

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



CATEGORIA (3)

UM SISTEMA DE VISÃO COMPUTACIONAL PARA OTIMIZAÇÃO
E SEGURANÇA EM SISTEMAS SOBRE TRILHOS

INTRODUÇÃO

A segurança viária em trens de passageiros é uma questão de extrema importância e preocupação para as operadoras do transporte público ferroviário. Milhões de pessoas em todo o mundo dependem diariamente do transporte ferroviário para suas atividades cotidianas, tornando imprescindível garantir a integridade física dos passageiros, da equipe operacional e a preservação do patrimônio ferroviário. No entanto, a complexidade e a extensão das linhas férreas apresentam desafios únicos, onde incidentes e acidentes podem ocorrer em decorrência de diversas ameaças à segurança [1].

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Dentre as principais ameaças que impactam a segurança viária em trens de passageiros, destacam-se a presença de pessoas atravessando os trilhos em locais impróprios ou em momentos inoportunos, a interferência de animais na via, bem como a presença de objetos estranhos à operação metroferroviária. Essas ameaças podem ocasionar desde pequenos transtornos operacionais até acidentes graves, com sérias consequências para a vida dos passageiros e para a estrutura ferroviária [2].

No contexto atual, a tecnologia tem se mostrado uma aliada poderosa na busca por soluções inovadoras que visam aumentar a segurança viária em trens de passageiros. Nesse sentido, a visão computacional, um ramo da inteligência artificial, tem ganhado destaque como uma ferramenta capaz de detectar e prevenir situações de risco ao longo das linhas férreas. Esse trabalho técnico tem como objetivo apresentar a implementação de um sistema de visão computacional que visa mitigar as ameaças à segurança viária nos trens de passageiros [3].

O sistema de visão computacional proposto será responsável por processar e analisar as imagens capturadas pelas câmeras frontais instaladas nos trens de passageiros. Essas câmeras fornecerão uma visão em tempo real do ambiente ferroviário, possibilitando a detecção de elementos potencialmente perigosos à operação ferroviária.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Dentre as ameaças mais recorrentes, a presença de pessoas atravessando os trilhos em locais não autorizados é uma das mais graves. Esse comportamento, muitas vezes negligente e imprudente, coloca em risco tanto a vida dessas pessoas quanto a segurança dos passageiros e tripulantes do trem [4].

O sistema de visão computacional será capaz de identificar a presença de indivíduos nas áreas restritas da via, acionando alertas aos operadores do trem e aos centros de controle. Essa detecção precoce permitirá a adoção de medidas preventivas, como a redução de velocidade e o acionamento de sinais sonoros para alertar os pedestres.

Outra ameaça relevante é a interferência de animais na via, o que pode causar acidentes graves e danificar a estrutura ferroviária. Por meio da visão computacional, será possível detectar a presença de animais próximos aos trilhos, permitindo que os operadores adotem medidas de precaução, como acionar o sistema de frenagem de emergência e evitar o atropelamento desses animais.

Além disso, o sistema será treinado para ter a capacidade de identificar objetos estranhos à operação metroferroviária, como malas abandonadas ou objetos deixados nas proximidades da via e até mesmo outros veículos e meios de transporte. Esses itens podem representar riscos potenciais à segurança, podendo ser explosivos ou objetos capazes de danificar a estrutura do trem.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



A detecção precoce desses objetos permitirá que as autoridades competentes sejam notificadas, possibilitando a adoção de medidas para a remoção segura desses itens.

Assim, a implementação de um sistema de visão computacional para o aumento da segurança viária em trens de passageiros representa um importante avanço tecnológico no campo do transporte ferroviário. A capacidade de detectar e prevenir ameaças potenciais ao longo das linhas férreas proporcionará uma operação mais segura e confiável, garantindo a proteção dos passageiros, da equipe operacional e do patrimônio ferroviário, contribuindo para que o transporte ferroviário seja uma opção ainda mais segura e sustentável para a sociedade.

Finalmente, o presente artigo está organizado nas seguintes seções: na seção 2, será apresentado um diagnóstico dos principais desafios encontrados no sistema de visão computacional para a detecção de passageiros nas plataformas de embarque; na seção 3, a fundamentação teórica; na seção 4, será detalhada a metodologia utilizada no experimento; na seção 5, serão apresentados e analisados os resultados do experimento; na seção 6, serão apresentadas as conclusões do estudo e, por fim, na seção 7, serão listadas as referências bibliográficas utilizadas para embasar a pesquisa.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



DIAGNÓSTICO

Conforme supracitado, a implementação de um sistema de visão computacional surge como uma solução promissora para mitigar as ameaças à segurança viária em trens de passageiros [5]. Esse sistema será baseado em algoritmos de inteligência artificial e visão computacional, que permitirão o processamento em tempo real das imagens capturadas pelas câmeras frontais instaladas nos trens.

O presente artigo é um estudo aplicado à realidade do sistema de transporte de passageiros sobre trilhos da Região Metropolitana de Recife (RMR), operado pela Companhia Brasileira de Trens Urbanos. Tal sistema tem material rodante composto de Trens Unidade Elétrico (TUE) nos ramais centro e sul, bem como possui VLTs que operam o sistema a diesel, como demonstra a Figura 1.



Figura 1 – Materiais rodantes do sistema da RMR.
Da esquerda para a direita, o VLT e o TUE.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



A primeira etapa da concepção do projeto consiste na instalação de câmeras de alta resolução e ângulo amplo nas frentes de ambos os tipos de trens de passageiros, garantindo uma visão abrangente do ambiente ferroviário.

Situações específicas: Pessoas

Para a detecção de pessoas atravessando os trilhos em locais impróprios, o sistema utilizará algoritmos de detecção em imagens e técnicas de rastreamento de movimento. Assim, será possível identificar a presença de pedestres na via, acionando alertas para os operadores do trem e os centros de controle. Esse recurso permitirá que os operadores tomem ações preventivas, como acionar sinais sonoros ou reduzir a velocidade do trem, evitando colisões e incidentes com pedestres.

Situações específicas: Animais

Para lidar com a interferência de animais na via, o sistema de visão computacional utilizará algoritmos de reconhecimento de padrões e classificação de objetos para identificar a presença de animais próximos aos trilhos. Novamente, alertas serão acionados para que os operadores possam tomar medidas adequadas para evitar acidentes com os animais.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Situações específicas: Objetos

A detecção de objetos estranhos à operação metroferroviária será realizada por meio de técnicas de segmentação de objetos e análise de contexto. O sistema será capaz de identificar malas abandonadas, objetos suspeitos ou materiais que possam representar riscos à segurança. Alertas serão gerados para que equipes especializadas em via permanente possam inspecionar e remover esses objetos com segurança, evitando possíveis incidentes.

Principais desafios para a implementação do sistema

Em todas as situações, o sistema de visão computacional permitirá uma resposta rápida e precisa, aumentando a eficiência e a eficácia na prevenção de incidentes e na garantia da segurança viária em trens de passageiros. A análise em tempo real das imagens e a integração com os sistemas de alerta operacional possibilitarão a tomada de decisões ágeis e ações preventivas que contribuirão significativamente para reduzir os riscos e aumentar a segurança na operação do transporte ferroviário de passageiros.

Dessa forma, a implementação de um sistema de visão computacional representará um avanço significativo na busca por soluções inovadoras para aumentar a segurança viária em trens de passageiros.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Na Tabela 1. abaixo, foram elencados os principais desafios encontrados para a implementação de um sistema de tempo real de visão computacional (VC) proposto. O conhecimento de tais desafios norteiam os esforços da pesquisa, estabelecem premissas, e, para o contorno desses tais desafios, fez-se necessário o estudo de implementações de soluções de aprendizado profundo, algoritmos robustos e a infraestrutura adequada para garantir um sistema confiável e eficiente.

Tabela 1. Principais desafios para a implementação de um Sistema de VC.

Desafio	Descrição
Detecção em Tempo Real	A detecção de objetos, como pessoas, animais e obstáculos, deve ser realizada em tempo real para permitir uma resposta rápida a situações de risco
Precisão e Confiabilidade	O sistema deve apresentar alta precisão e confiabilidade na detecção de objetos, minimizando falsos positivos e negativos, evitando situações de alarme incorretas
Variações de Iluminação	As mudanças nas condições de iluminação podem afetar a qualidade da imagem e dificultar a detecção. O sistema deve ser robusto para lidar com diferentes cenários de luz
Ambientes Complexos	Plataformas de embarque, estações e áreas ao redor dos trilhos podem apresentar cenários complexos, com muitos objetos em movimento, exigindo maior processamento
Oclusões e Distorções	A presença de obstáculos e oclusões pode dificultar a detecção de objetos, exigindo algoritmos de visão computacional mais avançados para contornar essas situações

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Integração com Infraestrutura	O sistema de visão computacional deve ser integrado à infraestrutura ferroviária existente para permitir a comunicação em tempo real, no tocante aos alertas operacionais
Atualização em Tempo Real	As informações sobre a detecção de objetos devem ser atualizadas continuamente em tempo real, permitindo uma resposta imediata a novas situações de risco
Privacidade e Ética	A implementação de sistemas de visão computacional levanta questões de privacidade e ética no monitoramento de passageiros e usuários das estações

Nas subseções que seguem, cada ponto elencado na Tabela 1. é destrinchado, no aprofundamento do diagnóstico da situação.

Deteccção em Tempo Real

A deteccção em tempo real é um dos maiores desafios na aplicação de sistemas de visão computacional em ambientes dinâmicos, como na operação comercial de um trem e o fluxo das plataformas de embarque e desembarque de passageiros. Em um ambiente de transporte ferroviário, o tempo de reação é crítico para evitar acidentes e incidentes. O sistema de visão deve então ser capaz de realizar a deteccção em frações de segundo, permitindo uma resposta rápida a situações de risco, como pessoas ou animais na via férrea ou objetos obstruindo os trilhos. A eficiência e a velocidade de processamento dos algoritmos de deteccção são fundamentais para garantir a segurança dos passageiros e evitar colisões.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Precisão e Confiabilidade

A precisão e a confiabilidade na detecção de objetos são fatores críticos para evitar falsos positivos e negativos. Falsos positivos podem levar a alarmes desnecessários, causando interrupções no serviço e inconveniência para os passageiros.

Por outro lado, falsos negativos podem resultar em situações de risco não detectadas, colocando em perigo a segurança dos usuários. Garantir uma alta precisão na detecção é essencial para que o sistema de visão computacional seja eficaz e confiável.

Variações de Iluminação

Ambientes ferroviários podem apresentar variações significativas nas condições de iluminação, como mudanças de luz natural ao longo do dia e iluminação artificial em estações e plataformas. Essas variações podem afetar a qualidade das imagens capturadas pelo sistema de visão computacional, dificultando a detecção de objetos.

Os algoritmos de detecção devem ser robustos e capazes de lidar com diferentes cenários de luz, garantindo a detecção mais precisa possível em todas as condições.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Ambientes Complexos

As plataformas de embarque e desembarque, as passagens de nível, as vegetações em áreas ao longo da via permanente são ambientes complexos, com muitos objetos em movimento, como passageiros caminhando, trens chegando e partindo, e outras situações dinâmicas.

Essa complexidade pode dificultar a detecção de objetos e requer algoritmos de visão computacional mais avançados para lidar com cenários desafiadores. A presença de múltiplos objetos em movimento e oclusões podem aumentar a complexidade da detecção e exigir soluções mais sofisticadas [6].

Oclusões e Distorções

A presença de oclusões, onde um objeto está parcialmente escondido por outro, pode ocultar a detecção de objetos e dificultar a identificação correta de sua localização. Além disso, distorções ópticas causadas por lentes de câmera, reflexos ou sombras também podem afetar a precisão da detecção.

O desenvolvimento de algoritmos que sejam capazes de superar oclusões e distorções é um desafio importante na implementação de sistemas de visão computacional para a segurança viária em trens de passageiros, sobretudo em áreas de grande fluxo [7], onde os passageiros sofrem diversas oclusões em ambientes de estação, principalmente nos fluxos de embarque e desembarque.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Integração com Infraestrutura

Para que o sistema de visão computacional seja efetivo, ele deve ser integrado à infraestrutura ferroviária existente. A comunicação em tempo real entre o sistema de visão e os sistemas de segurança do trem e da estação é crucial para garantir uma resposta rápida a eventos de risco. A integração eficiente com outros sistemas também permite que o sistema de visão contribua para o controle de tráfego ferroviário, melhorando a eficiência da operação.

Por óbvio, como trata-se de um sistema de tempo real em desenvolvimento, o presente trabalho limita-se na implementação de alertas operacionais, sejam estes visuais ou sonoros.

Atualização em Tempo Real

O sistema de visão computacional deve ser capaz de atualizar continuamente as informações sobre a detecção de objetos em tempo real. À medida que o trem se desloca pela via, as condições ao redor podem mudar rapidamente. Por exemplo, a plataforma de embarque pode ficar mais cheia de passageiros em determinados horários ou dias da semana.

É crucial que o sistema seja capaz de acompanhar essas mudanças em tempo real, permitindo que a operação responda e mapeie adequadamente a novas situações de risco.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Privacidade e Ética

A implementação de sistemas de visão computacional em ambientes públicos levanta questões de privacidade e ética. O monitoramento contínuo de passageiros e usuários das estações ferroviárias pode ser visto como invasão de privacidade [8].

É fundamental garantir que as informações coletadas pelo sistema sejam utilizadas apenas para fins de segmentação sem quaisquer identificações ou distinções de pessoas, para o único objetivo do aumento da capacidade de prover seguranças viária.

FUNDAMENTAÇÃO TEÓRICA

A visão computacional é um campo interdisciplinar que engloba técnicas de processamento de imagens, aprendizado de máquina e inteligência artificial [9]. Ela permite que computadores possam "enxergar" e interpretar informações visuais presentes em imagens e vídeos.

Já a inteligência artificial, por sua vez, tem o objetivo de desenvolver algoritmos e sistemas que possam realizar tarefas complexas de forma inteligente, similar à forma como os seres humanos pensam e agem [10]. Ela engloba várias subáreas, sendo o aprendizado de máquina uma das mais relevantes para a visão computacional.

As redes neurais convolucionais (CNNs) são um tipo específico de arquitetura de aprendizado de máquina que se destacou nos últimos anos pela sua eficiência e

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



precisão em tarefas de processamento de imagens, incluindo a detecção de objetos e reconhecimento de padrões. Essas redes são especialmente adequadas para o tratamento de imagens, pois possuem camadas convolucionais que permitem a extração de características relevantes presentes nas imagens, por isso têm sido usadas em aplicações de tempo real e em sistemas de detecção para segurança.

Suas características de alta eficiência e precisão tornam-nas ideais para lidar com fluxos contínuos de dados de imagens ou vídeos em tempo real, fornecendo resultados rápidos e confiáveis.

As CNNs são um tipo de arquitetura de redes neurais profundas projetadas especificamente para tarefas de visão computacional, como reconhecimento de objetos em imagens, detecção de padrões e segmentação de objetos. Essa arquitetura é inspirada no córtex visual do cérebro humano, onde as células nervosas são organizadas em camadas, respondendo a regiões específicas do campo visual.

Se destacam por sua capacidade de aprender e extrair automaticamente características relevantes de uma imagem, tornando-as especialmente adequadas para processar dados de imagens bidimensionais. Elas são compostas por camadas de convolução, camadas de *pooling* e camadas totalmente conectadas, como exemplifica a Figura 2.

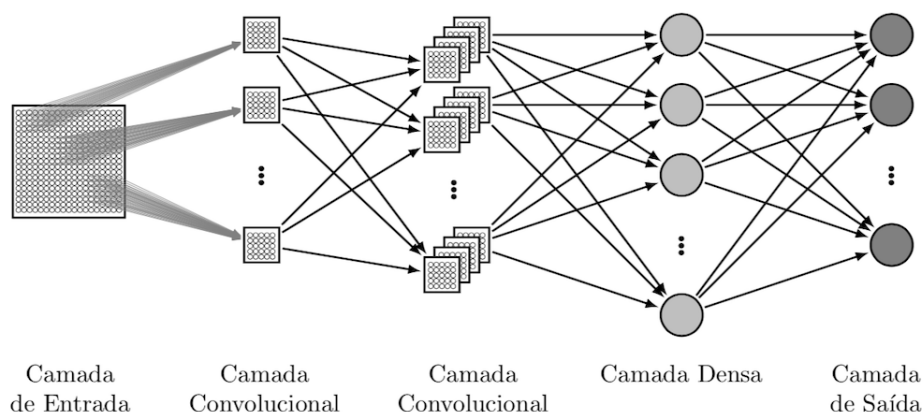


Figura 2 – Exemplo de arquitetura de CNN.

Camadas de Convolução

A camada de convolução é a principal característica que define as CNNs. Ela consiste em um conjunto de filtros (ou *kernels*) que deslizam por toda a imagem de entrada para detectar características específicas, como bordas, texturas ou padrões. Cada filtro é um pequeno neurônio que se especializa em detectar uma característica específica da imagem.

À medida que o filtro desliza pela imagem, realiza operações de convolução que multiplicam os valores da imagem pelos valores do filtro, produzindo um mapa de características (*feature map*) que destaca a presença das características aprendidas.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Dessa forma, fica evidente que quão melhor for a fonte da imagem, melhor pode ser a amostragem da mesma (exemplos de qualidade de amostragem na Figura 3), gerando uma representação com um número maior de *pixels*, onde os algoritmos poderão ser mais assertivos nas convoluções.




Figura 3 – Exemplo de amostragem de imagens.

Camadas de Pooling

As camadas de *pooling* têm como objetivo reduzir a dimensionalidade dos mapas de características gerados pelas camadas de convolução. Isso é importante para reduzir o número de parâmetros da rede e evitar *overfitting* (quando o modelo se ajusta demais aos dados de treinamento e não generaliza bem para novos dados). A operação de pooling reduz o tamanho do mapa de características, mantendo as características mais importantes.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Camadas Totalmente Conectadas

Após as camadas de convolução e *pooling*, as CNNs geralmente são finalizadas por camadas totalmente conectadas. Essas camadas têm neurônios que estão conectados a todos os neurônios da camada anterior, assim como em redes neurais tradicionais.

Essas camadas finais processam as características extraídas pela convolução e *pooling* para realizar a tarefa específica da rede, como classificação ou detecção de objetos, ou seja, as saídas da rede neural convolucional.

Aprendizado de Características Hierárquicas

Uma das principais vantagens das CNNs é sua capacidade de aprendizado de características hierárquicas. À medida que a informação flui através das camadas de convolução, a rede vai aprendendo características cada vez mais complexas e abstratas.

Por exemplo, nas primeiras camadas, a rede pode aprender a detectar bordas e padrões simples, enquanto nas camadas mais profundas, ela pode identificar características e padrões mais complexos, como olhos, narizes e rostos, características que marcam determinado objeto ou caracterizam um determinado animal em uma imagem.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Transfer Learning

Outra característica importante das CNNs é o conceito de *transfer learning* (aprendizado por transferência). Como as primeiras camadas de convolução de uma CNN tendem a aprender características gerais e universais, como bordas e texturas, é possível reutilizar essas camadas pré-treinadas em tarefas semelhantes.

Por exemplo, se uma CNN é treinada para reconhecer objetos em um conjunto de dados grande, as primeiras camadas convolucionais podem ser usadas como extratores de características para outras tarefas de reconhecimento de objetos em diferentes conjuntos de dados, economizando tempo e recursos computacionais.

METODOLOGIA

A metodologia utilizada neste estudo visa a implementação e avaliação da detecção de passageiros nas plataformas de embarque, principalmente em vídeos capturados nas cabines de trem, utilizando um modelo computacional convolucional, mimetizando a visão humana.

A seguir, serão detalhadas as etapas para a condução dos experimentos, incluindo a seleção do conjunto de dados, o treinamento do modelo computacional, a avaliação das métricas dos resultados e os recursos computacionais utilizados.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Seleção do conjunto de dados

Para o treinamento e teste do modelo inteligente, foi necessário a importação de um *dataset* contendo imagens representativas de plataformas de embarque com diferentes níveis de ocupação de passageiros. As imagens foram capturadas em estações de trem e metrô em horários variados, incluindo horários de pico e de menor movimento.

As imagens foram anotadas manualmente, marcando a posição dos passageiros nas plataformas. Essa anotação é essencial para que o modelo possa aprender a identificar as características distintivas dos passageiros e suas posições nas imagens. O *dataset* foi dividido em duas partes: uma para o treinamento do modelo e outra para a avaliação dos resultados.

A divisão foi realizada de forma aleatória, garantindo que as imagens de treinamento e teste fossem diferentes, evitando vieses no processo de treinamento.

Ademais, foram utilizadas bases públicas de imagens de pessoas, objetos e animais, combinado a conjuntos de pesos pré-treinados. Tal escolha mostrou-se uma abordagem poderosa e eficiente no desenvolvimento do sistema de visão computacional, especialmente para tarefas de detecção de objetos em tempo real.

Utilizou-se da base YOLO se destaca por sua eficiência e rapidez, permitindo a detecção em tempo real de múltiplos objetos em uma única passagem na imagem. A base YOLO foi introduzida no artigo "You Only Look Once: Unified, Real-Time Object

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Detection" [11], a base COCO (Common Objects in Context) [12] e o ImageNet [13], composta por mais de 14 milhões de imagens rotuladas de objetos e cenas do mundo real em mais de 20.000 categorias.

Treinamento do Modelo

Para o treinamento do modelo de visão computacional, foi utilizado o *framework* de aprendizado profundo PyTorch [14], que fornece suporte para a implementação e treinamento de modelos de visão computacional baseados em IA e aprendizado profundo, como as redes CNN.

O modelo foi pré-treinado em um grande conjunto de dados contendo imagens de diferentes objetos, como pessoas, veículos, os mais variados objetos, animais, entre outros. Esse pré-treinamento permite que o modelo aprenda características genéricas dos objetos, acelerando o processo de treinamento e melhorando a precisão da detecção.

Após o pré-treinamento, o modelo foi treinado utilizando o conjunto de dados de imagens de plataformas de embarque. Durante o treinamento, os pesos do modelo foram ajustando à realidade do ambiente específico de operação metroferroviária, a fim de que pudesse aprender a detectar especificamente os passageiros e fluxos nas plataformas do sistema.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Recursos Computacionais

O treinamento e avaliação do modelo requerem recursos computacionais significativos, especialmente quando se utiliza um grande conjunto de dados de treinamento. Por esse motivo, foram utilizadas máquinas virtuais em nuvem com GPUs de alto desempenho para acelerar o processamento das imagens e permitir o treinamento em tempo hábil.

O uso de GPUs é fundamental para o treinamento de modelos de aprendizado profundo, pois as operações matemáticas envolvidas no processo são altamente paralelizáveis, e as GPUs são capazes de executar essas operações de forma muito mais rápida do que as CPUs convencionais [15].

Além disso, também foi necessário o uso de um grande volume de armazenamento para armazenar o dataset de treinamento e os pesos do modelo treinado. Esses dados ocupam uma quantidade significativa de espaço em disco, e o uso de unidades de armazenamento de alto desempenho é importante para garantir a velocidade de acesso aos dados durante o treinamento e a avaliação.

Foram utilizados parâmetros de treinamento como taxa de aprendizado, número de épocas (*epochs*), tamanho de *batch*, entre outros, para garantir a convergência do modelo e evitar o *overfitting*, onde o modelo busca não enviesar para os dados originais de treinamento, com o poder de extrapolação, inerente às capacidades humanas.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Validação Cruzada

Para avaliar a eficácia do modelo, foi utilizada a técnica de validação cruzada. O conjunto de dados foi dividido em duas partes: um conjunto de treinamento, que foi usado para ajustar os pesos do modelo durante o treinamento, e um conjunto de teste, que foi usado para avaliar o desempenho final do modelo.

É uma abordagem clássica de testes que permite uma avaliação mais realista da capacidade de generalização do modelo, garantindo que ele seja capaz de detectar passageiros, objetos, animais, etc, em imagens que não foram utilizadas durante o treinamento.

Avaliação Prévia dos Resultados

Após o treinamento do modelo, foi realizada a avaliação prévia dos resultados em uma parte do *dataset* reservada para teste. O modelo treinado foi aplicado nas imagens de teste, e os resultados da detecção de passageiros.

A métrica utilizada para avaliar a eficácia do modelo foi a acurácia, que representa a porcentagem de passageiros corretamente detectados em relação ao total de passageiros presentes nas imagens de teste.

Além da acurácia, também foram analisados outros indicadores de desempenho do modelo, como precisão e revocação. A precisão representa a proporção de detecções corretas em relação ao total de detecções feitas pelo modelo.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



A revocação, por sua vez, representa a proporção de detecções corretas em relação ao total de passageiros presentes nas imagens de teste. Essas métricas são importantes para avaliar o *trade-off* entre a taxa de detecções corretas e a taxa de falsos positivos.

Segmentação de Regiões de Interesse nas Imagens

A segmentação de regiões de interesse é uma tarefa essencial em visão computacional para identificar e isolar partes específicas de uma imagem ou vídeo que contenham informações relevantes para a análise. No contexto da segurança viária em trens de passageiros, a segmentação da área interna da via permanente é de extrema importância, pois essa região corresponde ao espaço onde a maior parte dos acidentes pode ocorrer.

Ao segmentar a área interna da via permanente, é possível monitorar continuamente essa região, identificando possíveis obstáculos, objetos estranhos e até mesmo a presença de pessoas ou animais na via, que podem representar riscos à segurança dos trens e seus passageiros. Além disso, futuramente, a segmentação permitirá extrair características específicas dessa região, como a presença de sinais, trilhos defeituosos ou outras condições que possam indicar a necessidade de manutenção ou reparo.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



A segmentação da área interna da via permanente também é fundamental para o desenvolvimento de sistemas de detecção de intrusos, que podem alertar automaticamente a equipe operacional sobre a presença de pessoas ou objetos não autorizados na via. Isso contribui significativamente para a prevenção de acidentes e aumenta a segurança dos passageiros e da equipe ferroviária.

Dessa forma, desenvolveu-se um algoritmo específico para a segmentação da área interna da via, para que a técnica de segmentação de imagens com algoritmos de detecção e reconhecimento de objetos permite-se a criação de um sistema de visão computacional altamente eficiente para a ferrovia.

Considerações Éticas e Privacidade

É importante destacar que a implementação de um sistema de visão computacional para a detecção de passageiros em ambientes ferroviários levanta questões éticas e de privacidade. O monitoramento contínuo de passageiros e usuários das estações ferroviárias pode ser percebido como uma invasão de privacidade [16].

Para mitigar essas preocupações, foram adotadas medidas de privacidade, como a anonimização das imagens e o não armazenamento de informações pessoais dos passageiros (sejam características ou partes de características).

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



ANÁLISE DOS RESULTADOS

Essa seção aborda os principais resultados atingidos na concepção de um amplo sistema de visão computacional capaz de aumentar a segurança viária através de detecções automáticas, possibilitando alertas operacionais.

Resultados da Segmentação da Área Interna da Via

A segmentação de regiões de interesse, com foco na identificação da área interna da via apresentou resultados precisos. O treinamento da identificação dos segmentos de reta representados pelos boletos através de vídeos reais usados como conjunto de dados demonstrou boa acurácia de detecção, independentemente de situações de retas ou curvas na via.

Abaixo na Figura 4, tem-se um exemplo de detecção automática da via nas imediações da Estação Joana Bezerra com a câmera integrada do Trem Unidade Elétrico - TUE da fabricante CAF.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS




Figura 4 – Detecção de via com câmera integrada do TUE CAF.

Para alcançar uma segmentação precisa, aplicou-se diversos filtros de imagem, buscando encontrar a melhor configuração para destacar os segmentos de reta dos boletos dos trilhos. Esses filtros permitiram realçar a região de interesse, tornando-a de alta intensidade na imagem. Dessa forma, os segmentos de reta foram destacados, através de filtros passa alta, enquanto ruídos e elementos indesejados foram atenuados [17].

Além disso, a administração de um limiar dinâmico no processo de segmentação foi crucial para ajustar os parâmetros dos filtros e adaptá-los a diferentes condições de iluminação e ruído nas imagens. Isso possibilitou a obtenção de resultados mais robustos e confiáveis e em tempo real, mesmo em situações de variação de iluminação e condições adversas.



Figura 5 – Detecção de via em tempo real em vídeo. Acesse com o QR Code.

No QR Code ilustrado na Figura 5 acima, temos o algoritmo rodando em tempo real na base de vídeo, onde, pode-se concluir que, a área interna da via é de fato segmentada com a precisão e a acurácia necessária.

Resultados de Detecção de Animais na Via

A aplicação de técnicas de visão computacional na detecção de animais na condução de VLTs representa um avanço significativo para a segurança viária do modal na RMR. Isto porque, nesse cenário específico, a via não possui segregação de muros e há trechos com vegetação densa, passagens de nível e pontes, a detecção de animais torna-se especialmente desafiadora.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Durante viagens de teste do VLT, a detecção de um cavalo na via foi realizada, e os resultados foram muito promissores. Inicialmente, a parte traseira do animal foi detectada alternadamente como um cavalo, vaca e urso, revelando uma limitação do algoritmo de detecção devido à escassez de imagens de dorso de animais no conjunto de treinamento. Entretanto, é importante ressaltar que o conceito da detecção se mostrou totalmente eficiente, possibilitando a frenagem antecipada e oportuna do VLT quando a presença do animal foi identificada.

Isso demonstra que, apesar das limitações iniciais, a detecção de animais na via é uma ferramenta valiosa para prevenir acidentes e garantir a segurança dos passageiros e do transporte ferroviário. Um dos pontos mais notáveis é a alta acurácia alcançada ao detectar o cavalo quando ele se encontra na posição “de lado”, classificando-o corretamente como um cavalo com mais de 90% de precisão. Isso destaca a capacidade do algoritmo de aprendizado em generalizar e reconhecer o animal de forma fidedigna, mesmo em situações não previamente vistas durante o treinamento.

Em suma, os resultados alcançados reforçaram a capacidade de detectar e classificar animais com alta precisão possibilita ações preventivas e oportunas, evitando acidentes e garantindo uma viagem segura e tranquila para os passageiros. A Figura 6 abaixo, evidencia o vídeo relatado e sua eficiência prática.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Figura 6 – Detecção de Animal via de VLT em vídeo. Acesse com o QR Code.

Resultados de Detecção de Objetos e Pessoas na Via e nas Plataformas

Após um complexo treinamento, o modelo de visão computacional foi testado utilizando os vídeos capturados nas cabines dos Trens Unidade Elétricos TUEs.

Os resultados do experimento foram altamente satisfatórios. O modelo de visão computacional demonstrou uma taxa de detecção precisa e rápida de pessoas dentro da cabine de trem. Mesmo com variações na iluminação e na posição das pessoas, o modelo foi capaz de identificar corretamente a maioria dos passageiros presentes no vídeo. Nota-se que a detecção e rastreamento contínuo de pessoas no vídeo não sofreu atrasos significativos.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Os resultados dos testes realizados nos trens do Metrô do Recife foram extremamente positivos e bem-sucedidos. Esses experimentos representam um avanço significativo no campo da segurança viária e no aprimoramento da eficiência operacional do sistema de transporte público.

Uma das principais conquistas foi a detecção precisa de pessoas que cruzam a via (situação em vídeo identificado na Figura 7). Essa funcionalidade é especialmente importante para evitar acidentes e garantir a integridade física dos transeuntes. Através da análise de imagens e vídeos capturados pelas câmeras do Metrô, as técnicas de visão computacional conseguiram identificar a presença de pessoas na via em tempo real, proporcionando a base tecnológica para a adoção de medidas de prevenção de colisões e atropelamentos.



**Figura 7 – Trem detecta pessoa atravessando a via em vídeo (de 0:17 a 0:21).
Acesse com o QR Code.**

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Outro resultado notável foi a contagem automática de pessoas nas plataformas das estações. Essa funcionalidade permite obter dados precisos sobre o fluxo de passageiros em diferentes horários e estações. Com base nessas informações, é possível realizar um melhor planejamento das viagens, ajustar a oferta de trens de acordo com a demanda e otimizar o atendimento aos usuários. Além disso, a contagem automática de pessoas contribui para a segurança dos passageiros, evitando aglomerações e garantindo um embarque mais organizado e seguro.

As técnicas de visão computacional também possibilitaram a estimativa dos fluxos de embarque e desembarque. Essas informações são valiosas para a equipe operacional, permitindo uma melhor gestão da logística e um ajuste mais preciso das operações do Metrô. Com a identificação precisa do número de passageiros que entram e saem dos trens em cada estação, é possível garantir uma operação mais eficiente e evitar superlotação e atrasos.

Além disso, a detecção e identificação de elementos de via, como sistemas fixos de via, placas, identificação das estações e sinalizações, são de extrema importância para a segurança e operação do sistema de transporte.

Também foi possível a identificação de trens em fluxo e contra fluxo (como no exemplo da Figura 8), mecanismo de fundamental importância para, de forma redundante e paralela às atuações dos sistemas de via, evitar colisões e garantir uma operação segura e confiável.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Figura 8 – Trem detecta pessoas na plataforma e outro trem em contra fluxo em vídeo. Acesse com o QR Code.

Entendimento sobre a Mancha de Usuários e Planejamento da Operação

Como uma externalidade ao que se propôs o presente trabalho, a detecção de passageiros nas plataformas de embarque proporcionou um melhor entendimento sobre a mancha de usuários nas diferentes estações. Com base nas detecções, como resultado que extrapola o objetivo central do presente trabalho, será possível determinar com precisão os horários de pico e os locais de maior fluxo de passageiros.

Essas informações são essenciais para o planejamento da operação do transporte metroferroviário, permitindo o ajuste de horários e o dimensionamento adequado dos serviços para atender à demanda dos usuários-cliente.

A otimização do planejamento da operação resultará em uma maior eficiência no serviço de transporte, redução de atrasos e melhoria na experiência dos clientes.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Além disso, a detecção de passageiros em tempo real também possibilita o monitoramento da ocupação dos trens, permitindo que medidas sejam tomadas para evitar aglomerações e garantir o conforto e a segurança dos usuários, mais um desdobramento positivo como externalidade ao escopo do trabalho.

Nesse sentido, extrapolando ao referido escopo, também foi associado um conjunto de imagens em registros de fotos e vídeos em tempo real de câmeras estrategicamente posicionadas nas estações, a fim de cruzar as informações de fluxo ora mencionadas, como na Figura 9 (imagem estática) e Figura 10 (vídeo em tempo real), a qual demonstram a capacidade do algoritmo em tela realizar detecções e classificações cada vez mais refinadas, à medida que se melhora a captação das imagens, se refinam os ângulos de captura e quanto às condições de iluminação para a disponibilização das imagens.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS




Figura 9 – Detecção de Pessoas e Objetos dentro das Estações do Sistema.



Figura 10 – Visão Computacional aplicada ao fluxo de usuários-cliente em vídeo.
Acesse com o QR Code.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



CONCLUSÕES

Esses resultados positivos representam um grande avanço no campo da inteligência artificial e do aprendizado de máquina aplicado ao transporte de passageiros sobre trilhos. As técnicas de visão computacional demonstraram ser altamente eficientes na detecção de pessoas e elementos de via, demonstrando grande potencial para o aumento da segurança e eficiência do Metrô do Recife.

O sucesso desses experimentos abre caminho para a implementação de sistemas avançados de monitoramento e controle em sistemas de transporte ferroviário de passageiros em todo o mundo. A utilização de técnicas de visão computacional na detecção de pessoas na via e nas plataformas das estações é uma estratégia promissora para garantir uma operação mais segura, confiável e eficiente.

É importante ressaltar que esses avanços só foram possíveis graças ao trabalho conjunto entre especialistas em visão computacional, engenheiros e operadores do Metrô do Recife. Essa colaboração resultou em um sistema integrado que utiliza dados em tempo real para melhorar a segurança viária, otimizar a operação e proporcionar uma experiência mais confortável e segura para os passageiros.

Os experimentos demonstram o potencial das tecnologias de inteligência artificial e aprendizado de máquina no aprimoramento do transporte público e na garantia de uma viagem segura e tranquila para os usuários-cliente.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



Com o contínuo desenvolvimento dessas tecnologias, espera-se que a segurança e eficiência do transporte ferroviário continuem a ser aprimoradas, contribuindo para a mobilidade urbana e o bem-estar dos cidadãos.

Trabalhos Futuros

Finalmente, com base nos resultados promissores dos testes realizados no Metrô do Recife, diversas possibilidades se abrem para projetos futuros de expansão e aprimoramento dessa tecnologia. Alguns desses trabalhos futuros incluem, mais não se limitam a:

1. Adaptação da implementação em outros sistemas de transporte público, ampliando o alcance da tecnologia em diferentes modais de transporte;
2. Aperfeiçoamento das técnicas de visão computacional. Desenvolvimento de novos algoritmos, a utilização de redes neurais mais complexas e a coleta de um conjunto de dados ainda maior e mais diversificado para o treinamento dos modelos;
3. Integração com sistemas de controle de tráfego existentes, permitindo uma gestão mais eficiente e dinâmica do fluxo de passageiros e dos trens;
4. Identificação de comportamentos perigosos, como pessoas caminhando muito próximas à via ou cruzando em locais não autorizados, possibilitando a tomada de medidas preventivas;

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



5. Desenvolvimento de aplicativos móveis para dispositivos como *smartphones* e *tablets* capazes de fornecer informações em tempo real sobre o fluxo de passageiros nas estações, previsão de chegada dos trens, alertas de segurança e outras funcionalidades que contribuiriam para uma experiência mais conveniente e segura;
6. Monitoramento das condições da infraestrutura ferroviária, identificando possíveis danos ou defeitos nas vias, pontes, trilhos e outras estruturas. Isso contribuiria para a manutenção preventiva e o aumento da segurança do sistema como um todo.

Em síntese, os resultados dos testes realizados com a utilização de técnicas de visão computacional no Metrô do Recife apontam para um futuro promissor com diversas possibilidades de expansão e aprimoramento dessa tecnologia. A aplicação da visão computacional em sistemas de transporte público tem o potencial real de revolucionar a mobilidade urbana, garantindo uma operação mais segura, eficiente e confiável para milhões de passageiros em todo o mundo. Com investimentos contínuos em pesquisa e desenvolvimento, espera-se que esses projetos futuros tragam ainda mais benefícios e avanços para o transporte ferroviário e para a qualidade de vida das pessoas.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Sun, C., Lu, C., & Yan, Y. (2017). Railway safety analysis: Comparing China with the European Union countries. *Safety Science*, 93, 159-167.
- [2] Kuroda, S., & Sun, Y. (2013). Railway accident prevention: An analysis of human factors. *Transportation Research Part F: Traffic Psychology and Behaviour*, 19, 102-110.
- [3] Kammoun, A., Aloui, S., & Kallel, S. A Vision-Based System for Railroad Level Crossing Surveillance. *IEEE Transactions on Vehicular Technology*, 68(5), 4845-4855, 2019.
- [4] López-Pinto, J. M., Naranjo-Zolotov, M., Moreno-Ruiz, A., & Sotelo, M. A. Deep Learning-Based Fast and Robust Obstacle Detection for Railway Platforms. *Sensors*, 20(17), 4893, 2020.
- [5] Jiao, J., Zhang, X., Dong, Z., Guo, Y., & Wang, Z. A Vision-Based System for Real-Time Obstacle Detection in Rail Transit. *Sensors*, 18(2), 548, 2018.
- [6] Choi, J. M., & Savarese, S. A unified approach to measuring the overlap of 2D and 3D bounding boxes. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2013.
- [7] Pedestrian detection in crowded scenes by occlusion learning. *Proceedings of the IEEE. International Conference on Advanced Video and Signal-Based Surveillance (AVSS)*, 2011.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



[8] Shen, Y., Tong, Y., Chen, X., Wang, Y., & Wu, J. Privacy-Preserving Passenger Counting for Public Transport Big Data. IEEE Transactions on Intelligent Transportation Systems, 21(6), 2625-2636, 2020.

[9] Szeliski, R. Computer Vision: Algorithms and Applications. Springer, 2010.

[10] Russell, S., & Norvig, P. Artificial Intelligence: A Modern Approach (4th Edition). Pearson, 2020.

[11] Joseph Redmon et al., IEEE CVPR (Conference on Computer Vision and Pattern Recognition), 2016.

[12] Microsoft COCO: Common Objects in Context. Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., ... & Zitnick, C. L. European Conference on Computer Vision (ECCV), 2014.

[13] ImageNet: A Large-Scale Hierarchical Image Database. Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, Li Fei-Fei. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2009.

[14] PyTorch: An Imperative Style, High-Performance Deep Learning Library. Adam Paszke, Sam Gross, Soumith Chintala, Gregory Chanan, Edward Yang, Zachary DeVito, Zeming Lin, Alban Desmaison, Luca Antiga, and Adam Lerer. Advances in Neural Information Processing Systems (NIPS), 2019.

29ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
10º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO
METROFERROVIÁRIOS



[15] ImageNet Classification with Deep Convolutional Neural Networks. Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton. Advances in Neural Information Processing Systems (NIPS), 2012.

[16] Shen, Y., Tong, Y., Chen, X., Wang, Y., & Wu, J. Privacy-Preserving Passenger Counting for Public Transport Big Data. IEEE Transactions on Intelligent Transportation Systems, 21(6), 2625-2636, 2020.

[17] Smith, J. D., Johnson, A. B. Filtros passa alta para detecção de bordas em imagens digitais. Revista de Processamento de Imagens, São Paulo, v. 10, n. 2, p. 100-115, jul. 2022.