



Universidade Federal de Ouro Preto  
Escola de Minas  
CECAU - Colegiado do Curso de  
Engenharia de Controle e Automação



Larissa Lara de Lima Souza

## **Uso da Inteligência Artificial no Planejamento de Trajetórias**

Monografia de Graduação

Ouro Preto, 2023

Larissa Lara de Lima Souza

# **Uso da Inteligência Artificial no Planejamento de Trajetórias**

Trabalho apresentado ao Colegiado do Curso de Engenharia de Controle e Automação da Universidade Federal de Ouro Preto como parte dos requisitos para a obtenção do Grau de Engenheiro(a) de Controle e Automação.

Universidade Federal de Ouro Preto

Orientadora: Profa. Adrielle de Carvalho Santana

Ouro Preto

2023



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DE OURO PRETO  
REITORIA  
ESCOLA DE MINAS  
DEPARTAMENTO DE ENGENHARIA CONTROLE E  
AUTOMACAO



**FOLHA DE APROVAÇÃO**

**Larissa Lara de Lima Souza**

**Uso da Inteligência Artificial no Planejamento de Trajetórias**

Monografia apresentada ao Curso de Engenharia de Controle e Automação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de bacharel em Engenharia de Controle e Automação

Aprovada em 31 de Agosto de 2023

Membros da banca

Dra. Adrielle de Carvalho Santana - Orientadora (DECAT - Universidade Federal de Ouro Preto)

Dr. Danny Augusto Vieira Tonidandel - Examinador (DECAT - Universidade Federal de Ouro Preto)

Dra. Luciana Gomes Castanheira - Examinadora (DECAT - Universidade Federal de Ouro Preto)

Adrielle de Carvalho Santana, orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 31/08/2023



Documento assinado eletronicamente por **Adrielle de Carvalho Santana, PROFESSOR DE MAGISTERIO SUPERIOR**, em 31/08/2023, às 21:18, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0584250** e o código CRC **6069D9B1**.

# Agradecimentos

Agradeço primeiramente a Deus, por me dar a capacidade e não ter me deixado desanimar.

Aos meus professores, família e amigos pelo apoio.

A todas as pessoas que contribuíram para minha chegada até o presente momento, minha sincera gratidão.

*Não existe triunfo sem perda,  
não há vitória sem sofrimento,  
não há liberdade sem sacrifício.*

---

– J.R.R. Tolkien.

# Resumo

Este trabalho de conclusão de curso aborda o tema do uso da inteligência artificial no planejamento de trajetórias, explorando como algoritmos e técnicas de IA podem ser aplicados para otimizar a definição de trajetórias em diversas áreas, como robótica, engenharia, transporte autônomo, aviação, navegação e até mesmo em jogos de computadores. O estudo apresenta uma revisão das principais abordagens de IA utilizadas no planejamento de trajetórias, destacando suas vantagens, desafios e aplicações práticas. Além disso, são discutidos casos de sucesso e tendências futuras nesse campo, evidenciando o papel crucial da inteligência artificial no aprimoramento do planejamento de trajetórias.

**Palavras-chaves:** Inteligência Artificial, IA, planejamento de trajetórias e tempo real.

# Abstract

This undergraduate thesis addresses the topic of using artificial intelligence in trajectory planning, exploring how AI algorithms and techniques can be applied to optimize trajectory definition in various fields such as robotics, engineering, autonomous transportation, aviation, navigation, and even computer games. The study presents a review of the main AI approaches used in trajectory planning, highlighting their advantages, challenges, and practical applications. Furthermore, successful case studies and future trends in this field are discussed, showcasing the crucial role of artificial intelligence in enhancing trajectory planning.

**Key-words:** Artificial Intelligence, AI, trajectory planning and real-time.

# Lista de ilustrações

Figura 1 – Espaço de Configuração . . . . .	14
Figura 2 – Grafo de Busca do Algoritmo A* . . . . .	24
Figura 3 – Arquitetura RNN . . . . .	26
Figura 4 – Arquitetura CNN Iteração 1 . . . . .	27
Figura 5 – Arquitetura CNN Iteração 2 . . . . .	27
Figura 6 – Exemplo de Variável Linguística na lógica fuzzy . . . . .	29
Figura 7 – Comparação gráfica entre a lógica booleana (a) e lógica fuzzy (b) . . . . .	29
Figura 8 – Tipos de Funções de Pertinência . . . . .	30
Figura 9 – Regras e Inferência Fuzzy . . . . .	31
Figura 10 – Analogia PSO . . . . .	32



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>10</b>
<b>1.1</b>	<b>Objetivos</b>	<b>11</b>
1.1.1	Objetivos Gerais	11
1.1.2	Objetivos Específicos	11
<b>1.2</b>	<b>Justificativas e Relevância</b>	<b>11</b>
<b>1.3</b>	<b>Organização e estrutura</b>	<b>11</b>
<b>2</b>	<b>FUNDAMENTOS DO PLANEJAMENTO DE TRAJETÓRIA</b>	<b>13</b>
<b>2.1</b>	<b>Estado e Espaço de Configuração</b>	<b>13</b>
<b>2.2</b>	<b>Estados Inicial e Final</b>	<b>15</b>
<b>2.3</b>	<b>Caminho e Trajetória</b>	<b>15</b>
<b>2.4</b>	<b>Restrições</b>	<b>16</b>
<b>2.5</b>	<b>Crterios de Otimização</b>	<b>17</b>
<b>2.6</b>	<b>Evitar Colisões</b>	<b>18</b>
<b>2.7</b>	<b>Ambientes Dinâmicos vs. Estáticos</b>	<b>18</b>
<b>2.8</b>	<b>Planejamento de Caminho vs. Planejamento de Movimento</b>	<b>19</b>
<b>2.9</b>	<b>Planejamento Local vs. Global</b>	<b>20</b>
<b>2.10</b>	<b>Abordagens Baseadas em Amostragem</b>	<b>20</b>
<b>2.11</b>	<b>Controle Ótimo</b>	<b>21</b>
<b>2.12</b>	<b>Considerações em Tempo Real</b>	<b>22</b>
<b>3</b>	<b>ALGORITMOS DE INTELIGÊNCIA ARTIFICIAL NO PLANEJAMENTO DE TRAJETÓRIAS</b>	<b>23</b>
<b>3.1</b>	<b>Busca Heurística</b>	<b>23</b>
<b>3.2</b>	<b>Redes Neurais Artificiais</b>	<b>25</b>
<b>3.3</b>	<b>Algoritmos Genéticos</b>	<b>27</b>
<b>3.4</b>	<b>Lógica Fuzzy</b>	<b>28</b>
<b>3.5</b>	<b>Algoritmos de Otimização</b>	<b>31</b>
<b>3.6</b>	<b>Lógica Baseada em Regras</b>	<b>34</b>
<b>3.7</b>	<b>Aprendizado de Máquina por Reforço</b>	<b>34</b>
<b>3.8</b>	<b>Métodos de Planejamento Probabilístico</b>	<b>35</b>
<b>3.9</b>	<b>Lógica Temporal e <i>Model Checking</i></b>	<b>37</b>
<b>3.10</b>	<b>Sistemas Multiagentes</b>	<b>38</b>
<b>4</b>	<b>APLICAÇÕES</b>	<b>39</b>

5	<b>DESAFIOS E CONSIDERAÇÕES</b>	44
6	<b>TENDÊNCIAS FUTURAS</b>	46
7	<b>CONCLUSÕES</b>	47
7.1	<b>Trabalhos Futuros</b>	47
	<b>Referências</b>	49

# 1 Introdução

O planejamento de trajetória de objetos em movimento é um processo importante utilizado em diversas áreas, como robótica, engenharia, navegação e até mesmo em jogos de computador. Ele se refere ao processo de determinar uma sequência de posições, orientações e tempos que um objeto, veículo ou agente devem seguir para atingir determinado objetivo de maneira eficiente e segura.

Porém, o planejamento manual de trajetórias enfrenta diversos desafios devido à complexidade dos ambientes em que as trajetórias precisam ser definidas. Visualizar e analisar manualmente todas as possíveis trajetórias é difícil e propenso a erros, assim como considerar todas as restrições físicas, limitações de movimento, áreas proibidas, ambientes dinâmicos e outros fatores. Devido a esses desafios, a utilização de abordagens de inteligência artificial (IA) e técnicas de otimização têm se tornado cada vez mais importantes no planejamento de trajetórias. Com capacidades avançadas de análise, tomada de decisão e adaptação, elas podem lidar mais eficazmente com a complexidade e as restrições envolvidas em uma variedade de aplicações.

A essência da IA envolve a capacidade de máquinas aprenderem, computarem, tomarem decisões e resolverem problemas de maneira autônoma, simulando processos cognitivos humanos (RUSSELL; NORVIG, 2010). Para Russell e Norvig (2010) a Inteligência Artificial é o estudo de agentes que recebem percepções do ambiente e realizam ações. Esse campo tem ganhado um impulso significativo nos últimos anos devido aos avanços tecnológicos, à disponibilidade de dados massivos e ao aumento do poder computacional (ZENVIA, 2023).

É fato que, para alguns, o surgimento das IA's gera preocupações acerca do seu potencial impacto na sociedade e principalmente no mercado de trabalho e também levanta questões éticas, de privacidade e de segurança, uma vez que seu uso pode envolver a coleta e o processamento de grandes quantidades de dados pessoais. Ao mesmo tempo, a IA têm impulsionado avanços tecnológicos significativos na indústria 4.0, pois seu uso pode ser encontrado em variados setores, incluindo saúde, finanças, transporte, manufatura e entretenimento (MENDONÇA MÁRCIO, 2023) graças as suas diversas subáreas, como aprendizado de máquina, processamento de linguagem natural, visão computacional, robótica, raciocínio automatizado e representação de conhecimento (RUSSELL; NORVIG, 2010). Tendo em vista as preocupações legítimas relacionadas à ética, privacidade e impacto na sociedade, é importante que a implementação da IA seja cuidadosamente gerenciada para maximizar seus benefícios enquanto é usada de maneira responsável e segura.

Visto isso, este trabalho visa realizar um estudo do uso da Inteligência Artificial

aplicada ao planejamento de trajetórias e ao final identificar aplicações das técnicas mais utilizadas hoje em dia, além do desafio e tendências futuras dessa área em crescentes mudanças.

## 1.1 Objetivos

### 1.1.1 Objetivos Gerais

Este trabalho tem como objetivo geral investigar e analisar de que forma a inteligência artificial pode ser aplicada de maneira eficaz no planejamento de trajetórias em diversas áreas, visando aprimorar a eficiência, adaptabilidade e segurança desses processos.

### 1.1.2 Objetivos Específicos

- Analisar os Fundamentos do Planejamento de Trajetórias.
- Mapear algumas principais Abordagens de Inteligência Artificial no planejamento de trajetórias.
- Avaliar Casos de Aplicação.
- Analisar Desafios e Considerações.
- Explorar Tendências Futuras.

## 1.2 Justificativas e Relevância

A IA cria um campo de pesquisa empolgante dentro do planejamento de trajetória, pois capacita as máquinas a tomar decisões baseadas em informações sensoriais do ambiente, interagir fisicamente com ele e executar tarefas complexas de forma eficiente através do aprendizado de máquina.

A necessidade de enfrentar ambientes desconhecidos e de características variáveis levou ao desenvolvimento de estratégias de aprendizado, baseadas em regras e algoritmos de aprendizado de máquina. A aprendizagem de máquina permite que algoritmos sejam treinados com dados para identificar padrões, tomar decisões e realizar previsões.

Este trabalho busca explorar a interseção entre a IA e o planejamento de trajetórias, contribuindo no avanço do conhecimento na área de inteligência artificial.

## 1.3 Organização e estrutura

O trabalho está estruturado da seguinte forma:

- **Capítulo 1: Introdução** Este capítulo discute e introduz a importância da inteligência artificial no planejamento de trajetórias que, por sua vez, possui extrema relevância em diversas áreas. Além disso, apresenta os objetivos gerais e específicos do trabalho, além da justificativa e relevância de estudos dentro desse tema.
- **Capítulo 2: Fundamentos do Planejamento de Trajetória** Este capítulo explora os conceitos básicos do planejamento de trajetórias, abordando aspectos como estado e espaço de configuração, caminho e trajetória, restrições, critérios de otimização, entre outros. Isso estabelece a base para entender como a inteligência artificial pode ser integrada a esse contexto.
- **Capítulo 3: Algoritmos de Inteligência Artificial no Planejamento de Trajetórias** Neste capítulo, são apresentadas as principais abordagens de inteligência artificial utilizadas no planejamento de trajetórias. Isso inclui algoritmos de busca, como A\*, D\* e RRT (Rapidly-exploring Random Trees), assim como técnicas de aprendizado de máquina, como redes neurais e algoritmos genéticos. Cada abordagem é explicada em detalhes, destacando como ela é aplicada no contexto de planejamento de trajetórias.
- **Capítulo 4: Aplicações** Neste capítulo, são apresentadas revisões bibliográficas a respeito das aplicações práticas da utilização de inteligência artificial no planejamento de trajetórias.
- **Capítulo 5: Desafios e Considerações** Este capítulo aborda os desafios e algumas considerações associados ao uso da inteligência artificial no planejamento de trajetórias.
- **Capítulo 6: Tendências Futuras** Este capítulo aborda as principais tendências no planejamento de trajetórias que visam um futuro mais assertivo e eficiente para essa área de estudo.
- **Capítulo 7: Conclusões** Este capítulo conclui e avalia se os objetivos propostos foram cumpridos, além de propor trabalhos futuros que podem ser realizados na área de pesquisa apresentada.

## 2 Fundamentos do Planejamento de Trajetória

Segundo [Bellotto \(2008\)](#), planejamento de trajetórias envolve determinar um caminho viável para um objeto em movimento seguir do seu ponto de partida até o seu destino, levando em consideração várias restrições e objetivos. Aqui estão alguns conceitos básicos que fornecem uma base para entender as complexidades e desafios envolvidos no planejamento de trajetórias em várias aplicações e setores.

### 2.1 Estado e Espaço de Configuração

O Estado e Espaço de Configuração desempenham papéis fundamentais no planejamento de trajetórias, especialmente quando se trata da aplicação de algoritmos de inteligência artificial. Eles fornecem uma maneira de representar os diferentes estados possíveis de um sistema e o espaço em que esses estados estão localizados. O planejamento de trajetórias envolve navegar por esse espaço para alcançar o objetivo desejado. Definir esses conceitos é crucial porque eles fornecem uma maneira sistemática de modelar o sistema e os possíveis movimentos que ele pode executar.


Define-se “Estado” como “situação de algo ou alguém em determinado momento” ([ESTADO, 2023](#)). No contexto do planejamento de trajetórias, o estado representa a posição, orientação e outras variáveis relevantes que caracterizam o sistema em um determinado instante de tempo ([LAVALLE, 2006](#)).

O espaço de configuração é o conjunto de todos os estados possíveis que um sistema pode assumir ([ZARISKI, 1937](#)). É uma representação abstrata e multidimensional que define todos os parâmetros que caracterizam o sistema. No caso de um robô móvel, por exemplo, o espaço de configuração incluiria todas as possíveis combinações de coordenadas de posição e orientação que o robô poderia ocupar. E pode ser dividido em Espaço Livre (áreas livres de colisão e que não são ocupadas por obstáculos) e Caminho Livre (considera o caminho pertencente ao espaço livre e que não entra em contato com nenhum obstáculo, este, considerando as configurações, dimensões e propriedades do sistema) ([SOUZA, 2008](#)).

A figura 1 exemplifica a determinação do espaço de configuração, onde [Choset et al. \(2005\)](#) explica que:

“(a) O robô móvel circular se aproxima do obstáculo no espaço de trabalho. (b) Ao deslizar o robô móvel ao redor do obstáculo e acompanhando a curva traçada pelo ponto de referência, construímos o obstáculo no espaço de configuração.

Figura 1 – Espaço de Configuração



Fonte: [Choset et al. \(2005\)](#)

(c) O planejamento de movimento para o robô na representação do espaço de trabalho na (a) foi transformado em planejamento de movimento para um robô pontual no espaço de configuração.”

Os exemplos a seguir explicarão melhor o conceito de estado e espaço de configuração em diferentes contextos para o planejamento de trajetórias:

- **Robô Móvel em um Plano:** O estado de um robô móvel pode ser definido pelas coordenadas de sua posição ( $x, y$ ) no plano, bem como pela sua orientação (ângulo em relação a um eixo de referência) ([BEKEY, 2008](#)). Portanto, o estado do robô em um determinado momento inclui informações sobre onde ele está e para onde está apontando. Já para o espaço de configuração de um robô móvel em um plano, inclui-se todas as combinações de coordenadas ( $x, y$ ), abrangendo desde a posição inicial até a posição final, bem como todas as posições intermediárias.
- **Veículo Autônomo em um Ambiente Urbano:** No contexto de um veículo autônomo ([RODRIGUES, 2017](#)), o estado pode incluir informações como a posição GPS do veículo (latitude e longitude), sua velocidade atual, a direção em que está se movendo e a orientação em relação ao norte. Isso resulta em um espaço de configuração de várias dimensões. Essas informações são cruciais para determinar o estado atual do veículo e planejar sua trajetória futura.
- **Manipulador Robótico com Múltiplas Juntas:** Em um manipulador robótico industrial, o estado pode ser definido pelas posições articulares de cada junta do robô. Cada junta tem um ângulo específico que determina a configuração do robô e a dimensão no espaço de configuração em um momento dado ([CHOSSET et al., 2005](#)). Isso é crucial para garantir que o manipulador alcance uma posição desejada com precisão.

Em todos esses exemplos, o estado é uma representação detalhada das características relevantes do sistema em um determinado momento (LAVALLE, 2006). O Espaço de Configuração é uma representação abstrata que captura todas as possíveis configurações de um sistema (CHOSSET et al., 2005). Essas características podem variar amplamente dependendo do contexto, mas são fundamentais para entender e controlar o comportamento do sistema. No planejamento de trajetórias, a análise dos estados atuais e desejados, além do espaço de configuração permite que os algoritmos de inteligência artificial identifiquem as melhores sequências de estados para atingir um objetivo desejado de forma eficiente e segura.

## 2.2 Estados Inicial e Final

Os estados inicial e final são conceitos essenciais no planejamento de trajetórias e representam os estados em que um sistema começa e termina um determinado movimento ou tarefa. Eles são cruciais para a definição dos objetivos do planejamento e para determinar como o sistema deve se mover de um estado para outro (LAVALLE, 2006). O planejamento de trajetórias visa encontrar um caminho que conecte esses dois estados, satisfazendo as restrições.

Estes orientam os algoritmos de busca e otimização na determinação dos movimentos e ações necessárias para atingir o objetivo desejado de forma eficiente.

## 2.3 Caminho e Trajetória

Os termos “caminho” e “trajetória” são frequentemente usados em contexto de planejamento de movimento e navegação. Eles se referem a conceitos relacionados, mas distintos.

Um caminho é uma sequência de estados conectados que descreve a sequência de posições e movimentos que um sistema deve seguir para ir de um ponto inicial a um ponto final (LAVALLE, 2006). O caminho é uma representação idealizada do movimento, focando apenas nas posições intermediárias. Ele não leva em consideração restrições de movimento ou a dinâmica do sistema.

Uma trajetória, por outro lado, é a sequência real de estados que um sistema percorre durante o movimento. Ela considera as características físicas e dinâmicas do sistema, bem como restrições de movimento, como velocidade máxima, aceleração e limitações de espaço. A trajetória representa o movimento real do



sistema, levando em conta os aspectos práticos e físicos do movimento (CHOSSET et al., 2005).

## 2.4 Restrições

São limitações, condições ou critérios que precisam ser consideradas durante o planejamento de trajetórias. As restrições podem envolver diversas características do sistema, como suas capacidades físicas, limitações de espaço, segurança e requisitos específicos da tarefa. Elas são cruciais para garantir que o planejamento resulte em movimentos seguros, eficientes e viáveis para o sistema em questão. Abaixo alguns tipos de restrições que podem ocorrer ao definir uma trajetória (CHOSSET et al., 2005):

- **Restrições de Movimento Físico:** Essas restrições envolvem as capacidades físicas do sistema, como velocidade máxima, aceleração, capacidade de virar, alcance das juntas de um braço robótico, entre outros. Garantir que o movimento planejado respeite essas limitações é crucial para evitar danos ao sistema ou ação insegura.
- **Restrições de Colisão:** Evitar colisões com obstáculos é uma das restrições mais importantes. Isso envolve a consideração dos limites físicos do sistema e a presença de obstáculos no ambiente. Trajetórias que passam muito perto de obstáculos podem ser inseguras ou inviáveis.
- **Restrições de Espaço:** Dependendo do ambiente em que o sistema opera, pode haver áreas em que o acesso é proibido ou restrito. Trajetórias devem respeitar essas restrições de espaço, como zonas restritas, áreas sensíveis ou regiões onde a passagem é limitada.
- **Restrições Dinâmicas:** Em cenários onde há múltiplos sistemas móveis, como tráfego de veículos ou robôs colaborativos, as restrições dinâmicas envolvem evitar colisões em tempo real com outros agentes que também estão se movendo.
- **Restrições de Tempo:** Em certos casos, pode haver restrições temporais que devem ser atendidas. Isso pode envolver chegar a um determinado local dentro de um prazo específico.
- **Restrições de Energia:** Em sistemas alimentados por energia, como veículos elétricos ou drones, as restrições de energia podem influenciar o planejamento de trajetórias, evitando movimentos que exijam muito consumo de energia.

- **Restrições de Visibilidade:** Em sistemas que dependem da visibilidade, como veículos autônomos, a restrição de visibilidade pode limitar os movimentos quando a visão do sistema está obstruída.

Ignorar restrições pode levar a movimentos inviáveis, inseguros ou ineficientes. Portanto, a consideração cuidadosa das restrições é fundamental para o sucesso de qualquer algoritmo de planejamento de trajetórias.

## 2.5 Critérios de Otimização

O planejamento de trajetórias frequentemente envolve otimização, onde critérios específicos como parâmetros ou métricas usados para avaliar e comparar diferentes trajetórias ou caminhos possíveis, a fim de determinar qual é a solução mais adequada para um problema específico de planejamento. Esses critérios podem incluir fatores como distância percorrida, tempo gasto, consumo de energia, suavidade e evitar colisões (MELO et al., 2021). Alguns exemplos de Critérios de Otimização são:

- **Distância Percorrida:** Em muitos casos, o objetivo é encontrar uma trajetória que minimize a distância percorrida. Isso é especialmente importante em sistemas móveis para economizar energia e tempo.
- **Tempo de Chegada:** Em situações em que a velocidade é uma consideração crítica, o tempo de chegada pode ser um critério importante. Encontrar a trajetória mais rápida pode ser o objetivo principal.
- **Segurança:** Trajetórias seguras são aquelas que minimizam o risco de colisões com obstáculos ou outros agentes. Nesse caso, o critério de otimização seria encontrar trajetórias que evitem qualquer forma de colisão.
- **Eficiência Energética:** Em sistemas alimentados por energia, como veículos elétricos ou drones, otimizar a trajetória para economizar energia pode ser crucial para a vida útil da bateria ou autonomia.
- **Conforto:** Em sistemas que transportam seres humanos, como veículos autônomos ou drones de passageiros, o conforto dos passageiros pode ser um critério de otimização, buscando minimizar movimentos bruscos ou acelerações excessivas.
- **Custo Financeiro:** Em algumas aplicações comerciais, como logística, encontrar trajetórias que minimizem os custos financeiros (como custos de transporte) pode ser um objetivo.

- **Visibilidade:** Em sistemas que dependem da visibilidade, como veículos autônomos, o critério de otimização pode ser maximizar a visibilidade do sistema, evitando obstáculos que possam obstruir a visão.

Os critérios de otimização direcionam o processo de seleção de trajetórias, ajudando a avaliar e comparar diferentes soluções em relação aos objetivos desejados. No entanto, muitas vezes, existem *trade-offs* entre diferentes critérios. Por exemplo, otimizar a distância percorrida pode levar a trajetórias menos seguras. Portanto, a escolha dos critérios de otimização é fundamental para encontrar um equilíbrio entre os objetivos concorrentes e determinar a trajetória mais adequada para a aplicação específica.

## 2.6 Evitar Colisões

Evitar colisões envolve a prevenção proativa de qualquer contato indesejado (LAVALLE, 2006). Isso requer que o sistema seja capaz de perceber o ambiente ao seu redor, avaliar os riscos de colisão e tomar ações para ajustar sua trajetória a fim de evitar qualquer obstáculo. A prevenção de colisões é crítica para evitar danos materiais, lesões pessoais e até mesmo perdas de vida. Além disso, sistemas que colidem com obstáculos podem sofrer danos irreparáveis ou causar danos a outras partes do ambiente, resultando em prejuízos significativos.

Na pesquisa e no desenvolvimento de sistemas autônomos e robóticos, a capacidade de evitar colisões é uma área de foco central, com tecnologias avançadas, como visão computacional, aprendizado de máquina e planejamento de trajetórias, sendo empregadas para garantir que esses sistemas possam navegar com segurança em ambientes complexos e dinâmicos.

## 2.7 Ambientes Dinâmicos vs. Estáticos

Ambientes dinâmicos e estáticos são conceitos que descrevem as características de um ambiente em relação à presença e movimentação de elementos, como obstáculos, agentes e objetos. Eles desempenham um papel importante no planejamento de trajetórias e na navegação de sistemas autônomos. O planejamento de trajetórias pode ocorrer em ambientes dinâmicos, onde obstáculos e condições mudam ao longo do tempo, ou em ambientes estáticos, onde os obstáculos permanecem fixos.

- **Ambientes Estáticos:** Ambientes estáticos são aqueles em que os elementos não mudam de posição ao longo do tempo. Os obstáculos,

objetos e agentes presentes no ambiente permanecem em locais fixos, sem movimento significativo. Em um ambiente estático, o planejamento de trajetórias pode ser mais simplificado, pois o sistema não precisa se preocupar com a movimentação imprevisível de outros elementos. Um exemplo de um ambiente estático é um museu. As exposições, paredes e corredores permanecem nas mesmas posições ao longo do tempo. Um robô que navega nesse ambiente pode se concentrar principalmente em evitar obstáculos fixos, sem a preocupação de agentes em movimento.

- **Ambientes Dinâmicos:** Ambientes dinâmicos são aqueles em que os elementos estão em movimento ou podem mudar de posição ao longo do tempo. Isso adiciona complexidade ao planejamento de trajetórias, pois o sistema precisa levar em consideração a movimentação imprevisível de outros elementos ao seu redor. Um exemplo de um ambiente dinâmico pode ser uma estrada movimentada com vários veículos em trânsito. Os carros, caminhões e motocicletas estão em constante movimento e podem mudar de direção ou velocidade a qualquer momento. Navegar com sucesso nesse ambiente requer não apenas evitar obstáculos fixos, mas também prever os movimentos dos outros veículos e evitar colisões em tempo real.

Os avanços em tecnologias de sensoriamento, processamento de dados e algoritmos de planejamento permitiram que sistemas autônomos lidem melhor com ambientes dinâmicos, tornando possível a navegação segura e eficiente em cenários mais complexos, como tráfego urbano, ambientes industriais movimentados e espaços compartilhados por múltiplos agentes.

## 2.8 Planejamento de Caminho vs. Planejamento de Movimento

O planejamento de caminho e o planejamento de movimento são dois conceitos inter-relacionados, porém distintos, que estão envolvidos no processo de navegação e movimentação de sistemas autônomos, como robôs móveis, veículos autônomos e drones. O planejamento de caminho se concentra em encontrar um caminho geométrico viável através do espaço de configuração, enquanto o planejamento de movimento envolve determinar as entradas de controle (como velocidades e acelerações) que guiam o objeto ao longo do caminho (CHOSSET *et al.*, 2005). Ambos os conceitos são cruciais para garantir que um sistema

possa se mover com sucesso em um ambiente, mas eles abordam diferentes níveis de detalhe e complexidade.

Ambos os conceitos exigem considerações como restrições físicas, obstáculos, segurança, eficiência e eficácia. A integração harmoniosa entre o planejamento de caminho e o planejamento de movimento é essencial para garantir que um sistema autônomo possa se mover de forma segura e eficiente em ambientes complexos e dinâmicos.

## 2.9 Planejamento Local vs. Global

O planejamento local e global são duas abordagens diferentes para o planejamento de trajetórias em sistemas autônomos. O planejamento local lida com decisões e ajustes de curto prazo, muitas vezes considerando obstáculos imediatos e restrições, ele reage dinamicamente às mudanças no ambiente próximo e pode ajustar a trajetória conforme necessário para evitar colisões (TANG; MA, 2021). O planejamento global considera o caminho geral e está preocupado com decisões de longo prazo, ele considera o ambiente completo e suas características, como obstáculos, áreas proibidas e restrições de movimento, para calcular uma trajetória que atenda a essas condições ao longo de todo o trajeto (TANG; MA, 2021). Um exemplo é que, enquanto um veículo autônomo segue uma trajetória global para chegar a um destino (considerando as ruas, cruzamentos, semáforos e todos os possíveis obstáculos ao calcular uma trajetória da origem ao destino, levando em conta o caminho mais eficiente e seguro), o planejamento local leva em consideração os outros veículos, pedestres e objetos imediatamente à frente. Ele calcula manobras e ajustes de curto prazo para evitar colisões e ajustar a trajetória conforme o ambiente muda.

A integração bem-sucedida entre o planejamento global e local é fundamental para a navegação autônoma eficiente e segura. Sistemas autônomos modernos frequentemente usam abordagens híbridas, combinando o planejamento global para roteamento geral com o planejamento local para reações em tempo real, a fim de lidar com ambientes complexos e dinâmicos de maneira eficaz.

## 2.10 Abordagens Baseadas em Amostragem

As abordagens baseadas em amostragem são técnicas utilizadas em planejamento de trajetórias e navegação autônoma, onde discretizam o espaço de configuração em um conjunto de pontos de amostra e tentam conectá-los para formar uma trajetória. Essas abordagens são especialmente úteis em

ambientes complexos, onde encontrar uma trajetória ideal através de métodos determinísticos pode ser computacionalmente custoso ou até mesmo inviável. Em vez de explorar todo o espaço de configuração, as abordagens baseadas em amostragem selecionam estrategicamente um conjunto de amostras representativas (CHOSSET et al., 2005). Essas amostras servem como pontos de partida para gerar trajetórias potenciais. Assim, a partir das amostras iniciais, as trajetórias são construídas conectando esses pontos de amostra de forma a criar uma sequência de estados intermediários. Novas amostras são adicionadas e conectadas de acordo com critérios de otimização e restrições para expandir as trajetórias. As trajetórias geradas são avaliadas com base em critérios de otimização, como distância percorrida, segurança e eficiência. As trajetórias mais promissoras são selecionadas para serem refinadas e melhoradas. Todo esse processo é iterativo, onde mais amostras são selecionadas e adicionadas, e as trajetórias são aprimoradas à medida que o algoritmo progride. Exemplos de Abordagens Baseadas em Amostragem (LAVALLE, 2006):

- **RRT (*Rapidly-Exploring Random Trees*)**: Uma técnica popular que cresce uma árvore de amostras conectadas, explorando rapidamente o espaço de configuração.
- **PRM (*Probabilistic Roadmaps*)**: Gera uma rede de pontos de amostra conectados por arestas que formam trajetórias.
- **SST (*Stable Sparse-RRT*)**: Uma variação do RRT que prioriza a estabilidade das trajetórias geradas.
- **EST (*Expansive Space Trees*)**: Combina elementos de RRT e PRM para construir uma estrutura de árvore.

## 2.11 Controle Ótimo

O controle ótimo é uma abordagem no campo da Teoria de Controle que visa encontrar a melhor maneira de controlar um sistema dinâmico para otimizar um determinado critério, como minimizar o consumo de energia, maximizar o desempenho ou alcançar um objetivo específico. Ele requer uma compreensão profunda da dinâmica do sistema, das restrições e dos critérios de otimização, bem como habilidades em matemática, modelagem e algoritmos de otimização. O objetivo do controle ótimo é determinar as ações de controle ao longo do tempo que levarão o sistema de um estado inicial para um estado final, otimizando uma função objetivo definida (ATHANS; FALB, 1966). Os componentes do controle ótimo são:

- **Sistema Dinâmico:** Um sistema que evolui ao longo do tempo, geralmente descrito por equações diferenciais que relacionam as variáveis do sistema com suas derivadas em relação ao tempo.
- **Variáveis de Estado:** São as variáveis que descrevem o estado do sistema em determinado momento.
- **Variáveis de Controle:** São as variáveis manipuláveis que afetam o comportamento do sistema, como ações ou entradas aplicadas ao sistema.
- **Função Objetivo:** Uma expressão matemática que define o critério que se deseja otimizar. Pode incluir múltiplos objetivos, como minimizar custos ou maximizar desempenho.

Alguns problemas de planejamento de trajetórias envolvem encontrar entradas de controle que otimizam um objetivo específico.

## 2.12 Considerações em Tempo Real

As considerações em tempo real referem-se à capacidade de tomar decisões e agir com base em informações que estão disponíveis e são processadas quase que imediatamente, com o mínimo de atraso possível (LEVEN; HUTCHINSON, 2002). Isso é especialmente importante em sistemas autônomos, como robôs móveis, veículos autônomos e drones, onde a capacidade de reagir rapidamente a mudanças no ambiente é crucial para garantir um funcionamento seguro e eficiente. Alguns princípios que devem ser levados em conta para um sistema em tempo real, sendo eles a rapidez (tempo de resposta às informações em questões de milissegundos a poucos segundos), a sensibilidade ao tempo (capacidade de reagir rapidamente a eventos e mudanças no ambiente), adaptação (redefinição de trajetórias, mudanças nas velocidades ou outras decisões) e as tomadas de decisões rápidas (muitas vezes exige algoritmos e processos eficientes que possam analisar rapidamente as informações).

Em suma, as considerações em tempo real são fundamentais para a operação bem-sucedida de sistemas autônomos, permitindo que eles reajam rapidamente a mudanças no ambiente e tomem decisões adaptativas para alcançar seus objetivos com segurança e eficiência.

# 3

## Algoritmos de Inteligência Artificial no Planejamento de Trajetórias

Existem várias abordagens de inteligência artificial (IA) que são comumente utilizadas no planejamento de trajetórias. Essas abordagens visam otimizar a seleção de trajetórias considerando diversas restrições e objetivos. Além disso, podem ser usadas de forma isolada ou combinadas para lidar com os desafios específicos de planejamento de trajetórias em diferentes contextos e ambientes. A escolha da abordagem depende das características do problema e dos objetivos desejados. Muitas são as abordagens de IA para variadas aplicações, outras tantas estão sendo desenvolvidas e avaliadas. Nas subseções a seguir são analisadas as mais recorrentes até então e como elas se comportam dentro do planejamento de trajetórias.

### 3.1 Busca Heurística

O método de busca heurística é uma abordagem utilizada para resolver problemas de busca em que as informações específicas do problema são incorporadas ao processo de tomada de decisão, a fim de direcionar a busca para soluções mais promissoras. As buscas heurísticas exploram o espaço de estados do problema utilizando informações heurísticas, que são regras ou estimativas baseadas na experiência ou no conhecimento especializado.

Neste caso, a busca heurística desempenha um papel importante no planejamento de trajetórias, especialmente quando se trata de encontrar soluções eficientes em espaços de estados complexos e de alta dimensão.

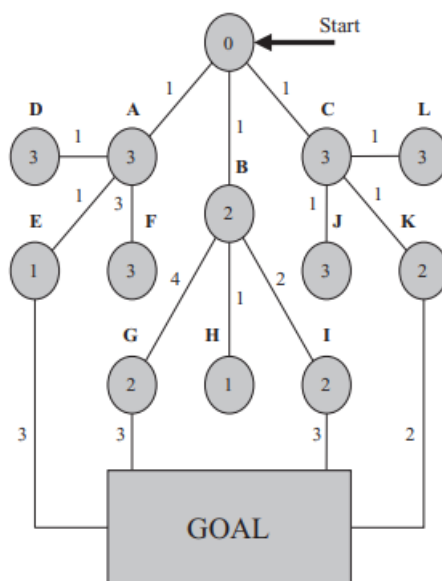
Alguns dos algoritmos de busca heurística mais encontrados em estudos de IA para o planejamento de trajetória incluem:

- **Algoritmo A\*/A-Star e variações**

Segundo [Choset et al. \(2005\)](#), o algoritmo A\* é um método de busca em grafos usado para determinar o caminho mais curto entre um nó de partida e um nó de destino, onde ele gerencia conjuntos de nós abertos (para expansão) e fechados (já expandidos). Ele seleciona nós do conjunto



Figura 2 – Grafo de Busca do Algoritmo A\*



Fonte: Choset et al. (2005)

aberto com base na prioridade, que é a soma do custo até o nó partindo do início e da estimativa heurística do custo até o destino.

A figura 2 exemplifica um grafo no qual cada nó é identificado por uma letra e carrega um valor heurístico dentro do ícone do nó. Os custos das arestas são indicados por números próximos a elas, e os nós de início e destino são identificados. O valor zero no nó de início serve para ressaltar que ele possui a maior prioridade inicialmente. Nota-se que o nó com menor prioridade é expandido, adicionando seus vizinhos ao conjunto aberto se não visitados ou se um caminho melhor for encontrado. O A\* continua até alcançar o destino ou esgotar o conjunto aberto. O caminho até o destino é recriado rastreamento os ponteiros armazenados durante a busca.

Dentro do planejamento de trajetórias o algoritmo A\* pode ser utilizado para encontrar o menor caminho (se existir) entre o estado inicial e o final, analisando todas as possíveis configurações de trajetórias. Com heurística admissível, o caminho ótimo local é encontrado. Mas, sua eficácia depende da qualidade da heurística. Se inadequada, o desempenho pode ser comprometido. Em espaços amplos, pode ser caro, porém é possível melhorar a eficiência podando nós com prioridades altas.

- **Algoritmo D\*/D-Star**

Muitas situações de planejamento de trajetória envolvem obstáculos

em movimento, incluindo outros robôs, criando ambientes dinâmicos. Segundo [Choset et al. \(2005\)](#), o algoritmo D\* é introduzido no planejamento de movimentos para planejar eficientemente trajetórias em ambientes nos quais as mudanças ocorrem mais lentamente do que o movimento do robô. O D\* começa estabelecendo um caminho do objetivo ao início usando uma busca de Dijkstra modificada. Ele modifica valores heurísticos e funções de heurística mínima. Esses valores se adaptam ao longo da busca de D\*, permitindo ajustes eficientes no caminho com base em mudanças. Em conclusão, o algoritmo D\* é utilizado para ajustar adaptativamente trajetórias em resposta a mudanças dinâmicas no ambiente, tornando-se uma ferramenta valiosa para o planejamento de trajetórias em tais cenários.

## 3.2 Redes Neurais Artificiais


Redes neurais artificiais são modelos computacionais inspirados pelo funcionamento do cérebro humano. Elas são compostas por unidades interconectadas, chamadas de neurônios artificiais ou nós, que processam informações e realizam tarefas de aprendizado a partir de dados ([IBM, s.d.](#)). As redes neurais têm a capacidade de aprender padrões complexos e extrair informações relevantes de grandes conjuntos de dados. O planejamento de trajetórias utiliza redes neurais para modelar e prever o movimento de agentes (como robôs ou veículos autônomos), modelagem de dinâmicas, decisões de navegação, adaptação a mudanças e aprendizado por imitação, a fim de tomar decisões informadas sobre as trajetórias ideais.

Em resumo, as redes neurais têm um papel crucial no planejamento de trajetórias, permitindo que os agentes autônomos naveguem em ambientes complexos e dinâmicos de maneira eficiente e segura. Elas contribuem para a tomada de decisões informadas e adaptáveis, garantindo que os agentes alcancem seus objetivos enquanto evitam colisões e reagem a mudanças no ambiente.

Alguns dos métodos de Redes Neurais mais encontrados em estudos de IA para o planejamento de trajetória incluem:

- **Redes Neurais Recorrentes (RNNs)** ([tech, s.d.\[b\]](#)) RNNs são adequadas para sequências de dados, como trajetórias temporais. Elas podem ser usadas para prever a evolução futura da trajetória com base nas informações atuais e passadas. Na [figura 3](#) temos a arquitetura básica de uma Rede Neural Recorrente (RNN). A RNN é ilustrada com um diagrama simples, composta por neurônios de entrada, neurônios na

Figura 3 – Arquitetura RNN



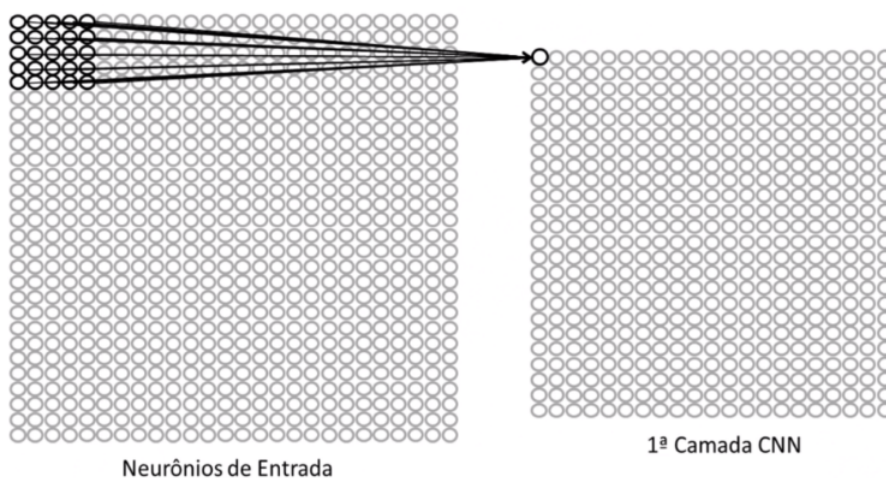
Fonte: Tech (s.d.[b])

camada oculta e neurônios de saída, além de uma camada adicional denominada “M” de memória. Cada neurônio é identificado com o índice “t”, correspondendo a diferentes momentos de tempo. As RNNs são destacadas como redes neurais que mantêm informações da iteração anterior, o que as diferencia das redes neurais densas. A camada oculta da RNN recebe informações não apenas dos dados de entrada, mas também dos neurônios na camada de memória, permitindo a retroalimentação cumulativa das informações ao longo do tempo. A camada de memória (representada como “M”) é de suma importância na RNN, já que ela armazena os valores anteriores e os retroalimenta na camada oculta para influenciar as decisões de trajetória.

- **Redes Neurais Convolucionais (CNNs)** (tech, s.d.[a]) A arquitetura de uma CNN é ilustrada na figura 4 com um exemplo de conexões entre neurônios de entrada e a primeira camada. No exemplo, 784 neurônios de entrada representam pixels de uma imagem, mas apenas 25 deles estão conectados a um neurônio da primeira camada. Em contraste, em uma rede neural densa, todos os 784 neurônios de entrada seriam conectados a cada neurônio da primeira camada. Na figura 5, o próximo neurônio da primeira camada oculta também se conecta a 25 neurônios de entrada, mas de maneira deslocada para a direita, resultando em um padrão que avança coluna por coluna e linha por linha. Esse processo continua até que todos os neurônios de entrada estejam conectados a pelo menos um neurônio da primeira camada.


A arquitetura da CNN é projetada para lidar com características espa-

Figura 4 – Arquitetura CNN Iteração 1



Fonte: Tech (s.d.[a])

Figura 5 – Arquitetura CNN Iteração 2



Fonte: Tech (s.d.[a])

ciais e hierarquias presentes em dados, como imagens, permitindo uma abordagem mais eficaz para o processamento de informações visuais. As CNNs podem ser usadas para processar dados de sensores, como imagens, para extrair recursos relevantes para o planejamento de trajetórias.

### 3.3 Algoritmos Genéticos

Algoritmos genéticos são técnicas de otimização baseadas na evolução biológica (PACHECO, M. A. C., s.d.). Eles podem ser aplicados para gerar e evoluir trajetórias ao longo do tempo, buscando soluções que atendam a critérios específicos de desempenho.

O funcionamento básico dos algoritmos genéticos envolve a criação de uma população inicial de soluções candidatas (indivíduos), representadas em forma

de cromossomos, que, no contexto de planejamento de trajetórias, carregam informações sobre as trajetórias possíveis. Esses cromossomos são manipulados através de operadores genéticos, como seleção, cruzamento e mutação, que simulam a seleção natural e a reprodução (PACHECO, M. A. C., s.d.).

Um exemplo de aplicação de algoritmos genéticos no planejamento de trajetórias poderia ser o seguinte: um veículo autônomo precisa navegar por um ambiente complexo, evitando obstáculos e chegando a um destino específico. O algoritmo genético representa diferentes trajetórias possíveis como indivíduos em uma população e usa os operadores genéticos para criar novas trajetórias, combinando partes de trajetórias existentes e introduzindo variações. Ao longo das gerações, os algoritmos genéticos tenderiam a produzir trajetórias melhores e mais otimizadas, considerando critérios como a distância percorrida, a velocidade, a segurança e outros fatores relevantes.

No entanto, é importante notar que a eficácia dos algoritmos genéticos no planejamento de trajetórias depende da formulação do problema, das características do ambiente, dos critérios de otimização e dos parâmetros escolhidos para os operadores genéticos. Além disso, a utilização de algoritmos genéticos pode ser computacionalmente intensiva, especialmente em problemas complexos, exigindo uma boa seleção de parâmetros e otimizações para alcançar resultados satisfatórios dentro de um tempo aceitável.

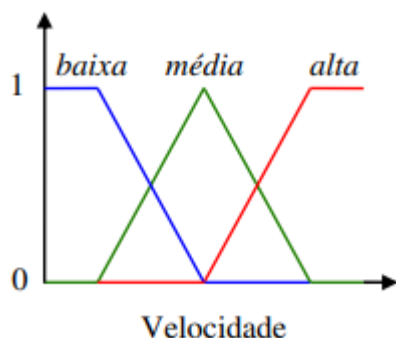
### 3.4 Lógica Fuzzy

A lógica fuzzy é usada para lidar com incertezas e imprecisões em dados. Ela pode ser aplicada para modelar a tomada de decisões em planejamento de trajetórias, levando em consideração informações vagas ou ambíguas. Seus princípios são:

- **Variáveis Linguísticas e Conjuntos Fuzzy:** Ao invés de usar valores numéricos exatos, a lógica fuzzy usa termos linguísticos, como “baixo”, “médio” e “alto”, para descrever as variáveis relevantes. Os conjuntos fuzzy representam esses termos e definem como os valores se relacionam com eles, como exemplificado na figura 6.


No caso dos conjuntos Fuzzy, ele se difere da lógica booleana pois pode assumir infinitos intervalos entre  $[0,1]$  e representados por pares ordenados (LÓGICA..., s.d.). A imagem apresentada na Figura 7 contrasta os conjuntos fuzzy (b) com a lógica booleana (a). No caso (a), quando um elemento X é deslocado para a fronteira do conjunto amarelo, ocorre uma transição repentina no comportamento da sua pertinência. No entanto,

Figura 6 – Exemplo de Variável Linguística na lógica fuzzy



Fonte: LÓGICA... (s.d.)

Figura 7 – Comparação gráfica entre a lógica booleana (a) e lógica fuzzy (b)

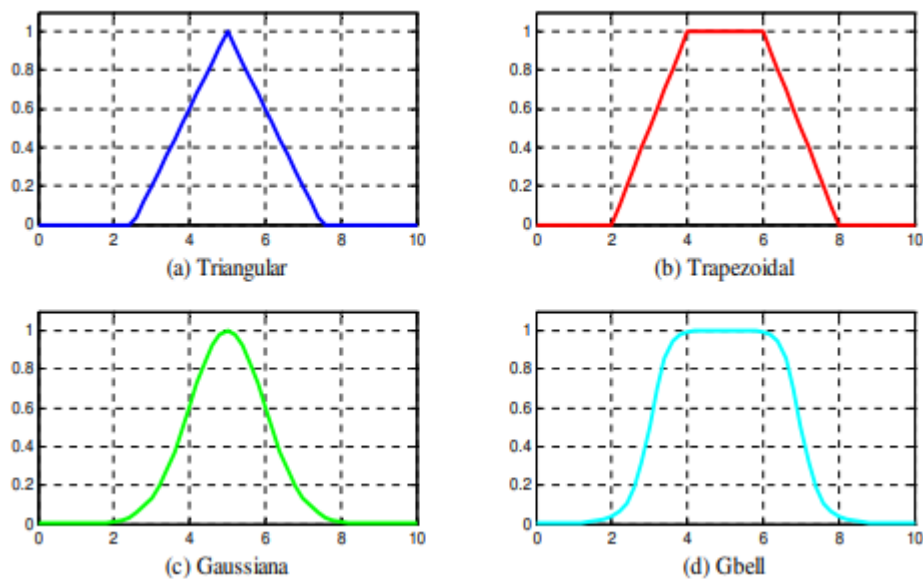


Fonte: LÓGICA... (s.d.)

no cenário (b), podemos observar as mudanças graduais nos pontos de transição entre as diferentes cores.

- **Funções de Pertinência:** Funções de pertinência na lógica fuzzy são representações matemáticas que definem como um valor de entrada pertence a um conjunto fuzzy. Essas funções mapeiam o grau de pertinência de um elemento em relação aos termos linguísticos que descrevem o conjunto fuzzy. Elas permitem modelar a incerteza e a imprecisão presentes em sistemas do mundo real, atribuindo graus de pertinência em uma escala contínua, ao contrário da abordagem binária da lógica booleana. As funções de pertinência geralmente são definidas por curvas, como triangulares, trapezoidais ou gaussianas, que descrevem a relação entre os valores de entrada e a pertinência aos conjuntos fuzzy (figura 8).
- **Regras Fuzzy:** As regras fuzzy são declarações que estabelecem como combinar múltiplos conjuntos fuzzy para obter uma resposta ou ação baseada em entradas difusas. Elas são fundamentais na lógica fuzzy para tomar decisões em sistemas que envolvem incerteza e imprecisão. Cada regra consiste em uma condição (antecedente) e uma ação (consequente).

Figura 8 – Tipos de Funções de Pertinência



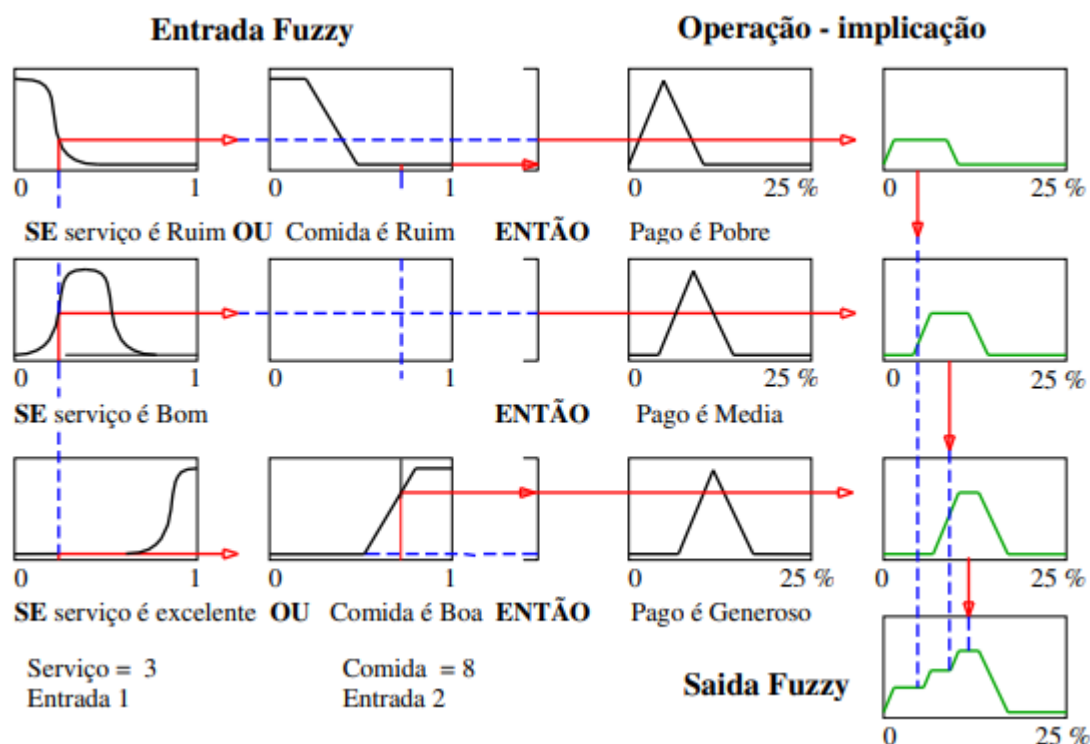
Fonte: LÓGICA... (s.d.)

Por exemplo, “Se a velocidade é alta e a distância é curta, então diminua a velocidade”. A condição é definida por conjuntos fuzzy e operadores lógicos fuzzy, e o consequente é o resultado associado à satisfação da condição (TANSCHUIT, s.d.).

- **Inferência Fuzzy:** A partir das regras fuzzy, a inferência é realizada para determinar as ações a serem tomadas. Isso envolve combinar as informações das regras para obter uma saída fuzzy que represente a decisão a ser tomada (LÓGICA..., s.d.).
- **Defuzzificação:** A saída fuzzy é então defuzzificada para obter um valor numérico que represente a ação a ser executada (LÓGICA..., s.d.). Isso envolve calcular um valor ponderado baseado nas funções de pertinência dos conjuntos fuzzy associados à saída.

No contexto do planejamento de trajetórias, a lógica fuzzy pode ser usada para lidar com informações imprecisas, como incerteza nas medições do ambiente, variações nas condições de direção e tomada de decisões em situações complexas de tráfego. Por exemplo, a lógica fuzzy pode ser aplicada para determinar a velocidade adequada, a distância de segurança e a direção em situações de tráfego desafiadoras.

Figura 9 – Regras e Inferência Fuzzy



Fonte: LÓGICA... (s.d.)

### 3.5 Algoritmos de Otimização

Algoritmos de otimização podem ser utilizados para encontrar trajetórias que otimizem funções de custo específicas, como tempo, energia ou suavidade da trajetória. Esses algoritmos buscam encontrar a melhor trajetória possível, levando em consideração diversos critérios e restrições. Aqui estão alguns exemplos de algoritmos de otimização comumente utilizados no planejamento de trajetórias:

- **Otimização por Enxame de Partículas (PSO):** O PSO simula o comportamento de um enxame de partículas que busca otimizar uma função objetivo. Cada “partícula” representa uma possível solução e é ajustada de acordo com seu desempenho e o das partículas vizinhas, com o objetivo de encontrar uma solução ótima (PACHECO, A., 2016), que no caso do planejamento de trajetórias, ele busca encontrar a trajetória ideal.

O artigo intitulado “A new optimizer using particle swarm theory” foi escrito por Russell C. Eberhart e James Kennedy e publicado em 1995 na Proceedings of the sixth international symposium on micro machine and human science, introduz o conceito de algoritmo de otimização por






Figura 10 – Analogia PSO

Fonte:([PACHECO, A., 2016](#))

enxame de partículas (PSO - Particle Swarm Optimization), uma técnica baseada na simulação do comportamento de um enxame de partículas em busca de soluções otimizadas para problemas complexos.

O algoritmo PSO proposto neste artigo é uma abordagem metaheurística que se inspira no comportamento social de pássaros e outros animais que se movem em grupo, a figura 10 faz a “analogia de um bando de pássaros em um espaço de busca de 3D. Considerando um problema de maximização, o pássaro azul é a partícula de solução ótima do problema” ([PACHECO, A., 2016](#)). A ideia central do PSO é modelar um conjunto de partículas virtuais que representam possíveis soluções para o problema de otimização. Cada partícula ajusta sua posição no espaço de busca com base em sua experiência passada e nas informações obtidas de outras partículas do enxame.

O algoritmo PSO, segundo [Eberhart e Kennedy \(1995\)](#) possui três componentes principais: posição da partícula, velocidade da partícula e a melhor posição encontrada pela partícula até o momento. As partículas ajustam suas velocidades e posições de acordo com uma combinação de fatores, incluindo sua própria melhor posição e a melhor posição global do enxame. Isso permite que as partículas explorem o espaço de busca de maneira eficiente, convergindo para soluções otimizadas.

Desde sua publicação, o algoritmo PSO se tornou uma técnica amplamente utilizada em otimização e resolução de problemas complexos. Sua abordagem intuitiva e flexibilidade para diferentes tipos de problemas o

tornaram uma escolha popular em diversas áreas de pesquisa e aplicação, incluindo o planejamento de trajetórias.

- **Otimização por Colônia de Formigas (ACO):** Segundo [CARVALHO e YAMAKAMI \(2008\)](#), a heurística de Otimização por Colônia de Formigas (ACO) é inspirada na observação das colônias de formigas reais cujas formigas conseguem encontrar o menor caminho entre a sua colônia e a fonte de alimento. Essa heurística envolve o Problema do Caixeiro Viajante (PCV), onde o Caixeiro Viajante deve encontrar o caminho mais curto para visitar um conjunto de cidades, passando por cada cidade uma vez e retornando à cidade de origem.

O algoritmo de colônia de formigas, segundo [Dorigo, Birattari e Stutzle \(2006\)](#) é aplicado para resolver problemas de otimização combinatória, inspirado pelo comportamento de formigas reais. Ao encontrar uma fonte de comida, as formigas depositam feromônios enquanto percorrem o trajeto até o formigueiro. Durante a busca por alimento, a quantidade de feromônio influencia as formigas na escolha do caminho, aumentando a probabilidade de selecionar rotas com mais feromônio. Isso resulta na convergência para o caminho mais curto, pois formigas que o escolhem concluem o percurso mais rapidamente, reforçando o feromônio e atraindo outras formigas. Com o tempo, os feromônios evaporam das rotas menos percorridas, deixando apenas a rota ideal com uma quantidade significativa de feromônio.

No caso do algoritmo, ele opera em intervalos discretos de tempo e apresenta uma característica notável: o percurso entre o formigueiro e a fonte de alimento é realizado em um único ciclo de execução, independentemente do tamanho do caminho escolhido na solução ([FARIA, 2019](#)). As formigas que seguem o algoritmo percorrem um grafo, com uma tabela de feromônios que contém uma entrada para cada aresta utilizada na construção da solução. Essa tabela registra a quantidade de feromônio presente em cada aresta ([DORIGO; BIRATTARI; STUTZLE, 2006](#)). Ao criar o percurso para uma formiga na iteração recorrente, o algoritmo avalia, em cada etapa do trajeto (momento de decisão), a probabilidade (custo) associada a cada possível opção disponível (cada aresta que a formiga pode seguir). A partir dessas probabilidades (que são definidas por um conjunto de parâmetros como: feromônio entre um nó e outro do grafo; parâmetros da ACO que controlam a importância do feromônio e da distância entre os vértices; a taxa de evaporação e deposição de feromônio; a quantidade de formigas e a quantidade de feromônio depositada

pela formiga analisada na aresta), a aresta é selecionada como próxima escolha para a formiga (FARIA, 2019).

A escolha do algoritmo de otimização depende do cenário específico, dos objetivos do planejamento de trajetórias e das características do sistema autônomo em questão. Em muitos casos, é necessário combinar diferentes abordagens e algoritmos para lidar com as complexidades do ambiente e das restrições envolvidas.

### 3.6 Lógica Baseada em Regras

Sistemas de lógica baseados em regras permitem definir um conjunto de regras que guiam a geração de trajetórias. Essas regras podem incluir diretrizes para evitar obstáculos, seguir caminhos pré-determinados ou cumprir outros requisitos. Nessa abordagem, o planejamento de trajetórias é guiado por um conjunto de regras lógicas que definem ações a serem tomadas em diferentes situações ou condições. Essas regras são geralmente formuladas por especialistas no domínio do sistema (CANTELE, 2016).

A lógica baseada em regras no planejamento de trajetórias oferece algumas vantagens, como a capacidade de incorporar conhecimento especializado e regras de segurança diretamente no sistema. Isso pode ser particularmente útil em ambientes controlados e cenários específicos onde as regras podem ser bem definidas. No entanto, essa abordagem também tem suas limitações, especialmente em situações dinâmicas e complexas, onde as regras podem se tornar muito numerosas e difíceis de gerenciar.

### 3.7 Aprendizado de Máquina por Reforço

Aprendizado por reforço envolve treinar um agente a tomar decisões sequenciais para maximizar uma recompensa ao longo do tempo. Pode ser aplicado ao planejamento de trajetórias, onde o agente aprende a selecionar ações que levam a trajetórias desejadas.

Segundo LUDERMIR (2021), o Aprendizado de Máquina (AM) se concentra em criar programas que melhoram seu desempenho através de exemplos. Isso demanda uma grande quantidade de exemplos para construir conhecimento computacional, que se traduz em hipóteses baseadas nos dados disponíveis. As abordagens de AM são impulsionadas pelos dados, gerando hipóteses a partir dessas informações. A precisão das generalizações aumenta com a qualidade

dos dados utilizados. O AM engloba três tipos principais: Supervisionado, Não Supervisionado e por Reforço.

Ainda segundo [LUDERMIR \(2021\)](#) no AM Supervisionado, cada exemplo requer uma resposta conhecida. O algoritmo constrói um classificador que determina a classe de novos exemplos. No AM Não Supervisionado, os exemplos são agrupados sem informações de rótulo, com base em semelhanças em seus atributos. O AM por Reforço envolve o algoritmo recebendo sinais de recompensa ou penalidade, formando hipóteses com base nos exemplos e avaliando o êxito.

A utilização do AM exige condições prévias, como uma base sólida e atualizada de exemplos, além da aplicação de técnicas para melhorar a qualidade dos dados. A escolha adequada de algoritmos é crucial, assim como a definição de seus parâmetros. Após o treinamento, a avaliação do desempenho e a atualização do sistema são necessárias para lidar com mudanças nos dados.

Segundo [Academy \(s.d.\)](#), a Aprendizagem por Reforço envolve treinar modelos de aprendizado de máquina para tomar sequências de decisões. O agente é capacitado a alcançar metas em ambientes incertos e complexos. Durante esse processo, a inteligência artificial enfrenta situações e busca soluções através de tentativa e erro. O modelo em si não recebe instruções detalhadas sobre como resolver o problema. Para garantir o comportamento desejado, a máquina é recompensada ou penalizada pelas ações tomadas, começando com abordagens aleatórias e progredindo para estratégias mais sofisticadas, visando maximizar a recompensa total. Através da exploração de pesquisa e diversas tentativas, a aprendizagem por reforço se destaca como uma forma eficaz de estimular a criatividade da máquina.

Ainda segundo [Academy \(s.d.\)](#), um desafio da Aprendizagem por Reforço é atingir um ótimo local, ou seja, embora funcional, o agente executa a tarefa, mas não de maneira ideal ou necessária. Além disso, há situações em que os agentes buscam maximizar as recompensas sem realmente executar a tarefa originalmente designada para eles.

### 3.8 Métodos de Planejamento Probabilístico

Os métodos de planejamento probabilístico lidam com a incerteza inerente ao ambiente e às informações sensoriais, permitindo que o sistema tome decisões informadas baseadas em probabilidades e distribuições de probabilidade. Esses métodos são especialmente úteis em ambientes complexos e dinâmicos nos quais é difícil prever com precisão o comportamento dos objetos e as condições

futuras. Algoritmos como Probabilistic Roadmaps (PRMs) e Rapidly-exploring Random Trees (RRTs) usam amostragem aleatória e probabilidades para explorar o espaço de configuração e encontrar trajetórias viáveis:

- **Probabilistic Roadmaps (PRMs):** Conforme [Polidoro \(2010\)](#), a abordagem de roadmap para planejamento de trajetórias consiste em mapear as áreas livres do ambiente em uma rede de curvas que representa a conectividade. Essa rede é considerada um conjunto predefinido de rotas. O processo de planejamento da trajetória é simplificado ao conectar os pontos de partida e chegada do robô nessa rede e buscar um caminho entre esses pontos. Se um caminho viável existir, ele será composto por três partes: um trecho do ponto de início até um ponto na rede, um trecho interno da própria rede e um último trecho da rede até o ponto final. Vários métodos foram desenvolvidos com base nessa ideia. A seguir, serão introduzidos alguns desses métodos:
- **Grafos de Visibilidade ([fernandes; bombacini; lima, 2019](#)):** Um grafo de visibilidade engloba todas as ligações potenciais entre quaisquer dois pontos que estão situados em áreas desobstruídas do ambiente. Isso implica que para cada ponto, são estabelecidas conexões com todos os outros pontos que podem ser visualizados a partir dele. Tanto o ponto de partida quanto o ponto de destino são considerados como pontos nesse contexto.
- **Diagrama de Voronoi ([fernandes; bombacini; lima, 2019](#)):** O diagrama de Voronoi é uma técnica abrangente de mapeamento de trajetórias que busca maximizar a distância entre o robô e os obstáculos no mapa. Para cada ponto livre no mapa, é calculada a distância até o obstáculo mais próximo. Esse diagrama é composto pelos pontos que estão igualmente distantes de um ou mais obstáculos, formando regiões que indicam as áreas acessíveis e livres de obstáculos para o robô.
- **Rapidly-Exploring Random Trees - RRTs:** Segundo [Choset et al. \(2005\)](#), as Árvores Aleatórias de Exploração Rápida (*Rapidly-Exploring Random Trees* - RRTs) foram originalmente projetados para planejamento de movimento cinemático, os RRTs são versáteis para vários problemas de planejamento.

A construção dos RRTs envolve a extensão de árvores enraizadas em configurações iniciais e alvo. Em cada iteração, uma configuração aleatória é amostrada de forma uniforme no espaço de configuração livre. A configuração mais próxima na árvore é identificada, e o progresso

é tentado em direção à configuração aleatória dentro de um tamanho de passo especificado. Se a nova configuração gerada, livre de colisões, atender aos critérios, ela é adicionada à árvore. O processo é repetido iterativamente, estendendo a árvore.

A implementação dos RRTs é mais simples em comparação com outros algoritmos, pois evita a manutenção de distribuições probabilísticas ou o cálculo de configurações dentro de uma vizinhança.

### 3.9 Lógica Temporal e *Model Checking*

Essas abordagens são frequentemente usadas em sistemas críticos, como robótica autônoma e aviação, para verificar se uma trajetória planejada satisfaz propriedades específicas de segurança ou comportamento. Essas abordagens permitem a especificação precisa de requisitos de trajetória e a validação formal das trajetórias geradas em relação a esses requisitos.

- **Lógica Temporal:** A lógica temporal é uma extensão da lógica proposicional que permite expressar propriedades sobre a ordem e a duração de eventos ao longo do tempo. Ela é especialmente útil para especificar restrições temporais nas trajetórias, como garantir que um determinado evento ocorra antes de outro, que uma condição seja atendida em algum momento ou que certos eventos não ocorram simultaneamente (LÓGICAS..., s.d.).

Existem várias linguagens de lógica temporal, como a Lógica Linear Temporal (LTL) e a Lógica de Árvore Temporal (CTL). Essas linguagens permitem a formulação de propriedades complexas de tempo e podem ser usadas para definir requisitos de trajetória em termos de sequências de eventos e condições temporais.

- **Model Checking:** O *model checking* é uma técnica de verificação formal que envolve a análise sistemática e automatizada de modelos para verificar se eles satisfazem propriedades especificadas (LÓGICAS..., s.d.). No contexto do planejamento de trajetórias, o *model checking* pode ser usado para verificar formalmente se as trajetórias geradas pelo sistema autônomo atendem aos requisitos de segurança, correção e outros requisitos específicos.

O processo de *model checking* envolve a criação de um modelo formal do sistema, que inclui o ambiente, as ações do sistema e as restrições temporais. A seguir, as propriedades são formuladas em lógica temporal

e são verificadas em relação ao modelo (LÓGICAS..., s.d.). O resultado do *model checking* pode indicar se as trajetórias planejadas atendem às propriedades desejadas ou se violam alguma restrição.

A combinação de lógica temporal e model checking no planejamento de trajetórias permite a especificação precisa de requisitos de comportamento e a verificação rigorosa desses requisitos. Por exemplo, imagine um veículo autônomo que precisa seguir trajetórias seguras e respeitar regras de trânsito. Usando a lógica temporal, é possível especificar propriedades como "o veículo nunca ultrapassará um sinal vermelho". Em seguida, o *model checking* pode ser aplicado para verificar se as trajetórias planejadas atendem a essa propriedade em todas as situações possíveis.

### 3.10 Sistemas Multiagentes

Segundo Araujo (2020), no contexto da Inteligência Artificial, um agente é uma entidade que atua de maneira autônoma e intencional em interações com um ambiente local. Um Sistema Multiagente (SMA) é composto por múltiplos agentes interagindo entre si. Essa área da IA estuda como essas interações entre agentes resultam em fenômenos emergentes, e oferece abordagens para desenvolver, analisar e estudar esses agentes e sistemas.

Ainda segundo Araujo (2020), esses agentes podem ser categorizados em três grupos: passivos, que não possuem objetivos internos; reativos, que reagem a estímulos de maneira pré-determinada; e cognitivos, que possuem objetivos, crenças e intenções complexas.

Em ambientes com múltiplos agentes em movimento, a IA pode ser aplicada para coordenar as trajetórias desses agentes, evitando colisões e garantindo um fluxo suave de movimento.

# 4

## Aplicações

Nesse capítulo é apresentada uma breve revisão de estudos e aplicações práticas em que a IA contribuiu para otimizar o planejamento de trajetórias. Além das técnicas de IA utilizadas em cada trabalho:

- ***Principles of Robot Motion: Theory, Algorithms, and Implementations* (choset et al., 2005) - Métodos de Busca Heurística explorados: RRT, A\* e D\***

O livro “*Principles of Robot Motion: Theory, Algorithms, and Implementations*” (CHOSET et al., 2005) é uma obra abrangente que explora os fundamentos do movimento de robôs. Ele aborda teoria, algoritmos e implementações práticas. O artigo detalha algoritmos de planejamento de movimento, com foco em métodos de busca heurística como o RRT, o A\* e o D\*. A seção teórica aborda os princípios fundamentais do movimento de robôs, incluindo representações de espaço de configuração, modelagem cinemática e dinâmica, bem como definições de colisões e restrições. Esses conceitos fornecem a base para as abordagens apresentadas posteriormente no artigo.

Uma das principais contribuições do trabalho é a exploração detalhada de algoritmos de planejamento de movimento, com foco particular em métodos de busca heurística, como o RRT (*Rapidly-exploring Random Trees*), o A\* (*A-Star*) e o D\* (*D-Star*).

Os autores exploram como o RRT pode ser aplicado para explorar eficientemente o espaço de estados em busca de soluções de movimento. Além disso, eles abordam o A\* e seu uso em cenários de planejamento de trajetória e o D\* em aplicações em ambientes dinâmicos.

O artigo também aborda implementações práticas, discutindo como os algoritmos teóricos podem ser traduzidos para aplicações do mundo real. Os autores destacam desafios como a consideração de restrições físicas dos robôs e a integração de sensores para tornar os métodos de planejamento mais adaptáveis a ambientes dinâmicos e incertos.



Em geral, o artigo “*Principles of Robot Motion: Theory, Algorithms, and Implementations*” é uma leitura valiosa para pesquisadores e profissionais interessados em compreender os fundamentos e as soluções práticas no campo do planejamento de movimento de robôs. Ele oferece uma combinação equilibrada entre teoria e aplicação, contribuindo para uma compreensão aprofundada dos desafios e das melhores práticas nesse campo em constante evolução.

- ***Learning to Navigate in Complex Environments* (mirowski et al., 2017) - Aprendizagem por Reforço e Redes Neurais**

Este artigo explora a aplicação de redes neurais profundas para ensinar robôs a navegar em ambientes complexos. Ele discute como as redes neurais podem ser usadas para aprender políticas de navegação diretamente a partir dos dados de sensoriamento do robô, permitindo que ele planeje trajetórias seguras e eficientes.

O trabalho utiliza uma estrutura de aprendizado por reforço que é abordado com o algoritmo *Asynchronous Advantage Actor-Critic* (A3C), que aprende a política de navegação dado um estado de observação para maximizar as recompensas. Os desafios incluem recompensas limitadas e elementos dinâmicos no ambiente. Para lidar com isso, os autores usam tarefas auxiliares para aumentar a eficiência de aprendizado. Essas tarefas envolvem a previsão de mapas de profundidade a partir de canais de cor (RGB) e a identificação de locais previamente visitados dentro de trajetórias locais. O codificador para a entrada RGB é uma rede convolucional de 3 camadas.

Os requisitos de memória são atendidos usando uma arquitetura de redes neurais *Long Short Term Memory* (LSTM) empilhada. Por fim, o agente é treinado para detectar fechamentos de loops como uma tarefa auxiliar adicional que incentiva a integração implícita de velocidade.

A abordagem é avaliada em ambientes de labirintos 3D com geometria complexa e objetivos dinâmicos. Os resultados mostram aprendizado e desempenho aprimorados em comparação com métodos tradicionais. O artigo enfatiza que o agente adquire habilidades de navegação críticas, mesmo que essas habilidades não estejam explicitamente presentes na função de perda. O agente é capaz de lidar com observações ambíguas, se localizar rapidamente em labirintos e alcançar recompensas de tarefas mais altas.

- ***Survey on Artificial Intelligence for Vehicles (li et al., 2018) - Redes Neurais e Aprendizagem por Reforço***

O artigo escrito por [Li et al. \(2018\)](#) traz a problemática da crescente demanda na mobilidade urbana e no setor de logística moderno e com o auxílio do recente desenvolvimento em inteligência artificial (IA), os veículos podem se tornar suficientemente inteligentes para resolver a problemática. O artigo procura introduzir o conceito dos AIV (inteligência artificial para veículos) que tem como objetivo aplicar técnicas práticas e avançadas de IA aos veículos para que eles possam executar comportamentos humanos ou até mesmo super-humanos.

Algoritmos como redes neurais profundas são projetados para imitar o princípio de funcionamento do cérebro e são treinados em conjuntos de dados grandes para realizar várias tarefas. Os veículos inteligentes combinam técnicas de IA, como percepção ambiental, construção de mapas e planejamento de trajetórias, e as integram com serviços de direção auxiliares em várias escalas e outras funções, para que os veículos possam tomar decisões inteligentes. O foco está nas aplicações de inteligência artificial, aprendizado de máquina e controle automático para veículos.

No contexto dos veículos autônomos, os autores [Li et al. \(2018\)](#) trazem as discussões das tecnologias essenciais, como percepção do ambiente de condução, mapa cognitivo, planejamento de trajetória e controle de estratégias. O uso de técnicas avançadas de aprendizado por reforço profundo é mencionado. São apresentados casos de uso significativos, incluindo o projeto da Google em 2010 e as conquistas da empresa NuTonomy em veículos autônomos em Cingapura. Também são destacadas as principais barreiras à adoção generalizada de veículos autônomos, como desafios tecnológicos, responsabilidade, resistência à perda de controle humano, preocupações de segurança, regulamentação governamental e questões relacionadas ao emprego e urbanização.

No contexto de veículos conectados, o artigo de [Li et al. \(2018\)](#) define veículos conectados como aqueles equipados com sensores, controladores, atuadores e tecnologias de comunicação modernas. Eles possuem a capacidade de compartilhar informações entre veículos e infraestrutura de estradas, permitindo a comunicação inter e intra-veículo. Isso possibilita serviços de compartilhamento de informações para garantir viagens seguras e convenientes, além de navegação via posicionamento por satélite e sistemas de aviso de emergência. Também são abordadas as novas tecnologias, como tecnologias de sensoriamento avançado, decisão

inteligente, controle, comunicação e plataformas de dados.

O artigo fornece uma visão geral abrangente das aplicações de inteligência artificial em veículos autônomos e conectados, abordando tecnologias-chave, casos de uso e desafios associados.

- **Planejamento de Trajetória para um Robô Móvel com duas Rodas Utilizando um Algoritmo A-estrela Modificado (Souza, 2008) - Variações do Algoritmo A\***

Segundo Souza (2008), o planejamento de trajetória na robótica móvel tem como objetivo capacitar os robôs a planejar seus próprios movimentos, sem intervenção humana. No entanto, a elaboração de um plano de movimentação é uma tarefa intrinsecamente complexa. Nesse sentido, este estudo propõe a utilização da técnica de decomposição celular para discretizar o espaço de estados de um robô. Além disso, desenvolve e implementa uma estratégia fundamentada na adaptação de um algoritmo A-Estrela modificado. No contexto da geração de trajetórias, o método apresenta uma solução com base no trajeto calculado pelo planejador, levando em consideração as restrições cinemáticas do robô.

Segundo Souza (2008), a descrição do algoritmo envolve a exploração dos estados vizinhos, conforme o conceito de expansão da fronteira de vizinhança. Inicialmente, o estado de partida é acrescentado à lista aberta, e os estados alcançáveis em um ou dois saltos são analisados. Se não houver obstáculos, os estados passáveis são incluídos na lista aberta, com o estado de partida sendo registrado como pai. O estado de partida é então movido da lista aberta para a lista fechada.

O algoritmo do trabalho também lida com a presença de obstáculos no espaço de configuração. A avaliação dos caminhos é feita por meio de uma função heurística que considera os custos de movimentação e o custo estimado até o estado final. Essa função é utilizada para determinar a direção a ser escolhida durante a busca do caminho, que é conduzida pela seleção repetida do estado com o menor valor heurístico na lista aberta. O algoritmo continua avançando até que o estado objetivo seja adicionado à lista fechada.

O algoritmo opera comparando a visibilidade entre os pontos de origem e destino de pares de estados vizinhos. Se um agente pode se mover entre esses pontos sem colidir com obstáculos, o estado de destino é atualizado para o estado de origem e o estado redundante é removido do caminho. Caso contrário, o próximo estado é considerado como novo ponto de

origem. Esse processo é repetido até que o destino do último estado seja igual ao destino final do caminho.

No contexto deste estudo, foi apresentado um Planejador de Trajetória para um Robô Móvel Autônomo utilizando o Algoritmo A-Estrela com a inovação do “Salto Duplo”. Diversas técnicas de planejamento de trajetória para robôs foram investigadas e, dentre elas, o método escolhido foi considerado o mais apropriado para abordar a problemática de movimentação autônoma em ambientes com obstáculos.

Para avaliar a eficácia dessa abordagem, o trabalho busca validar a proposta por meio do envio da trajetória final codificada via radiofrequência para um robô móvel. Após receber a trajetória, o robô é capaz de executar o percurso planejado de maneira precisa e eficiente.

# 5

## Desafios e Considerações

O uso da inteligência artificial (IA) no planejamento de trajetórias enfrenta uma série de desafios devido à complexidade dos ambientes e à necessidade de garantir segurança, eficiência e adaptabilidade. Alguns dos principais desafios incluem:

- **Ambientes Dinâmicos e Incertos:** Ambientes do mundo real são frequentemente dinâmicos e incertos, com a presença de obstáculos móveis, mudanças nas condições do terreno e ações imprevisíveis de outros agentes. Técnicas de aprendizado de máquina podem ser usadas para melhorar o planejamento, mas os ambientes em mudança podem desafiar a adaptação dos modelos de aprendizado.
- **Colisões e Conflitos:** Evitar colisões e conflitos é fundamental para a segurança. No entanto, antecipar as ações de outros agentes e evitar situações de risco exige previsões precisas e estratégias de planejamento robustas.
- **Balanceamento entre Eficiência e Segurança:** O planejamento de trajetórias deve equilibrar a busca por trajetórias eficientes com a necessidade de manter a segurança. Trajetórias otimizadas podem não ser as mais seguras em todos os momentos.
- **Dimensionalidade Elevada:** Ambientes complexos podem ter muitas dimensões (espaço 3D, tempo, velocidade, etc.). Isso aumenta a complexidade do espaço de busca e torna o planejamento mais desafiador.
- **Tempo Real e Reatividade:** Em muitos cenários, como veículos autônomos, as decisões de planejamento precisam ser tomadas em tempo real. Isso requer algoritmos eficientes e rápidos que possam lidar com a complexidade do ambiente e fornecer respostas rápidas.
- **Modelagem Precisa do Ambiente:** Para planejar trajetórias eficazes, é necessário ter informações precisas sobre o ambiente, incluindo a

localização de obstáculos, a topografia do terreno e as condições meteorológicas. Erros na modelagem podem levar a trajetórias inseguras ou ineficientes.

- **Integração de Diferentes Fontes de Dados:** O uso de IA no planejamento de trajetórias frequentemente requer a integração de dados de sensores diversos, como câmeras, lidar, GPS e IMU. Garantir a sincronização e a fusão correta desses dados é um desafio.
- **Validação e Testes:** Validar e testar algoritmos de planejamento em ambientes do mundo real é complexo e caro. É necessário desenvolver métodos eficazes de teste e validação para garantir a segurança e eficiência dos algoritmos.
- **Interpretabilidade:** Em cenários críticos, como veículos autônomos, entender como e por que um algoritmo tomou uma decisão é crucial para a confiança dos usuários e a aceitação regulatória.

Superar esses desafios requer pesquisa contínua e desenvolvimento de algoritmos mais sofisticados que possam lidar com a complexidade e a incerteza dos ambientes do mundo real. A combinação de diferentes abordagens de IA, como lógica fuzzy, aprendizado de máquina e algoritmos genéticos, pode ser necessária para atender a esses desafios fazendo com que os algoritmos fiquem mais robustos e complexos, consequentemente, menos propensos ao erro, porém, a junção de diferentes abordagens também geram custos principalmente de processamento.

# 6

## Tendências Futuras

Neste capítulo, são apresentadas as tendências emergentes no campo do planejamento de trajetórias com inteligência artificial. Isso inclui a integração de dados em tempo real, avanços na interpretação de ambientes complexos e a evolução de algoritmos de IA para lidar com cenários dinâmicos e imprevisíveis. Algumas das tendências mais significativas incluem:

- **Fusão de Dados de Sensores:** A combinação de dados de sensores diversos, como câmeras, lidar, radar e GPS, está se tornando mais sofisticada. Nos sistemas embarcados, a fusão de sensores opera por meio de um módulo personalizado conforme a aplicação, porém, com um núcleo compartilhado que se fundamenta na correção e estimativa de medidas com base no entendimento do comportamento específico do modelo matemático (NEVES, 2017). A fusão precisa desses dados melhora a compreensão do ambiente e a tomada de decisões confiáveis.
- **Tecnologia V2X (Veículo para Tudo):** A comunicação entre veículos e infraestruturas (V2I) e entre veículos (V2V) está sendo integrada ao planejamento de trajetórias. Isso permite que os veículos troquem informações sobre tráfego, condições da estrada e intenções de direção, melhorando a segurança e a eficiência. Acesso em: <https://www.mobi7.com.br/o-que-e-o-v2x-vehicle-to-everything-e-como-ele-e-uma-evolucao-para-carros-conectados-e-inteligentes/>
- **Integração com Veículos Autônomos e Drones:** O aumento da adoção de veículos autônomos e drones cria novas oportunidades e desafios para o planejamento de trajetórias. A integração perfeita desses agentes na infraestrutura existente requer soluções de planejamento inteligentes.

Essas tendências visam soluções mais robustas, adaptáveis e seguras para uma variedade de aplicações, desde veículos autônomos até drones e robôs móveis.

# 7

## Conclusões

A aplicação da Inteligência Artificial (IA) no planejamento de trajetórias tem revolucionado a forma como os sistemas autônomos e robóticos se movem e interagem em seus ambientes. As contribuições da IA nesse campo têm sido notáveis, trazendo melhorias significativas em termos de eficiência, precisão, segurança e adaptabilidade.

Uma consideração relevante a ser feita é que o leque de possibilidades e combinações de métodos de IA no planejamento de trajetória é grande. Os algoritmos de IA apresentados possuem seus prós e contras, mas que outro método em conjunto pode ser aplicado para corrigir erros e assim, melhorar os resultados obtidos na busca pela trajetória ótima, levando em conta as regras, obstáculos e ambientes dinâmicos.

O presente trabalho conseguiu cumprir com o objetivo principal de investigar e analisar de que forma a inteligência artificial pode ser aplicada de maneira eficaz no planejamento de trajetórias, trazendo as principais aplicações e métodos utilizados hoje em dia no planejamento de trajetórias em diversas áreas. Além de identificar os desafios e tendências futuras nessa área constante em crescimento.

### 7.1 Trabalhos Futuros

Dentro da direção de pesquisa delineada neste estudo, há um potencial significativo para implementar e aplicar práticas concretas de diversos métodos de Inteligência Artificial (IA) no contexto do planejamento de trajetória. Como uma sugestão para trabalhos futuros, é possível explorar a aplicação desses métodos em um cenário prático envolvendo um robô móvel, com o objetivo de avaliar e comparar a eficácia de diferentes abordagens. Além disso, pode-se considerar a simulação de um ambiente de veículo autônomo na plataforma de desenvolvimento Unity, incorporando princípios de Aprendizado de Máquina por meio do *framework ML-Agents*. Isso permitiria treinar o agente usando métodos de aprendizado por reforço até que ele seja capaz de atingir seus objetivos de maneira eficiente.



Após a conclusão dessa simulação, uma etapa subsequente poderia envolver a incorporação de algoritmos de otimização para aprimorar as soluções obtidas e otimizar o tempo de resposta do agente na busca da "melhor solução". Isso poderia resultar em um processo de tomada de decisão mais rápido e eficaz, reduzindo os requisitos de processamento e minimizando a carga de armazenamento de dados na memória.

Outra sugestão de desenvolvimento futuro seria a integração da simulação Unity com um ambiente real de robô móvel. Essa integração poderia empregar sensores e atuadores reais, além de câmeras para aplicar métodos de Redes Neurais Convolucionais (CNN). Ao introduzir obstáculos e ambientes dinâmicos, seria possível explorar conjuntos de métodos que ofereçam um planejamento de trajetória mais eficiente e adaptável às condições reais.

Em resumo, a continuação da pesquisa nesse campo oferece várias direções promissoras. A implementação prática e a combinação de métodos de IA, a simulação em ambientes virtuais e sua extensão para cenários reais podem contribuir para aprimorar ainda mais as estratégias de planejamento de trajetória.

# Referências

ACADEMY, Data Science. *Deep Learning Book*. Disponível em: <https://www.deeplearningbook.com.br/o-que-e-aprendizagem-por-reforco/>. Citado 2 vezes na página 35.

ARAÚJO, Ricardo. *Sistemas Multiagentes*. 2020. Disponível em: <https://ricardomatsumura.medium.com/sistemas-multiagentes-b65af9636e21#:~:text=Um%20Sistema%20Multiagente%20%C3%A9%20um,estudar%20estes%20agentes%20e%20sistemas..> Citado 2 vezes na página 38.

ATHANS, M.; FALB, P.L. *Optimal Control: An Introduction to the Theory and Its Applications*. McGraw-Hill, 1966. (Lincoln Laboratory publications). Disponível em: <https://books.google.com.br/books?id=gGbxAAAAMAAJ>. Citado 1 vez na página 21.

BEKEY, George A. Springer Handbook of Robotics (B. Siciliano and O. Khatib; 2008) [Book Review]. *IEEE Robotics Automation Magazine*, v. 15, n. 3, p. 110–110, 2008. DOI: [10.1109/MRA.2008.928399](https://doi.org/10.1109/MRA.2008.928399). Citado 1 vez na página 14.

BELLOTTO, N. et al. Appearance-based localization for mobile robots using digital zoom and visual compass. *Robotics and Autonomous Systems*, v. 56, n. 2, p. 143–156, 2008. DOI: [10.1016/j.robot.2007.07.001](https://doi.org/10.1016/j.robot.2007.07.001). Disponível em: [https://www.researchgate.net/publication/222529772\\_Appearance-based\\_localization\\_for\\_mobile\\_robots\\_using\\_digital\\_zoom\\_and\\_visual\\_compass](https://www.researchgate.net/publication/222529772_Appearance-based_localization_for_mobile_robots_using_digital_zoom_and_visual_compass). Citado 1 vez na página 13.

CANTELE, Regina. *Machine Learning: sistemas baseados em regras*. 2016. Disponível em: <https://imasters.com.br/tecnologia/machine-learning-sistemas-baseados-em-regras>. Citado 1 vez na página 34.

CARVALHO, M.B.; YAMAKAMI, A. Meta-heurística Híbrida de Sistema de Colônia de Formigas e Algoritmo Genético para o Problema do Caixeiro Viajante. *Tendências em Matemática Aplicada e Computacional*, v. 9, n. 1, p. 31–40, 2008. Disponível em: <https://tema.sbmac.org.br/tema/article/view/178/117>. Citado 1 vez na página 33.

CHOSSET, Howie et al. Configuration Space. In: *PRINCIPLES of Robot Motion: Theory, Algorithms, and Implementations*. 2005. P. 39–75. Citado 12 vezes nas páginas 13–16, 19, 21, 23–25, 36, 39.

DORIGO, Marco; BIRATTARI, Mauro; STUTZLE, Thomas. Ant colony optimization. *IEEE Computational Intelligence Magazine*, v. 1, n. 4, p. 28–39, 2006. DOI: [10.1109/MCI.2006.329691](https://doi.org/10.1109/MCI.2006.329691). Citado 2 vezes na página 33.

- EBERHART, R. C.; KENNEDY, J. A new optimizer using particle swarm theory. *In Proceedings of the sixth international symposium on micro machine and human science*, v. 1, p. 39–43, 1995. Citado 1 vez na página 32.
- ESTADO. *Infopedia, Porto Editora*. 2023. Disponível em: [https://www.infopedia.pt/apoio/artigos/\\$estado-fisico#:~:text=0%20estado%20f%C3%ADsico%20de%20um,o%201%C3%ADquido%20e%20o%20gasoso..](https://www.infopedia.pt/apoio/artigos/$estado-fisico#:~:text=0%20estado%20f%C3%ADsico%20de%20um,o%201%C3%ADquido%20e%20o%20gasoso..) Citado 1 vez na página 13.
- FARIA, Tiago P. de. *Uso de Algoritmo baseado em colônia de formigas para explorar sequências de otimização do compilador*. Universidade Federal de Uberlândia, 2019. Disponível em: <https://repositorio.ufu.br/bitstream/123456789/29093/7/UsoAlgoritmoBaseado.pdf>. Citado 2 vezes nas páginas 33, 34.
- FERNANDES, William; BOMBACINI, Marcos; LIMA, José. *Planejamento de Trajetória em Robô Móvel com Inteligência Artificial Embarcada*. Jul. 2019. Tese (Doutorado). Citado 2 vezes na página 36.
- IBM. *O que são redes neurais?* Disponível em: <https://www.ibm.com/br-pt/topics/neural-networks>. Citado 1 vez na página 25.
- LAVALLE, Steven M. *Planning Algorithms*. Cambridge University Press, 2006. DOI: 10.1017/CB09780511546877. Citado 6 vezes nas páginas 13, 15, 18, 21.
- LEVEN, Peter; HUTCHINSON, Seth. A framework for real-time path planning in changing environments. English (US). *International Journal of Robotics Research*, SAGE Publishing, v. 21, n. 12, p. 999–1030, dez. 2002. ISSN 0278-3649. DOI: 10.1177/0278364902021012001. Citado 1 vez na página 22.
- LI, Jun et al. Survey on Artificial Intelligence for Vehicles. *Automotive Innovation*, v. 1, mar. 2018. DOI: 10.1007/s42154-018-0009-9. Citado 4 vezes na página 41.
- LÓGICA Fuzzy. PUC - Rio. Disponível em: [https://www.maxwell.vrac.puc-rio.br/32823/32823\\_3.PDF](https://www.maxwell.vrac.puc-rio.br/32823/32823_3.PDF). Citado 3 vezes nas páginas 28–31.
- LÓGICAS Temporais para a Validação de Sistemas. PUC - Rio. Disponível em: [https://www.maxwell.vrac.puc-rio.br/10082/10082\\_4.PDF](https://www.maxwell.vrac.puc-rio.br/10082/10082_4.PDF). Citado 3 vezes nas páginas 37, 38.
- LUDERMIR, TERESA B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. *Estudos Avançados*, v. 35, p. 85–94, 2021. Citado 2 vezes nas páginas 34, 35.

MELO, Aurelio G. et al. Dynamic Optimization and Heuristics Based Online Coverage Path Planning in 3D Environment for UAVs. *Sensors (Basel, Switzerland)*, v. 21, 2021. Disponível em: <https://api.semanticscholar.org/CorpusID:231864955>. Citado 1 vez na página 17.

MENDONÇA MÁRCIO, et al. INTELIGÊNCIA ARTIFICIAL, FUNDAMENTOS, CONCEITOS, APLICAÇÕES E TENDÊNCIAS. *Ciência, Tecnologia e Inovação: Experiências, Desafios e Perspectivas 3*, v. 4, n. 3, p. 34–46, 2023. Citado 1 vez na página 10.

MIROWSKI, Piotr et al. *Learning to Navigate in Complex Environments*. 2017. arXiv: 1611.03673 [cs.AI]. Citado 1 vez na página 40.

NEVES, Felipe. *Introdução à Fusão de Sensores*. 2017. Disponível em: <https://embarcados.com.br/introducao-fusao-de-sensores-parte-1/>. Citado 1 vez na página 46.

PACHECO, André. *Otimização por enxame de partículas - PSO*. 2016. Disponível em: <http://computacaointeligente.com.br/algoritmos/otimizacao-por-enxame-de-particulas/>. Citado 2 vezes nas páginas 31, 32.

PACHECO, Marco A. C. *ALGORITMOS GENÉTICOS: PRINCÍPIOS E APLICAÇÕES*. Pontifícia Universidade Católica do Rio de Janeiro - ICA: Laboratório de Inteligência Computacional Aplicada. Disponível em: [https://www.inf.ufsc.br/~mauro.roisenberg/ine5377/Cursos-ICA/CE-intro\\_apost.pdf](https://www.inf.ufsc.br/~mauro.roisenberg/ine5377/Cursos-ICA/CE-intro_apost.pdf). Citado 2 vezes nas páginas 27, 28.

POLIDORO, Heitor L. *Planejamento de trajetória em ambientes com propriedades dinâmicas*. Universidade de São Paulo, 2010. Disponível em: [https://www.teses.usp.br/teses/disponiveis/55/55134/tde-17112010-104739/publico/Dissertacao\\_Heitor\\_Polidoro.pdf](https://www.teses.usp.br/teses/disponiveis/55/55134/tde-17112010-104739/publico/Dissertacao_Heitor_Polidoro.pdf). Citado 1 vez na página 36.

RODRIGUES, Leonardo C. *FUNDAMENTOS, TECNOLOGIAS E APLICAÇÕES DE VEÍCULOS AUTÔNOMOS*. Universidade Tecnológica Federal Do Paraná, 2017. Disponível em: [http://repositorio.utfpr.edu.br:8080/jspui/bitstream/1/16201/2/PG\\_COELE\\_2017\\_2\\_19.pdf](http://repositorio.utfpr.edu.br:8080/jspui/bitstream/1/16201/2/PG_COELE_2017_2_19.pdf). Citado 1 vez na página 14.

RUSSELL, Stuart; NORVIG, Peter. *Artificial intelligence: A modern approach (3th ed.)* Pearson, 2010. v. 3. Citado 3 vezes na página 10.

SOUZA, Sônia C. B. de. *PLANEJAMENTO DE TRAJETÓRIA PARA UM ROBÔ MÓVEL COM DUAS RODAS UTILIZANDO UM ALGORITMO A-ESTRELA MODIFICADO*. COPPE-UFRJ, 2008. Disponível em: <http://www.pee.ufrj.br/index.php/pt/producao-academica/dissertacoes->

[de-mestrado/2008-1/2008121701-2008121701/file](#). Citado 4 vezes nas páginas 13, 42.

TANG, Zhuozhen; MA, Hongzhong. An overview of path planning algorithms. *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, v. 804, n. 2, p. 022024, jul. 2021. DOI: [10.1088/1755-1315/804/2/022024](https://doi.org/10.1088/1755-1315/804/2/022024). Disponível em: <https://dx.doi.org/10.1088/1755-1315/804/2/022024>. Citado 2 vezes na página 20.

TANSCHUIT, Ricardo. *Sistemas Fuzzy*. PUC - Rio. Disponível em: <https://www.inf.ufsc.br/~mauro.roisenberg/ine5377/Cursos-ICA/LN-Sistemas%20Fuzzy.pdf>. Citado 1 vez na página 30.

TECH, Didática. *O que são Redes Neurais Convolucionais?* Disponível em: <https://didatica.tech/introducao-a-redes-neurais-convolucionais/>. Citado 1 vez nas páginas 26, 27.

TECH, Didática. *O que são Redes Neurais Recorrentes*. Disponível em: <https://didatica.tech/como-funcionam-redes-neurais-recorrentes-rnn/>. Citado 1 vez nas páginas 25, 26.

ZARISKI, Oscar. The Topological Discriminant Group of a Riemann Surface of Genus  $p$ . *American Journal of Mathematics*, v. 59, n. 2, p. 335–358, 1937. DOI: [10.2307/2371416](https://doi.org/10.2307/2371416). Citado 1 vez na página 13.

ZENVIA. *Qual a diferença entre Machine Learning e Inteligência Artificial?* ZENVIA. Jun. 2023. Disponível em: <https://www.zenvia.com/blog/diferenca-machine-learning-inteligencia-artificial/>. Citado 1 vez na página 10.