



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

CATEGORIA 3

VISÃO COMPUTACIONAL APLICADA A INSPEÇÃO EM AMV COM DRONE

AUTORES

INTRODUÇÃO

A indústria ferroviária, especialmente a de transporte de carga, opera em um ambiente complexo e exigente, onde a segurança e a confiabilidade são requisitos indispensáveis, dependendo de inspeções regulares e precisas dos ativos. Este trabalho é fundamental para garantir a integridade do sistema e prevenir falhas que podem levar a acidentes e interrupções nas operações.

Tradicionalmente, esses métodos de inspeção eram realizados manualmente por inspetores experientes, um processo demorado, custoso e sujeito a erros humanos.

Visando superar essas limitações, a visão computacional surge como uma solução inovadora e promissora para a inspeção de ativos ferroviários. Através da integração de



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

algoritmos inteligentes com câmeras e sensores, é possível automatizar o processo de inspeção, tornando-o mais eficiente, preciso e seguro.

O advento da visão computacional, câmeras e drones oferece uma solução inovadora e promissora para essa problemática. Ao integrar essas tecnologias, é possível automatizar o processo de inspeção de forma eficiente, precisa e segura.

DIAGNÓSTICO

No complexo universo ferroviário, diversos componentes se entrelaçam para viabilizar o transporte seguro e eficiente de cargas e passageiros. Entre eles, os aparelhos de mudança de via (AMV's) assumem papel fundamental de guiar os trens para diferentes trilhos, permitindo a conexão entre linhas, manobras, desvios e acessos a pátios e terminais, porém, também exigem atenção redobrada devido à sua criticidade.



Figura 1 – Aparelho de Mudança de Via

Uma falha em um ativo de AMV pode ocasionar em descarrilhamento, restrição ou interrupção da circulação. Logo, para garantir a confiabilidade destes ativos, são



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

tomadas algumas medidas estratégicas, que são: Inspeções frequentes, manutenções preventivas e corretivas, e monitoramento contínuo.

O método tradicional de inspeção, apresenta algumas limitações, como:

- **Tempo e Custo:** O processo manual é demorado e exige grande contingente de inspetores, elevando os custos operacionais.
- **Fadiga Humana:** A inspeção manual e repetitiva e em ambientes desfavoráveis, o que pode levar à fadiga humana e aumentar a probabilidade de erros.
- **Precisão e Confiabilidade:** A inspeção manual é subjetiva e suscetível à variabilidade entre inspetores, impactando a precisão e confiabilidade dos resultados.
- **Segurança:** A inspeção manual pode expor os trabalhadores a riscos com atropelamentos, quedas, torções, intempéries, animais peçonhentos e entre outros.

O método tecnológico desenvolvido para otimizar o processo de inspeção, consiste na utilização drones acoplados com câmeras de alta resolução para aquisição de imagens precisas, que posteriormente são processadas em softwares específicos gerando os dados visuais e topográficos do ativo.

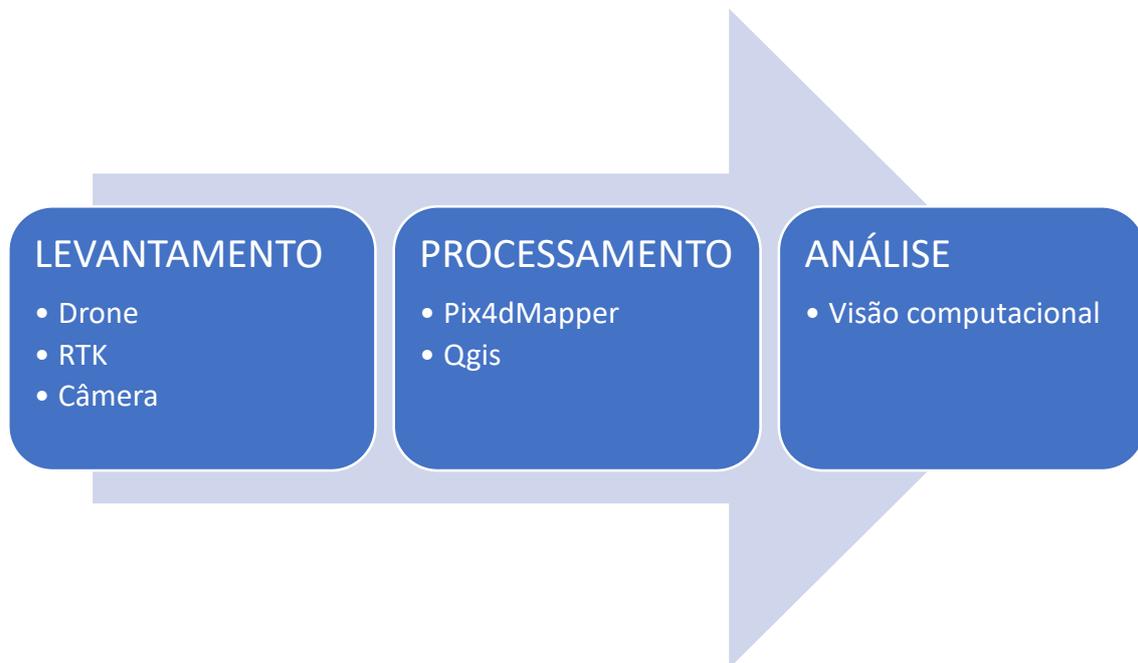
Seguindo para o processo de análise dos dados gerados, a visão computacional surge como solução para superar os desafios da inspeção manual, automatizando o processo



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

de identificação de componentes, detecção de anomalias, segmentação de peças, e posteriormente medição de cotas.

O fluxo abaixo ilustra como funciona o processo de inspeção com drones e visão computacional:



A junção destas tecnologias traz diversos benefícios, entre eles:

- Dados de Alta Resolução: Drones equipados com câmeras de alta resolução podem capturar imagens e dados detalhados, permitindo uma análise mais precisa dos AMV's.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- **Análise Precisa:** Algoritmos de visão computacional podem analisar as imagens capturadas para identificar componentes e anomalias com maior precisão e confiabilidade do que a inspeção manual.
- **Padrão de inspeção:** Assinaturas e padrões de anomalias definidas garantem uma confiabilidade dos resultados.
- **Segurança:** Drones podem inspecionar áreas sem a necessidade de adentrar o gabarito da linha, podendo operar o equipamento de uma área segura próximo ao ativo, reduzindo o risco para os trabalhadores.

Os dados gerados pela inspeção são essenciais para o planejamento estratégico da manutenção, direcionando os investimentos para os ativos de maior criticidade, garantindo a segurança operacional, reduzindo os custos com investimento desnecessários e manutenções corretivas.

A figura 2 ilustra o painel de acompanhamento dos dados gerados a partir das inspeções, que são disponibilizadas as equipes de planejamento estratégico da manutenção.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

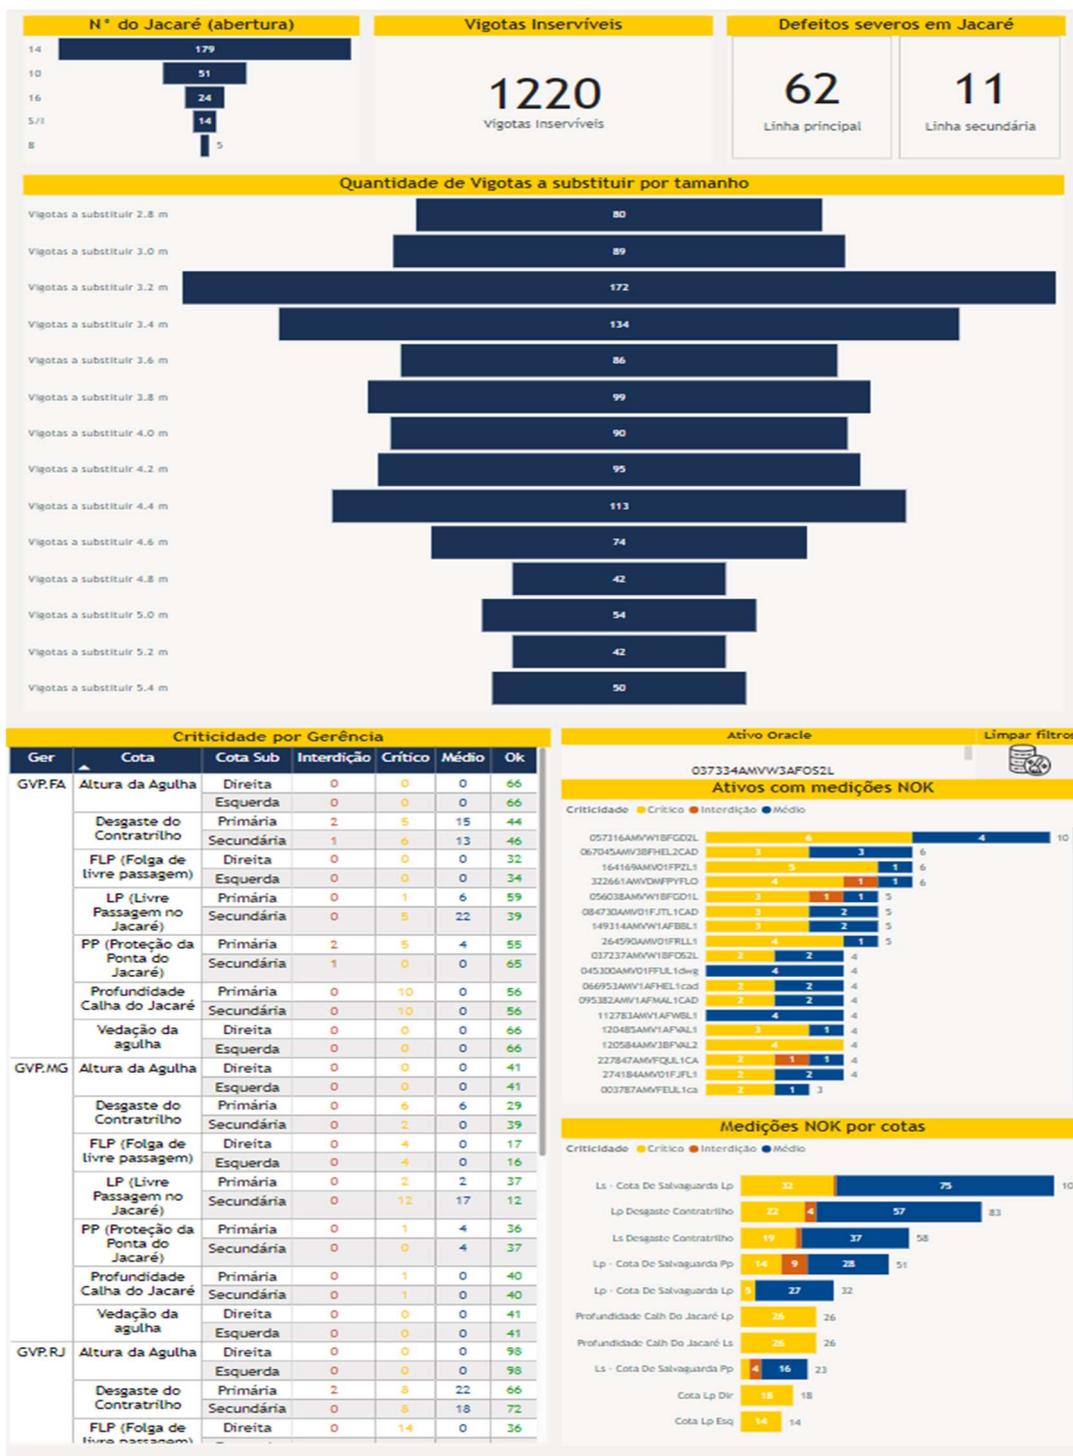


Figura 2 – Painel de acompanhamento dados inspeção.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

ANÁLISE DOS RESULTADOS

1. Resultados obtidos com a implantação do processo de coleta de dados utilizando drone

A primeira fase é migrar a coleta de dados em campo utilizando equipamentos manuais como réguas, trenas e paquímetros para a captura de imagens por drones. Este processo representa um salto significativo em termos de eficiência, precisão e segurança, porém para garantir uma transição suave e bem-sucedida, deve ser realizada de forma graduada e seguindo algumas etapas, como: Definição de metodologia, hardwares, softwares, treinamentos, desenvolvimento de fluxo de trabalho e outros.

a. Etapa de definição de equipamento para levantamento em campo:

Estabelecidos os requisitos para a qualidade das imagens, o drone DJI Matrice 300/350 RTK junto a câmera Zenmuse P1 de 35MM garante uma coleta de imagens em alta resolução, atendendo os parâmetros desejados com uma operação precisa e segura.

b. Definição de equipamentos e softwares para processamento:

Para transformar as imagens capturadas em informações acionáveis e insights valiosos, é crucial recorrer ao poder de workstations de processamento e softwares especializados. Nesse cenário, se destaca o Pix4Dmapper, capaz de transformar as imagens de drone em modelos 3D precisos e mosaicos impecáveis. Sua expertise



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

reside na capacidade de identificar pontos de referência homólogos entre as imagens, tecendo uma malha complexa que captura a verdadeira forma do objeto ou área mapeada, gerando arquivos informações como: mosaico, modelo digital de terreno e superfície, modelo 3D, nuvem de pontos entre outros.

c. Definição de softwares para manipulação:

Posteriormente ao processamento e extração dos produtos gerados, eles precisam ser manipulados em outros softwares específicos, se destacando o Qgis e o Civil 3D. Com o QGIS, é possível visualizar, editar e analisar mosaicos, nuvens de pontos e modelos 3D, extraindo informações valiosas como relevo do terreno e cotas altimétricas da superfície, sendo essencial para a extração precisa de perfis longitudinais e transversais a partir do modelo digital de superfície, no qual é possível extrair as rampas das linhas férreas, além de destacar a diferença de altura entre os trilhos, conhecida como superelevação. Essa análise detalhada do perfil ferroviário é crucial para diversos fins, entre irregularidades na geometria da via e rampas nas linhas de páteo, análise crucial para garantir a frenagem segura e eficaz dos vagões. Para análise detalhada os mosaicos são importados para o Civil 3D, onde são manipulados e inspecionados de forma manual cada um dos componentes do ativo, esta inspeção manual consiste na avaliação dos dados qualitativos e quantitativos conforme tabela 01, contando com alguns itens desta inspeção. A utilização do Civil 3D junto a mosaicos gerados em alta resolução, garantem uma



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

precisão milimétrica nas medições, atendendo os requisitos para inspeção em ativos ferroviários.

ANÁLISE DADOS COLETADOS (INSPEÇÃO)	
<u>Quantitativos</u>	<u>Qualitativos</u>
Medição de Bitola região da Agulha e Jacaré	Fixações (placas, grampos, tirefonds)
Abertura de calhas contratrilho e jacaré	Defeitos superficial pista de rolamento
Folga de livre passagem de agulha	Dormente inservível
Espaçamento de dormentes	Lastro contaminado (Bolsão)
Esquadro agulha	Movimentação de lastro (Geometria)
Posicionamento contratrilho	Alinhamento barras de conjugação
Distâncias de projeto	Avarias em juntas

Tabela 1: Itens para inspeção em AMV

Após todas as definições, treinamentos e testes com os equipamentos, se iniciou a fase de validação, sendo realizado comparativos entre os dados gerados através da inspeção com drone e os dados de levantamento técnicos em campo de forma tradicional. Foram realizados comparativos com dados qualitativos como identificação de anomalias em

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

componente e dados quantitativos como medição de bitola e cotas conforme figuras 3, 4 e 5.

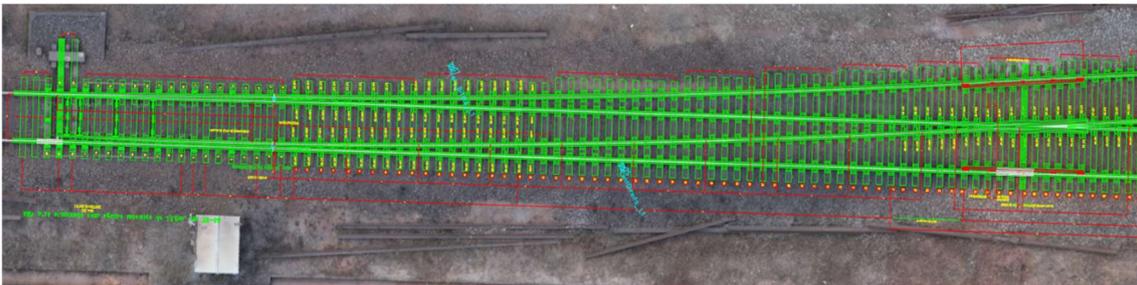


Figura 3 – Conferência de medidas de projeto.



Figura 4 – Medição de cotas jacaré.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

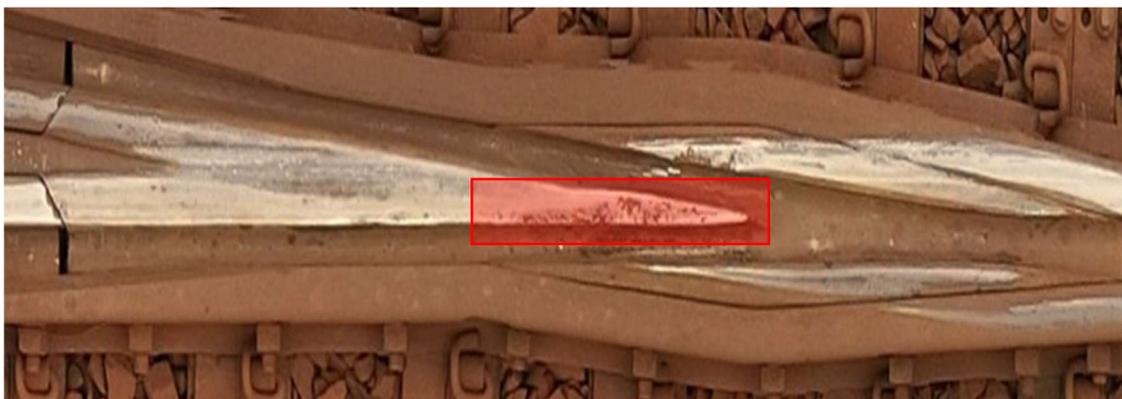


Figura 5 – Defeito ponta material jacaré

Os resultados dos comparativos foram satisfatórios, validando o processo de inspeção com drones, viabilizando a implantação do processo para inspeção de ativos de mudança de via em linhas principais.

Com a implantação deste formato, visto a qualidade e confiabilidade dos dados obtidos com o drone associados aos dados de veículos de inspeção geométrica, foi viabilizado a redução em 35% o ciclo de inspeção em AMV's de linha principal, reduzindo o número de inspeções manuais, que anteriormente eram realizadas trimestralmente, passaram a ser realizadas semestralmente.

O novo método trouxe ganhos exponenciais, porém ainda havia capacidade evoluir, visto que toda a análise seria manual através dos softwares especificados, gerando alguns desafios, como:

- Demorada e trabalho, especialmente para grandes conjuntos de imagens.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- Suscetível à fadiga, erros humanos e variações de interpretação devido ao excesso de repetitividade.
- Impraticável para análise em larga escala ou em curto tempo.

Buscando reduzir o tempo de análise gerar ainda mais qualidade e confiabilidade, visto que a avaliação dos dados coletados apesar de agora serem realizadas em um ambiente confortável sem interferências e riscos, ainda era totalmente manual através das imagens processadas.

Logo, foi identificada a oportunidade de implementar visão computacional para análise automatizada e otimizada dos dados, agregando qualidade e produtividade ao processo.

2. Resultados obtidos com a criação do modelo de Visão Computacional

O modelo de Visão Computacional utiliza a imagem entregue pelo drone para fazer inferências. Esta é efetuada para detectar ativos do AMV além de seus tipos de falhas associados de forma que seja entregue para o colaborador na forma de marcações na imagem por tipo de classe e relatórios resumidos com a localização, tipo de ativo e falha associada.

As classes definidas a serem detectadas pelo modelo são:

Tirefon	Grampo	Placa	Tirefon Faltante
Placa Gêmea	Porca Tala	Placa Deslizante	Falta Grampo



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

	Junta	Escora Lateral	
--	-------	----------------	--

Yolov8 foi a biblioteca utilizada para este desenvolvimento, esta biblioteca se destaca como um modelo preciso para detecção de objetos em tempo real, sendo capaz de identificar e localizar diversos objetos em imagens e vídeos com precisão e agilidade, abrindo um leque de possibilidades para aplicações inovadoras.

Para o treinamento do modelo foi utilizado um banco de dados de 4417 imagens. Através da utilização de técnicas de **augmentations**, como por exemplo o espelhamento, giro de imagens etc., foi possível consolidar um banco de dados de 9863 imagens dispostos em '**TRAIN SET**', '**VALID SET**' E '**TEST SET**' conforme figura 6:

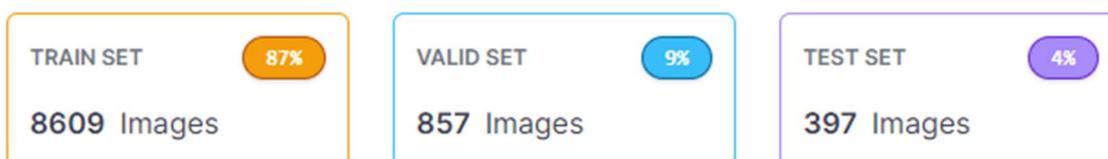


Figura 6: Banco de imagens usado para treinamento do modelo

A figura 7 abaixo mostra a quantidade de anotações por classe efetuadas no banco de dados original.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

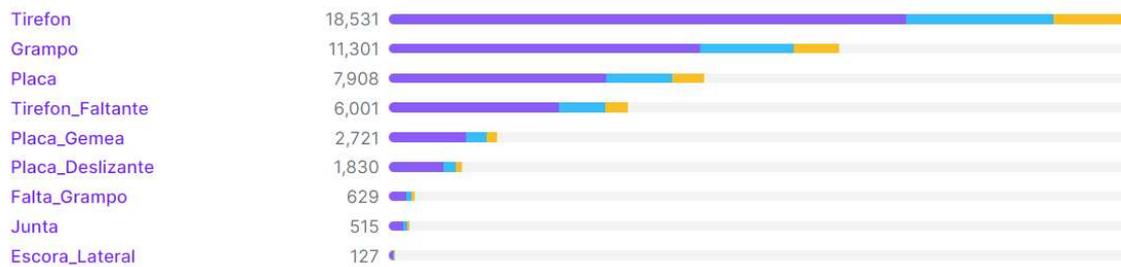


Figura 7: Quantidade de anotações efetuadas no bando de dados

A curva de **Precision-Recall** (PR) da figura 8 oferece uma visão abrangente do desempenho do modelo, revelando a relação entre a precisão e a capacidade do modelo de encontrar todos os objetos relevantes. No caso em questão, a curva avalia a performance de um modelo treinado para identificar as 9 classes de objetos nas imagens.

Para melhor entendimento dos indicadores, **Precision** está relacionado com a quantidade de falsos positivos, neste caso, quanto mais próximo de 1 menor a quantidade de falsos positivos, o mesmo ocorre com **Recall**, porém em relação a quantidade de falsos negativos. Na curva por classes, quanto mais próximos do valor unitário de cada classe, melhor o desempenho do modelo.

A área sob a curva PR (AUC-PR) representa a probabilidade média do modelo classificar um objeto relevante corretamente em todas as possíveis classificações. Um valor de AUC-PR alto indica que o modelo tem bom desempenho geral na detecção de objetos.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

No caso da figura, a AUC-PR média para todas as classes é de 0,934, demonstrando que o modelo apresenta um bom desempenho geral.

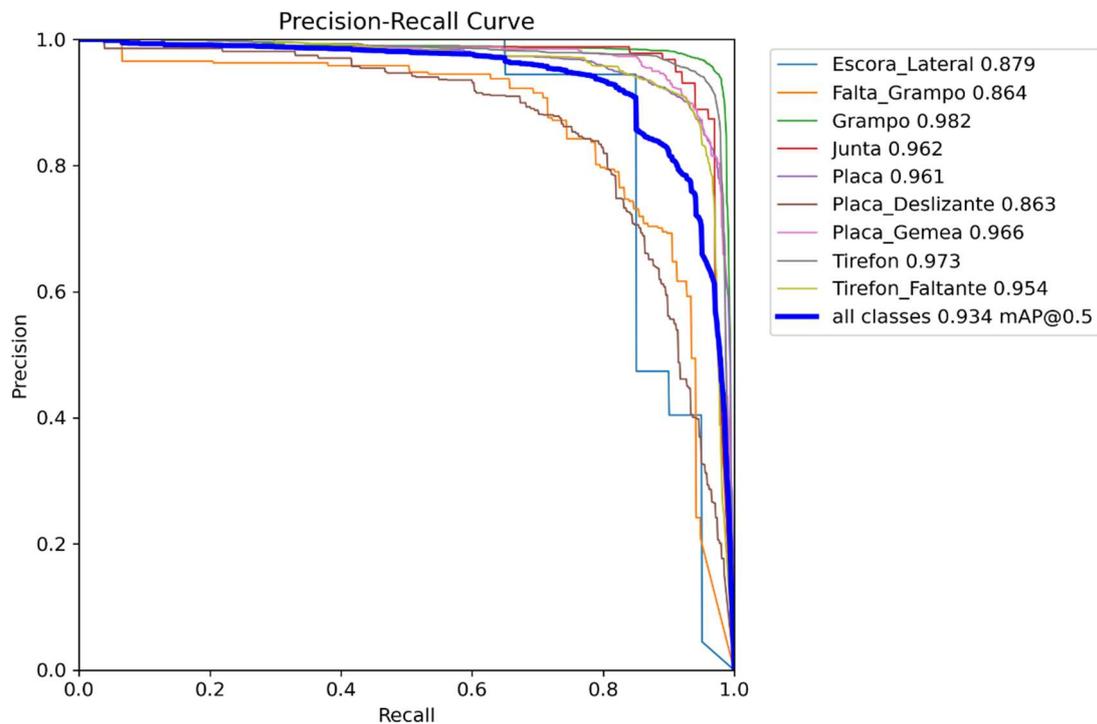


Figura 8: Precision-Recall Curve

A matriz de confusão, figura 9, apresenta um panorama detalhado do desempenho de um modelo de detecção de objetos, permitindo uma análise profunda do desempenho do modelo, ela avalia a performance de um modelo treinado para identificar 9 classes de objetos em imagens: Escora Lateral, Falta_Grampo, Grampo, Junta, Placa, Placa_Deslizante, Placa_Gemea, Tirefon e Tirefon_Faltante.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

A diagonal principal da matriz destaca a precisão do modelo, ou seja, a proporção de objetos corretamente classificados em cada classe. Observa-se que a maioria das classes apresenta alta precisão, com valores acima de 0,8. Isso indica que o modelo consegue identificar com sucesso a maioria dos objetos presentes nas imagens. No entanto, classes como Placa_Deslizante e Tirefon_Faltante apresentam precisão menor devido a quantidade reduzida de amostras e tamanho na imagem respectivamente.

As células fora da diagonal principal revelam os erros de classificação do modelo. Os falsos positivos (valores na linha de cada classe) representam objetos incorretamente classificados como pertencentes a uma determinada classe. Já os falsos negativos (valores na coluna de cada classe) indicam objetos que o modelo falhou em detectar.

A alta precisão na maioria das classes demonstra a efetividade do modelo, enquanto os erros de classificação em algumas classes indicam áreas que podem ser aprimoradas através de técnicas como rebalanceamento de dados, ajuste de hiperparâmetros e utilização de algoritmos mais robustos.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

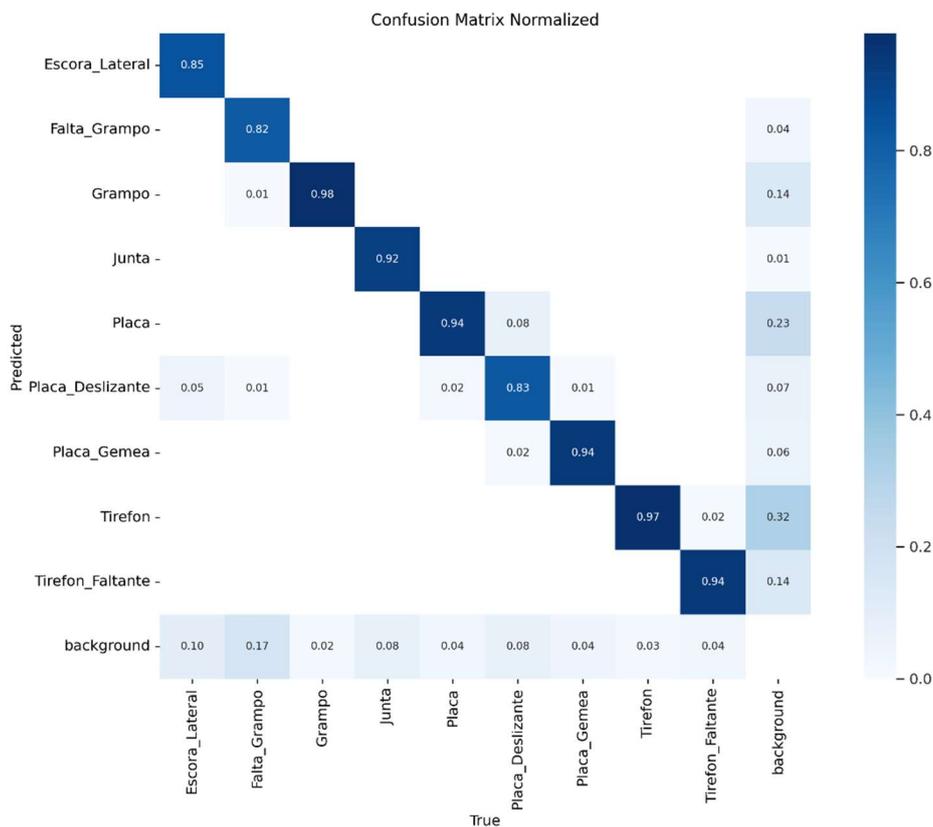


Figura 9: Matriz Confusão do modelo

Abaixo são mostradas imagens de validação do modelo, onde a imagem da esquerda são classes marcadas antes do treinamento e a imagem da direita são os resultados de predição feitas pelo modelo nas mesmas imagens com o grau de probabilidade de acerto dentro de cada **bounding box** (retângulo que indica o objeto detectado), reforçando a resultado indicado pelos indicadores apresentados anteriormente, figura 10:

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

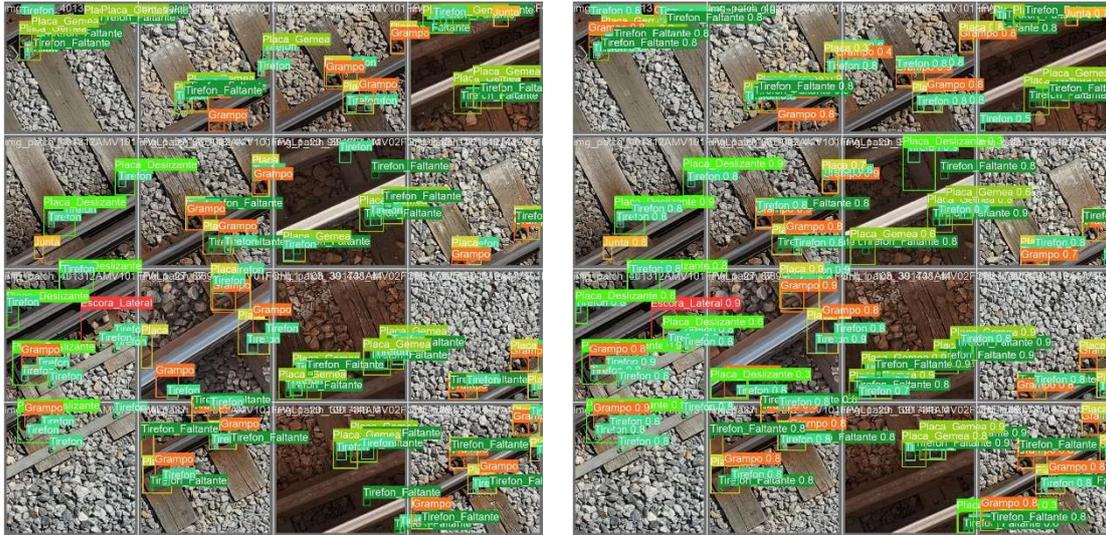


Figura 10: Dados de Validação

Neste projeto o YOLOv8, que é baseado em uma rede neural profunda, foi treinado com um vasto conjunto de dados de imagens provenientes das imagens entregues pelo drone, conforme mostra a figura 11.



Figura 11 – Imagem entregue pelo drone

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

A imagem é então processada pelo algoritmo e recortada em ‘patches’ conforme figura 12.

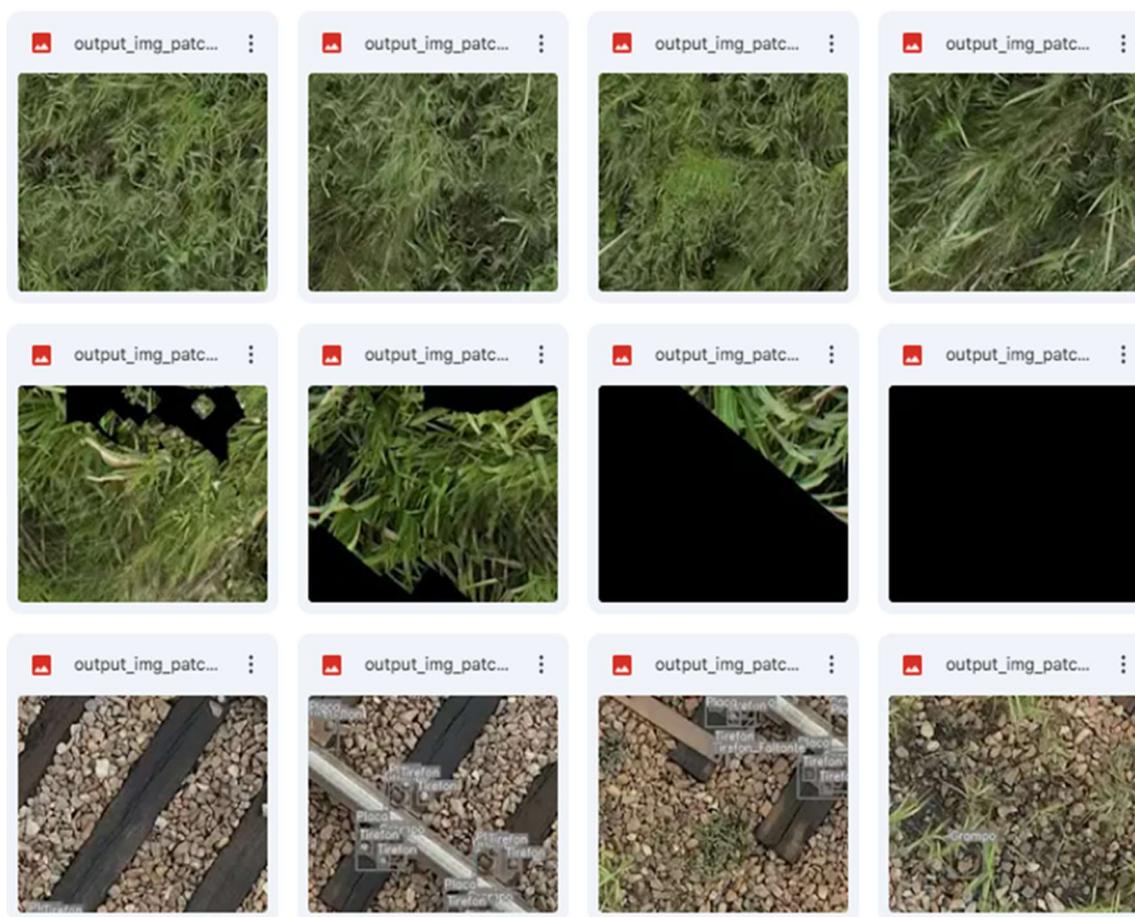


Figura 12 – Patches processados pelo algoritmo

A imagem contém em seus metadados as coordenadas geográficas Latitude e Longitude, portanto cada pixel tem valor distinto de coordenadas, de forma que ao ocorrer a detecção em forma de **bounding box** é possível encontrar seus valores de coordenadas de seu centro conforme indicado na figura 13.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

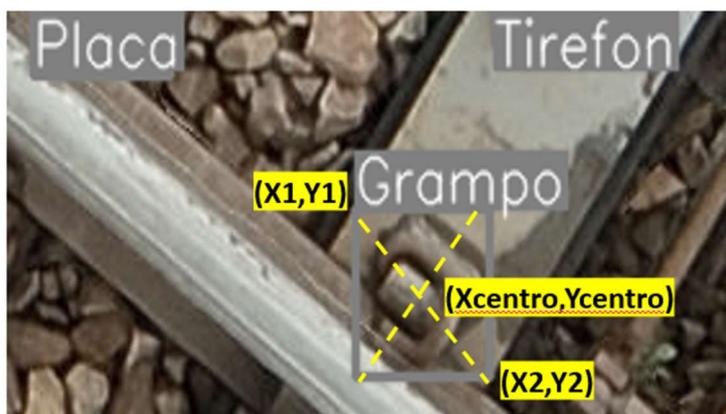


Figura 13: Detecção de itens com a identificação de suas coordenadas

Uma vez determinadas as detecções e suas coordenadas são possível gerar imagens distintas do AMV para cada tipo de item classificado com o objetivo de facilitar o entendimento do especialista, além de relatórios resumidos com todos os itens detectados, figura 14.

Nome da Figura	Classe	Coordenada X1	Coordenada Y1	Coordenada X2	Coordenada Y2	X1	Y1	latitude	longitude
img_patch_297451AMVFJCFAL1.tif_7_28_448_448.png	Grampo	211	125	243	155	227	140	7725779,015	606621,7375
img_patch_297451AMVFJCFAL1.tif_7_30_448_448.png	Grampo	138	203	184	255	161	229	7725778,771	606624,0117
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Grampo	318	221	365	268	341,5	244,5	7725777,501	606587,6809
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Grampo	169	20	215	68	192	44	7725778,051	606587,2713
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Grampo	327	132	373	180	350	156	7725777,744	606587,7042
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Grampo	161	111	208	158	184,5	134,5	7725777,803	606587,2507
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Placa	275	200	362	281	318,5	240,5	7725777,512	606587,6179
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Grampo	0	0	42	40	21	20	7725778,117	606586,8027
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Tirefon	156	144	176	164	166	154	7725777,749	606587,2
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Placa	335	123	416	199	375,5	161	7725777,73	606587,7741
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Placa	118	89	204	169	161	129	7725777,818	606587,1863
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Tirefon	282	229	304	252	293	240,5	7725777,512	606587,548
img_patch_297451AMVFJCFAL1.tif_8_0_448_448.png	Placa	178	9	259	87	218,5	48	7725778,04	606587,3439

Figura 14: Relatório de saída dos itens detectados na imagem

Abaixo segue imagem da detecção da classe 'Grampo', figura 15.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

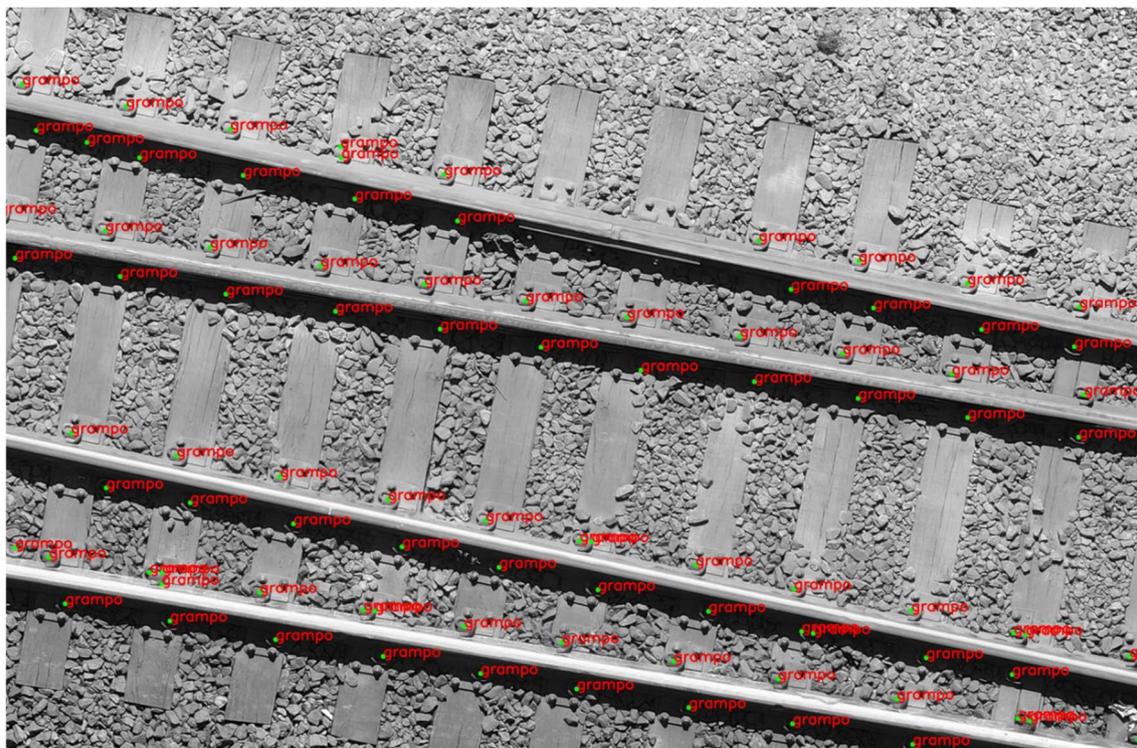


Figura 15: Detecção de Grampo

Uma vez construído o relatório de detecções com localizações, é possível efetuar inferências condicionais cruzando estes dados, de forma que poderão ser realizadas detecções de condições de risco, como por exemplo 'Placas sem todos os Tirefons', aumentando o leque de análises pelo especialista, nestes casos a imagem resultante indicará apenas as condições de risco determinadas pelo especialista, figura 16.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

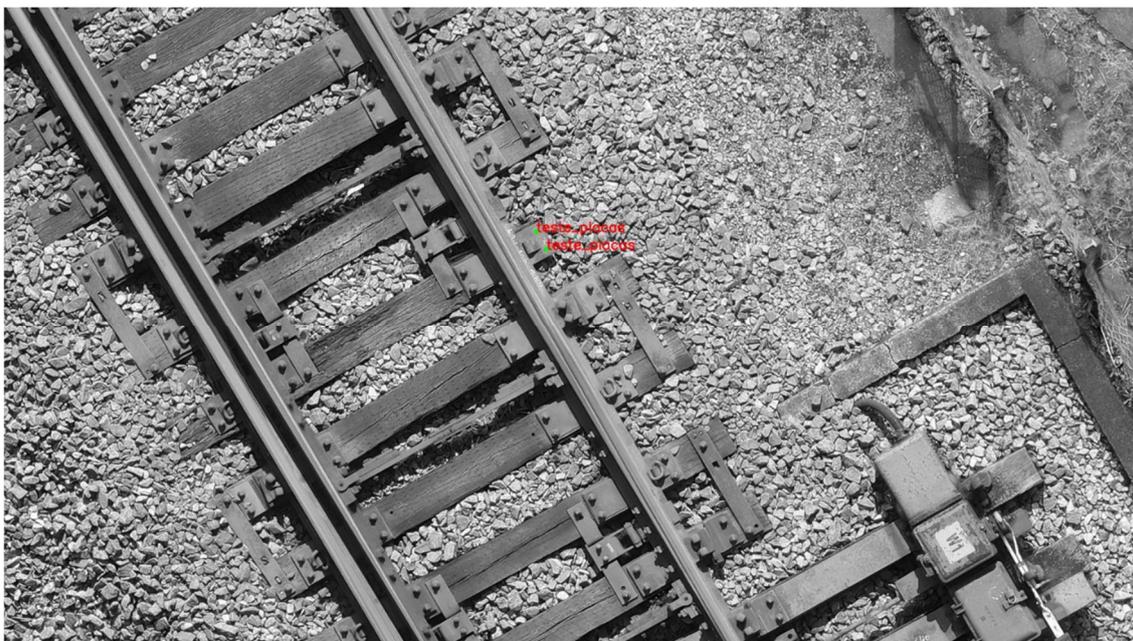


Figura 16: Detecção de Placas sem todos os Tirefons

CONCLUSÕES

Conforme é possível verificar no desenvolvimento do trabalho, a mudança do processo de coleta de dados com drone trouxe ganhos com a redução da subjetividade, qualidade no levantamento dos dados e segurança para o colaborador responsável pelas inspeções em campo. Neste ponto a Visão Computacional acelerou significativamente o processo de análise, garantindo a confiabilidade, melhorando o planejamento estratégico da manutenção e garantindo uma circulação segura.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Nos próximos passos estão o aumento de capacidade para análise de 100% dos dados coletados pelos drones, abrangendo todos os componentes da superestrutura ferroviária, permitindo uma análise mais abrangente e precisa da infraestrutura, possibilitando a detecção precoce de falhas e anomalias, prevenindo falhas catastróficas e otimizando a manutenção preventiva.

No sentido de aprofundamento da análise dos dados coletados por drones e IA na inspeção ferroviária, outro passo será o desenvolvimento de ferramentas intuitivas que facilitem a identificação de padrões e tendências, permitindo decisões estratégicas e otimizadas na manutenção. Uma plataforma amigável apresentará relatórios com pontos críticos e medições, auxiliando na comunicação clara do estado da superestrutura, no acompanhamento ao longo do tempo e na tomada de decisões estratégicas para gestão da manutenção e investimentos.

A implementação dos próximos passos propostos neste artigo terá o potencial de aprimorar significativamente a inspeção ferroviária com visão computacional.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

REFERÊNCIAS BIBLIOGRÁFICAS

1. Bojarczak, P., & Lesiak, P. (2021). UAVs in rail damage image diagnostics supported by deep-learning networks. *Journal Title*, (339-348).
2. Kumar, K. (2020). Improving Train Track Safety using Drones, Computer Vision and Machine Learning. [Cornell University].
3. Banić, M., Miltenović, A., Pavlović, M., & Ćirić, I. (2019) Intelligent Machine Vision based Railway Infrastructure Inspection and Monitoring using UAV. [Facta Universitatis] (357-364).
4. Wu, Y., Chen, P., & Qin, Y. (2023). Automatic Railroad Track Components Inspection Using Hybrid Deep Learning Framework. [IEEE].
5. Yilmazer, M. (2021). Detection and Measurement of Railway Expansion Gap with Image Processing. [ICDABI].
6. Guclu, E. (2021). Development of Vision-Based Autonomous UAV for Railway Tracking. [3ICT].
7. Sevi, M. (2022) Rail Tracking and Detection with Drone in Gazebo Environment. [DASA].



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- 8· <https://revistaoe.com.br/aerofotogrametria-com-drones-inspeciona-linhas-e-amvs/>
- 9· <https://infraroi.com.br/2018/10/09/ferrovia-usa-inteligencia-artificial-para-inspecao/>
- 10· <https://models.roboflow.com/object-detection/yolov5>
- 11· <https://stackoverflow.com/questions/66472578/meaning-of-the-metrics-in-yolov5>
- 12· <https://blog.roboflow.com/yolov5-improvements-and-evaluation/>
- 13· <https://blog.roboflow.com/mean-average-precision/>
- 14· <https://blog.roboflow.com/boosting-image-detection-performance-with-data-augmentation/>
- 15· <https://medium.com/axinc-ai/map-evaluation-metric-of-object-detection-model-dd20e2dc2472>
- 16· <https://github.com/ultralytics/yolov5/wiki/Train-Custom-Data>
- 17· <https://pyimagesearch.com/2018/11/12/yolo-object-detection-with-opencv/>
- 18· <https://www.youtube.com/watch?v=MdF6x6ZmLAY>



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

19 - Associação Brasileira de Norma Técnicas [ABNT].2020 - NBR 16827 - Aparelho de Mudança de Via – Localização do AMV no traçado geométrico da via – Requisitos – Primeira Edição, Item 4.

19 - Fabricante de equipamento de levantamento topográficos e drones. Disponível em: <https://enterprise.dji.com/pt-br/matrice-350-rtk>

20 - Software de processamento de imagens. Disponível em:
<https://www.pix4d.com/pt/>

21 – Autodesk Civil3d. Disponível em: Autodesk Civil 3D Ajuda | Tutoriais do Autodesk Civil 3D | Autodesk