

12º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2021

CONSTRUÇÃO DE UM AMBIENTE VIRTUAL PARA SIMULAÇÃO DE VEÍCULOS AUTÔNOMOS

MARCEL FERNANDES DE MATTOS¹, FABIANO GONZAGA FUMES²

¹ Graduando em Bacharelado de Ciências da Computação, Bolsista PIBIFSP, IFSP, Câmpus Salto, mattos.m@aluno.ifsp.edu.br

² Docente IFSP, Câmpus Salto, fabiano.fumes@ifsp.edu.br

Área de conhecimento (Tabela CNPq): 1.03.00.00-7 Ciência da Computação

RESUMO: O setor de transportes atravessa um momento de grande transição, passando do modelo em que veículos são conduzidos por humanos para uma condução autônoma, em que as decisões são tomadas por meio de algoritmos de Inteligência Artificial (IA), que podem ter o controle total ou parcial dos veículos. Neste contexto, diversos esforços acadêmicos e produtivos vêm sendo realizados no sentido de aplicar estas novas técnicas de condução por meio de máquinas capazes de aprender, objetivando que as condições técnicas, éticas, de segurança e de viabilidade econômica possam ser atendidas. Os Sistemas Avançados de Assistência ao Condutor, conhecido pela sigla ADAS (*Advanced Driver Assistance Systems*) são projetados tendo como elemento fundamental os ambientes de simulação computacional, em que as respostas dos algoritmos, anteriormente à sua introdução em modelos reais, podem ser testadas de maneira rápida e sem riscos aos seres humanos. Este projeto, neste contexto, tem como objetivo a análise dos recursos atualmente disponíveis para simulação, bem como dos diversos paradigmas de IA. Além disso, faz parte do escopo a escolha de um ambiente de simulação e a implementação dos alguns dos modelos baseados em IA de veículos autônomos.

PALAVRAS-CHAVE: simulação; veículo autônomo; redes neurais; inteligência artificial; aprendizado de máquina.

CONSTRUCTION OF A VIRTUAL ENVIRONMENT FOR SIMULATION OF AUTONOMOUS VEHICLES

ABSTRACT: Transport sector is going through a moment of great transition, from the model in which vehicles are driven by humans to autonomous driving, in which decisions are made through Artificial Intelligence (AI) algorithms, having full or partial control of the vehicle. In this context, several academic and productive efforts have been made in order to apply these new driving techniques through machines capable of learning, aiming that the technical, ethical, safety and economic viability conditions can be met. The Advanced Driver Assistance Systems, known by the acronym ADAS are designed with computer simulation environments as a fundamental element, in which the responses of algorithms, prior to their introduction into real models, can be tested in a fast way and without risk to human beings. This project, in this context, aims to analyze the resources currently available for simulation, as well as the different AI paradigms. In addition, the choice of a simulation environment and the implementation of some of the AI-based models of autonomous vehicles is part of the scope.

KEYWORDS: simulation; autonomous vehicle; neural networks; artificial intelligence; machine learning.

INTRODUÇÃO

O uso das tecnologias de inteligência artificial (IA) já estão totalmente inseridas em nosso dia-a-dia, com o intuito de facilitar e modernizar tanto os afazeres diários como atividades complexas e perigosas para os seres humanos. Um dos campos que se destaca como objeto de aplicação das IAs são os meios de transportes, como por exemplo aviões, que são programados para seguir o percurso estabelecido e se adaptar às mudanças sofridas durante a viagem, requerendo pouca atenção do piloto para certas atividades, como explica BUTTON (2019). Outro exemplo de destaque é dado pelos veículos autônomos, capazes de levar passageiros a seus destinos, sem qualquer intervenção de um motorista, ou seja, o próprio carro é capaz de controlar suas ações e tomar todas as decisões referentes ao trânsito em que está inserido (DAVIES, 2018), transformando a maneira como vivemos, trabalhamos e nos divertimos, criando estradas mais seguras e eficientes como dita o site da NVIDIA (2015).

Para treinar uma IA com capacidade de direção semelhante a um ser humano, seria necessário coletar dados de uma frota com 100 carros autônomos dirigindo ininterrupta por mais de 500 anos a 40 quilômetros por hora (KOUL, 2019). Como isso é impraticável e custoso, devemos realizar esses testes por meio de softwares de simulação aonde podemos refinar essas tecnologias até se tornarem seguras para aplicá-las em modelos reais.

O projeto visa empregar um ambiente virtual de simulação de veículos para testar algoritmos de reconhecimento de imagem e redes neurais, estudar as diferenças entre as tecnologias utilizadas e os benefícios que elas trazem consigo para futura aplicação em modelos de pequena escala.

MATERIAL E MÉTODOS

Realizamos uma busca pelos métodos que os veículos autônomos são treinados e encontramos uma ampla variedade de softwares com objetivos de treinar carros, testar dispositivos de detecção e recriar ambientes com variáveis modificáveis como clima, obstáculos no caminho e sinalização. Com isso conseguimos classificar os simuladores encontrados em dois tipos: os com enfoque em direção e controle do carro, e os com foco na manutenção de instrumentos de detecção como o LiDAR (Light Detection and Ranging). Os simuladores para direção são relativamente mais simples, possuindo uma pista podendo ter obstáculos para treinar a direção do veículo, enquanto simuladores de instrumentos buscam simular o funcionamento de suas ferramentas da maneira mais realista possível para garantir a leitura de seus arredores como sinalização e outros veículos com precisão.

Para o escopo do trabalho, buscamos um simulador simples para treinamento em uma pista sem obstáculos, o *Udacity AV Simulator* foi o que melhor atendeu os requisitos com sua estrutura de veículo único em pista fechada. Nele há uma seleção entre dois modos básicos: o primeiro é um treino com condução manual, em que se dá a captura de imagens a serem processadas, isso foi um grande fator para sua escolha pois agiliza o processo de coleta de imagens; o segundo modo é ambiente de testes de condução autônoma, para aplicação dos algoritmos desenvolvidos a partir de técnicas de IA alimentadas pelas informações provenientes do modo manual. O ambiente conta, durante a condução manual, com funções nativas de captura de imagens e o respectivo ângulo de rotação das rodas, de forma a ser possível a correlação entre qual lado o carro está se direcionando e sua respectiva imagem, possibilitando um treinamento por redes neurais.

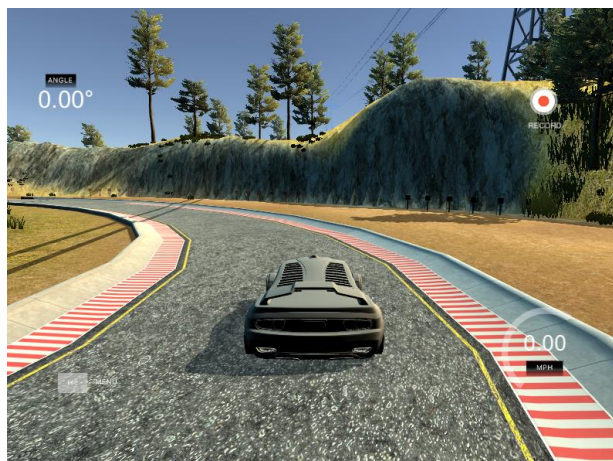


FIGURA 1. Ambiente de treinamento Udacity AV Simulator, com a opção de gravação das imagens ao canto superior direito

Foi utilizada uma função embutida no simulador da *Udacity* para gravar o carro manualmente percorrendo a pista de teste por algumas voltas, a fim de gerar imagens que seriam utilizadas de treinamento do modelo. São então utilizados, via tutorial pelo canal MURTAZA'S WORKSHOP (2020), códigos em Python que utilizam bibliotecas como *OpenCV*, *Tensorflow* e *Keras* para gerar e treinar redes neurais convolucionais, cujo resultado é a geração dos modelos de resposta do veículo para serem aplicados de volta no simulador.

Devido à maioria das imagens gravadas serem durante a condução em linha reta, deve ser feito um tratamento preliminar para a retirada do excesso de dados repetitivos para que o treinamento possa contar com uma gama mais confiável de respostas. Isto porque o excesso de exemplos cuja ação é manter-se em frente pode criar um viés no treinamento, fazendo com que ele decore o ato de seguir reto ao encontrar curvas e consequentemente podendo sair da pista. Desta forma é criada uma função especializada que analisa o ângulo das rodas e, se elas estiverem próximas de -1 ou 1, elas estão voltadas respectivamente a esquerda ou direita, e se for próxima de 0 elas se mantem retas. Assim o código busca os valores próximos de 0 e retira uma parte deste conjunto a partir de determinado valor de corte.




FIGURA 2. Gráfico inicial à esquerda demonstrando quantidade de imagens por ângulo das rodas, gráfico final a direita após a remoção de imagens.

Ainda como tratamento de imagens, são aplicadas edições em um processo denominado *Data Augmentation*, que consiste em gerar imagens mais variadas de acordo com o que já foi capturado para aumentarmos a sua diversidade e treinar para casos como luminosidade baixa ou visão reduzida. São aleatoriamente aplicados 4 efeitos: alteração no brilho, zoom, deslocamento da imagem e espelhamento. Se este último ocorrer são alterados os ângulos das rodas, pois o sentido da pista será alterado.




FIGURA 3. Exemplo de edição aplicada em uma imagem

Para o processo de treinamento na rede neural são definidos os tamanhos dos lotes de treinamento e validação (em que são as imagens analisadas pela rede neural e processadas de forma a entender a direção que o carro está tomando) a quantidade de épocas de treinamento (i.e., as rodadas de treinamento dos lotes na rede neural) e as funções de ativações, que são funções matemáticas que determinam a ativação de neurônio da rede neural. Ao serem processados esses dados durante o treinamento, resulta-se um valor chamado *loss* indicando o erro entre a ação prevista pelo algoritmo e a resposta correta do banco de imagens original. Quanto menor o valor deste erro, mais precisa a rede neural se torna em tomar as decisões corretas para determinadas situações.

RESULTADOS E DISCUSSÃO

Foram iniciados os primeiros testes com um lote de captura com cerca de 25 mil imagens, o que equivalem a 3 voltas em ambos os sentidos no modo de treinamento, e com a função de ativação ELU (*Exponential Linear Unit*), os primeiros 3 testes não tiveram bons resultados e o 4º gerou um veículo com tendência a se desviar à esquerda a todo momento, embora completando o percurso.




FIGURA 4. Gráfico de perda dos primeiros testes por época

Com as tentativas do primeiro lote de captura tendo alguns problemas de direção foi gravado um segundo lote com 46 mil imagens e se comportou melhor diante dos diferentes testes, sendo o 6º teste aplicado com 600 passos de teste e validação com 10 épocas o melhor modelo feito com poucos problemas de controle na pista, mas o 7º teste teve apenas a adição de 10 épocas e isso gerou um caso de *overfitting*, onde houve tantos exemplos que pequenos erros de interpretação podem causar uma grande alteração no modelo de testes, como explicado por GÉRON (2019).




FIGURA 5. Gráficos demonstrando a diferença entre o teste 6 (esquerda) e teste 7 (direita)

Após adquirir um modelo estável, foi possível testar outras funções de ativação nas redes neurais com as mesmas especificações do 6º teste. A primeira foi a ReLU (*Rectified Linear Units*) que gerou valores de *loss* menores, porém quando aplicada no simulador, notaram-se erros e colisões no meio da pista. Em seguida utilizou-se Tanh (Tangente Hiperbólica) que resultou num gráfico semelhante, mas com um desempenho muito melhor podendo completar o percurso com poucas instâncias de desvios para os lados.




FIGURA 6. Gráficos demonstrando a diferença entre a função ReLU (esquerda) e Tanh (direita)

CONCLUSÕES

O veículo conseguiu se locomover com o devido treinamento, mas é evidenciado que o refinamento dos parâmetros é essencial para seu avanço, tomando cuidado com os casos de *overfitting*. A busca por uma função de ativação ótima também deve ser feita a fim de encontrar um modelo que leia as imagens de teste com maior facilidade e clareza. Assim se estabelece a necessidade de mais testes para aprimorar o software desenvolvido, com a intenção de futuramente aplicar um modelo funcional em um protótipo com escala reduzida e iniciar testes de reconhecimento de imagem em situações reais.

AGRADECIMENTOS

Os autores agradecem ao IFSP pela bolsa PIBIFSP, através do edital 026/2020.

REFERÊNCIAS

BUTTON, Keith. **A.I. in the cockpit**. Disponível em: <<https://aerospaceamerica.aiaa.org/features/a-i-in-the-cockpit/>>. Acesso em 22 de ago. de 2021.

DAVIES, Alex. **The WIRED Guide to Self-Driving Cars**. Disponível em: <<https://www.wired.com/story/guide-self-driving-cars/>>. Acesso em 22 de ago. de 2021.

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2 ed. California: O'Reilly Media, 2019.

KOUL, Anirudh; GANJU, Siddha; KASAM, Meher. **Practical Deep Learning for Cloud, Mobile & Edge: Real-World AI & Computer-Vision Projects Using Python, Keras & TensorFlow**. California: O'Reilly Media, 2019.

MURTAZA'S WORKSHOP. **CV Zone: Self Driving Simulation using NVIDIA's Model**. Disponível em: <<https://www.computervision.zone/courses/self-driving-simulation-using-nvidias-model/>>. Acesso em: 22 de ago. de 2021.

NVIDIA. **NVIDIA Automotiva**. Disponível em: <<https://www.nvidia.com/pt-br/self-driving-cars/>>. Acesso em: 13 de out. de 2021.