoa com Capacete, Pessoa, Detector de Tensão e Vara de Manobra.

O modelo foi treinado a partir da rede neural convolucional pré-treinada Darknet53, que serve como a base do YOLOv4.

A rede do modelo composta por 24 camadas convolucionais, seguidas por duas camadas densamente conectadas, e utiliza camadas de redução combinadas com camadas convolucionais para otimizar o aprendizado. A arquitetura foi projetada para balancear eficiência computacional e precisão, garantindo desempenho adequado em cenários de alta demanda.

O conjunto de dados foi dividido em 80% para treinamento e 20% para teste. Durante o treinamento, foram adotados hiperparâmetros ajustados para maximizar a capacidade de generalização da rede. As configurações incluíram um *batch size* de 64, subdivisões de 32, resolução das imagens de 416×416, taxa de aprendizado inicial de 0.001, número máximo de iterações de 10.000 e a função de ativação Leaky ReLU. O treinamento foi conduzido utilizando a infraestrutura do Google Colaboratory na versão paga, que permitiu acesso a recursos computacionais de alto desempenho, essenciais para processar o grande volume de dados e iterar sobre o modelo de forma eficiente.

Após o treinamento, o modelo foi validado com métricas padrão da área, incluindo *mean Average Precision* (mAP) e *Intersection over Union* (IoU). Os resultados demonstraram alta precisão e desempenho geral. O mAP@0.50 alcançou 97.97%, com desempenhos por classe superiores a 95% em todas as categorias avaliadas. O modelo obteve uma precisão de 95%, *recall* de 96%, F1-Score de 0.96 e IoU médio de 81.51%.

Para tornar o entendimento dos resultados mais claro, observe que a métrica mAP avalia a precisão média das previsões em relação aos dados considerados verdadeiros, utilizando um limiar que mede a sobreposição entre a região prevista pelo modelo e a região real ou esperada, conhecida pelo termo IoU, de 50% para considerar uma detecção como correta. Um valor de 97,97% indica que, em média, as previsões do modelo têm uma correspondência muito próxima com as localizações reais dos objetos nas imagens. Na prática, isso significa que o modelo consegue identificar corretamente as classes de interesse com alta acurácia.

Observe também que, ao obtermos desempenhos por classe superiores a 95%, significa que o modelo é consistente na detecção de todas as categorias avaliadas (Pessoa sem Capacete, Pessoa com Capacete, etc.), com precisão superior a 95% para cada uma. Isso demonstra que o treinamento foi equilibrado entre as classes, sem tendência de superestimativa ou subestimativa de nenhuma categoria específica.

A precisão mede a proporção de detecções corretas em relação ao total de detecções realizadas. Um valor de 95% significa que, dentre todas as previsões feitas pelo modelo, 95% eram verdadeiros positivos. Na prática, isso reduz falsos positivos, garantindo que o modelo identifique os elementos corretos com confiança.

A métrica *recall* avalia a capacidade do modelo de identificar corretamente todos os objetos relevantes no conjunto de teste. Com 96%, o modelo perde apenas 4% dos objetos que deveria detectar.

O F1-Score é a média harmônica entre precisão e *recall*, equilibrando os dois aspectos, 0 (zero) indica o pior desempenho possível e 1 (um) o melhor. Um valor de 0.96 demonstra que o modelo mantém um equilíbrio entre identificar corretamente os objetos (precisão) e não perder objetos relevantes (*recall*).

Por fim, IoU médio de 81,51% significa que as caixas delimitadoras geradas pelo modelo têm, em média, mais de 80% de interseção com as caixas reais. Na prática, isso indica que o modelo não apenas detecta a presença dos objetos, mas também os localiza com boa precisão espacial.

A etapa de inferência foi realizada com eficiência, com um tempo médio de 14 segundos para processar o conjunto de teste. Esses resultados confirmam a robustez do modelo YOLOv4 para a detecção de elementos de interesse em ambientes do setor elétrico, beneficiando-se de uma base de dados representativa, estratégias avançadas de aumento de dados e a utilização de uma arquitetura previamente treinada para acelerar o aprendizado e melhorar o desempenho final.

3. Conclusão

A Plataforma Partner foi instalada no ambiente de Pesquisa, Desenvolvimento e Inovação (P&DI) da Celesc para fins de teste e capacitações. Também foi implantada em ambiente de produção e atualmente soma mais de 4 mil registros de inspeções.

Uma das principais propostas do sistema é permitir que supervisores antecipem-se a possíveis acidentes, utilizando o levantamento contínuo de evidências para identificar e mitigar riscos antes que eventos adversos ocorram. Além disso, o sistema foi projetado para ser integrável aos demais sistemas corporativos existentes, o que facilita sua adoção e potencializa sua funcionalidade ao trabalhar de forma conjunta com outras ferramentas de gestão e segurança, ampliando a capacidade de supervisão e resposta da concessionária.

O período de uso confirma que o uso da plataforma pode reduzir os custos e aprimorar a supervisão e inspeções de segurança do trabalho, reduzindo os incidentes. Também proporciona aos fiscais de obras e aos centros de operações informações adicionais, em tempo real ou offline, dos serviços realizados no Sistema Elétrico de Potência. Essa redução ocorre porque, ao utilizar a plataforma, um inspetor pode acom-

panhar simultaneamente várias equipes sem a necessidade de se deslocar fisicamente até os locais onde os serviços estão sendo executados. Mesmo em situações de inspeção presencial, o uso da plataforma agrega valor ao processo, oferecendo suporte tecnológico que torna as inspeções mais ágeis, precisas e com melhor registro de evidências, resultando em um processo de supervisão mais eficiente e confiável. O aspecto da Inteligência Artificial (IA), considerado o componente mais inovador do projeto, revelou-se um grande desafio devido à necessidade de soluções personalizadas para o problema. A revisão do estado da arte evidenciou que não existem técnicas genéricas amplamente aplicáveis em diferentes domínios, tornando essencial o desenvolvimento de abordagens específicas para cada aplicação. Nesse contexto, a escolha por redes neurais convolucionais (CNNs) demonstrou ser uma decisão acertada, permitindo a criação de um software dinâmico, escalável e adaptável. A arquitetura da plataforma possibilita a inclusão de novos objetos a serem detectados simplesmente por meio de novo treinamento da rede neural, eliminando a necessidade de alterações na codificação da plataforma, o que é um diferencial importante para sua evolução.

Os resultados obtidos com o treinamento do modelo de IA indicaram um desempenho robusto na detecção de elementos de interesse, como capacetes, pessoas e ferramentas específicas do setor elétrico. Métricas como precisão média (mAP@0.50 de 97.97%) e F1-score de 0.96 refletem a confiabilidade e a eficácia do sistema.

Além disso, a plataforma demonstra alinhamento com as demandas crescentes de digitalização e automação nos processos industriais e de segurança. O uso de IA, combinado à coleta sistemática de dados em campo e à possibilidade de supervisão remota, sinaliza avanços promissores no uso de tecnologia para a promoção de ambientes de trabalho mais seguros e eficientes. Esse projeto, portanto, representa uma contribuição significativa para o setor, unindo inovação tecnológica, redução de custos operacionais e melhoria contínua nos processos de segurança do trabalho.

Como trabalho futuro, propõe-se a ampliação do escopo de aplicação da plataforma para outros setores além do elétrico, explorando sua adaptabilidade a diferentes contextos industriais. Além disso, planeja-se a incorporação de novas funcionalidades baseadas em inteligência artificial, como análises preditivas de riscos e a geração automatizada de relatórios. Também se sugere o treinamento da rede neural com tecnologias mais recentes, como o Yolo X, com o objetivo de aumentar a precisão na detecção de objetos e expandir a eficiência e o alcance da plataforma em aplicações futuras.

4. Referências bibliográficas

- ANEEL. (2017). *Banco de dados da ANEEL*. Retrieved 2017 98; 20 Dezembro from Projetos de P&D: <http://www.aneel.gov.br/documents/656831/15189212/Atualiza%C3%A7%C3%A3o+21-02-17/f89493eb-cc29-bef4-3996-96dee41fb022>.
- Araujo, E. R. (2016). Sistema videomonitoramento COPEL - VMC: Uma solução para a gestão de dados do processo de videomonitoramento de serviços operacionais Copel. *XXII Seminário Nacional de Distribuição de Energia Elétrica - SENDI*. Curitiba.
- ARAUJO, E. R. (2016). Sistema videomonitoramento copel - VMC: Uma solução para a gestão de dados do processo de videomonitoramento de serviços operacionais Copel. *XXII Seminário Nacional de Distribuição de Energia Elétrica - SENDI*. Curitiba - PR.
- Calzavara, F. (2017). Sistema de gestão de segurança – SGS. *IX Seminário Nacional de Segurança e Saúde no Setor Elétrico Brasileiro - SENSE*. São Paulo: FUNCOGE.

- Olson, E. (2011). AprilTag: A robust and flexible visual fiducial system. *International Conference on Robotics and Automation - ICRA*. IEEE.
- Queiroz, F. (2017). Uso de ferramentas de supervisão de instalações - experiência de desenvolvimento de sistema de videomonitoramento para a UHE Nova Ponte. *VIII Seminário Nacional de Operadores de Sistemas e de Instalações Elétricas - SENOP*. Foz do Iguaçu.
- Ramaswamy, S., Gnanaraj, S. J., Sekar, K. C., & Muthukumaran, N. (Nov de 2023). Analysis of Distribution Line in Link with Substation using GSM Technology. *International Conference on Sustainable Communication Networks and Application (ICSCNA)*.
- Reis, L. (2013). Monitoria Veicular, um novo Modelo de Gestão dos Riscos e Supervisão. *VIII Seminário Nacional de Segurança e Saúde no Setor Elétrico - SENSE*. Foz do Iguaçu.
- Wang, J., & Olson, E. (2016). AprilTag 2: Efficient and robust fiducial detection. *International Conference on Intelligent Robots and Systems (IROS)* (pp. 4193-4198). IEEE/RSJ.
- Yabiku, S. C., Fischer, H. K., Kiyohara, H. K., Magrini, L. C., Masuda, M., & Jardini, M. G. (2003). Sistema de Vídeo-Monitoramento e Controle e Subestações com Transmissão via TCP/IP. *II Congresso de Inovação Tecnológica em Energia Elétrica - CITENEL*. Salvador - BA.