



SEI-SICITE 2021

Pesquisa e Extensão para um mundo em transformação

XI Seminário de Extensão e Inovação  
XXVI Seminário de Iniciação Científica e Tecnológica  
08 a 12 de Novembro - Guarapuava/PR



## Aprendizado de máquina em algoritmos de seguidores de linha competitivos

### Machine learning in algorithms for competitive line-followers

**Rafael Farias Meneses**

[rafaelfariasm@live.com](mailto:rafaelfariasm@live.com)

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

**Fábio Rizental Coutinho**

[fabiocoutinho@utfpr.edu.br](mailto:fabiocoutinho@utfpr.edu.br)

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

#### RESUMO

Vista a inércia do atual Estado da técnica do desenvolvimento de seguidores de linha, e o crescente entusiasmo da comunidade perante a implementação de novas tecnologias, este trabalho apresenta a utilização de aprendizado de máquina no desenvolvimento de algoritmos para robôs seguidores de linha objetivando a participação em eventos de competição de robótica. A aplicação realizada neste estudo permitiu a criação de um modelo de inteligência artificial capaz de completar tarefas às quais os robôs atuais estão aptos a executar, entretanto, com uma mínima necessidade de interferência humana no processo de configuração e ajuste. O modelo criado neste trabalho foi treinado em um ambiente simulado, onde o Agente teve como objetivo a otimização do trajeto do robô seguidor de linha em circuitos competitivos. Através de tal implementação foi possível provar a sua viabilidade em relação aos métodos presentes de desenvolvimento, dado o menor tempo necessário para efetivação do algoritmo uma vez que o modelo esteja treinado.

**PALAVRAS-CHAVE:** Aprendizado de máquina. Robô. Seguidor de linha.

#### ABSTRACT

Given the inertia of the current state of the art in the development of line followers, and the growing community enthusiasm for the implementation of new technologies, this paper presents the use of machine learning in the development of algorithms for line following robots aiming to participate in competitions of robotics. The application carried out in this study allowed the creation of an artificial intelligence model capable of completing tasks that current robots are able to perform, however, with a minimum need for human interference in the configuration and adjustment process. The model created in this work was trained in a simulated environment, where the Agent aimed to optimize the path of the line follower robot in competitive circuits. Through such implementation, it was possible to prove its viability in relation to the present development methods, given the lesser time needed to implement the algorithm once the model is trained.

**KEYWORDS:** Machine learning. Robot. Line follower.



## INTRODUÇÃO

As competições de robôs seguidores de linha é vista por muitos como o método de entrada de crianças e adultos no meio das competições de robótica, devido à facilidade de compreensão das regras e criação do equipamento para participação, porém, ainda assim possuindo um limite superior de complexidade extremamente alto, proporcionando desafios para equipes e indivíduos iniciantes e avançados. Desafios que foram utilizados por Gomes *et al.* (2020) como forma de introduzir alunos do ensino médio à robótica. Segundo Santos *et al.* (2020), a modalidade de competição de seguidor de linha teve a segunda maior procura durante o evento de robótica Robotarena.

O processo atual de criação de inteligências artificiais para robôs seguidores de linha competitivos requer um alto gasto de recursos devido a necessidade de ajustes para alcançar resultados eficientes e satisfatórios, um método consolidado e que cumpre as tarefas designadas. Entretanto, o crescimento da complexidade das ações a serem executadas é constante. Visto a oportunidade de aplicação de um método novo em um meio relativamente estagnado a motivação do presente artigo foi identificada. O uso de aprendizado de máquina para a criação da Inteligência artificial dos robôs, uma tecnologia inovativa que cativa a curiosidade de muitos e neste contexto aplicada de forma tangível e com efeitos perceptíveis. Este trabalho busca desmistificar e mostrar a possibilidade do uso dessa tecnologia nas competições.

## MATERIAIS E MÉTODOS

Este trabalho é constituído por dois componentes principais, sendo eles um ambiente para simulação e um algoritmo de treino. Para simulação foi utilizado o motor de jogos Unity3d (FAROUK; GWENDAL; ADLEN, 2015) juntamente com o ML-Agents, conforme Juliani *et al.* (2020), que se trata de um kit de ferramentas que possibilita a implementação de algoritmos de aprendizagem dentro de ambientes do Unity3d provindo também uma série de benchmarks. O processo de treino foi realizado através do PyTorch, uma biblioteca de aprendizado de máquina em Python que suporta código como modelo, facilita a depuração, encapsula outras bibliotecas modernas para computação científica e suporta aceleração por hardware (PASZKE *et al.*, 2019).

A execução do treino pode ser dividida em duas partes, sendo elas o Modelo, também chamado de Agente ou Cérebro, o qual será implementado no equipamento, e a Escola, classe que tem a finalidade de treinar o modelo. Foi utilizado o método de aprendizado por reforço e a seguir serão descritas as ações efetuadas pela Escola durante o processo de treino de um Cérebro.

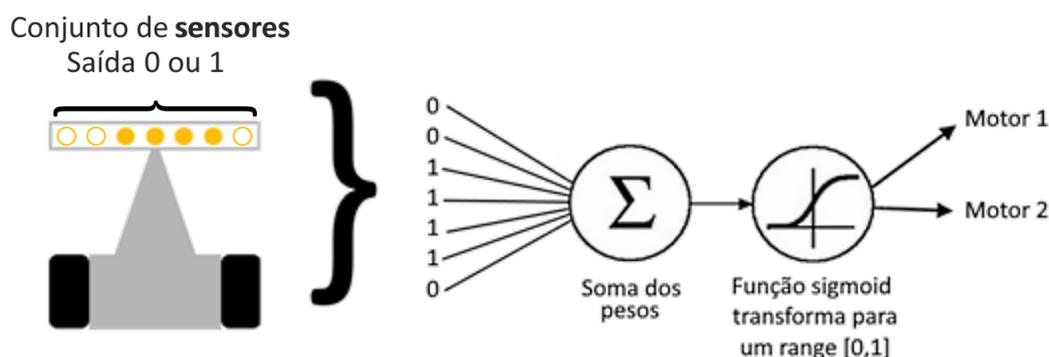
As ações tomadas pelo Modelo se baseiam em Pesos, estes servem para influenciar funções que recebem como entrada o valor dos sensores do robô. A Escola tem o trabalho de modificar esses pesos para um valor que resulte numa operação eficiente. Durante o processo de aprendizado são atribuídos pontos para determinadas ações, dessa forma a Escola pode determinar o desempenho dos Agentes, ao fim de cada geração a Escola tem o papel de selecionar os melhores modelos e levá-los para a próxima geração, onde serão modificados em busca de um aprimoramento de seu desempenho.

Neste trabalho o modelo foi aplicado em um robô seguidor de linha para competições de robótica, nesses eventos os robôs são colocados em um circuito pré-definido e o participante que completá-lo em menor tempo é declarado vencedor. Através do motor de jogos Unity3D foi criado um ambiente para

simulação condizente com o real, o robô tem as suas ações definidas a partir do estado de seus sensores, onde após passar pelo Modelo resultará em valores a serem executados pelos motores.

A Figura 1 apresenta um diagrama simplificado do funcionamento do sistema, o qual é composto por sensores, modelo do cérebro e motores.

Figura 1 – Diagrama de funcionamento



Fonte: Autoria própria (2021).

O cérebro implementado é composto por:

- 1x Camada de entrada com 7 valores de verdadeiro ou falso.
- 3x Camadas de Pesos, esses Pesos são matrizes que são multiplicadas ao valor de entrada.
- 2x Camadas escondidas, essas camadas possuem a função de transformar o valor em um resultado contínuo entre 0 e 1, foram utilizadas funções sigmóide para esse projeto.
- 1x Camada de operações, operações básicas para transformar o resultado em um número que faça sentido para a aplicação.
- 1x Camada de saída com 2 valores contínuos que estão diretamente ligados aos motores

O treinamento foi executado em um ambiente virtual a uma taxa de simulação de 3x com 9 instâncias diferentes. Foram realizados 3 treinos no qual a inteligência artificial teve a oportunidade de treinar com pistas com diferentes características, os tempos de treino podem ser observados na Tabela 1.

Tabela 1 – Tempo de treino

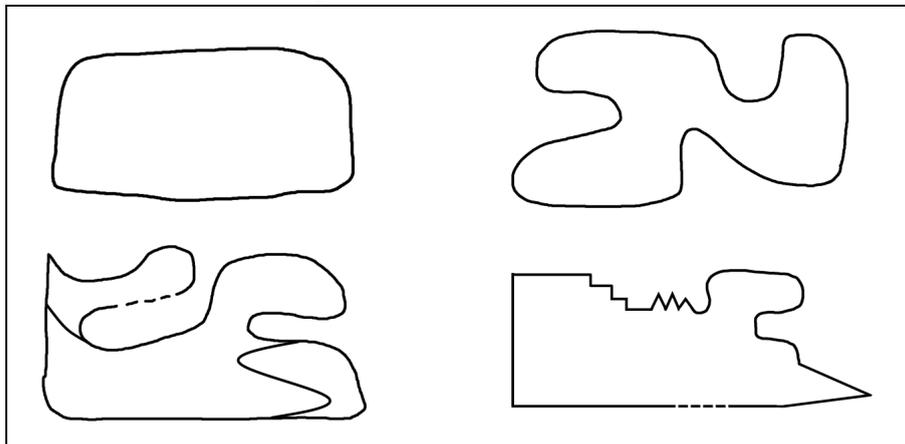
Versão	Tempo real (min)	Tempo simulado (min)
Treino 1	7	189
Treino 2	12	324
Treino 3	58	1566
<b>Total</b>	<b>77</b>	<b>2079</b>

Fonte: Autoria própria (2021).



O modelo foi testado nas pistas apresentadas na Figura 2, as quais serviram para ensinar características diferentes para a Inteligência artificial. Ao fim dos testes o modelo possuía uma taxa de sucesso de 98% nas pistas iniciais e de 81% nas pistas com maior complexidade, valor que pode ser otimizado com mais tempo para treinamento.

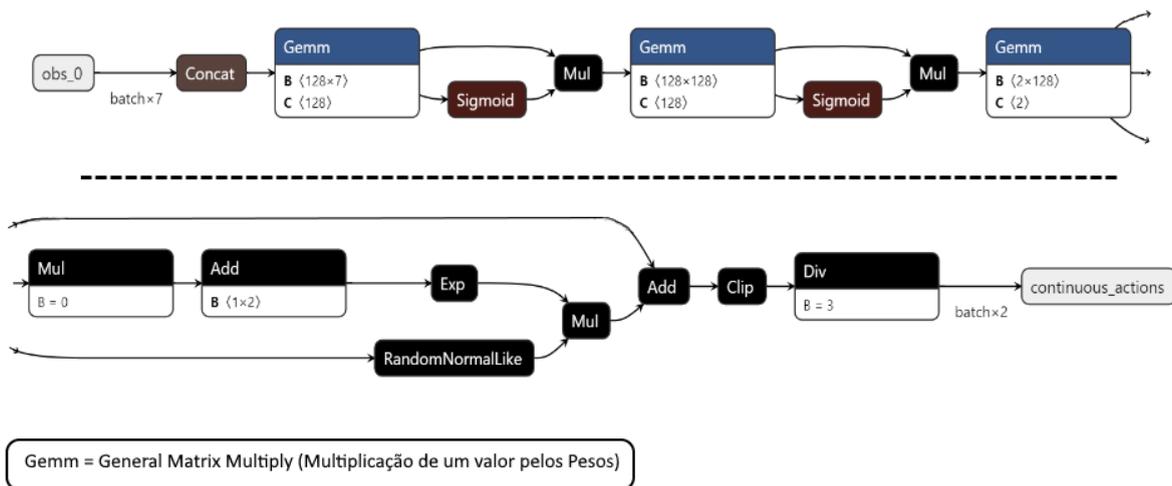
Figura 2 – Circuitos para treino



Fonte: Autoria própria (2021).

A Figura 3 mostra uma representação real dos operadores presentes no modelo, o formato desses é definido pelo ONNX (Open Neural Network Exchange), um ecossistema aberto que provê um formato de código livre para formatação de modelos de inteligência artificial, o que possibilita a implementação do modelo em diferentes tipos de plataformas e hardwares (SHRIDHAR; TOMSON; INNES, 2019).

Figura 3 – Modelo do cérebro implementado

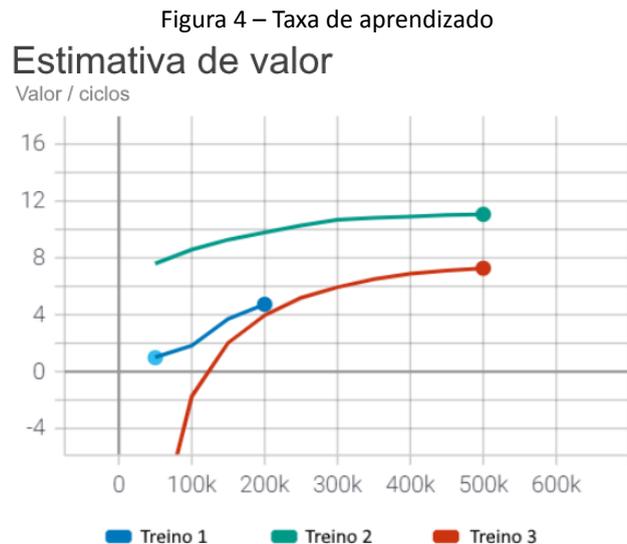


Fonte: Autoria própria (2021).



## RESULTADOS E DISCUSSÕES

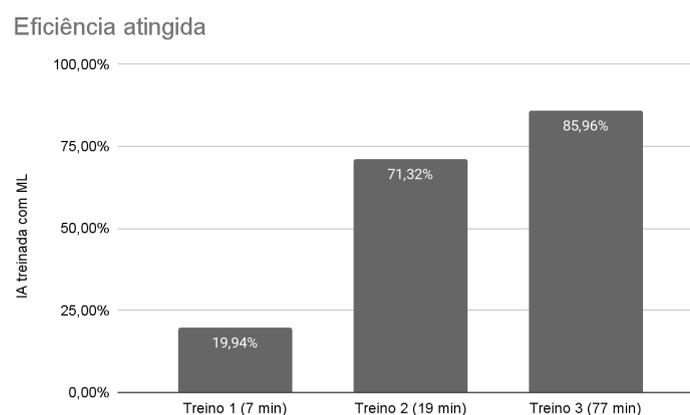
Os resultados coletados são relativos à performance do modelo após 3 treinos com tempo real total de aprendizado de 77 minutos, a Figura 4 representa a taxa de aprendizado da inteligência artificial, pode-se notar a desaceleração da taxa de aprendizado em relação ao número de ciclos.



Fonte: Autoria própria (2021).

A eficiência atingida pôde ser calculada através do tempo teórico mínimo dos circuitos e do tempo atingido pelo modelo, tal relação pode ser vista na Figura 5.

Figura 5 – Eficiência atingida por tempo de treino



Fonte: Autoria própria (2021).

A inteligência artificial foi capaz de aprender rapidamente a navegar os percursos de maneira eficiente, mesmo com o pouco tempo de treino, e a necessidade de interferência humana durante o processo de



SEI-SICITE 2021

Pesquisa e Extensão para um mundo em transformação

XI Seminário de Extensão e Inovação  
XXVI Seminário de Iniciação Científica e Tecnológica  
08 a 12 de Novembro - Guarapuava/PR



aprendizado foi basicamente nula, o que mostra a vantagem desse método em relação ao Estado da técnica atual.

## CONCLUSÃO

A implementação de aprendizado de máquina cativa o interesse de grande parte da comunidade científica e de robótica, através deste projeto pôde-se notar a viabilidade da aplicação, vendo que a eficiência do modelo possui espaço para aperfeiçoamento, melhora essa que pode ser executada sem necessidade de interferência por humanos. Sendo assim, com mais tempo de treino a inteligência artificial criada pode vir a se tornar competitiva, e com os benefícios criados pelo treino através de aprendizado de máquina.

O presente trabalho foi apresentado durante a Robotarena 2021.1, um evento efetuado de maneira totalmente online com o papel de difundir conhecimentos sobre robótica, não só com a comunidade estudantil, mas também com o público comum, a audiência do evento se mostrou atraída para com o método discutido neste artigo, exibindo curiosidade e empolgação em relação ao assunto, o que gerou comentários, perguntas e momentos de discussão.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Fundação Araucária por meio do Programa Institucional de Bolsas de Extensão Universitária (PIBEX).

## REFERÊNCIAS

GOMES, Eloí Lucas Amendola *et al.* Introdução à robótica para alunos do Centro da Juventude de Toledo-PR. In: SEMINÁRIO DE EXTENSÃO E INOVAÇÃO DA UTFPR, 10., 2020, Toledo. **Anais** [...]. Toledo, PR: [s. n.], 2020. Disponível em: <<https://eventos.utfpr.edu.br//sei/sei2020/paper/viewFile/7104/2653>>. Acesso em: 28 ago. 2021.

SANTOS, Lucas Freitas *et al.* Robotarena, um evento de competição de robótica. In: SEMINÁRIO DE EXTENSÃO E INOVAÇÃO DA UTFPR, 10., 2020, Toledo. **Anais** [...]. Toledo, PR: [s. n.], 2020. Disponível em: <<https://eventos.utfpr.edu.br//sei/sei2020/paper/viewFile/7007/2650>>. Acesso em: 28 ago. 2021.

JULIANI, Arthur *et al.* Unity: A General Platform for Intelligent Agents. **ArXiv**, San Francisco, CA, EUA, 2018. Disponível em: <<https://arxiv.org/pdf/1809.02627.pdf>>. Acesso em: 30 ago. 2021.

FAROUK , Messaoudi; GWENDAL , Simon; ADLEN, Ksentini. Dissecting games engines: The case of Unity3D. In: INTERNATIONAL WORKSHOP ON NETWORK AND SYSTEMS SUPPORT FOR GAMES, 2015, Zagreb, Croácia. **Anais** [...]. [S. l.: s. n.], 2015. p. 1-6. DOI 10.1109/NetGames.2015.7382990. Disponível em: <[https://www.researchgate.net/publication/295861816\\_Dissecting\\_Games\\_Engines\\_the\\_Case\\_of\\_Unity3D](https://www.researchgate.net/publication/295861816_Dissecting_Games_Engines_the_Case_of_Unity3D)>. Acesso em: 6 set. 2021.

PASZKE, Adam *et al.* PyTorch: An Imperative Style, High-Performance Deep Learning Library. In: NEURIPS, 33., 2019, Vancouver, Canadá. **Anais** [...]. Vancouver, Canada: Curran Associates, Inc., 2019. Disponível em:



SEI-SICITE 2021

Pesquisa e Extensão para um  
mundo em transformação

XI Seminário de Extensão e Inovação  
XXVI Seminário de Iniciação Científica e Tecnológica  
08 a 12 de Novembro - Guarapuava/PR



<<https://proceedings.neurips.cc/paper/2019/file/bdbca288fee7f92f2bfa9f7012727740-Paper.pdf>>. Acesso em: 30 ago. 2021.

SHRIDHAR , Ayush; TOMSON , Phil; INNES, Mike. Interoperating Deep Learning models with ONNX.jl. **The Open Journal**, Shridhar, Índia, v. 1, n. 1, 2020. DOI 10.21105/jcon.00059. Disponível em: <<https://proceedings.juliacon.org/papers/10.21105/jcon.00059#>>. Acesso em: 30 ago. 2021.