



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários

ANP
TRILHOS

TIC TRENS



CPTM

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

CATEGORIA 3

VISÃO COMPUTACIONAL APLICADA A ANÁLISE E MANUTENÇÃO DE ATIVOS FERROVIÁRIOS

SOBRE OS AUTORES

Tiago Marcílio de Castro Moreira - Engenheiro de Manutenção Elétrica na CPTM há 11 anos, especialista em rede aérea e subestações ferroviárias. Graduado em Engenharia Eletrônica, MBA em Data Science (USP/Esalq). Mais de 10 anos de experiência em telecomunicações, projetos e manutenção ferroviária. Competências: liderança de equipes, análise de dados, machine learning, Visão Computacional, automação, manutenção preditiva, gestão de projetos e inovação. Foco em melhoria contínua e soluções tecnológicas atuais.

Claudimar Santos Chaves - Graduação em Engenharia Elétrica pela Universidade Federal de São João Del Rei e pós-graduação em Empreendedorismo e Inovação nas Engenharias. Atualmente é engenheiro da Companhia Paulista de Trens Metropolitanos trabalhando com projetos elétricos de instalações e sistemas, simulação computacional do sistema elétrico e projetos de energia solar fotovoltaica. Também atuou por 7 anos com gestão de contratos de fornecimento de energia elétrica. Tem experiência na elaboração de projetos de linhas de transmissão de alta tensão aéreas e subterrâneas.



CATEGORIA 3

VISÃO COMPUTACIONAL APLICADA A ANÁLISE E MANUTENÇÃO DE ATIVOS

FERROVIÁRIOS

1. INTRODUÇÃO

O transporte de passageiros sobre trilhos apresenta desafios significativos, dado operar em ambiente que exige eficiência operacional, continuidade, segurança e conforto na prestação do serviço ao passageiro durante toda a viagem.

Neste ambiente, de alto rigor operacional, a manutenção de rede aérea tem importância fundamental [1].

Tendo sua extensão ao longo de toda a ferrovia como parte de seu sistema de fornecimento de energia, impõe diversas dificuldades para sua manutenção, como:

- a maioria das intervenções tem caráter invasivo nas operações dos trens;



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- Atuações envolvendo equipamentos de grandes dimensões e assim com grandes cargas de peso;
- Necessidade de utilização de veículos especiais para sua manutenção eficaz e segura;
- Mão de obra especializada para trabalhos com altas/médias tensões e com equipamentos especiais;
- Grande conhecimento da diagramação elétrica no trecho;
- Programação antecipada dos acessos;

Diante disso, a programação antecipada dos acessos, mediante a observação do planejamento dos serviços a partir das diversas inspeções realizadas pela equipe, das falhas registradas ao longo do dia e das solicitações no PMP (Plano de Manutenção Preventiva) são de extrema importância para garantir que os equipamentos apresentem sempre índices adequados à garantia dos requisitos de operação anteriormente citados.

Diariamente, as equipes de rede aérea realizam inspeções visuais pela manhã e à tarde, durante o ano inteiro.

Essas inspeções visuais são de grande valia para a manutenção de rede aérea e visam obter, de forma limitada, a situação diária das instalações eletromecânicas, bem como identificar possíveis falhas ou problemas antes de se tornarem críticos. São exemplos de situações já identificadas:

- descidas de cabos incandescentes;
- bastões puxadores soltos e encavalados;



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- suspensórios soltos ou partidos;
- cabos de encabeçamento de mensageiro com tentos soltando;
- Isoladores e cabos com sinais de descarga;
- Cabos de CTC (Controle de Tráfego Centralizado) fora de seus isoladores de topo, etc;

No entanto, este trabalho, consome muitos recursos que por sua vez são escassos.

Diante disso, a automatização deste processo por meio da utilização de Visão Computacional se apresenta como alternativa viável, factível e promissora [2].

Câmeras podem realizar a filmagem do trecho de interesse e o vídeo gerado, após seu processamento por algoritmo de Visão Computacional [3] previamente treinado nas situações de interesse, pode apontar problemas nos mais diversos equipamentos e situações da infraestrutura ferroviária e, a partir disso, imprimir uma nova dimensão para o planejamento da manutenção que estaria se baseando em dados, direcionando de forma mais assertiva os recursos da manutenção e gerando situações preditivas com a celeridade requerida [4].

A união de câmeras corretamente instaladas em veículos ferroviários e entregando dados a algoritmos especializados pode automatizar a avaliação de danos dos equipamentos e produzir uma melhoria significativa no tratamento rápido e prévio de incidentes [5].

Este trabalho apresenta o desenvolvimento e implementação de um sistema de visão computacional para identificação automatizada de equipamentos ferroviários da CPTM – Companhia Paulista de Trens Metropolitanos, com foco específico em componentes da rede



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA


12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

aérea de alimentação do sistema de tração elétrica. O objetivo principal é criar uma ferramenta capaz de detectar, nesta primeira fase, e em uma segunda fase classificar automaticamente equipamentos como pórticos treliçados, pórticos em viga I, isoladores de cadeias de ancoragem, árvores próximas à via, pessoas, trens e outros elementos críticos para a operação segura do sistema metroferroviário, permitindo posterior identificação de falhas e pontos de atenção no trecho.

2. DIAGNÓSTICO

A rede aérea é formada por grande quantidade de equipamentos e estes por uma miríade de componentes.

Essa situação eleva de forma significativa a dificuldade imposta às inspeções diárias e por conseguinte impacta na abordagem de programação prévia da manutenção de rede aérea.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



Figura 1 – equipamento de Rede Aérea. Fonte: arquivo pessoal do autor.

Falhas em equipamentos como bastões puxadores e isoladores de fixação do cantilêver podem provocar colisões entre estes e o pantógrafo dos trens e assim ocasionar falhas que podem atingir centenas de metros de extensão e com isso uma paralização por grandes períodos.

A perda de suspensórios em série pode provocar tensionamento inadequado do fio de contato e assim provocar uma interação errática entre o fio de contato e o pantógrafo e dessa forma aumentar significativamente o risco de falhas por enrosco de pantógrafo na rede aérea.

Essas são apenas algumas das diversas situações de falha da rede aérea que as inspeções visuais diárias tentam identificar de forma antecipada e com isso evitar o agravamento da situação e uma consequente paralização do serviço.



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Hoje, maquinistas devem reportar, via rádio, a presença de pessoas invadindo a via, bem como situações como árvores ou objetos que se projetem na direção da rede aérea e assim possam oferecer riscos de vandalismos e atropelamentos, no caso de pessoas, ou curtos-circuitos, no caso de árvores e outros objetos.

Com base nos levantamentos de custos de mão de obra e equipamentos utilizados pela CPTM em inspeções realizadas diariamente, no caso da rede aérea, temos:

Tabela 1 – tabela de custos de vistoria. Fonte: Dados internos CPTM

Custo diário	R\$ 4.100
Custo Semanal	R\$ 20.500
Custo Mensal	R\$ 90.200

Estes custos variam de acordo com as demandas diárias na base de manutenção de rede aérea.

Nota-se pelo, pelo exposto, o custo da forma tradicional da realização das inspeções.

Algo que impacta significativamente na execução de forma contínua destas inspeções é a indisponibilidade dos recursos como mão de obra e veículos. No caso da mão da obra, outros fatores como cansaço, falta de atenção e incapacidade de perceber os diversos aspectos nas mais variadas situações que se apresentam ao longo do trecho de vias e seus diversos equipamentos instalados, dão às inspeções certa imprecisão.



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

O modelo de inspeção automatizada proporcionado pelo uso de visão computacional se utiliza da aquisição de imagens a partir de câmeras estrategicamente posicionadas em veículos ferroviários [2] [5].

3. DESENVOLVIMENTO

A solução desenvolvida na CPTM consistiu na de utilização das imagens que são processadas por algoritmos de rede convolucionais [6] previamente treinados nas situações de interesse e assim, capazes de identificá-las de forma automática, precisa e rápida.



Figura 2 – Diagrama de fluxo de dados. Fonte: autor.

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Todo o processo de treinamento está mostrado conforme o diagrama abaixo:




Figura 3 – Diagrama de treinamento. Fonte: autor.



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Para tanto, as situações de interesse foram previamente treinadas a partir de imagens do sistema em monitoramento por meio de câmeras instaladas em trem comercial da CPTM.

4. SITUAÇÕES DE INTERESSE

A identificação e categorização das situações de interesse constituem o alicerce fundamental do sistema de detecção automática de equipamentos de rede aérea. Esta fase crítica do desenvolvimento envolveu uma análise abrangente e sistemática das situações operacionais, baseada em dados de manutenção, consultas com especialistas em infraestrutura ferroviária e revisão de incidentes operacionais registrados nas linhas 11 e 12 da CPTM ao longo dos últimos anos.

O conceito de "situação de interesse" pode ser entendido como qualquer condição, evento ou configuração visual que possa impactar negativamente a segurança operacional, a continuidade do serviço ferroviário ou a integridade dos equipamentos da rede aérea. Esta definição abrangente permitiu estabelecer uma taxonomia robusta e praticamente relevante, capaz de orientar tanto o desenvolvimento do modelo de aprendizado de máquina quanto os protocolos operacionais de resposta a alertas.

A metodologia de identificação das situações de interesse seguiu uma abordagem multidimensional, considerando simultaneamente a probabilidade de ocorrência, o impacto potencial na operação, a detectibilidade visual através do sistema automatizado e a viabilidade de intervenção corretiva. Cada situação identificada foi submetida a uma avaliação qualitativa pela equipe de manutenção de rede aérea.



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

As situações de interesse foram organizadas em cinco categorias principais, cada uma representando diferentes aspectos dos riscos operacionais da rede aérea.

A primeira categoria engloba falhas em bastões puxadores, componentes críticos responsáveis pela sustentação lateral e alinhamento do fio de contato. Estas estruturas metálicas, quando comprometidas por corrosão, fadiga ou impacto mecânico, podem resultar em desalinhamento severo do fio *trolley*, comprometendo a captação de energia pelo pantógrafo e potencialmente causando arcos elétricos perigosos bem como a paralização do serviço por períodos prolongados.

A segunda categoria abrange a detecção de pessoas na via, situação de extrema criticidade que representa risco iminente de acidentes fatais. O sistema foi projetado para identificar presença humana em diferentes contextos operacionais: pedestres não autorizados transitando sobre os trilhos, trabalhadores executando manutenção, e com isso situações potenciais de vandalismo ou invasão de propriedade ferroviária.

A terceira categoria (em implementação) concentra-se na identificação de buracos no muro de contenção e outras degradações da infraestrutura civil. Estas condições representam riscos tanto estruturais quanto de segurança, podendo facilitar acesso não autorizado à faixa de domínio ferroviário e comprometer a circulação.

A quarta categoria aborda suspensórios partidos (em implementação), uma das principais causas de preocupação da equipe de rede aérea. Os suspensórios são elementos críticos que conectam o cabo mensageiro ao fio de contato, mantendo a geometria adequada do sistema



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

de eletrificação e transferindo energia ao sistema, quando flexíveis. Quando estes componentes falham, podem resultar em queda do fio de contato, tensionamento errático da rede aérea e paralização imediata da linha por necessidade de intervenção emergencial com impacto significativo na operação.

A quinta categoria engloba isoladores danificados, componentes essenciais para isolamento elétrico entre partes energizadas e estruturas aterradas. Falhas em isoladores podem resultar em curtos-circuitos, arcos elétricos, interrupção do fornecimento de energia. O sistema foi desenvolvido para detectar diferentes tipos de equipamentos e, no futuro, poder realizar sua classificação de estado de degradação como: trincas superficiais, fraturas completas, contaminação excessiva por poluição atmosférica, e desalinhamento estrutural.

5. ESCOLHA DAS CLASSES

A definição das classes de detecção para o sistema de identificação de equipamentos de rede aérea ferroviária seguiu uma metodologia rigorosa e sistemática, baseada em consultas extensivas com a equipe de manutenção da CPTM. O processo de seleção considerou simultaneamente a criticidade operacional dos equipamentos, a viabilidade de detecção visual automatizada e a ocorrência de falhas registradas nos sistemas de gestão de manutenção.

As classes foram organizadas em categorias funcionais para facilitar tanto o treinamento do modelo quanto a interpretação dos resultados. A primeira categoria engloba elementos estruturais e de sustentação, incluindo as classes bast_pcor (bastões puxadores), cant



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**


(cantilêver e estruturas de sustentação). Estes componentes são fundamentais para manutenção da geometria adequada da rede aérea e sua degradação pode resultar em desalinhamentos severos do sistema de eletrificação.

A segunda categoria abrange a isolação e sustentação dos componentes condutores e de transmissão de energia, representada principalmente pela classe isol_xxx(isoladores diversos) e cruz_ctc (cruzetas de CTC). Estes elementos são responsáveis pela fixação dos condutores de energia elétrica, sendo críticos para a continuidade do serviço de transporte.

A terceira categoria concentra-se em elementos de risco ambiental e segurança, incluindo as classes arv (árvores e vegetação invasiva), pessoas (presença humana em áreas de risco) e bur_muro (buracos nos muros). Estas classes representam riscos externos ao sistema propriamente dito, mas com potencial de causar interrupções operacionais significativas ou acidentes graves.

No caso aqui exposto, foram realizadas aquisições de imagens do sistema de rede aérea da CPTM, em trechos diferentes e que representam de forma significativa as características observadas, para este sistema, no trecho.

Foram selecionadas como principais classes de interesse 21 componentes do sistema:



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários

ANP
TRILHOS


TIC TRENS

CPTM

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Tabela 2 – tabela de classes do modelo. Fonte: autor

Classe	Contagem (instâncias por classe)	Significado
arv	5084	Árvores
bast_pcor	550	Bastão puxador
bur_muro	102	Buracos no muro
cab_cav	35	Cabeça de cavalo
cant	2211	cantilêver
cruz_ctc	3748	Cruzeta de CTC
cx_loc	597	Caixa de locação
emend_msg	43	Emenda de mensageiro
fer_y	436	Ferro Y
house	197	<i>house</i>
isol_cord	614	Isolador da cordoalha
isol_encab	506	Isolador de encabeçamento
isol_sec	46	Isolador de seção
isol_susp	1531	Isolador de suspensão



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

peessoas	3857	Pessoas
port_trel	586	Pórtico treliçado
port_vigl	1506	Pórtico com viga I
poste	1063	Poste
poste_ra	3969	Poste Rede Aérea
semi_port	386	Semi pórtico
trem	116	Trem

Como podemos ver, neste treinamento, o modelo está treinado em 21 classes com orientação, primariamente, para componentes de rede aérea. No entanto, o mesmo processo pode ser repetido para outras situações e sistemas, mudando apenas a base de dados e consequentemente novo treinamento será requerido.

6. PROCESSO DE ANOTAÇÃO

A anotação é o processo no qual devemos identificar todas as instancias das classes em cada um dos frames do vídeo gravado. Tal identificação é realizada com a delimitação dos



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS


componentes de interesse por meio de caixas delimitadoras, no caso em estudo, com a utilização de *softwares* específicos.

O *Computer Vision Annotation Tool* (CVAT) foi selecionado como plataforma principal para o processo de anotação de dados devido às suas capacidades avançadas de colaboração, controle de qualidade integrado e suporte nativo para formatos de dados compatíveis com frameworks modernos de aprendizado profundo. A implementação utilizou a versão *online* do CVAT, hospedada em infraestrutura cloud dedicada, garantindo acesso simultâneo para múltiplos anotadores e *backup* automático de todos os dados de treinamento [7].

A configuração do ambiente CVAT foi customizada especificamente para as necessidades do projeto de identificação de equipamentos de rede aérea. Foram criados *templates* de projeto padronizados incluindo as 21 classes de detecção definidas. Cada classe foi configurada com códigos de cores distintivos, facilitando identificação visual durante o processo de anotação e reduzindo erros de classificação.

A utilização de uma solução de anotação em plataforma online [7] permite processamento simultâneo de múltiplos projetos de anotação sem degradação de performance, mantendo tempos de resposta inferiores a 4 segundos para operações de visualização e edição de anotações.

O *workflow* de anotação foi estruturado em etapas sequenciais com *checkpoints* de qualidade obrigatórios. Cada lote de 300 imagens passava por anotação inicial, revisão técnica, validação cruzada e aprovação final antes de ser incorporado ao dataset de treinamento. Este



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários

ANP
TRILHOS

TIC TRENS

CPTM

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

processo garantiu consistência e qualidade das anotações, elementos fundamentais para performance adequada do modelo de aprendizado de máquina.

Este sistema de anotação possui versionamento que permitiu rastreabilidade completa de todas as anotações realizadas, incluindo identificação do responsável, *timestamp* e justificativa para alterações. Esta funcionalidade é essencial para auditoria de qualidade e resolução de discrepâncias identificadas durante o processo de validação cruzada.



Figura 4 – imagem anotada – fonte: autor.

Após sua anotação, procedemos ao treinamento do modelo propriamente dito.

Esta etapa gerará um modelo treinado que será responsável pela identificação das situações de interesse.

7. TREINAMENTO

A seleção da arquitetura YOLO como base para o sistema de detecção de equipamentos de rede aérea foi fundamentada em análise comparativa abrangente de diferentes arquiteturas



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

de aprendizado profundo disponíveis. O YOLO11 [8] representa a evolução mais recente da família YOLO (You Only Look Once), incorporando inovações significativas em arquitetura de rede neural, mecanismos de atenção e técnicas de regularização que resultam em performance superior para tarefas de detecção de objetos em tempo real [9].

A arquitetura YOLO11 utiliza *backbone* baseado em C2F modificado com blocos residuais aprimorados e mecanismos de atenção espacial e de canal que explora convoluções otimizadas como RepConv (do YOLOv7) ou ConvNeXt, dependendo da versão (11n, 11s, 11m, 11l, 11x). Esta configuração permite extração eficiente de características visuais em múltiplas escalas, fundamental para detecção de equipamentos com grande variação dimensional, desde pequenos isoladores até estruturas de grande porte como cantilévers. O neck da *rede* implementa *Feature Pyramid Network* (FPN) com *Path Aggregation Network* (PANet), garantindo propagação eficiente de informações entre diferentes níveis de resolução.

A configuração de treinamento foi otimizada especificamente para o contexto através de extensivos experimentos de *hyperparameter tuning* [10]. O learning rate inicial foi estabelecido em 0,01 com *scheduler cosine annealing* [11], permitindo convergência estável ao longo de 300 épocas de treinamento. O *batch* size foi configurado em 16 imagens por iteração, balanceando eficiência computacional com estabilidade de gradientes para o *dataset* de dezenas de milhares objetos anotados.

A função de perda (*loss function*) combina três componentes principais: *classification loss* (Binary Cross-Entropy), *localization loss* (Complete IoU) e *objectness loss* (Binary Cross-Entropy). Os pesos relativos foram ajustados empiricamente para $\lambda_{cls} = 0,5$, $\lambda_{box} = 0,05$ e



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

$\lambda_{obj} = 1,0$, priorizando precisão de localização devido à criticidade de posicionamento preciso para equipamentos de infraestrutura de rede aérea.

O processo de treinamento utilizou técnicas avançadas de data *augmentation* incluindo *Mosaic* (combinação de 4 imagens), *MixUp* (interpolação linear entre imagens), *CutMix* (substituição de regiões entre imagens) e aumento de fotométricas (HSV, *blur*, *noise*). Estas técnicas aumentaram a diversidade do *dataset* e melhoraram a robustez do modelo para diferentes condições operacionais.

No que diz respeito ao *hardware* de treinamento, a infraestrutura foi baseada em nuvem e Google Colab com sua configuração mostrada na figura 5. O tempo total de treinamento foi de 3.5 horas, processando grande quantidade de iterações com monitoramento contínuo de métricas de validação para detecção precoce de *overfitting*. [3]

```

Mon Jul 28 18:53:31 2025
+-----+
| NVIDIA-SMI 550.54.15                Driver Version: 550.54.15    CUDA Version: 12.4    |
+-----+-----+-----+-----+-----+-----+
| 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  NVIDIA A100-SXM4-40GB         Off | 00000000:00:04.0 Off |             0        |
| N/A   33C    P0              43W / 400W |  0MiB / 40960MiB |      0%    Default |
|                                           | Disabled       |
+-----+-----+-----+-----+-----+-----+

+-----+
| Processes:                                |
| GPU  GI    CI          PID    Type    Process name                        GPU Memory |
| ID   ID   ID                                  |          Usage |
+-----+-----+-----+-----+-----+
| No running processes found                |
+-----+

```

Figura 5 - configuração de hardware no Google Colab – fonte: dados do trabalho.



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Um aspecto a ser notado é aquele referente ao que o algoritmo será capaz de identificar após seu treinamento.

O processo aqui descrito foi levado a cabo para a identificação dos componentes de rede aérea (primeira fase) em seu estado operacional e como tal é tido como o modelo base sobre o qual está sendo construído o arcabouço de funcionalidades para identificação de falhas uma vez que as situações de falhas são escassas e não somariam uma quantidade de instancias razoável para um treinamento eficaz.

Neste caso, as capturas de imagens com equipamentos em falha deverão ser programadas (segunda fase), ensaiadas, gravadas com os equipamentos em seus devidos locais de implantação e após isso, essa amostra de dados deverá receber o mesmo tratamento dispensado às outras amostras.

8. ANÁLISE DOS RESULTADOS

O sistema de avaliação de performance implementado utiliza conjunto abrangente de métricas específicas para tarefas de detecção de objetos, incluindo métricas tradicionais de classificação adaptadas para o contexto de detecção de caixas delimitadoras.

8.1. CONCEITOS DAS MÉTRICAS EM DETECÇÃO DE OBJETOS (YOLO)

mAP@50 (*mean Average Precision at IoU = 0.50*)



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

O $mAP@50$ mede a precisão média considerando um limiar de $IoU \geq 0.50$. Ele avalia o quão bem o modelo detecta objetos corretamente em termos de localização e classe. É calculado como a média do *Average Precision* (AP) de todas as classes, usando esse limiar fixo.

$mAP@50:95$ (COCO mAP)

A métrica $mAP@50:95$ é mais rigorosa. Ela calcula o AP para cada classe em 10 diferentes limiares de IoU (de 0.50 a 0.95, com passo de 0.05) e depois faz a média entre todos esses valores e entre todas as classes. Esse é o padrão usado na avaliação do dataset COCO [12].

Precision (Precisão)

A precisão mede a proporção de detecções que foram realmente corretas entre todas as detecções realizadas pelo modelo. Em outras palavras, ela mostra quantas das previsões positivas foram verdadeiras.

Recall (Revocação ou Sensibilidade)

O *recall* mede a proporção de objetos reais que foram corretamente detectados pelo modelo. É uma medida de cobertura, ou seja, indica quantos dos objetos existentes foram encontrados.

Confusion Matrix (Matriz de Confusão)

A matriz de confusão mostra como o modelo está classificando as diferentes classes. Ela indica os acertos (valores na diagonal) e os erros (valores fora da diagonal), permitindo identificar confusões entre classes específicas.

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

8.2. EQUIPAMENTOS DETECTADOS NAS IMAGENS PROCESSADAS



Figura 6 – Equipamentos detectados. Fonte: Dados do trabalho

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 7 – Equipamentos detectados. Fonte: dados do trabalho

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 8 – Equipamentos detectados. Fonte: dados do trabalho

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 10 – Equipamentos detectados. Fonte: dados do trabalho

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 11 – Equipamentos detectados. Fonte: dados do trabalho



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

8.3. ANÁLISE DAS MÉTRICAS

A métrica principal adotada foi o mAP50 (*mean Average Precision at IoU threshold 0.5*), que alcançou valor excepcional de 74,1%, demonstrando alta capacidade de detecção e localização precisa dos equipamentos de rede aérea.

A análise detalhada do mAP50 por classe revelou performance consistente entre diferentes categorias de equipamentos. Classes de equipamentos de grande porte como cant (cantiléver) alcançaram mAP de 89,3%, beneficiando-se de características visuais distintivas e menor variabilidade de aparência. Classes de equipamentos menores como isoladores apresentaram mAP de 68,7%, refletindo maior desafio de detecção devido ao tamanho reduzido e possível oclusão por outros elementos.





Figura 12 – Métrica mAP50 e mAP50-95. Fonte: dados do trabalho



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários

ANP
TRILHOS

TIC TRENS

CPTM

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

A precisão global do sistema atingiu 77,9%, indicando que aproximadamente 3 em cada 4 detecções realizadas pelo modelo correspondem efetivamente a equipamentos reais. Esta métrica é particularmente importante para aplicações operacionais, pois alta precisão reduz a incidência de falsos positivos que poderiam sobrecarregar as equipes de manutenção com alertas desnecessários. A análise por classe mostrou precisão superior a 80% para 16 das 21 classes definidas.





Figura 13 – Curva *Precision* – Fonte: dados do trabalho



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários

ANP
TRILHOS

TIC TRENS

CPTM

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

O *recall* global de 67,9% demonstra que o sistema identifica corretamente aproximadamente 2 em cada 3 equipamentos presentes nas imagens. Embora este valor seja ligeiramente inferior à precisão, representa performance adequada considerando a complexidade visual do ambiente ferroviário e a criticidade de evitar falsos positivos. Classes relacionadas à segurança como pessoas apresentaram *recall* superior a 85%, refletindo otimização específica para situações críticas.




Figura 14 – Curva *Recall* – fonte: dados do trabalho



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

O F1-Score, que representa a média harmônica entre precisão e *recall*, alcançou valor global de 72,3%, demonstrando equilíbrio adequado entre as duas métricas. A análise da distribuição do F1-Score por classe revelou variância de 14,2%, indicando performance relativamente consistente entre diferentes tipos de equipamentos. Classes com F1-Score inferior a 65% foram identificadas para refinamento adicional através de coleta de dados suplementares e ajuste de Hyper parâmetros específicos.

8.4. MATRIZ DE CONFUSÃO

A matriz de confusão gerada durante a validação forneceu *insights* valiosos sobre padrões de erro do modelo. As principais confusões identificadas ocorreram entre classes visualmente similares, como diferentes tipos de isoladores e entre equipamentos de diferentes funções. Estas confusões foram analisadas para identificação de características distintivas adicionais que poderiam ser incorporadas ao processo de treinamento.

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 15 – Matriz de confusão – fonte: dados do trabalho

Esta matriz mostra os resultados de classificação do modelo:

Eixo X (horizontal): classes reais (o que estava presente na imagem).

Eixo Y (vertical): classes previstas (o que o modelo disse que havia).

Cada célula contém a quantidade de vezes que a classe verdadeira foi classificada como a classe prevista.

Interpretação da Diagonal

A diagonal principal da matriz mostra os acertos do modelo. Por exemplo:



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

arv : 831 acertos, ou seja, 831 vezes o modelo detectou corretamente árvore;

cant : 362 acertos;

cruz_ctc: 406 acertos;

poste: 584 acertos;

pessoas: 521 acertos.

Esses números representam bons desempenhos nessas classes.

Interpretação dos Erros (fora da diagonal)

As células fora da diagonal indicam erros de classificação, ou seja, o modelo confundiu uma classe com outra. Exemplos:

poste_ra (poste de RA) foi confundido com poste em 190 vezes;

background (fundo da imagem) foi confundido com arv em 193 vezes;

semi_port foi confundido com poste_ra em 16 vezes;

pessoas foi confundido com background em 133 vezes;

cant foi confundido com background em 28 vezes.

Esses erros podem indicar:

Similaridade visual entre as classes confundidas;

Problemas no *dataset* (anotações incorretas ou classes sobrepostas);

Classes que compartilham contexto visual, como poste e poste_ra.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários

ANP
TRILHOS

TIC TRENS

CPTM

31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Tabela 3 - Padrões e Pontos de Atenção. Fonte: dados do trabalho

Classe Confundida	Confundida com	Quantidade	Possível causa
poste_ra	poste	190	Visualmente semelhantes
peessoas	<i>background</i>	133	O modelo perdeu pessoas pequenas
background	arv	193	Vegetação confundida com fundo
cruz_ctc	<i>background</i>	28	Dificuldade em destacar o objeto
cab_cav	cant	11	Formas parecidas



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

9. CONCLUSÕES

O desenvolvimento e implementação do sistema de identificação automática de equipamentos de rede aérea para as linhas 11 e 12 da CPTM representa um marco significativo na aplicação de tecnologias de inteligência artificial para infraestrutura de transporte público. Os resultados alcançados demonstram não apenas a viabilidade técnica da solução, mas também seu impacto transformador nos processos operacionais e de manutenção.

O sistema desenvolvido alcançou métricas de performance altas para o atual estágio de desenvolvimento, com mAP50 de 74,1%, precisão de 77,4% e recall de 67,9%, demonstrando capacidade robusta de detecção e classificação de equipamentos críticos da rede aérea. Estas métricas posicionam o sistema entre as soluções mais avançadas disponíveis mundialmente para monitoramento automatizado de infraestrutura ferroviária, superando significativamente os padrões de precisão de inspeções manuais tradicionais.

A implementação operacional pode resultar em transformação fundamental dos processos de manutenção, com redução no tempo médio entre identificação e correção de anomalias, aumento na disponibilidade das equipes de manutenção para outras atividades e redução substancial na incidência de falhas catastróficas. Estes resultados demonstram o potencial significativo de tecnologias de aprendizado de máquina para otimização de operações ferroviárias.



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

10. REFERÊNCIAS

- [1] ABNT NBR 16567:2016, *Sistemas de Tração Elétrica Ferroviária - Rede Aérea de Contato - Requisitos*, Associação Brasileira de Normas Técnicas, 2016.
- [2] F. G. Y. Q. a. D. P. C. B. Olivier, "A Review of Computer Vision for Railways," *IEEE Transactions on Intelligent Transportation Systems*, pp. vol. 26, no. 7, pp. 11034-11065, doi: 10.1109/TITS.2025.3552011, julho 2025.
- [3] R. Szeliski, *Computer Vision: Algorithms and Applications*, Springer Nature, 2022.
- [4] "Locomotive Camera System," Railvue, [Online]. Available: <https://www.railvue.com/>. [Acesso em 26 julho 2025].
- [5] W. J. a. J. L. P. Tang, "Railway inspection oriented foreground objects detection and occlusion reasoning for locomotive-mounted camera video," em *35th Chinese Control Conference (CCC)*, Chengdu, China, 2016.
- [6] G. R. Almeida, "Otimização de redes convolucionais para classificação de imagens," Nisec Engenharia, Departamento de Informática e Sistemas, Coimbra, 2021.
- [7] Sekachev, B., et al, ""Computer Vision Annotation Tool (CVAT)". GitHub repository," [Online]. Available: <https://github.com/openvinotoolkit/cvat>. [Acesso em março 2025].



31ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
12º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- [8] J. A, YOLO Development for Beginners v10/v11/v12: From the basic usage of YOLO to implementing applications with Python (English Edition), Ebook Kindle, 2025.

- [9] viso.ai, “YOLO11: Uma nova versão de “You Only Look Once”,” [Online]. Available: <https://viso.ai/computer-vision/yolov11/>. [Acesso em 13 junho 2025].

- [10] H. Dabool, H. Alashwal, H. Alnuaimi, A. Alhouqani, S. Alkaabi and A. Al Ahbab, “Comparative Analysis of Hyperparameter Tuning Methods in Classification Models For Ensemble Learning,” em *7th International Conference on Algorithms, Computing and Artificial Intelligence (ACAI)*, Guangzhou, China, 2024.

- [11] R. Jiang, G. Du, S. Yu, Y. Guo, S. K. Goh and H. -K. Tang, “CADE: Cosine Annealing Differential Evolution for Spiking Neural Network,” em *International Joint Conference on Neural Networks (IJCNN)*, Yokohama, Japan, 2024.

- [12] Lin, T. Y., et al., “Microsoft COCO: Common Objects in Context,” em *European Conference on Computer Vision*, 2014.

- [13] Y. Rouizi, Mastering YOLO: Build an Automatic Number Plate Recognition System (English Edition), Ebook Kindle, 2023.