

O USO DE DEEP LEARNING COMO UM POSSÍVEL OTIMIZADOR DE TRÁFEGO URBANO EM SEMÁFOROS – ENGENHARIA DA COMPUTAÇÃO– UNISOCIESC/ CAMPUS JOINVILLE

PROCHNOW, Gustavo ¹
MARCON, Vinicius ²
PETRI, Marcelo ³

RESUMO

Explorando as possibilidades de inovação em sistemas de controle de tráfego urbano, este projeto em Engenharia de Computação propõe a criação de um sistema inteligente baseado em visão computacional e redes neurais. O objetivo central é implementar uma solução capaz de identificar e contar, em tempo real, veículos e pedestres em cruzamentos, possibilitando assim, um controle de semáforos mais dinâmico. Ao utilizar câmeras de segurança pública, o sistema captura imagens do ambiente urbano na região do semáforo, e por meio do uso de redes neurais treinadas, realiza a identificação precisa de veículos e pedestres. Essa abordagem proporciona uma contagem eficiente, servindo como base para uma possível otimização do controle de semáforos de forma adaptativa, trazendo otimização de tempo, dinamicidade e segurança para os transeuntes. Os resultados almejados visam não apenas melhorar a eficiência do tráfego, mas também explorar as capacidades das redes neurais na aprendizagem de padrões em ambientes dinâmicos. Este estudo propõe uma contribuição significativa para a área de sistemas inteligentes de controle de tráfego urbano, destacando a aplicação prática de visão computacional e de redes neurais. O sistema proposto é capaz de entregar uma eficiência de 98% para identificação e contagem de veículos e de 97% para a identificação e contagem de pedestres utilizando imagens de câmeras de segurança já instaladas nos locais monitorados.

Palavras-chave: Visão Computacional; Redes Neurais; Deep Learning; Inteligência Artificial; Controle de Tráfego.

¹Graduando do Curso de Engenharia da computação do Centro Universitário UNISOCIESC, prochnow.gu@gmail.com; ²Graduando do Curso de Engenharia da computação do Centro Universitário UNISOCIESC, berkembrock.vinicius@gmail.com; ³Professor orientador, Centro Universitário UNISOCIESC, marcelo.petri@unisociesc.com.br;

ABSTRACT

Exploring innovation possibilities in urban traffic control systems, this Computer Engineering project proposes the development of an intelligent system based on computer vision and neural networks. The central objective is to implement a solution capable of identifying and counting vehicles and pedestrians in real-time at intersections, thus enabling a more dynamic traffic light control. By utilizing public security cameras, the system captures images of the urban environment at the traffic light region and, through trained neural networks, accurately identifies vehicles and pedestrians. This approach provides efficient counting, serving as a basis for potential adaptive optimization of traffic lights, bringing time efficiency, dynamism, and safety for pedestrians. The intended results aim not only to enhance traffic efficiency but also to explore neural networks' capabilities in learning patterns in dynamic environments. This study proposes a significant contribution to the field of intelligent urban traffic control systems, highlighting the practical application of computer vision and neural networks. The proposed system demonstrates 98% efficiency in vehicle identification and counting and 97% in pedestrian identification and counting using images from already-installed security cameras in monitored locations.

Keywords: Computer Vision; Neural Networks; Deep Learning; Artificial Intelligence; Traffic Control.

1 INTRODUÇÃO

Por volta de 1869 (NOTTINGHAM, 2009), o semáforo, originado diretamente da sinalização ferroviária como um dispositivo movido a gás para coordenar as locomotivas que percorriam as linhas férreas, foi inicialmente implementado na metrópole de Londres pelo engenheiro ferroviário John Peake Knight. Essa inovação visava regular a passagem de trens em pontos de interseção entre duas vias urbanas. O semáforo de tráfego surgiu pela primeira vez no início do século 20 na cidade de Nova York, com o propósito de gerenciar o fluxo em constante crescimento de automóveis, pedestres e carruagens que compartilhavam as principais ruas da cidade (Andrew Gardner, 2017).

Na contemporaneidade, assistimos a um aumento natural no número de veículos, impulsionado pela conveniência e praticidade que esses meios de transporte oferecem. No entanto, esse crescimento, aliado ao desafio de vias frequentemente não projetadas para acomodar tal volume, culmina na formação de congestionamentos, sobretudo durante os horários de pico. Esta realidade sublinha a urgência de investigar soluções para esse dilema global. Uma abordagem eficaz reside na implementação de estratégias voltadas para a otimização do fluxo de veículos em cruzamentos regulamentados, objetivando a redução do tempo de espera e a melhoria geral na eficiência das locomoções.

Para atingir essa solução, torna-se viável a utilização de sensores ou sistemas inteligentes, conforme abordado neste estudo. A aplicação de técnicas de Deep Learning associadas ao processamento digital de imagens possibilita a identificação e contagem precisa da presença de veículos nas vias, proporcionando um controle de tráfego mais eficiente. Os benefícios dessa abordagem extrapolam a simples gestão do fluxo veicular, uma vez que, ao otimizar os momentos de parada, favorece a fluidez do tráfego, contribuindo de maneira substancial para o aprimoramento da segurança, economia de tempo e melhoria na segurança rodoviária através da redução do índice de acidentes.

Este trabalho demonstra a implementação de um sistema de inteligência artificial que utilizará de deep learning para criar um sistema de gestão de sinais de semáforos de forma eficiente, aumentando a otimização do sistema como um todo.

2 REFERENCIAL TEÓRICO

O desenvolvimento de um contador de veículos e pedestres utilizando deep learning para servir como um otimizador de fluxo de tráfego representa um avanço significativo nas soluções de transporte inteligente. O referencial teórico para este artigo abrange as áreas de visão computacional, aprendizagem de máquinas e deep learning.

2.1 SISTEMA DE VISÃO COMPUTACIONAL


Um sistema de visão computacional pode ser definido como um sistema computadorizado capaz de adquirir, processar e interpretar imagens correspondentes a cenas reais (FILHO; NETO, 1999).

A obtenção de imagens é o ponto inicial e fundamental para diversas aplicações em visão computacional. Utilizam-se equipamentos como câmeras, cuja escolha da lente depende de fatores como condições de iluminação, resolução, velocidade de captura e distância entre o objeto de interesse e o dispositivo de aquisição (PEDRINI & SCHWARTZ, 2007).

O estágio subsequente, conhecido como pré-processamento, visa otimizar a qualidade da imagem para etapas posteriores. Envolve manipulações na matriz de pixels, tais como ajustes de contraste, brilho, redução de ruído e realce de cores (GONZALES & WOODS, 2018).

Uma vez finalizado o pré-processamento, a segmentação da imagem emerge como um passo crucial. Essa fase pode dividir a imagem em regiões ou identificar objetos de interesse. Métodos de segmentação podem variar desde análises baseadas na diferença entre valores de pixels até a subtração de imagens para destacar áreas específicas, como exemplificado na Figura 1.

Figura 1 - Exemplo de Subtração de Imagens (Fundo, Foto, Resultado)



Fonte: (FERREIRA; CUNTO, 2018)

Continuando o fluxo de processamento, a etapa subsequente após a segmentação é a extração de características do objeto de interesse. Esta fase pode ser realizada através do uso de descritores, cuja função é identificar e representar de maneira apropriada um objeto na imagem. Esses descritores são estruturas de

dados essenciais para os algoritmos de reconhecimento, permitindo a extração de informações relevantes, como texturas, pixels de mesma cor, entre outros (GONZALES & WOODS, 2018).

Por fim, a interpretação representa a última fase de um sistema de visão computacional. Essa etapa pode ser categorizada com base na análise das características extraídas no processo anterior (PEDRINI & SCHWARTZ, 2007).

2.2 APRENDIZADO DE MÁQUINA

Dentro do contexto da inteligência artificial (IA), o Aprendizado de Máquina, frequentemente referido pelo termo em inglês "Machine Learning", representa um subcampo essencial, conforme ilustrado na Figura 2. Os algoritmos de Machine Learning geralmente se destacam por seu aprendizado baseado em exemplos e são desenvolvidos com o intuito de emular a capacidade humana de aprendizado, conforme descrito por Naqa e Murphy (2015).

De acordo com Burkov (2019), o aprendizado de máquina pode ser descrito como um processo para resolver problemas práticos, seguindo os passos:

- Coleta do dataset, sejam eles dados brutos ou fotos.
- Construção do algoritmo e modelo estatístico de rede neural artificial, baseado na coleta de dados descrita acima.
- Análise da acurácia da rede em identificar o que é necessário nas imagens.

Além disso, os algoritmos de aprendizado de máquina são caracterizados por um processo computacional que utiliza dados de entrada para aprender a executar tarefas específicas. Esse procedimento de aprendizagem é denominado treinamento, no qual os dados de entrada são fornecidos juntamente com os resultados desejados (NAQA & MURPHY, 2015).


2.3 DEEP LEARNING

Recentemente, o interesse pelo aprendizado de máquina tem experimentado um notável crescimento. Essa abordagem faz uso de algoritmos para analisar e

processar dados, resultando na geração de previsões e tendências altamente refinadas (Domingos, 2015).

De acordo com Nielsen (2019), os algoritmos de Deep Learning são mais desafiadores de treinar do que os de redes neurais tradicionais, demandando uma quantidade maior de dados de entrada. No entanto, conseguem atingir uma eficiência superior, conforme ilustrado na figura 2. Essa capacidade de atingir uma eficiência maior tem impulsionado o interesse e a adoção crescente desses modelos no campo do aprendizado de máquina.

Figura 2 - Desempenho x Quantidade de Dados aplicado ao Deep Learning



Fonte: (NIELSEN, 2019)

3 METODOLOGIA

Este Trabalho de Conclusão de Curso explora o uso de algoritmos de Deep Learning para a contagem e identificação de pedestres e veículos em ambientes urbanos. A precisão na contagem e na identificação desses elementos pode desempenhar um papel significativo no aprimoramento de sistemas de gerenciamento de tráfego, tornando-os mais eficazes e seguros.

Ao que se diz respeito à metodologia, delineamos as abordagens e técnicas específicas que serão aplicadas ao longo deste estudo, enfatizando a importância da utilização de Redes Neurais Profundas (Deep Neural Networks) na análise de imagens de trânsito. Além disso, discutimos os procedimentos de coleta de dados, o

treinamento do modelo e a validação dos resultados, realçando a relevância desta pesquisa no contexto da melhoria da mobilidade urbana e na promoção de cidades mais inteligentes e sustentáveis.

3.1 INTRODUÇÃO AO PROBLEMA

A crescente urbanização global tem intensificado a demanda por sistemas de transporte mais eficientes e inteligentes. Neste contexto, a otimização do fluxo de tráfego torna-se uma necessidade, não só para mitigar congestionamentos, mas também para melhorar a segurança viária e reduzir o impacto ambiental. Desafios surgem quando se considera a dinâmica complexa dos ambientes urbanos, onde o fluxo de veículos e pedestres coexiste e interage entre si continuamente.

O controle semafórico tradicional muitas vezes não se adapta às condições de tráfego em tempo real, levando a congestionamentos, ineficiências e atrasos. Além disso, uma contagem manual de veículos e pedestres para análises de tráfego é onerosa, demorada e propensa a erros. Portanto, há uma necessidade em desenvolver sistemas automáticos que possam gerenciar e otimizar o fluxo de tráfego de forma mais eficaz.

Neste artigo, é proposto uma abordagem inovadora que emprega técnicas de deep learning para automatizar a contagem de veículos e pedestres em interseções semaforicas, e posteriormente, a possibilidade de utilização desses dados para um controle de fluxo otimizado, independente do dia e clima. Utilizando um software de interface amigável, dinâmica e desempenho robusto para criação de redes neurais baseadas na análise de imagens, nosso sistema não apenas conta os veículos e pedestres com precisão, mas também prediz a densidade do tráfego. Isso permite a otimização adaptativa dos tempos de sinalização, resultando em um tráfego mais fluido e reduzindo o tempo de espera para todos os usuários da via.

A implementação de uma solução baseada em deep learning para análise de tráfego oferece diversas vantagens: aprendizado e adaptação contínuos a partir de dados, alta precisão em diversas condições ambientais e a capacidade de processar grandes volumes de dados em tempo real. Essas características tornam o deep learning uma ferramenta poderosa para enfrentar as complexidades do gerenciamento de tráfego urbano e abrir novos caminhos para sistemas de

transporte inteligentes e autônomos. Este trabalho visa demonstrar o potencial dessa tecnologia e fornecer uma base sólida para futuras inovações no campo da engenharia de tráfego.


3.2 OBJETIVOS

O objetivo deste artigo é desenvolver e demonstrar um otimizador de fluxo de tráfego baseado em deep learning, que seja capaz de contar e analisar o fluxo de veículos e pedestres em interseções urbanas. Busca-se desenvolver o estudo e criar um sistema que possa, no futuro, através das contagens e dados obtidos, adaptar os tempos de sinalização semafórica em tempo real, de acordo com as condições dinâmicas do tráfego, visando melhorar a eficiência do trânsito e a segurança dos pedestres.

3.3 LOCAL ESTUDADO

O local escolhido para o estudo foi a rua Benjamin Franklin Parkway, presente no coração da cidade da Filadélfia, estado da Pensilvânia, Estados Unidos. Foi escolhido esse local por conta da câmera de tráfego pública presente no famoso museu científico The Franklin Institute. A câmera está apontada para a biblioteca pública Foundation Board-Free Library, que pode ser vista na figura 3 abaixo.

Figura 3 - Imagem da câmera presente no museu The Franklin Institute



Fonte: EARTHCAM, 2023

A imagem gerada, obtida pela câmera, tem grandes vantagens para geração de dados que compuseram o dataset, como boa resolução, qualidade de imagem independente do horário e nível de iluminação, um ponto de vista sem obstrução da visão da câmera por outdoors, placas de grande porte ou estruturas, além de ter uma pista de sentido único, com as identificações e sinalizações bem demarcadas e com um ótimo estado de conservação.

3.4 DESENVOLVIMENTO DO SISTEMA

Nessa etapa do documento será apresentado como foi construído o estudo para identificação de pedestres e veículos em semáforos através do uso de Deep Learning.


3.4.1 Dataset

Através do site EarthCam foi realizada uma busca de uma câmera de tráfego pública que fornecesse imagens com qualidade em diferentes climas e índices de iluminação, a câmera selecionada foi apresentada no capítulo 3.3 anterior. A partir das imagens acessadas foi realizada a gravação em diferentes horários e dias para a geração de um dataset com diversidade nas características das imagens, para a gravação dos dados foi utilizado o software OBS studio e em seguida os arquivos de vídeo foram utilizados para a geração de aproximadamente 73 mil imagens através do software Shotcut.

3.4.2 Pré Processamento

Antes das imagens convertidas serem importadas para o treinamento da rede neural, elas foram processadas e ajustadas no software Cognex Designer seguindo o esquema apresentado na figura 4, e a partir desses ajustes foram criados novos Datasets definitivos e específicos de cada região da imagem que fosse desejável analisar individualmente.


Figura 4 - Arquitetura do sistema para extrair as regiões de análise



Fonte: Autor¹, 2023

A etapa inicial, Cam_Acquire recebeu como input o dataset criado com as imagens das gravações das câmeras e em seguida foram processadas dentro da aplicação VisionProToolBlock, sua função é poder manipular e transformar através de regiões geométricas novas imagens dentro de uma imagem original. A ferramenta consegue também remover efeitos de rotação e inclinação presentes dentro da nova região gerada como imagem. A ferramenta foi configurada para extrair somente as 4 regiões necessárias como novas imagens de saída, assim como é mostrado na figura 5 abaixo:

Figura 5 - Regiões de análise



Fonte: Autor¹, 2023

Essa parte do estudo representa o início da arquitetura do sistema criador, nessa etapa cada imagem convertida foi dividida em 4 regiões, sendo elas a área

01, área de veículos, a área 02, pedestres cima, a área 03, pedestres baixo e a área 04, faixa de pedestres. As demais regiões excedentes da imagem não são analisadas, pois não são importantes ou não contribuem para o estudo.

3.4.3 Treinamento da rede neural

Após a conclusão do processamento das imagens tratadas, foi necessário realizar a transição de todo o banco de imagens convertido anteriormente para uma nova versão, sendo essa uma versão ajustada e tratada para um novo tamanho. Essas imagens foram então salvas para serem posteriormente importadas para o ViDi, onde a rede neural seria treinada.

Dentro do software ViDi foram criados workspaces para separar as imagens para o treinamento conforme as diferentes regiões separadas na etapa anterior. Primeiramente foram realizadas as configurações para a identificação dos veículos, onde são levadas em consideração informações referentes às dimensões e movimentações dos veículos nas imagens, com os ajustes realizados foi possível realizar a identificação automática em imagens, onde o próprio sistema sinalizada, conforme a figura 6:



Fonte: O Autor¹, 2023

Em seguida foram realizadas as configurações para a identificação de pedestres, que tiveram parâmetros diferentes e locais de procura diferentes, atendendo os requisitos funcionais do sistema, é possível visualizar a identificação realizada pelo sistema na figura 7.

Figura 7 - Demarcação de pedestres - Região Superior



Fonte: O Autor¹, 2023

Após o treinamento da rede neural o output do sistema é gerado através de blocos separados conforme as áreas separadas anteriormente na figura 20.

3.7.4 Aplicação para análise de resultados


Também foi desenvolvida uma interface para apresentação do funcionamento da rede neural baseada em Deep Learning. Através dela é possível simular o funcionamento de um sistema de visão computacional como esse.

A simulação é feita através de novos vídeos coletados do semáforo, os vídeos processados pelo editor de vídeos e transformados em imagens, que por sua vez são importadas para o Designer onde serão tratadas e encaminhadas para a rede neural analisar.

A interface foi confeccionada para oferecer várias informações ao usuário, tanto de monitoramento das vias de veículos, como dos principais pontos de espera e travessia dos pedestres. Toda a interface foi personalizada conforme o contexto da aplicação.

Abaixo é possível visualizar a face da interface já em funcionamento e apresentando a contagem de veículos e pedestres conforme as imagens processadas:

Figura 8 - Interface de Apresentação dos Resultados



Fonte: O Autor¹, 2023

4 RESULTADOS E DISCUSSÃO

Nesta seção do documento, são apresentados os resultados matemáticos obtidos com as redes neurais treinadas e sua performance. Além disso, foram discutidos os desafios e contratempos enfrentados ao longo do estudo, incluindo situações em que o sistema não se comportou conforme o esperado ou não alcançou a precisão desejada.

Ao término da seção, foram listadas possíveis abordagens a serem exploradas no futuro para melhorar a precisão e a confiabilidade do sistema. Também foi sugerida uma maneira de expandir o estudo para abranger uma escala maior, possibilitando sua replicação em outros semáforos e regiões. Essas iniciativas visam contribuir para a melhoria da coordenação e otimização do tráfego urbano, fundamentadas em tecnologias estáveis e confiáveis, visando garantir a segurança de todos os usuários em ambientes urbanos de tráfego intenso.

4.1 RESULTADOS OBTIDOS E PERFORMANCE DAS REDES NEURAIS

Neste artigo, são apresentados os resultados obtidos através da análise de dados gerados por vídeos com a utilização de uma rede neural treinada. Os resultados apresentam a taxa de eficiência do sistema desenvolvido, juntamente com uma visão macro de pontos que podem ser desenvolvidos para uma maior abrangência no atendimento do problema principal.

4.1.1 Resultados Obtidos - Rede Neural de Identificação e Localização de Veículos

Abaixo, na tabela 1, são apresentados os resultados conforme a tabela gerada pelo treinamento da rede neural de identificação e localização de veículos. Para compreender os resultados obtidos, a matriz e suas informações foram separadas em 5 grupos, dessa forma conseguimos explicar de uma melhor forma os resultados retornados e exibidos pela rede neural.

Tabela 1 - Resultado - Rede Neural de Veículos

Recurso	Encontrados	Treinados	Marcados	Recall	Precisão	F-Score
Carro	12084	3714	7522	97%	100%	98,5%
Moto	665	321	672	99,15%	100%	99,57%
Ônibus	1004	479	967	98,2%	100%	99,07%
Caminhão	22	12	25	69,2%	100%	81,8%
Total	13776	4526	9186	97,2%	100%	98,6%

Fonte: O Autor¹, 2023

A tabela acima representa a acurácia da rede neural em identificar veículos, onde Recurso representa as opções de veículos em que a rede pode encontrar na imagem. Encontrados representam quantos de cada recurso foram encontrados nas imagens, Treinados é respectivo a quantas imagens foram usadas para treinar a rede neural conforme cada recurso, e Marcados representam quantos recursos foram marcados nas imagens para a rede neural fazer a identificação.

Por fim estão descritas as métricas de acurácia da rede neural, onde o Recall representa a precisão da rede em encontrar veículos marcados nas imagens, a Precisão representa a precisão da rede em encontrar veículos que não foram marcado nas imagens, e por fim, o F-Score representa a média entre Recall e Precisão e dessa forma é considerada como precisão geral da rede em identificar veículos nas imagens.

4.1.2 Resultados Obtidos - Rede Neural de Identificação e Localização de Pedestres

Abaixo, na tabela 2, são apresentados os resultados conforme a tabela gerada pelo treinamento da rede neural de identificação e localização de pedestres. Para compreender os resultados obtidos, a matriz e suas informações foram separadas em 5 grupos, dessa forma conseguimos explicar de uma melhor forma os resultados retornados e exibidos pela rede neural.

Tabela 2 - Resultado - Rede Neural de Pedestres

Recurso	Encontrados	Treinados	Marcados	Recall	Precisão	F-Score
Cima	9138	2543	6728	97,5%	97,9%	97,7%
Faixa	9177	287	2329	97,2%	97,6%	97,4%
Baixo	13106	597	1195	97,3%	99,32%	98,3%
Total	31421	3427	10252	97,3%	98,3%	97,8%

Fonte: O Autor¹, 2023

As premissas para avaliar a tabela de resultados da rede neural é o mesmo descrito anteriormente no fim do capítulo 4.1.1. Onde a principal métrica de avaliação é o F-Score gerado pela rede neural artificial.

4.1.3 Resultados Gerais

Abaixo a tabela 3 considerando o resultado geral obtido com os treinos realizados para identificação de pedestres e veículos no local escolhido.

Tabela 3 - Resultado Geral - Redes Neurais


Rede Neural	Recall	Precision	F-Score
Veículos	97,2%	100%	98,6%
Pedestres	97,3%	98,3%	97,8%
Total	97,25%	99,15%	98,2%

Fonte: O Autor¹, 2023

Portanto, o sistema desenvolvido teve acurácia de 98,2% em identificar pedestres e veículos nas imagens do local analisado.

4.1.4 Arquitetura Final de Processamento de Imagens

A Figura 9 abaixo representa a arquitetura final do sistema de identificação construído. Os blocos em cinza à direita na imagem representam cada saída da rede neural, correspondendo à localização de um pedestre na calçada ou faixa, ou de um carro no semáforo, além da contagem de quantos estão presentes em cada imagem.

Figura 9 - Arquitetura Final

Fonte: O Autor¹, 2023

5. CONSIDERAÇÕES FINAIS

Os testes obtiveram resultados satisfatórios, com uma acurácia geral de aproximadamente 98%. As redes neurais artificiais apresentadas foram treinadas com um banco de imagens geradas a partir de uma fonte real que ofereceu condições reais para o treinamento e para os testes e estudos gerados.

A problemática do alto índice de fluxo intenso urbano, engarrafamentos e congestionamentos excessivos levaram à consideração de um sistema que pode ser usado e implementado como um auxiliar, de forma automática, em semáforos, identificando e enviando sinais que representam a quantidade de pedestres ou de veículos aguardando os seus respectivos semáforos abrirem, com uma gestão eficiente para que o problema em questão possa ser combatido e amenizado de forma rápida e em grande volume.

Portanto, foi desenvolvido um sistema robusto e confiável para auxiliar o sistema de trânsito sem a geração de consequências negativas no fluxo do trânsito. O intuito do estudo e aplicação desenvolvida é para que possa ser utilizada como um aditivo ao semáforo convencional, onde, através da implementação junto do semáforo que já conhecemos, possa ser usada conforme a necessidade em qualquer momento do dia que for necessária sua utilização.

Com a utilização de um volume maior de dados, se tornaria possível, também, o treinamento da rede neural para a identificação de veículos de alto grau de prioridade nas vias, tais como viaturas, ambulâncias e demais veículos de acionamento emergencial, e com estas informações um sistema pode fazer o processamento das informações para tomar decisões da gestão do fluxo, como por exemplo, decidir quando fechar um semáforo com base na quantidade de pessoas aguardando a travessia e o número de carros que estão atravessando o semáforo em um determinado período de tempo. Outra possibilidade é a de calcular o volume do fluxo de veículos em determinado direcionamento e realizar uma compensação nos tempos de ciclo dos semáforos para que haja um intervalo de tempo com sinal verde maior nos sentidos mais demandados.

O intuito do estudo não seria desenvolver um novo modelo de semáforo, e sim realizar o estudo de viabilidade de um agente auxiliar para os semáforos já existentes, onde o sistema de Deep Learning teria como função principal ajudar os semáforos a otimizarem os seus tempos de funcionamento conforme o fluxo atual, garantindo e assegurando, além de tudo, a segurança das pessoas que seriam influenciadas pelos resultados obtidos através da inteligência artificial.

Por fim, o estudo serviu para demonstrar a capacidade de introdução de novas tecnologias no meio urbano, garantindo vantagens antes praticamente inexistentes, que podem ser obtidas através de um investimento relativamente baixo, tendo em vista que a demanda por capacidade de processamento das imagens é baixa, algo próximo a 10 milissegundos, e que em uma grande maioria dos casos os recursos para obtenção de imagens já são existentes, como câmeras de segurança e de monitoramento de cruzamentos e vias. E quando levado em consideração a eficiência do sistema que é responsável por gerar um input para um sistema de gerenciamento de trânsito, percebe-se que o resultado obtido é extremamente satisfatório e que atende as necessidades previstas. Além disso, o projeto não gera nenhum impacto ambiental e oferece um meio eficaz de implementar tecnologias para o desenvolvimento das cidades.

6. IMAGENS E FIGURAS EXTRAS

Abaixo estão disponíveis imagens referentes ao treinamento da rede neural e da aplicação desenvolvida para monitoramento do sistema de visão computacional.


6.1 IMAGENS DO RESULTADO DA REDE NEURAL TREINADA - VEÍCULOS

Figura 10 – Rede Neural Treinada - Veículos



Fonte: O Autor¹, 2023

Figura 11 – Rede Neural Treinada - Veículos



Fonte: O Autor¹, 2023

6.2 IMAGENS DO RESULTADO DA REDE NEURAL TREINADA - PEDESTRES

Figura 12 – Rede Neural Treinada - Pedestres




Fonte: O Autor¹, 2023

Figura 13 – Rede Neural Treinada - Pedestres



Fonte: O Autor¹, 2023


Figura 14 – Rede Neural Treinada - Pedestres



Fonte: O Autor¹, 2023


6.5 IMAGENS DA APLICAÇÃO COM INTERFACE DESENVOLVIDA PARA SIMULAÇÃO E VISUALIZAÇÃO DOS RESULTADOS

Figura 15 – Aplicação Desenvolvida - Funcionamento



Fonte: O Autor¹, 2023

Figura 16 – Aplicação Desenvolvida - Funcionamento



Fonte: O Autor¹, 2023

7. AGRADECIMENTOS

7.1 Agradecimentos Gustavo Prochnow - Autor¹

Primeiramente, agradeço à minha esposa Amanda Sayuri Fujino Prochnow pelo apoio incansável, paciência e inspiração constante ao longo desta jornada. Aos meus pais Jaime Prochnow e Sueli Buccio Prochnow, pelo amor incondicional e pelo suporte emocional que sempre me deram. Agradeço ao meu primo Daian Ramos, que considero como irmão, pelas diversas vezes em que me apoiou durante toda minha formação acadêmica.

Agradeço também pelo apoio de todos meus queridos amigos que me apoiaram e me influenciaram diariamente no decorrer desse trabalho, são eles: Bruno de Oliveira, Diego Senem, Henrique Parucker, Igor Soares e Lucas Ev.

Um agradecimento especial à minha professora Solange Alves Costa Andrade de Oliveira, cuja orientação, apoio e recomendação para que eu mantivesse essa temática como trabalho de conclusão de curso. Suas contribuições foram inestimáveis e moldaram significativamente o resultado final.

Também gostaria de estender minha gratidão à empresa Pollux Part of Accenture, em específico ao meu superior Marcos Almeida, pela generosa cessão dos materiais essenciais para a realização do trabalho apresentado. Sua colaboração foi fundamental para a concretização deste estudo.

A todos os mencionados e a tantos outros que de alguma forma contribuíram para este trabalho, meu sincero obrigado.

7.2 Agradecimentos Vinicius Berkembrock Marcon - Autor²

À minha noiva, Ana Paula, por seu apoio inabalável, paciência e compreensão ao longo deste período desafiador.

Aos meus pais, cujo apoio incansável e compreensão nos momentos desafiadores foram fundamentais para que eu pudesse me dedicar plenamente à realização deste trabalho acadêmico.

Aos professores que compartilharam seu conhecimento e orientação ao longo do curso, contribuindo significativamente para o meu crescimento profissional e para a concretização deste projeto.

Às pessoas que, de alguma forma, contribuíram com seus conselhos, discussões e incentivo durante esta jornada acadêmica.

7. REFERÊNCIAS

- [1] BBC, **THE MAN who gave us traffic lights: We must thank a Nottingham engineer for making drivers stop and go at busy road junctions**. Disponível em: <https://www.bbc.co.uk/nottingham/content/articles/2009/07/16/john_peake_knight_traffic_lights_feature.shtml>. Acesso em: 17 nov. 2023.
- [2] BURKOV, A. **The Hundred-Page Machine Learning Book**. Quebec City, Canada: <http://themlbook.com/>, 2019.
- [3] COGNEX, **Documentation about ViDi**, 2020. Disponível em: <https://support.cognex.com/docs/vidi_341/web/EN/vidisuite/Content/ViDi_Topics/0_GettingStarted/getstarted.htm> Acesso em: 20 nov. 2023.
- [4] COGNEX, **Documentation about Cognex Designer, 2023**. Disponível em: <https://support.cognex.com/docs/designer_443/web/EN/designer/Content/Designer_Topics/GettingStarted/getstarted.htm> Acesso em: 20 nov. 2023.
- [5] COSSETTI, Melissa Cruz – **O que é inteligência artificial?**: Disponível em: <<https://tecnoblog.net/263808/o-que-e-inteligencia-artificial/>> acesso em 15 nov. 2023.
- [6] DATA SCIENCE BRIGADE – **Diferença entre inteligência artificial, machine learning e deep learning**: 25 ago. 2016. Disponível em: <<https://medium.com/data-science-brigade/a-diferen%C3%A7a-entre-intelig%C3%Aancia-artificial-machine-learning-e-deep-learning-930b5cc2aa42>>. acesso em 16 nov. 2023.
- [7] DEEP AI – **Hidden Layer**: Disponível em: <<https://deepai.org/machine-learning-glossary-and-terms/hidden-layer-machine-learning#:~:text=In%20neural%20networks%2C%20a%20hidden,inputs%20entered%20into%20the%20network>> Acesso em 14 nov. 2020. acesso em 17 nov. 2023.
- [8] FERREIRA, L. S.; CUNTO, F. J. C. **Método de subtração de fundo para detecção veicular em condições de tráfego interrompido**. 32 Congresso de Pesquisa e Ensino em Transporte ANPET, 2018.
- [9] FILHO, O. M.; NETO, H. V. **Processamento Digital de Imagens**. Rio de Janeiro, RJ: Brasport, 1999.
- [10] GARDNER, Andrew. **A Brief History of Traffic Lights**. Disponível em: <<https://www.artsy.net/article/artsy-editorial-history-traffic-lights>>. Acesso em: 17 nov. 2023.

[11] GONZALES, R. C.; WOODS, R. E. **Digital Image Processing**. University of Tennessee: Pearson, 2018.

[12] LENZ, Geanderson – **Qual a diferença entre machine learning e deep learning?**: 24 mai. 2020. Disponível em: <<https://medium.com/drafter-ai/qual-a-diferen%C3%A7a-entre-machine-learning-e-deep-learning-31720b069183>>. acesso em 17 nov. 2023.

[13] MALIK, Farhad – **What are hidden layers?**: 20 may.2019. Disponível em: <<https://medium.com/fintechexplained/what-are-hidden-layers-4f54f7328263>>.

[14] MEDIUM, **Entendendo Redes Convolucionais (CNNs)**. Disponível em: <<https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>>. Acesso em: 24/11/2023

[15] NAQA, I. E.; MURPHY, M. J. **What is machine learning? Machine Learning in Radiation Oncology**, 2015

[16] NIELSEN, M. **Neural Networks and Deep Learning**. [s.n.], 2019. Disponível em: <Neural networks and deep learning> Acesso em: 17 nov. 2023.

[17] PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. [S.I.]: Editora Thomson Learning Edições Ltda, 2007.

[18] RESEARCHGATE, **Representação de um neurônio artificial**. Disponível em: <https://www.researchgate.net/figure/Representacao-de-um-neuronio-artificial_fig3_264735169>. Acesso em: 24/11/2023

[19] ROSEBROCK, A. **Deep Learning for Computer Vision**. pyimagesearch.com: Pyimagesearch, 2017.

[20] SANTANA, Marlesson – **Deep learning, do conceito às aplicações**. 19 jul. 2018. Disponível em: <<https://medium.com/data-hackers/deep-learning-do-conceito-%C3%A0s-aplica%C3%A7%C3%B5es-e8e91a7c7eaf>>. acesso em 16 nov. 2023.

[21] SAS – **Deep learning, o que é e qual sua importância?**. Disponível em: <https://www.sas.com/pt_br/insights/analytics/deep-learning.html>acesso em 15 nov. 2023.