

ANÁLISE DE MOBILIDADE E FLUXO DE USUÁRIOS NA RODOVIÁRIA DE BRASÍLIA UTILIZANDO VISÃO COMPUTACIONAL

Professor orientador: Pedro Henrique Rodrigues
Mendes

Aluno: Guilherme Dias Barbosa

PROGRAMA DE
INICIAÇÃO CIENTÍFICA
PIC/CEUB

RELATÓRIOS DE PESQUISA
VOLUME 9 Nº 1- JAN/DEZ
•2023•

ISSN: 2595-4563





**CENTRO UNIVERSITÁRIO DE BRASÍLIA - CEUB
PROGRAMA DE INICIAÇÃO CIENTÍFICA**

GUILHERME DIAS BARBOSA

**ANÁLISE DE MOBILIDADE E FLUXO DE USUÁRIOS NA RODOVIÁRIA DE
BRASÍLIA UTILIZANDO VISÃO COMPUTACIONAL**

Relatório final de pesquisa de Iniciação Científica apresentado à Assessoria de Pós-Graduação e Pesquisa.

Orientação: Pedro Henrique Rodrigues Mendes

BRASÍLIA

2024

DEDICATÓRIA

A todos os trabalhadores de Brasília. Planaltina, Sobradinho, Ceilândia, Samambaia, Vicente Pires e todas as cidades do entorno. Gostaria de dedicar essa pesquisa a cada operário que acorda cedo, depende do nosso sistema de transporte público e corre para que essa cidade respire todos os dias.

AGRADECIMENTOS

Gostaria de agradecer a parceria e tutoria do Professor Pedro Henrique Rodrigues Mendes que se dispôs desde a conceituação inicial dessa pesquisa a me auxiliar nesse processo complexo de iniciação na pesquisa acadêmica.

Gostaria também de agradecer aos meus colegas de turma que me inspiraram e fizeram parte do processo criativo da pesquisa, em especial aos amigos Bento Barbosa, Gustavo Zitta e Enzo Dias que me ouviram e acolheram minhas incertezas em momentos de crise.

Por fim, agradeço imensamente a minha parceira, Larissa Domingos por todo o suporte dado, pelo companheirismo e por nunca deixar que eu me sentisse sozinho durante a minha extensa jornada no desenvolvimento deste trabalho.

“Instrua-se, porque necessitaremos de toda a sua inteligência. Atue, porque necessitaremos de todo o seu entusiasmo. Organize-se, porque necessitaremos de toda a sua força”.

Antonio Gramsci

RESUMO

A mobilidade urbana é um elemento crucial e dinâmico na vida das cidades, influenciando diretamente a qualidade de vida e a sustentabilidade de uma cidade. À medida que as cidades crescem, a necessidade de otimizar o fluxo de passageiros e garantir a eficiência dos sistemas de transporte torna-se cada vez mais evidente. Neste contexto, a análise de fluxo de usuários na rodoviária de Brasília utilizando visão computacional emerge como uma abordagem inovadora e promissora, com o objetivo de compreender os padrões de movimento e comportamento dos passageiros em tempo real. A aplicação de técnicas avançadas de visão computacional oferece uma perspectiva minuciosa da concentração de usuários, permitindo não apenas a identificação de pontos críticos de congestionamento, mas também a detecção de comportamentos anômalos e a previsão de tendências emergentes. Essas informações são inestimáveis para o planejamento e a gestão eficazes do transporte público, pois possibilitam a otimização da infraestrutura existente e dos recursos disponíveis, além de melhorar a experiência geral dos usuários do sistema. O estudo propõe a integração dessas tecnologias avançadas de visão computacional com dados de fluxo de usuários coletados na Rodoviária de Brasília, com o intuito de desenvolver modelos de inteligência artificial (IA) que possam ser aplicados para aprimorar a eficiência operacional do terminal e a experiência dos passageiros. Para tanto, serão utilizados conhecimentos de estudos pregressos na área de análise de fluxo de usuários, que serão combinados com métodos analíticos para avaliar a precisão dos modelos e a qualidade das inferências geradas. A expectativa é que o projeto não apenas contribua significativamente para a melhoria da infraestrutura e dos serviços de transporte em Brasília, mas também crie precedentes para o uso de tecnologias de visão computacional em outros contextos de mobilidade urbana. A aplicação dessas tecnologias pode proporcionar um novo patamar de eficiência e segurança nos sistemas de transporte público, ao permitir um monitoramento contínuo e uma resposta ágil às necessidades dos usuários, reforçando a capacidade das cidades de gerenciar o crescimento urbano de maneira sustentável e eficaz. Os principais resultados indicam que, embora o modelo tenha atingido uma acurácia de 75% na detecção de grandes aglomerações, há desafios relacionados à variação de resolução das imagens e à capacidade do modelo em lidar com aglomerados de passageiros em ambientes de baixa resolução. Para mitigar esses problemas, foram propostas estratégias de segmentação das imagens, permitindo uma análise mais precisa e eficiente do fluxo de passageiros. A redistribuição sugerida pelo modelo baseia-se na classificação das plataformas em termos de lotação, buscando minimizar o índice de dispersão e a sobrecarga nas áreas mais críticas da rodoviária. A aplicação do modelo desenvolvido nesta pesquisa possibilitou a extração de insights e dados significativos, permitindo uma análise das principais variáveis associadas às aglomerações. Além disso, os dados obtidos proporcionam subsídios para o planejamento e a implementação de estratégias de mitigação de grandes congestionamentos na rodoviária.

Palavras-chave: redes neurais convolucionais; visão computacional; logística.

LISTAS DE FIGURAS, TABELAS, QUADROS, GRÁFICOS, SÍMBOLOS E ABREVIÇÕES

LISTA DE FIGURAS

1. INTRODUÇÃO

Figura 1.1: Brasileiros na fila para o embarque nos ônibus em horário de pico 9

2. RESULTADOS E DISCUSSÃO

Figura 2.1: Arquitetura original YOLO 20

Figura 2.2: Diferentes escalas de resolução em imagem 21

Figura 2.3: Duas figuras da mesma plataforma com resoluções diferentes 22

Figura 2.4: Corte segmentado de uma das fotos usadas na base de dados 23

Figura 2.5: Mapa de densidade da Rodoviária do Plano Piloto 24

Figura 2.6: Etiquetas realizadas pelo modelo durante sua predição 26

Figura 2.7: Predições e reorganização das linhas 27

LISTA DE FLUXOGRAMAS

1. MÉTODO

Fluxograma 1.1: Fluxo da metodologia da pesquisa 16

Fluxograma 1.2: Fluxo do desenvolvimento dos modelos preditivos utilizados na pesquisa 17

LISTA DE TABELAS

1. RESULTADOS E DISCUSSÃO

Tabela 1.1: Porcentagem de ocupação do total observado em ambas as plataformas fora de horário de pico 28

Tabela 1.2: Valor de Sobrecarga 29

SUMÁRIO

INTRODUÇÃO	9
Objetivos	10
FUNDAMENTAÇÃO TEÓRICA	11
Redes Neurais Artificiais	11
Redes Neurais Convolucionais	12
YOLO(Only Look Once)	13
Análise de Fluxo de Usuários	14
Estações Rodoviárias	14
MÉTODO	18
RESULTADOS E DISCUSSÃO	18
Implementação	18
Análise de dados primários e secundários	21
CONSIDERAÇÕES FINAIS	25
REFERÊNCIAS	30

1. INTRODUÇÃO

Um tema constantemente discutido na capital é a mobilidade pública, seja durante períodos eleitorais ou ao longo do tempo, à medida que se torna uma questão cada vez mais crítica. Em Brasília, a Rodoviária do Plano Piloto se destaca como um ponto nevrálgico no sistema de transporte público, servindo como o principal terminal para embarque e desembarque de passageiros em ônibus urbanos e interestaduais. Além disso, a rodoviária é um espaço multifuncional que também abrange atividades comerciais, fluxos de trânsito, e é palco de manifestações sociais, o que aumenta ainda mais a complexidade de gerenciar o fluxo de pessoas nesse ambiente.

A relevância deste estudo emerge a partir dos desafios enfrentados pela Rodoviária de Brasília, que frequentemente lida com superlotação nas plataformas, congestionamento nos horários de pico e dificuldades de locomoção devido à infraestrutura inadequada. Esses problemas são exacerbados por eventos como a paralisação da linha ferroviária local, que leva a uma concentração ainda maior de passageiros nas áreas de embarque e desembarque de ônibus. Segundo Eufrásio, Carvalho e Cardim (2023), a superlotação crônica e os congestionamentos frequentes na rodoviária refletem a necessidade urgente de intervenções que possam melhorar a eficiência e a organização do fluxo de passageiros.

Figura 1.1: Brasilienses na fila para o embarque nos ônibus em horário de pico.



Fonte: mobilize.org.br

O tema desta pesquisa é a aplicação de técnicas de visão computacional para monitorar e analisar o fluxo de usuários na Rodoviária de Brasília, com o objetivo de propor soluções que possam mitigar os problemas identificados. A literatura existente, como os trabalhos de Nagaraj e Gururaj (2022), que utilizaram redes neurais para prever a movimentação de passageiros em sistemas de transporte, demonstra que a ciência de dados e a inteligência artificial têm um potencial significativo para melhorar a gestão de fluxos em terminais rodoviários. Esses estudos forneceram uma base teórica sólida que orientou a abordagem metodológica desta pesquisa.

Atualmente, a aplicação de modelos de visão computacional em sistemas de transporte público é uma área em crescimento, com foco em melhorar a eficiência operacional e a experiência dos usuários. No Brasil, onde a dependência do transporte rodoviário é alta, conforme discutido por Mendonça (2018) e Andrew (2019), a implementação dessas tecnologias pode representar um avanço significativo na gestão de grandes volumes de passageiros, especialmente em terminais críticos como a Rodoviária de Brasília.

Diante desse cenário, este estudo delimita-se à análise do fluxo de passageiros nas plataformas inferiores da Rodoviária de Brasília, utilizando técnicas de visão computacional para monitoramento e redistribuição de filas. A pesquisa foi conduzida em um ambiente real, levando em consideração as restrições físicas e operacionais do local, com o intuito de desenvolver modelos que possam ser aplicados para otimizar a utilização do espaço e melhorar a qualidade do serviço oferecido aos usuários.

OBJETIVOS

- Objetivo Geral:

Criar um algoritmo que seja capaz de processar o trânsito de pessoas nas plataformas inferiores, tendo em vista todos os fatores que influenciam no processo, e que seja capaz de gerar modelos de remanejamentos dentro da rodoviária visando melhorar o fluxo de pessoas e evitando grandes

aglomerações de passageiros em filas. A técnica utilizada para a criação deste algoritmo será a de redes neurais profundas, *Deep Learning*.

- Objetivos específicos:
 - Desenvolver um modelo de rede neural capaz de identificar indivíduos em ambiente de alta movimentação, e que possa ser adaptável para a Rodoviária de Brasília.
 - Criar uma base de treinamento robusta e completa, composta por imagens relevantes da movimentação de passageiros na Rodoviária, com o intuito de capacitar o modelo de forma prévia.
 - Compor informações a partir dos dados processados e propor sugestões de redistribuição de linhas na plataforma por meio da utilização do modelo de análise de imagens, visando à melhoria da organização do fluxo de pessoas no local.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Redes Neurais Artificiais

As redes neurais artificiais são uma forma de computação não-algorítmica baseada na estrutura biológica dos neurônios. Segundo Sompolinsky (2013), a reprodução artificial de um neurônio é chamada de perceptron, que foi idealizada pelo psicólogo Frank Rosenblatt em 1957, presente no artigo *The Perceptron: A Perceiving and Recognizing Automaton*. O perceptron é o tipo mais simples de rede neural e consiste em apenas uma camada de pesos conectando as entradas e saídas do sistema. A interação de várias unidades desses perceptrons em uma camada resulta em uma ANN, que utiliza a abordagem conexionista, não precisando de regras ou lógica para seu funcionamento.

A estrutura de uma rede neural consiste em uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Segundo Yüksel (2011), a camada de entrada é responsável por captar os dados exteriores da rede e direcioná-los para cada um dos perceptrons na camada escondida. A camada de saída realiza o processamento

de todos esses sinais e resulta em uma única ativação final da rede com a decisão ou classificação por uma função de ativação, que neste caso de estudo é a função degrau. Todo esse processo é descrito como feedforward.

Para validar os resultados obtidos pela rede neural, é comumente utilizado o erro absoluto presente na função de custo. O algoritmo Backpropagation é utilizado para ajustar os pesos das interconexões entre os neurônios artificiais rumo à minimização do erro do sistema. Conforme Yüksel (2011), o ajuste é feito utilizando a função integrada no algoritmo de Backpropagation, que busca o valor mínimo global do erro absoluto do sistema por meio de um processo iterativo de ajustes de pesos, usando o vetor gradiente descendente do erro. No entanto, as redes neurais de simples camada única possuem limitações, conforme apontado por Sompolinsky (2013). Para solucionar problemas linearmente separáveis, foi apresentada a técnica de múltiplas camadas escondidas, utilizando-se de repetidas multiplicações de matrizes e entrelaçando-as com a função de ativação. Essa técnica é utilizada para solucionar problemas que não podem ser resolvidos com o perceptron de uma única camada.

2.2 Redes Neurais Convolucionais

Redes Neurais Convolucionais (CNNs) são um tipo especializado de Rede Neural Artificial que tem se destacado em aplicações de processamento de imagens e visão computacional. De acordo com Lecun (2015), CNNs foram inspiradas pelo sistema visual biológico e são capazes de extrair automaticamente características úteis das imagens através da aplicação de filtros convolucionais. Os filtros convolucionais funcionam de forma similar a um filtro passa-baixa, onde cada filtro é aplicado à imagem original para detectar padrões específicos, como bordas, cantos ou texturas.

Uma das principais vantagens das CNNs é a capacidade de reduzir a dimensionalidade dos dados de entrada, preservando ao mesmo tempo a informação relevante. Essa redução é alcançada por meio de camadas de pooling, que realizam a subamostragem da imagem, reduzindo o seu tamanho. A utilização de camadas de pooling permite a invariância espacial, ou seja, a rede neural pode identificar padrões independentemente da posição em que eles aparecem na imagem (Krizhevsky, 2012).

Além disso, as CNNs também podem incluir camadas totalmente conectadas, que processam as características extraídas pelas camadas convolucionais para produzir uma saída final. O uso de camadas totalmente conectadas permite que as CNNs realizem tarefas mais complexas, como classificação de imagens, reconhecimento de objetos e detecção de rostos (Liu, 2019). A eficácia das CNNs tem sido comprovada em diversas aplicações, incluindo sistemas de reconhecimento de imagens em tempo real, como é o caso de veículos autônomos.

2.2.1: YOLO(Only Look Once)

YOLO, sigla para "You Only Look Once", é uma arquitetura de rede neural convolucional desenvolvida para detecção de objetos em tempo real. Ao contrário de outros métodos que passam a imagem por uma rede várias vezes, o YOLO realiza a detecção em uma única passagem, tornando-o extremamente eficiente. O YOLO divide a imagem de entrada em uma grade $S \times S$. Cada célula da grade é responsável por prever um número fixo de caixas delimitadoras (bounding boxes) e suas pontuações de confiança. Estas pontuações refletem a probabilidade de a caixa conter um objeto e a precisão da predição da caixa delimitadora em relação ao objeto.

Além disso, cada caixa delimitadora carrega predições de classes para indicar o tipo de objeto presente. A arquitetura YOLO consiste em uma série de camadas convolucionais que extraem características das imagens. Essas camadas são seguidas por camadas totalmente conectadas que transformam essas características em previsões de bounding boxes e classes. A vantagem do YOLO é a sua capacidade de fazer essas previsões simultaneamente, o que permite a detecção de objetos em tempo real. Uma das principais vantagens do YOLO é sua velocidade, sendo capaz de processar até 45 frames por segundo na versão original. Isso é possível porque o YOLO trata a detecção de objetos como um problema de regressão único, em vez de uma tarefa de classificação em múltiplos estágios. Isso o torna ideal para aplicações que requerem processamento rápido e em tempo real, como vigilância de segurança, veículos autônomos, e sistemas de assistência ao motorista.

2.3 Análise de Fluxo de Usuários

A análise de fluxo de usuários é uma abordagem utilizada para estudar o comportamento das pessoas em ambientes físicos, como shoppings, estações de transporte, aeroportos, entre outros. Essa análise consiste na coleta e processamento de dados de movimentação dos usuários, com o objetivo de compreender como eles interagem com o ambiente e entre si. Através dessa análise, é possível identificar padrões de comportamento, fluxos de movimento, congestionamentos, entre outras informações que são importantes para o planejamento e gestão desses espaços.

Estudos na área de análise de fluxo de usuários têm ganhado destaque nos últimos anos, principalmente com o advento da tecnologia de Visão Computacional. A Visão Computacional é uma área de estudo que utiliza técnicas de processamento de imagens para extrair informações úteis a partir de imagens ou vídeos capturados por câmeras. Na análise de fluxo de usuários, essa tecnologia é utilizada para identificar a posição e movimentação dos usuários em tempo real, o que permite a coleta de dados de forma mais eficiente e precisa (Zheng, 2019).

2.4 Estações Rodoviárias

As estações rodoviárias são importantes centros de transporte para o deslocamento de passageiros por ônibus intermunicipais e interestaduais. As estações rodoviárias possuem infraestrutura que atende às necessidades dos passageiros, como áreas de embarque e desembarque, plataformas de acesso aos ônibus, estacionamento e serviços de apoio, como lojas, restaurantes e banheiros (WATANABE, 2019). Além disso, segundo o especialista em transportes Luis Antonio Lindau, as estações rodoviárias são importantes para a organização do fluxo de ônibus nas cidades e para a oferta de linhas de ônibus que conectam diferentes localidades.

O projeto arquitetônico das estações rodoviárias é um fator importante para garantir a comodidade e segurança dos passageiros. O projeto deve considerar aspectos como acessibilidade, iluminação, ventilação, conforto térmico, segurança e

sinalização (LIMA,2020). Além disso, a disposição dos espaços deve ser pensada de forma a facilitar o acesso dos passageiros aos serviços disponíveis.

As estações rodoviárias são um ponto de conexão entre diferentes modais de transporte, como ônibus, metrô, trem e bicicleta. Ademais, as estações rodoviárias contribuem para a redução de acidentes nas rodovias, ao garantir a segurança e conforto dos passageiros durante as viagens de longa distância (PEREIRA, 2019).

3. MÉTODO

O método de pesquisa desdobra-se na metodologia de estudo de caso, com a finalidade de estudar a aplicação do modelo em cima do movimento rotineiro da rodoviária do Plano Piloto, utilizando atributos referentes à implementação e qualidade dos resultados gerados para extrair o melhor método de treino de uma CNN.

Conseguimos visualizar as fases e andamento do processo por meio do fluxograma 1.1, na primeira etapa apresentada é a Coleta e Tratamento, que consiste na criação de uma base de dados transformada e otimizada que será aplicada no modelo de visão computacional criado. O modelo é criado na primeira fase em razão da biblioteca escolhida para o desenvolvimento do projeto. YOLO é uma biblioteca amplamente utilizada no campo da visão computacional, que disponibiliza modelos ajustáveis para diversas aplicações. A principal característica que permite o aprimoramento efetivo das redes neurais desta biblioteca é a capacidade de personalização e otimização das variáveis internas da rede. Através do ajuste preciso de parâmetros como a taxa de aprendizado, número de camadas, e funções de ativação, é possível refinar o desempenho do modelo, adaptando-o às especificidades do conjunto de dados e ao contexto do problema a ser resolvido. Esta flexibilidade torna YOLO uma ferramenta eficiente para o desenvolvimento de sistemas avançados de reconhecimento e análise de imagens.

Fluxograma 1.1: Fluxo da metodologia da pesquisa



Fonte: Própria

Durante a fase de implementação, o levantamento de dados primários constitui a base inicial para a subsequente análise dos resultados. Nesta etapa, os dados que foram tratados e transformados na fase de coleta e tratamento serão utilizados como parâmetros essenciais para a análise.

Itens primários, como o número de passageiros e a capacidade das plataformas, serão destacados nesta fase para assegurar que a metrificação subsequente seja mais coesa e precisa. Esse enfoque no levantamento minucioso dos dados primários não apenas garante uma base sólida para a análise, mas também facilita a identificação de padrões e a inferência de insights relevantes sobre o comportamento do fluxo de passageiros. Conseqüentemente, isso permite que as propostas de redistribuição de passageiros sejam fundamentadas em dados concretos e análises rigorosas,

proporcionando recomendações práticas e efetivas para a melhoria do fluxo nas plataformas inferiores da rodoviária. Dessa forma, conseguimos realizar a implementação, ajustando os parâmetros de uma rede neural para o treinamento.

Fluxograma 1.2: Fluxo do desenvolvimento dos modelos preditivos utilizados na pesquisa



Fonte: Própria

A análise de dados primários e secundários é essencial para o desenvolvimento robusto do modelo. Inicialmente, os dados primários são coletados e analisados de forma detalhada, servindo como a principal fonte de informação para a calibração do modelo. Os dados secundários, por sua vez, são extraídos com base nos resultados obtidos a partir da análise dos dados primários. Esses dados secundários incluem informações derivadas de comportamentos imprevistos e de variáveis menos relevantes que emergem durante a análise inicial. Esse processo de análise permite a identificação de padrões e anomalias que não são imediatamente evidentes nos dados primários. A utilização de dados secundários complementa e refina os resultados da análise inicial, proporcionando uma compreensão mais abrangente e detalhada do fluxo de passageiros. Esses dados são particularmente úteis para ajustar e otimizar os parâmetros do modelo de rede neural, permitindo uma adaptação mais precisa às condições específicas da rodoviária de Brasília.

Na etapa de métricas, a avaliação de resultados busca gerar insights valiosos que possam fundamentar propostas para o redesenho das plataformas da rodoviária, baseando-se nos dados detalhadamente coletados e analisados. A principal métrica para validação do modelo de rede neural foi a acurácia. O valor de acurácia de predição de um modelo se dá pela soma de verdadeiros positivos e verdadeiros negativos dividido por todas as previsões.

$$Acurácia = \frac{\text{Número de previsões corretas}}{\text{Número de previsões totais}}$$

Utilizada em aprendizado de máquina e estatísticas, a acurácia mede a proporção de previsões corretas em relação ao total de previsões realizadas.

A análise criteriosa desses dados permite identificar padrões e ineficiências no fluxo de passageiros, oferecendo uma base sólida para intervenções estruturais e operacionais. A etapa de métricas não se limita à análise de desempenho dos modelos de deep learning implementados, mas se estende à aplicação prática dos insights obtidos, promovendo uma série de melhorias estruturais e operacionais que visam a otimização do fluxo de passageiros na rodoviária de Brasília.

Para a validação do modelo, o grupo de validação é empregado durante o processo de treinamento para ajustes e otimização dos hiperparâmetros do modelo, como a taxa de aprendizado e o número de camadas da rede neural. Estudos como o de Yang et al. (2018), e de Li e Zhao(2020) mostram que a divisão mais interessante para treinamento de redes neurais profundas com o objetivo de segmentar imagens é a de 80% para treino e 20% para testes, e apesar de não existirem métodos de divisão universais, o estudo *“Pixel-level pavement crack segmentation with encoder-decoder network”* por Tang et al.(2021) traz uma abordagem interessante ao mostrar boas métricas com uma divisão de 70% para treinamento e validação e 30% para teste. Inspirado por esses resultados a divisão da base de imagens de passageiros foi dividida em 70% para treinamento, 20% para validação e 10% para teste do modelo. A partir dessa conclusão, todas as bases de dados dessa pesquisa foram divididas dessa forma.

4. RESULTADOS E DISCUSSÃO

Implementação

A primeira etapa, conforme delineado na metodologia, baseia-se na coleta e no tratamento de dados nas plataformas inferiores da rodoviária de Brasília, com o


objetivo de construir uma base sólida para o treinamento, teste e validação do modelo de visão computacional. Para tanto, foram capturadas fotos e vídeos das plataformas em diferentes dias e horários, abrangendo períodos de alta movimentação, como dias úteis, e períodos de menor fluxo de pessoas, como finais de semana. Além da simples coleta, essas imagens passam por uma série de transformações, incluindo rotações e cortes, para que o modelo possa se adaptar a diferentes ângulos e posições das câmeras. Esse processo de aumento de dados (data augmentation) é crucial para criar um modelo mais robusto e versátil, capaz de lidar com variadas condições operacionais. Dessa forma, a base de dados se torna mais representativa e eficaz, melhorando a capacidade do modelo de generalizar e performar bem em situações reais.

Para esse propósito, foi utilizada a ferramenta RoboFlow para criar uma base de dados diversificada. O RoboFlow é uma plataforma de visão computacional que facilita a etiquetagem e categorização de informações cruciais, como a localização individual dos passageiros, a rotulagem de objetos para treinamento e a aplicação de transformações visuais, incluindo rotações, cortes, mudanças cromáticas e embaçamento de imagem. A base de imagens coletadas foi transferida para a ferramenta, onde as modificações necessárias foram realizadas. A utilização do RoboFlow simplificou significativamente o processo de argumentação de dados, proporcionando uma interface intuitiva para a gestão e transformação das imagens.

Com as imagens devidamente tratadas e etiquetadas, realizou-se a divisão do conjunto de dados em grupos de treino, teste e validação. O grupo de treino é utilizado para ajustar os parâmetros do modelo, permitindo que ele aprenda a reconhecer padrões e características específicas das imagens. O grupo de teste, por sua vez, é utilizado para avaliar a performance do modelo após o treinamento. Este conjunto de dados permanece "invisível" ao modelo durante o treinamento, servindo para verificar se o modelo se generaliza bem para novos dados. A arquitetura do YOLO (You Only Look Once) é uma das mais inovadoras no campo da visão computacional para a detecção de objetos em tempo real. Diferentemente de outras abordagens que passam a imagem por uma rede múltiplas vezes para detectar objetos, o YOLO trata a detecção de objetos como um problema de regressão único. Ele divide a imagem em uma grade

e, para cada célula dessa grade, prevê diretamente as caixas delimitadoras e as probabilidades de classe. Segundo REDMON et al. (2016), essa abordagem permite que o YOLO processe imagens em uma única passada através da rede neural, resultando em uma detecção extremamente rápida e eficiente. A arquitetura é composta por várias camadas convolucionais que extraem características das imagens e, em seguida, uma camada de saída que prevê as posições das caixas delimitadoras e as respectivas classes dos objetos.

Figura 2.1: Arquitetura original YOLO



Fonte: REDMON et al.(2016)

Durante o desenvolvimento desta pesquisa, a versão YOLOv8 foi escolhida para implementação devido ao fato de ser a última versão disponível durante o desenvolvimento dessa pesquisa, incorporando as mais recentes melhorias e otimizações em termos de precisão e velocidade. YOLOv8 oferece avanços significativos em relação às versões anteriores, incluindo uma arquitetura mais eficiente, melhores técnicas de pré-processamento e pós-processamento, e a capacidade de realizar detecções com maior precisão. Além disso, a comunidade de desenvolvedores e pesquisadores fornece suporte contínuo e atualizações para o YOLOv8, garantindo que ele permaneça uma escolha robusta e confiável para


aplicações de detecção de objetos. A escolha pelo YOLOv8 garante que a pesquisa esteja alinhada com os mais recentes desenvolvimentos tecnológicos, proporcionando uma base sólida para a implementação de um sistema de detecção de fluxo de passageiros na rodoviária de Brasília.

Análise de dados primários e secundários

As fotografias capturadas e utilizadas na biblioteca de tratamento variam significativamente em termos de localização e densidade de pessoas, garantindo uma diversidade de cenários. Em praticamente todas as imagens há algum nível de aglomeração, permitindo que a capacidade do modelo de diferenciar indivíduos em situações de alta densidade seja rigorosamente testada. Após os primeiros ciclos de treinamento, denominados épocas, observou-se a eficácia da arquitetura YOLO de deep learning em aprender a segmentar diferentes classes de objetos. O desempenho promissor nas primeiras épocas indica que a abordagem escolhida é adequada para as complexidades do ambiente analisado.

Apesar da facilidade de aprendizado do modelo existem algumas limitações dentro da própria base de dados utilizada. O principal desafio para uma rede como essa é lidar com um aglomerado muito grande em uma imagem (ou segmento de imagem) com baixa resolução.


Figura 2.2: Diferentes escalas de resolução em imagem



Fonte: Learning multiple layers of features from tiny images (Krizhevsky, 2009)

A variação de resolução nas imagens mostrou-se um elemento desafiador no treinamento da rede neural convolucional (CNN), impactando negativamente a uniformidade do aprendizado da rede. Essa disparidade nas resoluções introduziu interferências que reduziram a consistência dos resultados obtidos. Durante os testes realizados, a qualidade da detecção foi avaliada e ranqueada com base na acurácia dos resultados. Entre os testes realizados, o melhor resultado alcançado foi uma acurácia de 54%, indicando uma considerável limitação do modelo em lidar com grandes aglomerações de passageiros. Essa dificuldade é agravada pela variação da resolução de passageiros em uma só imagem dada como entradas na rede neural, o que compromete a qualidade da análise visual. Na figura X.X, é possível observar as diferentes resoluções de um passageiro que uma mesma imagem pode fornecer à CNN, o que interfere diretamente nos parâmetros de treinamento.

Figura 2.3: Duas figuras da mesma plataforma com resoluções diferentes



Fonte: Adaptado de Winston, 2024

A figura da esquerda exibe os passageiros em maior resolução que a imagem da direita.

A variação de resolução em imagens durante o treinamento de uma rede neural pode afetar negativamente o desempenho do modelo devido à inconsistência na

aprendizagem. Segundo DODGE e KARAM (2016), quando uma rede neural convolucional é treinada com imagens de resoluções muito diferentes, ela pode ter dificuldade em extrair características consistentes, o que leva a uma redução na precisão e na capacidade de generalização do modelo.

Para mitigar a problemática da variação de resolução nas imagens durante o treinamento da rede neural, foi proposto um método de segmentação das imagens. Cada imagem inserida no treinamento foi cortada de modo a simular uma câmera única focada em cada fila da plataforma. Dessa forma, a rede neural pode receber inputs de resoluções menores sem perder os detalhes cruciais, como características dos pedestres, ao mesmo tempo em que se evita a perda de informações relevantes de outros passageiros. Esta abordagem não apenas melhora a capacidade de generalização da rede, mas também facilita um controle mais preciso do fluxo de passageiros, permitindo uma separação eficiente por terminais. Ao segmentar as imagens dessa maneira, é possível manter a integridade dos detalhes necessários para a detecção e identificação de indivíduos, ao mesmo tempo que se reduz a interferência causada pela variação de resolução. Esse método também contribui para um treinamento mais eficiente e uma análise mais detalhada do fluxo de passageiros, fornecendo dados mais consistentes e permitindo uma avaliação mais precisa das condições de aglomeração em diferentes áreas da plataforma.

Figura 2.4: Corte segmentado de uma das fotos usadas na base de dados




Fonte: Adaptado de internet

Exemplo de segmento de imagem de terminal na plataforma, esse corte permite maior consistência nos resultados da CNN

Durante o estudo dos dados secundários não analisáveis pela rede neural, constatou-se uma concentração maior de passageiros no lado leste das plataformas inferiores. Essa observação sugere que, com a atual distribuição das linhas, o modelo provavelmente irá gerar sugestões que envolvam o deslocamento de passageiros do lado leste para o lado oeste das plataformas na maioria das vezes. Esta tendência é significativa, pois destaca a necessidade de um remanejamento que possa equilibrar melhor a distribuição de passageiros e otimizar o fluxo, evitando congestionamentos no lado leste. Além disso, essa descoberta sublinha a importância de uma análise contínua e detalhada das imagens coletadas e sugestões geradas para identificar padrões de movimentação específicos. Ao compreender essas dinâmicas, é possível propor intervenções mais eficazes e direcionadas, melhorando a eficiência operacional da rodoviária. A aplicação de técnicas de visão computacional permite uma modelagem precisa dessas interações, facilitando a implementação de soluções que atendam às necessidades reais dos passageiros e das operações diárias da rodoviária.

Outro ponto crucial a considerar é que, em caso de instalação de câmeras pontuais nos terminais para detecção, especialmente durante os horários de pico, que vão de 17h30 às 19h30, segundo a Agência Brasília(2017), as sugestões geradas pelo modelo poderiam estimar um número de passageiros superior ao efetivamente presente nas filas. Isso ocorre devido à alta densidade de pessoas, como demonstrado na figura 2.6, fazendo com que as filas se estendam além dos terminais designados. A presença de aglomerações nas áreas adjacentes às plataformas influencia a precisão das estimativas de fluxo e demanda. Essas aglomerações comumente advêm de filas tão extensas que chegam a alcançar partes de outras filas e seções da rodoviária.

Figura 2.5: Mapa de densidade da Rodoviária do Plano Piloto



Seguindo os objetivos desta pesquisa, o modelo proposto não se responsabiliza pelo cálculo exato do número de passageiros. Em vez disso, seu foco principal é a detecção e redistribuição de grandes aglomerações de pessoas nas plataformas. O intuito é melhorar a eficiência na movimentação e minimizar congestionamentos, garantindo uma melhor experiência para os usuários. Este enfoque permite ao modelo concentrar-se na identificação de áreas de alta densidade de passageiros, propondo soluções para redistribuir esses aglomerados de maneira eficaz.

Análise de Resultados

Com a acurácia do modelo atingindo 75%, um índice considerado satisfatório para a detecção de grandes aglomerações de pessoas, torna-se viável a implementação do modelo de sugestões. Esse nível de precisão indica que o modelo é suficientemente robusto para identificar corretamente padrões de aglomeração e, assim, fornecer recomendações confiáveis para a redistribuição de passageiros.

Inicialmente, o modelo é empregado para contar o número de passageiros presentes em cada uma das plataformas da rodoviária de Brasília. Após a coleta dos dados, as plataformas são classificadas em quatro categorias de lotação: Vago, Moderado, Cheio e Superlotado, dependendo do número de passageiros detectados. Esta classificação serve como base para a redistribuição das filas, cuja principal finalidade é reduzir aglomerações e otimizar o uso do espaço disponível. A lógica do algoritmo consiste em ordenar as plataformas com base no número de passageiros e, em seguida, intercalar as plataformas mais lotadas com as menos lotadas.

Esta estratégia visa a minimizar o índice de dispersão, que mede a variabilidade na distribuição de passageiros, e a sobrecarga, que representa o excesso de passageiros em relação à média ideal. O índice de dispersão é calculado como o desvio padrão da quantidade de passageiros nas plataformas, oferecendo uma medida estatística que reflete o grau de desigualdade na distribuição de passageiros. Um valor elevado de dispersão sugere uma distribuição desigual, com algumas plataformas sobrecarregadas e outras subutilizadas. Paralelamente, a sobrecarga é definida como a soma dos excessos de passageiros em plataformas que estão acima da média ideal, fornecendo um indicativo da pressão adicional em certas áreas da rodoviária.

Devido à impossibilidade de utilizar câmeras em determinadas áreas predefinidas, optou-se por uma abordagem alternativa para o monitoramento da densidade de pessoas na rodoviária. As imagens capturadas, bem como aquelas utilizadas no treinamento do modelo de detecção, foram deliberadamente segmentadas para simular seções específicas da rodoviária onde é viável medir a densidade de pessoas. Essa estratégia permitiu a coleta de dados suficientes para que o modelo pudesse gerar sugestões eficazes para a redistribuição dos passageiros, mesmo em ambientes com restrições quanto ao uso de dispositivos de vigilância.

Imagem 2. 6: Etiquetagens realizadas pelo modelo durante sua predição.



Fonte: Autoria própria

Aqui as imagens são apresentadas já segmentadas para que o classifique como 2 filas de uma mesma plataforma

A segmentação das imagens foi realizada com o intuito de representar áreas de interesse dentro da rodoviária, como estações de ônibus, em que o fluxo de passageiros poderia ser monitorado de forma indireta. Essa técnica não apenas assegura a conformidade com as restrições impostas, mas também mantém a integridade dos dados. Ao focar em seções específicas, é possível obter uma estimativa precisa da densidade populacional em áreas críticas, permitindo que o sistema de sugestões funcione adequadamente, mesmo sem a cobertura total da rodoviária por câmeras.

É importante se atentar que a finalidade do corte nas imagens no teste e no treinamento diferem, no momento de teste do modelo, as razões seguem uma linha de integridade de coleta dos dados. Além disso, essa abordagem simula cenários reais em que a cobertura de câmeras é parcial ou limitada a certas zonas, refletindo de maneira mais precisa as condições sob as quais o modelo será implementado. Para a formulação das sugestões do modelo, as imagens previamente segmentadas foram organizadas de acordo com a sequência das estações, conforme representado na figura, permitindo a execução precisa de todas as medições a serem registradas nesta pesquisa.

Figura 2.7: Predições e reorganização das linhas

```

image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo1.jpg: 736x800 49 heads, 390.7ms
Speed: 5.5ms preprocess, 390.7ms inference, 0.0ms postprocess per image at shape (1, 3, 736, 800)
image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo2.jpg: 448x800 53 heads, 240.9ms
Speed: 2.0ms preprocess, 240.9ms inference, 1.0ms postprocess per image at shape (1, 3, 448, 800)
image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo3.jpg: 480x800 38 heads, 260.2ms
Speed: 3.0ms preprocess, 260.2ms inference, 0.0ms postprocess per image at shape (1, 3, 480, 800)
image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo4.jpg: 320x800 41 heads, 209.9ms
Speed: 1.0ms preprocess, 209.9ms inference, 1.0ms postprocess per image at shape (1, 3, 320, 800)
image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo5.jpg: 416x800 73 heads, 238.0ms
Speed: 2.0ms preprocess, 238.0ms inference, 0.0ms postprocess per image at shape (1, 3, 416, 800)
image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo6.jpg: 320x800 36 heads, 178.0ms
Speed: 1.0ms preprocess, 178.0ms inference, 0.0ms postprocess per image at shape (1, 3, 320, 800)
image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo7.jpg: 352x800 44 heads, 191.3ms
Speed: 1.0ms preprocess, 191.3ms inference, 1.0ms postprocess per image at shape (1, 3, 352, 800)
image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo8.jpg: 352x800 50 heads, 206.1ms
Speed: 1.0ms preprocess, 206.1ms inference, 0.0ms postprocess per image at shape (1, 3, 352, 800)
...
Speed: 1.5ms preprocess, 204.8ms inference, 1.0ms postprocess per image at shape (1, 3, 384, 800)
image 1/1 C:\Users\guidi\Desktop\PIBITI\novas-img-rodo\rodo10.jpg: 288x800 45 heads, 164.1ms
Speed: 1.0ms preprocess, 164.1ms inference, 1.0ms postprocess per image at shape (1, 3, 288, 800)
Output is truncated. View as a scrollable element or open in a text editor. Adjust cell output settings...
Total de passageiros: 447
Estação 5: 73 passageiros detectados - Classificação: Cheio
Estação 9: 18 passageiros detectados - Classificação: Vago
Estação 2: 53 passageiros detectados - Classificação: Cheio
Estação 6: 36 passageiros detectados - Classificação: Moderado
Estação 8: 50 passageiros detectados - Classificação: Cheio
Estação 3: 38 passageiros detectados - Classificação: Moderado
Estação 1: 49 passageiros detectados - Classificação: Cheio
Estação 4: 41 passageiros detectados - Classificação: Moderado
Estação 10: 45 passageiros detectados - Classificação: Cheio
Estação 7: 44 passageiros detectados - Classificação: Moderado
Índice de Dispersão: 13.28
Sobrecarga Total: 46.50


```

Fonte: Própria

Os resultados obtidos a partir da análise do número de passageiros nas plataformas da rodoviária indicam que, apesar da redistribuição, ainda há variações

notáveis na ocupação das plataformas. O índice de dispersão calculado sugere que, mesmo após a reordenação das filas, ainda existe uma variação considerável no número de passageiros entre as plataformas. Isso pode indicar que o processo de intercalação, embora tenha mitigado parcialmente as aglomerações, não foi capaz de uniformizar completamente a distribuição dos passageiros. Esse comportamento pode ser atribuído à natureza do fluxo de passageiros, que pode ser influenciado por fatores como horários de pico e a localização das plataformas em relação às entradas e saídas da rodoviária. Nesse contexto, a variável em análise são os destinos das estações. As viagens com destino às cidades do entorno, majoritariamente localizadas na porção leste da rodoviária, correspondem a trajetos mais longos e, conseqüentemente, formam grandes aglomerações durante os horários de pico. Em contraste, a maioria das viagens com destino aos bairros locais estão concentradas na parte oeste da rodoviária. Embora essa região também enfrente alta demanda nos horários de pico, sendo classificada como "Cheia" em todas as medições realizadas nesse período, a taxa de ocupação da plataforma oeste varia entre 53% e 85% da ocupação total das plataformas quando medidas em horários anteriores.

Tabela 1.1: Porcentagem de ocupação do total observado em ambas as plataformas fora de horário de pico



A taxa de ocupação das plataformas Leste e Oeste em uma semana típica, com uma escala de ocupação entre 10% e 90%. Em cada gráfico, a soma das ocupações para ambos os lados (Leste e Oeste) é ajustada para sempre totalizar 100% para cada dia e horário, refletindo a distribuição do tráfego de passageiros entre as duas plataformas em diferentes períodos do dia.

Adicionalmente, a plataforma leste foi classificada como "Superlotada" em 95% das medições realizadas, totalizando 38 ocorrências dessa classificação em 40 testes conduzidos.

Esses resultados refletem no valor de sobrecarga calculado cuja análise revela que algumas plataformas ainda carregam uma quantidade significativa de passageiros além do ideal. O Valor de sobrecarga é calculado em quantas vezes a sua própria capacidade passa a lotação de pessoas naquela área. Isso sugere que, embora o algoritmo tenha redistribuído as plataformas, a capacidade de reduzir a sobrecarga depende de quão flexíveis são as opções de redistribuição. Em situações reais, limitações físicas e operacionais, como o espaço disponível ou a necessidade de manter certas plataformas próximas a serviços específicos, podem restringir a eficácia da redistribuição completa.

Tabela 1.2: Valor de Sobrecarga

Horários (hrs)	Valor de sobrecarga
8-10	1,3x
10-12	1,1x
12-14	0,8x
14-16	0,9x
16-18	1,5x
18-20	2,1x
20-22	1,8x

Conforme ilustrado na Figura X.X, o modelo é capaz de processar cada detecção em um intervalo de 2 a 3 segundos. Esse tempo de processamento ligeiramente elevado é atribuído à alta carga de elementos detectáveis, o que faz com que o YOLO

leve mais tempo do que o usualmente esperado em previsões típicas. Diante disso, a aplicação do modelo em um sistema de captura de imagens provenientes de câmeras de alta resolução, em vez de processamento em tempo real, seria mais apropriada. Esse método garantiria que nenhum detalhe crucial do fluxo de passageiros fosse perdido, considerando que as filas nas rodoviárias são formações estacionárias e de baixa dinâmica.

5. CONSIDERAÇÕES FINAIS

A implementação de um sistema de coleta de dados constante e contínuo permitiria a análise em tempo real das condições das plataformas, integrando as áreas adjacentes e superiores da rodoviária ao modelo de monitoramento. Ao ampliar o escopo de análise para incluir essas outras áreas, o sistema poderia fornecer sugestões ainda mais precisas e abrangentes para a redistribuição de passageiros, potencialmente mitigando problemas de aglomeração em toda a rodoviária.

A instalação de câmeras em pontos estratégicos, em conjunto com o processamento de imagens de alta resolução, permitirá capturar um panorama detalhado do fluxo de passageiros ao longo do dia. Essa abordagem não apenas refina a detecção e redistribuição das filas, mas também oferece uma visão holística da movimentação de passageiros em toda a estação. Com a implementação deste sistema, o modelo pode ser ajustado e calibrado continuamente, utilizando os dados em tempo real para adaptar-se às variações diárias e sazonais do fluxo de passageiros.

Além disso, com a coleta contínua de dados pelo modelo, será possível gerar sugestões mais inteligentes e complexas, que considerem padrões de movimentação mais detalhados e variáveis contextuais adicionais. Esse aprimoramento permitirá que o sistema ofereça soluções de redistribuição de passageiros que não apenas previnam aglomerações, mas também otimizem a eficiência operacional de toda a rodoviária. Ao aplicar o modelo em uma infraestrutura real, será possível validar empiricamente as previsões e sugestões geradas, garantindo que as recomendações ofereçam melhorias

tangíveis na eficiência operacional da rodoviária. Esse ciclo de feedback contínuo, alimentado por dados reais e atualizados, permitirá que o sistema evolua de forma iterativa, tornando-se cada vez mais eficaz na gestão do fluxo de passageiros e na prevenção de aglomerações, o que é essencial para a segurança e o conforto dos usuários da rodoviária do Plano Piloto.

REFERÊNCIAS

EUFRÁSIO, Jéssica; CARVALHO, Milena; CARDIM, Nathália. Passageiros enfrentam ônibus lotados, paradas cheias e atrasos após pane geral no metrô do DF. Metrôpoles. Disponível em:

<<https://www.metropoles.com/distrito-federal/estacoes-do-metro-no-df-amanhecem-fechadas-apos-problemas-na-sinalizacao>>. Acesso em 26 de abril de 2024.

Nagaraj, N., Gururaj, H.L., Swathi, B.H. et al. Passenger flow prediction in bus transportation system using deep learning. *Multimed Tools Appl* 81, 12519–12542 (2022).

MENDONÇA, Cláudio. Transporte rodoviário - Por que o Brasil depende tanto desse sistema. UOL, 2023. Disponível em:

<<https://educacao.uol.com.br/disciplinas/geografia/transporte-rodoviario-por-que-o-brasil-depender-tanto-desse-sistema.htm>>. Acesso em 24 de abril de 2024.

ANDREW, Nicolas. A História da Malha Ferroviária Brasileira. Rodoquick, 2019.

Disponível em:

<<https://rodoquick.com.br/blog/a-historia-da-malha-rodoviaria-brasileira/>> Acesso em 24 de abril de 2024.

DUTRA, Francisco. Rodoviária do Plano: MP aponta falhas de acessibilidade e infraestrutura. Metrôpoles. Disponível em

<<https://www.metropoles.com/distrito-federal/rodoviaria-do-plano-mp-aponta-falhas-de-acessibilidade-e-infraestrutura>>. Acesso em 10 de julho de 2024.

Sompolinsky, H. (2013). Neural networks: a new framework for statistical mechanics. *Annual review of condensed matter physics*, 4, 117-139.

Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386-408.

Yüksel, S. (2011). Artificial neural networks. In *Data mining and knowledge discovery for process monitoring and control* (pp. 179-207). Springer, Berlin, Heidelberg.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.

Liu, S., Huang, D., & Wang, Y. (2019). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Access*, 7, 36306-36322.

WATANABE, Roberto Massaru. “Estações rodoviárias: Infraestrutura para passageiros”. *Revista da Construção*, edição 102, nov/dez 2019.

LIMA, Emanuelle. “Arquitetura de estações rodoviárias: projetando para o conforto e segurança dos passageiros”. ArchDaily, 11 de setembro de 2020.

PEREIRA, Paulo César. “Estações rodoviárias são importantes para a mobilidade urbana”. O Tempo, 17 de dezembro de 2019.

GARCIA, F. O IMPACTO DA PRIVATIZAÇÃO E ABERTURA DE CAPITAL NA EFICÁCIA DOS SERVIÇOS DE SANEAMENTO BÁSICO NO BRASIL. Dissertação (mestrado profissional MPE) – Fundação Getulio Vargas, Escola de Economia de São Paulo. São Paulo, p. 74. 2023.

Tarcísio critica Enel, mas quer vender Sabesp mesmo diante do fracasso das privatizações. Sintaema São Paulo, 2024. Disponível em:

<<https://sintaemasp.org.br/noticias/tarcisio-critica-enel-mas-quer-vender-sabesp-mesmo-diante-do-fracasso-das-privatizacoes>>. Acesso em 20 de julho de 2024.

BAHETI, Pragati. Train Test Validation Split: How To & Best Practices [2024]. V7 Labs, 2024. Disponível em:

<<https://www.v7labs.com/blog/train-validation-test-set#:~:text=In%20general%2C%20putting%2080%25%20of,dimension%20of%20the%20data%2C%20etc.>>. Acesso em 26 de junho de 2024.

Kannoja, Suresh & Jaiswal, Gaurav. (2018). Effects of Varying Resolution on Performance of CNN based Image Classification An Experimental Study. International Journal of Computer Sciences and Engineering. 6. 451-456. 10.26438/ijcse/v6i9.451456.

Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. "Gradient-based learning applied to document recognition.", *Proceedings of the IEEE*, Vol.86, Issue.11, pp.2278-2324, 1998.

Krizhevsky, Alex, and Geoffrey Hinton., "Learning multiple layers of features from tiny images", Technical report, University of Toronto, Vol.1, Issue.4, 2009

Confusion Matrices (Contingency Tables). The R Project for Statistical Computing. Disponível em:

<[Acesso em 15 de junho de 2024.](https://search.r-project.org/CRAN/refmans/qwraps2/html/confusion_matrix.html#:~:text=accuracy%20%3D%20(TP%20%2B%20TN),TP%20%2F%20(TP%20%2B%20FP)>.</p></div><div data-bbox=)

CAMARGO, Júlia. Alvo de privatização no DF, Rodoviária do Plano Piloto terá atividade do Movimento Passe Livre nesta sexta (19). *Brasil de Fato*, 2024. Disponível em:

<<https://www.brasildefato.com.br/2024/01/19/alvo-de-privatizacao-no-df-rodoviaria-d-o-plano-piloto-tera-atividade-do-movimento-passe-livre-nesta-sexta-19>>. Acesso em 05 de agosto de 2024.

S. Li and X. Zhao, "Automatic Crack Detection and Measurement of Concrete Structure Using Convolutional Encoder-Decoder Network," in *IEEE Access*, vol. 8, pp. 134602-134618, 2020, doi: 10.1109/ACCESS.2020.3011106.

keywords: {Convolution;Distortion measurement;Feature extraction;Surface cracks;Image segmentation;Concrete;Computer architecture;Concrete crack;detection and measurement;convolutional encoder-decoder network;deep learning},

Understanding How Image Quality Affects Deep Neural Networks. 2016. Disponível em: <https://arxiv.org/abs/1604.04004>. Acesso em: 18 jul. 2024.