



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Acarcio Gomes de Almeida Junior

**FM-ACC:** Um Controlador de Cruzeiro Adaptativo *Fuzzy* Mamdani aplicado a Veículos Autônomos de Escala Reduzida em *Platooning*

Recife

2024

Acarcio Gomes de Almeida Junior

**FM-ACC:** Um Controlador de Cruzeiro Adaptativo *Fuzzy* Mamdani aplicado a Veículos Autônomos de Escala Reduzida em *Platooning*

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação.

**Área de Concentração:** Engenharia da Computação

**Orientador :** Dr. Abel Guilhermino da Silva Filho

Recife

2024

Catálogo na fonte  
Bibliotecária: Luiza de Oliveira/CRB 1316

A447f Almeida Junior, Acarcio Gomes de

FM-ACC: um controlador de cruzeiro adaptativo fuzzy mamdani aplicado a veículos autônomos de escala reduzida em platooning / Acarcio Gomes de Almeida Junior – 2024.

84 fls. Il.: fig., tab.

Orientador: Abel Guilhermino da Silva Filho.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. Cin. Programa de Pós-Graduação em Ciência da Computação. Recife, 2024.

Inclui referências.

1. Veículos autônomos . 2. Fuzzy. 3. Platooning. 4. Veículos de pequena escala. I. Silva Filho, Abel Guilhermino da. II. Título.

621.39

CDD (23. ed.)

UFPE - CCEN 2024 – 98

**Acarcio Gomes de Almeida Junior**

“**FM-ACC**: Um Controlador de Cruzeiro Adaptativo *Fuzzy* Mamdani aplicado a Veículos Autônomos de Escala Reduzida em *Platooning*”

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação.

Aprovado em: 02/08/2024

**BANCA EXAMINADORA**

---

Prof. Dr. Divanilson Rodrigo de Sousa Campelo  
Centro de Informática / UFPE

---

Prof. Dr. Evandro Leonardo Silva Teixeira  
Universidade de Brasília – FGA

---

Prof. Dr. Abel Guilhermino da Silva Filho  
Centro de Informática / UFPE  
**(Orientador)**

## **AGRADECIMENTOS**

Gostaria de agradecer aos meus pais, Acarcio Gomes e Ezenilda Bezerra, por serem meus maiores incentivadores. Seu apoio e encorajamento foram essenciais em minha jornada.

Agradeço às minhas irmãs Ávila, Águida e a toda minha família, que sempre me incentivaram.

Ao professor Dr. Abel Guilhermino por sua dedicação durante esta jornada, seu apoio foi fundamental.

Aos meus amigos, Alexsandro Ferreira, Antônio, Gabriel Vasconcelos, Jonatas Coelho, Marcos Eduardo, Émerson Guilhermino agradeço pelas colaborações valiosas e eficientes ao longo do tempo em que estiveram dispostos a me ajudar no laboratório e nas reuniões de projetos. Agradeço também aos amigos do LIVE por toda a ajuda.

A todas as pessoas que contribuíram direta ou indiretamente para a realização deste trabalho

## RESUMO

A indústria do transporte tem enfrentado desafios significativos nos últimos anos, como o grande número de acidentes de trânsito. De acordo com a Organização Mundial da Saúde (OMS), os acidentes rodoviários são uma das principais causas de morte de pessoas. É importante ressaltar que a maioria dos acidentes de trânsito é causada por erros humanos, como imprudência, uso de álcool ou tempo de reação do condutor. Dessa forma, surge a necessidade de automatizar a condução para torná-la mais eficaz e segura. Este estudo concentra-se na automatização da condução longitudinal, visando controlar um grupo de veículos, denominado *platooning*, que viaja com o mesmo destino e mantém uma curta distância entre os veículos, com o objetivo de garantir uma maior segurança nas rodovias.

Para alcançar esse objetivo, propõe-se uma arquitetura de controle em cascata composta por dois níveis. O controlador de baixo nível é responsável pela aceleração e frenagem do veículo em escala reduzida, enquanto o controlador de alto nível se encarrega de manter uma distância segura entre os veículos. Este controlador de alto nível é baseado no conceito de *Adaptive Cruise Control*, que utiliza controle *fuzzy* para criar o plano de velocidade ideal para o veículo. O controlador *fuzzy* de distância recebe, por meio de um sensor, a medição da distância em relação ao veículo à frente ou ao veículo líder e, com base no erro entre essa medição e a distância de referência, gera uma velocidade de referência. Essa velocidade de referência é então transmitida ao controlador de baixo nível, que ajusta a aceleração e frenagem do veículo para manter a velocidade desejada.

Os controladores desenvolvidos foram implementados no *software* MATLAB/SIMULINK, onde o controlador FM-ACC apresentou um excelente desempenho, superando em todas as métricas um controlador PI desenvolvido pelo método de Ziegler-Nichols, apresentando uma redução de 92.25% de sobresinal, 77.26% de tempo de acomodação, 41.52% de tempo de pico, 7.84% de tempo de subida e 35.23% de tempo de atraso. Além disso, o controlador foi validado em um estudo de caso em veículos de escala reduzida onde o controlador apresentou um desempenho semelhante aos resultados simulados. Por fim, o controlador foi submetido a um estudo de caso de um *platooning* com 7 veículos simulados no MATLAB, onde o controlador conseguiu controlar um *platooning* de cinco elementos com boas respostas temporais e apresentou grandes perturbações para os últimos dois veículos.

**Palavras-chaves:** veículos autônomos; *fuzzy*; *platooning*; veículos de pequena escala.

## ABSTRACT

The transportation industry has faced significant challenges in recent years, such as the high number of traffic accidents. According to the World Health Organization (WHO), road accidents are one of the leading causes of death. It is important to note that most traffic accidents are caused by human errors, such as recklessness, alcohol use, or driver reaction time. Therefore, there is a need to automate driving to make it more efficient and safer. This study focuses on the automation of longitudinal driving, aiming to control a group of vehicles, called a platoon, which travels with the same destination and maintains a short distance between vehicles, to ensure greater road safety.

To achieve this goal, a two-level cascade control architecture is proposed. The lower-level controller is responsible for the acceleration and braking of the scaled-down vehicle, while the upper-level controller is tasked with maintaining a safe distance between the vehicles. This upper-level controller is based on the concept of Adaptive Cruise Control, which uses fuzzy control to create the optimal speed plan for the vehicle. The fuzzy distance controller receives, via a sensor, the measurement of the distance to the vehicle ahead or the leading vehicle and, based on the error between this measurement and the reference distance, generates a reference speed. This reference speed is then transmitted to the lower-level controller, which adjusts the vehicle's acceleration and braking to maintain the desired speed.

The developed controllers were implemented in the MATLAB/SIMULINK software, where the FM-ACC controller demonstrated excellent performance, surpassing a PI controller developed using the Ziegler-Nichols method in all metrics. It achieved a 92.25% reduction in overshoot, 77.26% reduction in settling time, 41.52% reduction in peak time, 7.84% reduction in rise time, and 35.23% reduction in delay time. Additionally, the controller was validated in a case study involving scaled-down vehicles, where it exhibited performance similar to the simulated results. Finally, the controller was subjected to a case study of a platooning scenario with 7 vehicles simulated in MATLAB, where it successfully controlled a platoon of five elements with good temporal responses and exhibited significant disturbances for the last two vehicles.

**Keywords:** autonomous vehicles; fuzzy; platooning; small-scale vehicles.

## LISTA DE FIGURAS

Figura 1 – Principais causas de acidentes no Brasil . . . . .	13
Figura 2 – Principais tipos de acidentes no Brasil . . . . .	14
Figura 3 – Traçado das vias com acidentes no Brasil . . . . .	14
Figura 4 – Estrutura da rede CNN . . . . .	19
Figura 5 – Diagrama de blocos do CC . . . . .	20
Figura 6 – Arquitetura de controle ACC . . . . .	21
Figura 7 – Arquitetura de controle LAC . . . . .	22
Figura 8 – Método Pulse and Glide . . . . .	23
Figura 9 – Platooning baseado em ACC . . . . .	25
Figura 10 – Platooning baseado em EACC . . . . .	26
Figura 11 – Platooning baseado em CACC . . . . .	27
Figura 12 – Representação das forças longitudinais . . . . .	29
Figura 13 – Arquitetura da rede NARX . . . . .	34
Figura 14 – Filosofia de controle clássico . . . . .	37
Figura 15 – Filosofia de controle Fuzzy . . . . .	39
Figura 16 – Funções de pertinência tipo triangular para variável nível com as devidas variáveis linguísticas . . . . .	40
Figura 17 – Representações gráficas: (a) conjunto A de função triangular, (b) conjunto B de função trapezoidal, (c) operação de união entre A e B, (d) operação de intersecção entre A e B, (e) operação de complemento de A e (f) operação de complemento de B . . . . .	42
Figura 18 – Defuzzyficação pela média do máximo . . . . .	43
Figura 19 – Defuzzyficação pelo Centro de Área . . . . .	44
Figura 20 – Curva de resposta em degrau unitário . . . . .	46
Figura 21 – Veículo de Escala Reduzida . . . . .	49
Figura 22 – Arquitetura de sensoriamento do Veículo de Escala Reduzida . . . . .	50
Figura 23 – Sinal de entrada . . . . .	51
Figura 24 – Sinal de saída . . . . .	51
Figura 25 – Arquitetura CNN-REI proposta . . . . .	52
Figura 26 – Arquitetura de controle proposta . . . . .	53

Figura 27 – Oscilação sustentada com período $P_{cr}$ . . . . .	55
Figura 28 – Função de Pertinencia da variável de entrada Erro do FM-ACC . . . . .	56
Figura 29 – Função de Pertinencia da variável de entrada dErro do FM-ACC . . . . .	57
Figura 30 – Função de Pertinencia da variável de saída do FM-ACC . . . . .	58
Figura 31 – Resposta do Sistema para um $K_{cr} = 733$ . . . . .	60
Figura 32 – Resposta ao degrau para o controlador sintonizado por Ziegler-Nichols . . . . .	61
Figura 33 – Resposta ao degrau para o controlador ajustado . . . . .	62
Figura 34 – Resposta do Sistema para um $K_{cr} = 1300$ . . . . .	63
Figura 35 – Resposta do controlador PI . . . . .	64
Figura 36 – Resposta do controlador PI ajustado . . . . .	64
Figura 37 – Resposta do controlador FM-ACC . . . . .	66
Figura 38 – (a) entrada FM-ACC (b) Saída . . . . .	67
Figura 39 – Ajuste de acordo com o número de estados . . . . .	69
Figura 40 – (a) Ajuste dos dados de saída da rede NARX com os dados coletados; (b) Erro entre os dados coletados e previstos pela rede . . . . .	70
Figura 41 – (a) Ajuste dos dados de saída da rede CANN-REI com os dados coletados; (b) Erro entre os dados coletados e previstos pela rede . . . . .	71
Figura 42 – Resposta dos controladores ACC-PI e FM-ACC . . . . .	73
Figura 43 – Veículos na pista de teste . . . . .	74
Figura 44 – Desempenho do FM-ACC em um veículo de pequena escala real . . . . .	74
Figura 45 – Desempenho do FM-ACC em um veículo de pequena escala real . . . . .	75
Figura 46 – Velocidades e Sinais de comando do Lider . . . . .	76
Figura 47 – Velocidades e Sinais de comando dos veículos . . . . .	77
Figura 48 – Posição dos veículos em relação ao veículo lider . . . . .	77
Figura 49 – Erro de distância do veículo a frente e a $dist_{ref}$ . . . . .	78

## LISTA DE TABELAS

Tabela 1 – Tipos de controladores aplicado a <i>platooning</i> . . . . .	24
Tabela 2 – Sintonização Ziegler-Nichols . . . . .	55
Tabela 3 – Parâmetros das funções de pertinência do controlador FM-ACC . . . . .	58
Tabela 4 – Regras Fuzzy para o FM-ACC . . . . .	59
Tabela 5 – Sintonização Ziegler-Nichols - <i>Cruise Control</i> . . . . .	60
Tabela 6 – Sintonização Ziegler-Nichols Modified - <i>Cruise Control</i> . . . . .	61
Tabela 7 – Desempenho dos controladores PID de Baixo Nível . . . . .	62
Tabela 8 – Sintonização Ziegler-Nichols - <i>ACC-PI</i> . . . . .	63
Tabela 9 – Ajuste da sintonia Ziegler-Nichols - <i>Cruise Control</i> . . . . .	64
Tabela 10 – Desempenho do controlador ACC-PI . . . . .	65
Tabela 11 – Desempenho do controlador FM-ACC . . . . .	66
Tabela 12 – Fit do modelo de Função de Transferência de acordo com o número de polos e zeros . . . . .	68
Tabela 13 – Desempenho dos Modelos . . . . .	72
Tabela 14 – Desempenho dos controladores ACC . . . . .	73
Tabela 15 – Desempenho do controlador FM-ACC em veículo real . . . . .	75

## LISTA DE ABREVIATURAS E SIGLAS

<b>ACC</b>	Adaptive Cruise Control
<b>ADAS</b>	Advanced Driver Assistance Systems
<b>CACC</b>	Cooperative Adaptive Cruise Control
<b>CC</b>	Cruise Control
<b>CNN</b>	Convolutional Neural Network
<b>CNT</b>	Confederação Nacional do Transporte
<b>CoA</b>	Centro de Área
<b>CoG</b>	Centro de Gravidade
<b>CoM</b>	Centro do Máximo
<b>EACC</b>	Extended Adaptive Cruise Control
<b>FM-ACC</b>	Fuzzy Mamdani Adaptive Cruise Control
<b>IA</b>	Inteligência Artificial
<b>LAC</b>	Look Ahead Control
<b>MIMO</b>	Multiple Input Multiple Output
<b>MISO</b>	Multiple Input Single Output
<b>MoM</b>	Média do Máximo
<b>PID</b>	Proportional Integral Derivative
<b>PnG</b>	Pulse and Glide
<b>SCMA</b>	Sistema de Controle em Malha Aberta
<b>SCMF</b>	Sistema de Controle em Malha Fechada
<b>SIMO</b>	Single Input Multiple Output
<b>SISO</b>	Single Input Single Output
<b>V2I</b>	Vehicle-to-Infrastructure
<b>V2V</b>	Vehicle-to-Vehicle

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	PROJETO SEGURAUTO	16
1.2	PERGUNTA DE PESQUISA	16
<b>1.2.1</b>	<b>Hipótese</b>	<b>16</b>
1.3	OBJETIVOS	17
1.4	ESTRUTURA DO TRABALHO	17
<b>2</b>	<b>REVISAO BIBLIOGRÁFICA</b>	<b>18</b>
2.1	IDENTIFICAÇÃO DE SISTEMAS	18
2.2	MÉTODOS DE CONTROLE	19
<b>2.2.1</b>	<b><i>Cruise Control</i></b>	<b>20</b>
<b>2.2.2</b>	<b><i>Adaptive Cruise Control</i></b>	<b>20</b>
<b>2.2.3</b>	<b><i>Look-Ahead Control</i></b>	<b>21</b>
<b>2.2.4</b>	<b><i>Pulse and Glide</i></b>	<b>22</b>
2.3	ESTRATÉGIA DE CONTROLE DE <i>PLATOONING</i>	23
<b>2.3.1</b>	<b><i>Platooning sem comunicação</i></b>	<b>24</b>
<b>2.3.2</b>	<b><i>Platooning com comunicação</i></b>	<b>25</b>
2.3.2.1	<i>Platooning não cooperativo</i>	26
2.3.2.2	<i>Platooning Cooperativo</i>	27
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>29</b>
3.1	DINÂMICA LONGITUDINAL DE VEÍCULOS	29
<b>3.1.1</b>	<b>Força de Tração/Frenagem</b>	<b>30</b>
<b>3.1.2</b>	<b>Força Gravitacional</b>	<b>30</b>
<b>3.1.3</b>	<b>Força de Rolagem</b>	<b>30</b>
<b>3.1.4</b>	<b>Força de Resistência Aerodinâmica</b>	<b>31</b>
3.2	IDENTIFICAÇÃO DE SISTEMAS	31
<b>3.2.1</b>	<b>Modelos Paramétricos</b>	<b>32</b>
<b>3.2.2</b>	<b>Modelos Inteligentes</b>	<b>33</b>
<b>3.2.3</b>	<b>Avaliação dos Modelos</b>	<b>34</b>
3.3	SISTEMAS DE CONTROLE	35
3.4	CONTROLADORES FUZZY	38

3.4.1	<b>Controladores <i>Fuzzy</i> Mamdani</b>	39
3.5	AVALIAÇÃO DE CONTROLADORES	44
4	<b>METODOLOGIA</b>	47
4.1	SETUP EXPERIMENTAL	47
4.2	VEÍCULO DE ESCALA REDUZIDA	49
4.3	MODELAGEM EM CAIXA PRETA	50
4.3.1	<b><i>Dataset</i></b>	50
4.3.2	<b>Arquitetura de Modelo Inteligente (CNN-REI)</b>	51
4.4	ARQUITETURA DE CONTROLE PROPOSTA	53
4.4.1	<b>Controlador de Aceleração/Frenagem</b>	54
4.4.2	<b>FM-ACC</b>	55
5	<b>PROJETO DOS CONTROLADORES</b>	60
5.1	CONTROLADOR BAIXO NÍVEL	60
5.2	CONTROLADOR DE ALTO NÍVEL	62
5.2.1	<b>ACC-PI</b>	63
5.2.2	<b>FM-ACC</b>	65
6	<b>RESULTADOS</b>	68
6.1	IDENTIFICAÇÃO DE SISTEMAS	68
6.1.1	<b>Função de Transferência</b>	68
6.1.2	<b>Espaço de Estado</b>	69
6.1.3	<b>NARX</b>	70
6.1.4	<b>CNN-REI</b>	71
6.1.5	<b>Desempenho dos Modelos</b>	72
6.2	COMPARAÇÃO DOS CONTROLADORES DE ALTO NÍVEL	72
6.3	ESTUDO DE CASO	73
6.3.1	<b>Veículos em Escala Reduzida</b>	73
6.3.2	<b><i>Platooning</i></b>	75
7	<b>CONCLUSÃO</b>	79
7.1	LIMITAÇÕES	80
7.2	TRABALHOS FUTUROS	80
	<b>REFERÊNCIAS</b>	82

## 1 INTRODUÇÃO

De acordo com a Organização Mundial da Saúde (OMS) (OMS, 2023), os acidentes rodoviários são uma das principais causas de morte de pessoas com idade entre 5 e 29 anos e a 12ª causa entre pessoas de todas as idades. De acordo com o Relatório Global de Status sobre Segurança no Trânsito de 2023 da OMS, cerca de 1,19 milhão de pessoas morrem anualmente em todo o mundo devido a acidentes de trânsito, sendo que cerca de um terço são ocupantes de veículos automotores (OMS, 2023).

Sendo uma das principais causas de morte e principal contribuinte para a incapacidade, as lesões causadas pelo trânsito também impõem um enorme custo econômico às sociedades. Algumas estimativas colocam o custo macroeconômico global das lesões causadas pelo trânsito em 1,8 trilhão de dólares (OMS, 2023).

No Brasil, em 2023, a Confederação Nacional do Transporte (CNT), registrou 67.620 acidentes nas rodovias federais, com 56.666 dos acidentes tendo vítimas (mortos ou feridos) resultando em 5.605 vidas perdidas (CNT, 2023). Quando comparado com o ano de 2022, o Brasil teve um aumento de 4,8% no número total de acidentes e de 3,1% no número de mortes.

A CNT estimou que os acidentes nas rodovias federais brasileiras custaram cerca de R\$ 14 bilhões aos cofres públicos apenas em 2023 (CNT, 2023). É importante ressaltar que a maioria dos acidentes de trânsito é causada por erros humanos, como imprudência, uso de álcool ou tempo de reação do condutor como pode ser visto na Figura 1.

Figura 1 – Principais causas de acidentes no Brasil

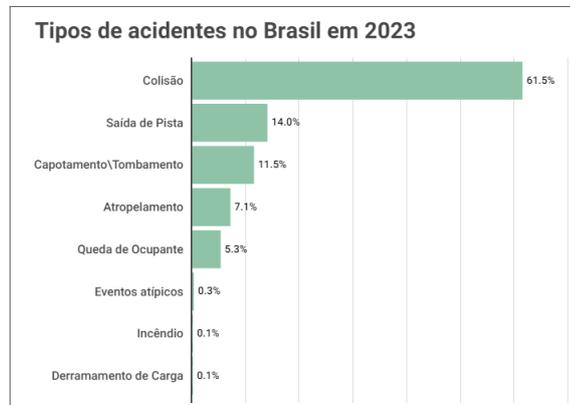


Fonte: CNT (2023)

Segundo a CNT, o tipo de acidente mais comum no Brasil é a colisão, que representa

61.5% do acidentes com vítimas, conforme a Figura 2.

Figura 2 – Principais tipos de acidentes no Brasil



Fonte: CNT (2023)

Além disso, a maioria dos acidentes são ocasionados em vias com traçado reto onde se encontra 55.7% dos acidentes conforme a Figura 3.

Figura 3 – Traçado das vias com acidentes no Brasil



Fonte: CNT (2023)

Diante desses números alarmantes e da necessidade urgente de modernização da interação entre motoristas e veículos, universidades, empresas de tecnologia e do setor automotivo estão direcionando seus esforços para o desenvolvimento de sistemas que possam aprimorar a condução tanto em áreas urbanas quanto em rodovias, por meio da incorporação de tecnologias de ponta, como sistemas embarcados, redes de comunicação sem fio e Inteligência Artificial (IA) (COELHO, 2023). Essa combinação tecnológica vem possibilitando o surgimento de diversas aplicações voltadas para o auxílio à condução, melhoria na percepção e até mesmo a condução totalmente autônoma.

Neste contexto, os fabricantes de automóveis têm instalado sistemas de apoio à condução longitudinal e transversal com o objetivo de minimizar os impactos negativos dos acidentes

---

de trânsito e garantir um maior conforto para os passageiros, proporcionando um tráfego mais seguro e eficiente nas estradas e nas cidades, como é o caso do Controle de Cruzeiro Adaptativo, do inglês *Adaptive Cruise Control*(ACC).

O ACC é um sistema de apoio à condução longitudinal capaz de manter o veículo a uma distância de segurança dos veículos à sua frente. Ele controla a aceleração e frenagem do veículo, evitando colisões. Diversas estratégias de controle podem ser aplicadas para este contexto. Uma abordagem clássica se utiliza dos controladores Proporcional-Integral-Derivativo (PID) para controlar o sistema considerando o erro de distância dos veículos. Outra opção é a utilização de técnicas de controle moderno, como é o caso dos controladores *fuzzy*, que tenta emular sistematicamente e matematicamente o raciocínio humano nas tomadas de decisões.

Embora eficaz, este tipo de abordagem destina-se apenas a um veículo. Por outro lado, uma abordagem que envolve um grupo de veículos, como o *platooning*, pode alcançar mais vantagens. Segundo Restivo (2022) o *platooning* é uma técnica que busca manter a mínima distância entre veículos dentro de um grupo viajando para o mesmo destino, a fim de explorar o arrasto aerodinâmico e reduzir o consumo de energia. Cada elemento do grupo deve ser capaz de, no mínimo, monitorar a posição do veículo à sua frente, seja através de sensores ou comunicação entre veículos, de forma a manter a distância adequada.

Neste contexto, este trabalho propõe o desenvolvimento de um sistema que garanta uma distância de segurança entre os veículos por meio de controlador *fuzzy* baseado no ACC visando a segurança do *platooning* e minimize os riscos de acidentes nas estradas.

Para o desenvolvimento de um sistema de controle, geralmente é modelada a planta do sistema a fim de projetar e testar o controlador antes da sua implementação em um sistema real (DUARTE; FIGUEIREDO, 2022). Dessa forma, é proposto um modelo inteligente baseado em redes convolucionais para realizar a modelagem do sistema dinâmico. O modelo é uma adaptação do modelo de séries temporais proposto por KIRISCI; YOLCU (2022) para que se torne possível sua aplicação em identificação de sistemas.

A arquitetura de controle proposta é composta por dois controladores em cascata. A utilização dessa configuração ajuda a suavizar as respostas do veículo, evitando mudanças bruscas de velocidade que podem causar desconforto ao motorista e aos passageiros. Além disso, o controlador de baixo nível permite uma resposta rápida a pequenas variações na velocidade, enquanto o controlador de alto nível se concentra em manter a distância segura. Isso é crucial em situações de tráfego variável.

## 1.1 PROJETO SEGURAUTO

Este trabalho foi realizado em colaboração com o projeto de pesquisa SegurAuto. O SegurAuto que faz parte do programa ROTA 2030<sup>1</sup>, cujo objetivo principal é incentivar projetos de P&D em toda a cadeia automotiva e é desenvolvido no âmbito da chamada CONSEV: Condução Segura e Eficiente de Veículos, da Fundação de Desenvolvimento da Pesquisa (FUNDEP).

O projeto SegurAuto visa desenvolver Pesquisa, Desenvolvimento e Inovação (PD&I) de Sistemas de Segurança Veicular. O projeto desenvolve funções de Sistemas Avançados de Assistência ao Condutor (ADAS), além de proporcionar o desenvolvimento de ambiente para condução autônoma, sendo inicialmente aplicado em veículos de pequena escala, porém com potencial para aplicar em veículos de passeio e comerciais.

Neste contexto, este trabalho colabora com o projeto SegurAuto por meio do desenvolvimento de um sistema de controle para *platooning*, que servirá de base para os testes e análises das funções ADAS. Todas as atividades práticas deste trabalho foram realizadas no Laboratório de Inovação para Cidades Inteligentes (LIVE) da Universidade Federal de Pernambuco (UFPE).

## 1.2 PERGUNTA DE PESQUISA

Como melhorar o desempenho de um ACC aplicado a um *platooning* de veículos autônomos de escala reduzida, visando otimizar a resposta do sistema e reduzir os tempos de reação?

### 1.2.1 Hipótese

Devido a dinâmica longitudinal de um veículo ser um sistema não linear, um controlador do tipo *fuzzy*, pode ser desenvolvido e utilizado para realizar o controle de veículos autônomos com menores tempos de reação que controladores tradicionais.

<sup>1</sup> O programa ROTA 2030 é uma iniciativa governamental brasileira que incentiva a pesquisa, desenvolvimento e inovação na indústria automotiva, visando a competitividade e sustentabilidade do setor.

### 1.3 OBJETIVOS

O objetivo principal deste trabalho é o desenvolvimento de um controlador do tipo *fuzzy* para veículos autônômicos de escala reduzida na função de um ACC dentro de um sistema *platooning*.

Os objetivos específicos são:

- Desenvolver um modelo que represente a dinâmica longitudinal de um veículo de escala reduzida;
- Desenvolver um controlador de baixo nível responsável por controlar a aceleração/frenagem do veículo;
- Desenvolver um controlador que exerça a função de um ACC para um sistema *platooning*;
- Validar o controlador proposto por meio de um estudo de caso em veículos de escala reduzida e simulado para um sistema *platooning*.

### 1.4 ESTRUTURA DO TRABALHO

O trabalho está estruturado em capítulos, sendo este o primeiro, que engloba a introdução, motivação e objetivos. O Capítulo 2 aborda a revisão bibliográfica, apresentando as técnicas desenvolvidas para controle longitudinal no setor automotivo. O Capítulo 3 apresenta conceitos e definições a respeito de dinâmica longitudinal de veículos, sistemas de controle, e sistemas de inferência *fuzzy*. No Capítulo 4 é apresentada a metodologia do trabalho, mostrando detalhes do veículo em escala reduzida utilizado, bem como a arquitetura de controle proposta. No Capítulo 5 é apresentado o projeto dos controladores propostos. Os testes realizados e os resultados obtidos são descritos no Capítulo 6. Por fim, no Capítulo 7, são apresentadas as considerações finais e possíveis direcionamentos para futuras pesquisas.

## 2 REVISAO BIBLIOGRÁFICA

Neste capítulo, é apresentada a Revisão Bibliográfica que serve de base para a pesquisa, com as definições necessárias para a compreensão geral do trabalho. Na Seção 2.1, são detalhados os trabalhos que utilizam técnicas de identificação de sistemas para modelagem de sistemas dinâmicos. Na Seção 2.2, serão descritos os métodos de controle utilizados pelo setor automotivo para a dinâmica longitudinal. Por fim, na Seção 2.3, serão abordadas as estratégias de controle de um *platooning* de veículos.

### 2.1 IDENTIFICAÇÃO DE SISTEMAS

A modelagem parte da análise do sistema dinâmico envolvido no estudo por meio das equações diferenciais que regem o sistema. No entanto, quando não é possível obter o modelo por meio dessas equações, deve-se utilizar técnicas de identificação de sistemas para obter um modelo que apresente uma resposta próxima à resposta da planta. Assim, em DUARTE; FIGUEIREDO (2022) é desenvolvido um modelo que representa a dinâmica do sistema de direção de um veículo de escala reduzida, que possui como entrada o sinal PWM e como saída o ângulo das rodas.

Em DONJAROENNON; NUCHKUM; LEETON (2021) é utilizado o *system identification toolbox* para extrair a função de transferência de um sistema em malha fechada para controle de velocidade de motor DC, é possível avaliar a simplicidade e eficácia da ferramenta na modelagem do problema.

Em NAUNG et al. (2018), é realizada a comparação entre o modelo com uma rede neural com entradas exógenas e o modelo de função de transferência gerado em caixa preta. Os modelos representam dinâmica de um motor DC, onde o objetivo é controlar a velocidade do motor, considerando o sinal de tensão dos motores. O desempenho do modelo NARX provou a capacidade das redes neurais de se adaptarem melhor a sistemas dinâmicos mais complexos.

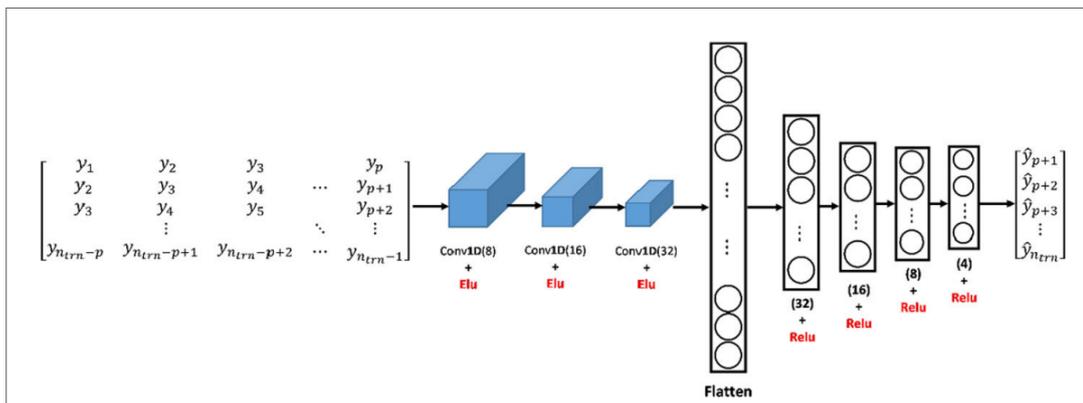
CHRISTUDAS; DHANRAJ (2021) apresenta um modelo RNN-LSTM para realizar a modelagem de um sistema de tanque cônico. Os modelos de Redes Neurais Recorrentes (RNN) são modelos de *deep learning* baseados na utilização de informações passadas para realizar as previsões futuras. Apesar dos modelos apresentarem boa capacidade em aprender dados não-lineares de series temporais, esses modelos apresentam problemas relacionados ao gradiente

(CHRISTUDAS; DHANRAJ, 2021). Para solucionar esse problema, foram utilizadas as redes *Long Short Term Memory* (LSTM), que são basicamente um tipo de RNN que utiliza unidades fechadas. Dessa forma, foi possível obter um modelo não linear, que apresenta um melhor desempenho quando comparado com modelos paramétricos como a função de transferência (TF), autoregressive exogenous (ARX) e o modelo de rede neural NARX.

MOREIRA (2020) utiliza um modelo neuro-*fuzzy* para modelar um sistema experimental de bombeamento de água com demanda variável. O modelo neuro-*fuzzy* possui a grande vantagem de não ser necessária a exigência de um especialista sobre o sistema, pois durante o treinamento a rede possui a capacidade de aprender a melhor combinação de regras e funções de pertinência do sistema *fuzzy*. Após um comparativo do modelo neuro-*fuzzy* com diversos modelos paramétricos e inteligentes, o modelo neuro-*fuzzy* superou o desempenho de todos os modelos inclusive o de uma rede neural artificial.

A Figura 4 apresenta um modelo de Rede Neural Convolutiva, do inglês (*Convolutional Neural Network*, CNN) proposto por KIRISCI; YOLCU (2022) para realizar previsões em séries temporais do mercado financeiro. A utilização de CNN para aplicações de séries temporais é uma proposta relativamente inovadora, visto que tradicionalmente as redes neurais convolucionais são comumente utilizadas em processamento de imagens.

Figura 4 – Estrutura da rede CNN



Fonte: KIRISCI; YOLCU (2022)

## 2.2 MÉTODOS DE CONTROLE

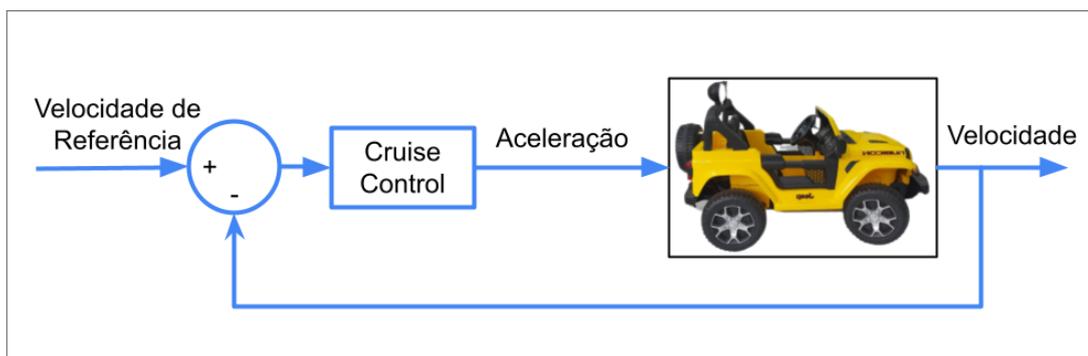
Para automatizar um *platooning*, manter pequenas distâncias entre veículos de forma eficaz e segura, e diminuir a resistência aerodinâmica, o controle deve ser baseado em informações obtidas através de sensores instalados nos veículos ou por alguma forma de comunicação.

Assim, neste capítulo são apresentadas tecnologias de controle longitudinal encontradas na literatura que suportam o *platooning* e suas funcionalidades, possibilitando a percepção do ambiente ao redor do veículo.

### 2.2.1 *Cruise Control*

O *Cruise Control* (CC) é um sistema de assistência à condução longitudinal baseado em um sistema de controle em malha fechada, como pode ser observado na Figura 5. Popularmente conhecido como piloto automático, o CC compara a velocidade atual do veículo com a velocidade de referência definida, calculando assim o erro no sistema. Caso o erro seja maior que zero, o sistema acelera o veículo; caso seja menor que zero, o sistema desacelera o veículo. Este sistema é frequentemente instalado em veículos de passageiros.

Figura 5 – Diagrama de blocos do CC



Fonte: O autor (2024)

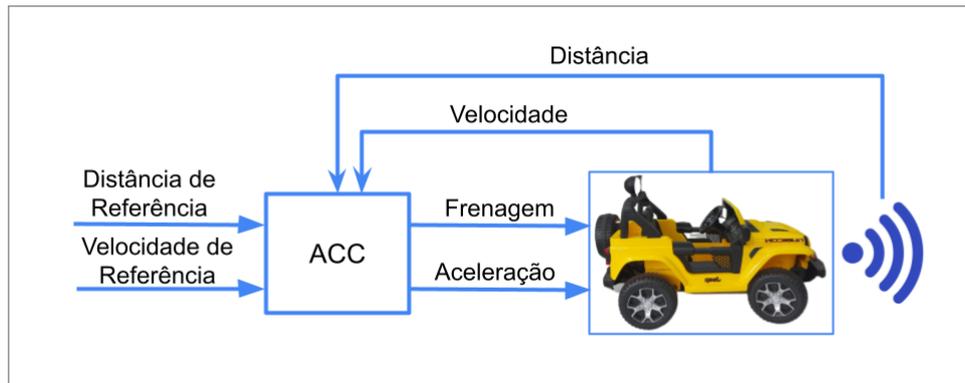
Em ULSOY; PENG; ÇAKMAKCI (2012) é projetado um *cruise control* do tipo Proporcional-Integral (PI), considerando um modelo de dinâmica longitudinal linearizado para a condição de velocidade constante. A utilização do controlador PI apresentou uma resposta temporal dentro dos parâmetros de projeto, tendo erro de regime permanente zero e tempo de acomodação de 45 segundos.

### 2.2.2 *Adaptive Cruise Control*

O CC, apesar de proporcionar um maior conforto em viagens longas, não oferece nenhum tipo de segurança, uma vez que sua preocupação é apenas manter a velocidade desejada. Assim, como o objetivo de adicionar mais segurança aos veículos, foi criado e lançado o *Adaptive Cruise Control* (ACC), que surge instalado em veículos de luxo no final dos anos 90

(RESTIVO, 2022). Ao contrário do CC, o ACC é capaz de controlar não só a aceleração do veículo como também a sua frenagem. Desta forma, este controlador é capaz de manter a velocidade cruzeiro do veículo, como no CC, mas quando detecta um veículo à sua frente é capaz de manter uma distância de segurança deste compensando assim a carência de segurança do CC, Figura 6.

Figura 6 – Arquitetura de controle ACC



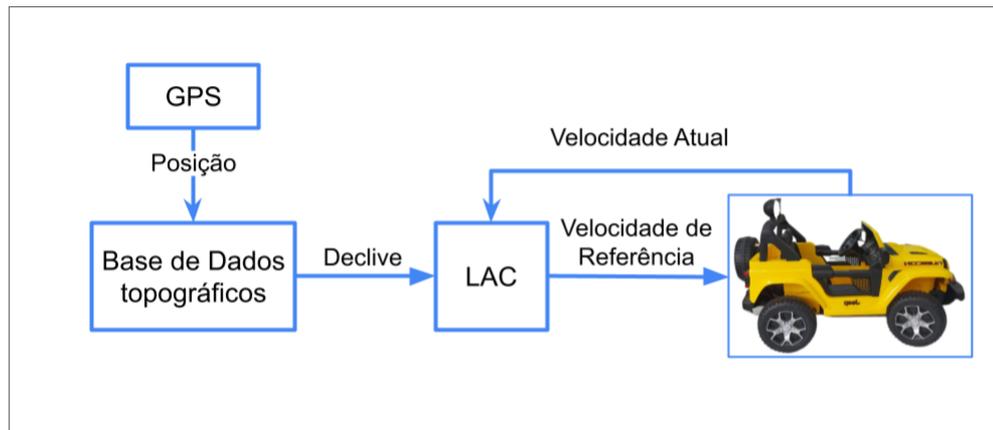
Fonte: O autor (2024)

Para realizar este tipo de controle, são necessários dados adicionais aos necessários para o CC. Esses dados podem ser obtidos pelo próprio veículo por meio de sensores. Em geral, esse tipo de controlador é baseado em dados de um radar instalado na frente dos veículos, porém, é possível utilizar outros sensores para fornecer a distância dos objetos, como é o caso do LIDAR e de um conjunto de câmeras estereoscópicas que fornecem o mapa de profundidade das imagens.

### 2.2.3 *Look-Ahead Control*

O *Look Ahead Control* (LAC) é um controle preditivo com conhecimento adicional sobre alguns dos distúrbios futuros, (HELLSRTOM et al., 2009). O LAC tem como princípio de funcionamento a utilização da posição e da topografia da estrada na qual o veículo segue para traçar o melhor plano de velocidade para o trajeto. O LAC utiliza o sistema GPS com o objetivo de obter a posição do veículo a controlar e verifica, numa base de dados topográfica, o declive da estrada à qual o veículo se aproxima (RESTIVO, 2022). Desta forma, é calculado o plano de velocidade ideal para a trajetória que segue de forma a minimizar o consumo de combustível do veículo Figura 7.

Figura 7 – Arquitetura de controle LAC



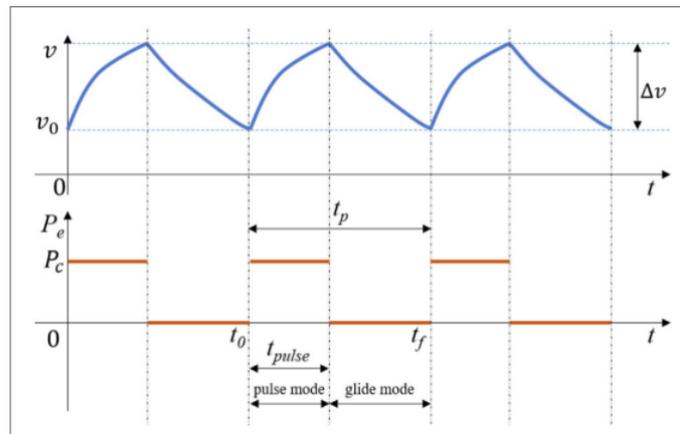
Fonte: O autor (2024)

Em HELLSRTOM et al. (2009) pode-se constatar que este tipo de controle torna o veículo mais eficiente energeticamente, uma vez que, foi obtido uma redução no consumo de combustível de cerca de 3.5% no percurso de 120km sem o aumento do tempo de viagem. Isso é possível apenas pelo fato de o controlador evitar frenagens desnecessárias quando o veículo está se aproximando de subidas, como também evita acelerações no início de descidas. Além disso, o número médio de trocas de marcha foi reduzido em 42% devido as mudanças de marchas evitadas, o que aumenta significativamente o tempo de vida do sistema de transmissão.

#### 2.2.4 *Pulse and Glide*

O *Pulse and Glide* (PnG) consiste em uma estratégia de economia de combustível que se divide em dois momentos. No momento *Pulse*, o veículo acelera um pouco acima da velocidade desejada pelo condutor, já no momento *Glide*, o carro desacelera (RESTIVO, 2022). Outra nomenclatura encontrada na literatura para esse tipo de controlador é "ON-OFF". A desaceleração pode ocorrer com o carro "com a marcha engatada" ou em ponto morto, dependendo sempre do tipo de transmissão e motor que o veículo possui. Um exemplo de um veículo executando este ciclo pode ser observado na Figura. 8.

Figura 8 – Método Pulse and Glide



Fonte: RESTIVO (2022)

Diversos estudos, como CAO; YUNO; KAWABE (2022) e XU et al. (2015), comprovam a eficácia deste método na redução de combustível mas um ponto negativo na utilização do PnG é o desconforto que provoca no condutor uma vez que este passa bastante tempo na cabine e o motor acelera e desacelera de forma rítmica. Apesar deste ponto negativo, este método encontra-se bastantes vezes conjugado com alguns tipos de arquitetura de controle de *platooning*, melhorando bastante a sua eficácia (RESTIVO, 2022).

Em OHLSEN; STEN (2018), os resultados mostram que o PnG reduz o consumo de combustível e, quando aliado à arquitetura ALAC, os resultados com a marcha constante indicam que o PnG pode reduzir o consumo de combustível para um *platooning* em cerca de 1 – 3%.

### 2.3 ESTRATÉGIA DE CONTROLE DE *PLATOONING*

O *platooning* de veículos pode ser descrito como um alinhamento de vários veículos que viajam a uma certa velocidade, onde cada veículo deve se manter a uma distância mínima ao veículo que se encontra imediatamente à sua frente, dentro dos limites de segurança, de forma a utilizar o vácuo causado pela forma e velocidade do veículo precedente com o objetivo reduzir a resistência aerodinâmica e, conseqüentemente, os seus consumos (RESTIVO, 2022).

A implementação de mais sensores e sistemas de controle nos veículos permitiu funcionalidades e recursos mais avançados. Uma seção dos novos recursos desenvolvidos são os Sistemas Avançados de Assistência ao Motorista (ADAS), onde tem-se como exemplo o (ACC) e os sistemas de segurança, como avisos de saída de faixa, que alertam o motorista ao sair involuntariamente da faixa atual (OHLSEN; STEN, 2018).

Diversas estratégias de controle podem ser aplicadas a *platooning*. Os tipos de controladores utilizados podem variar de acordo com as características dos veículos que irão formar o *platooning*. RESTIVO (2022) classifica estratégias de controle para *platooning* considerando aspectos como a existência de comunicação entre os veículos e/ou infraestruturas, utilização de sensores que forneçam informações sobre as condições das vias, e a existência de cooperação entre os veículos, conforme a Tabela. 1.

Tabela 1 – Tipos de controladores aplicado a *platooning*

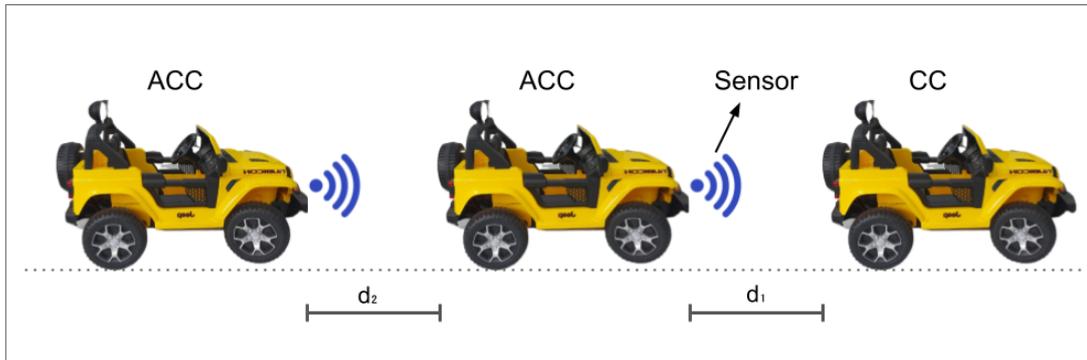
	<i>platooning</i> sem comunicação	<i>platooning</i> não cooperativo	<i>platooning</i> cooperativo
Sem informações topográfica posterior	ACC	EACC	CACC
Com informação topográfica posterior	LAC	ALAC	CLAC

Fonte: RESTIVO (2022)

### 2.3.1 *Platooning* sem comunicação

O *platooning* sem comunicação trata-se da forma mais básica de *platooning* (RESTIVO, 2022). Nesta forma de *platooning*, os veículos seguem um veículo líder e são controlados considerando apenas os dados dos sensores instalados no próprio veículo, ou seja, não existe cooperação. Por essa razão, o ACC é considerado um controlador para *platooning* por RAJAMANI; ZHU (2002). Como é descrito na subseção 2.2.4, o ACC é capaz de alterar a velocidade do veículo a fim de manter uma distância de segurança para o veículo à frente. Dessa forma, a utilização de um ACC possibilita uma forma de *platooning*, visto que é possível ter vários veículos seguindo a mesma trajetória e cada um mantendo uma distância de segurança para o veículo à frente. Este método de *platooning* não é muito eficaz, pois, como o veículo seguidor não tem qualquer informação sobre o veículo que segue, além da distância em que se encontra, poderão ocorrer situações de aceleração e frenagem indesejadas (RESTIVO, 2022).

Figura 9 – Platooning baseado em ACC



Fonte: O autor (2024)

É possível observar na Figura 9 que o líder do *platooning* utiliza o CC, que controla apenas a sua aceleração, já os restantes membros do *platooning* seguem o líder tendo como referência a distância a que se encontram do veículo à sua frente. Esta distância pode ser fornecida por diversos sensores como radar, lidar ou câmeras estereoscopia instalados na parte frontal do veículo. Atualmente, o ACC é constituído por mais e melhores sensores que são capazes de fornecer mais informações e mais precisas (RESTIVO, 2022). Apesar de o ACC garantir a distância de segurança entre os veículos, em LU; HEDRICK (2004) é discutida a estabilidade do sistema de acordo com o número de veículos, onde é demonstrado que, se o *platooning* for formado por três ou mais veículos, o sistema torna-se instável. Isso ocorre devido aos atrasos na detecção de mudança de velocidade, causados por atrasos na comunicação e no processamento dos dados.

### 2.3.2 *Platooning* com comunicação

A comunicação é uma das principais características do *platooning* de veículos autônomos (COELHO, 2023). Existem dois tipos de comunicação usados nessa técnica: a comunicação Veículo a Veículo (*Vehicle-to-Vehicle*, V2V) e a comunicação Veículo a Infraestrutura (*Vehicle-to-Infrastructure*, V2I). A comunicação V2V permite que os veículos troquem informações entre si, como a posição, velocidade e aceleração, para que possam se ajustar e manter a formação. Já a comunicação V2I permite que os veículos recebam informações do ambiente ao redor, como o estado do trânsito, a presença de obstáculos e as condições meteorológicas. Essas informações ajudam os veículos a se adaptarem às condições de condução e a tomar decisões mais precisas (COELHO, 2023).

A comunicação permite assim a implementação do *platooning* com comunicação que se-

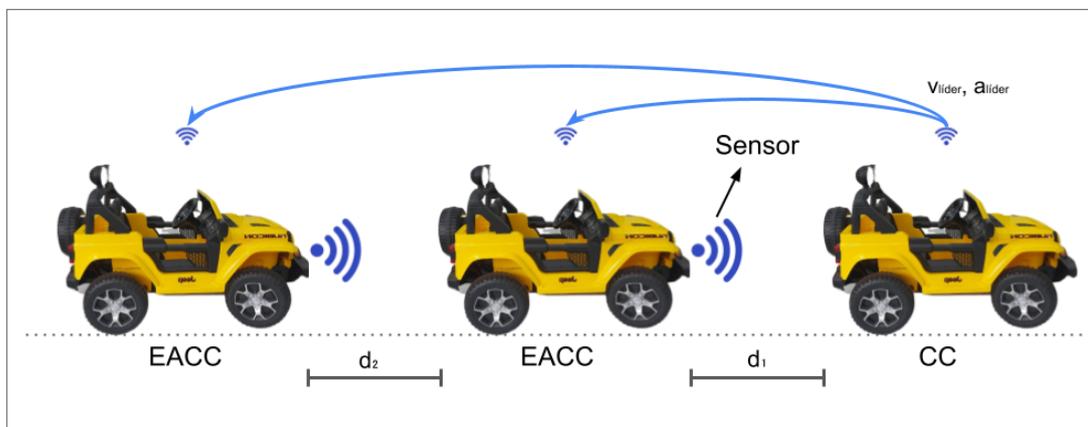
gundo RESTIVO (2022) pode ser dividido em duas categorias, o cooperativo e o não cooperativo. O platooning cooperativo procura adaptar a estratégia de cada veículo de forma a obter a máxima eficiência do conjunto enquanto que no platooning não cooperativo cada veículo procura otimizar o seu próprio trajeto com as informações fornecidas pelos outros veículos.

### 2.3.2.1 Platooning não cooperativo

No *platooning* não cooperativo, cada veículo utiliza a comunicação V2V /V2I para receber informações dos outros veículos e/ou da infraestrutura, com a finalidade de minimizar os seus próprios objetivos sem considerar o objetivo geral do *platooning* (RESTIVO, 2022).

A comunicação, aliada aos sistemas de apoio à condução longitudinal descritos anteriormente, pode auxiliar na correção de algumas falhas que o platooning sem comunicação apresenta. Em OHLSEN; STEN (2018) é proposto um método no qual combina o ACC com a comunicação V2V, onde cada veículo utiliza a velocidade e aceleração dos elementos precedentes de forma a eliminar a propagação de erros existente no controle de um *platooning* utilizando apenas ACC, os autores referem-se a esta arquitetura de controle como *Extended Adaptive Cruise Control* (EACC), a arquitetura proposta pode ser visualizada na Figura 10. O modelo, testado através de simulações, comprovou ser bastante eficaz tendo apenas pouca eficácia em descidas mais acentuadas. Isso deve-se ao fato de que, na simulação, os veículos não utilizam o sistema de freios para desacelerar o veículo.

Figura 10 – Platooning baseado em EACC



Fonte: O autor (2024)

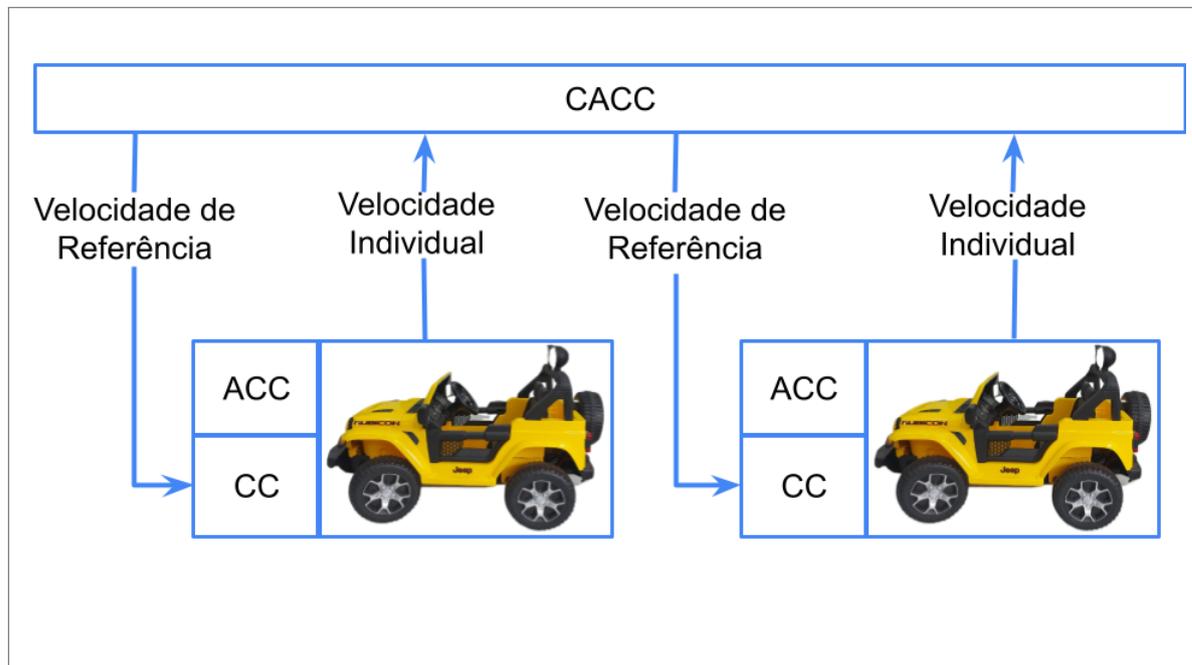
Em RESTIVO (2022), é proposto um controle de *platooning* com comunicação, não cooperativo, que possui a mesma arquitetura do controlador ACC para distância. No entanto, o plano de velocidade gerado na saída do controlador deve seguir de forma a manter a distância

$d$  ( $d = d_{ref} \times i$ ) do veículo líder. Com essa estratégia, foi possível o controle de um *platooning* com seis veículos, em comparação com o resultado de quatro veículos para um *platooning* sem comunicação.

### 2.3.2.2 *Platooning Cooperativo*

No *platooning* cooperativo, os veículos trocam informações entre si (V2V) e com a infraestrutura (V2I) com a finalidade de minimizar os objetivos gerais do grupo. O controlador deve receber informações sobre todos os veículos do *platooning* e definir o plano de velocidade ótimo para cada veículo, comunicando a cada elemento do *platooning*, conforme mostra a Figura 11. Dessa forma, a implementação do controlador não está fixa a nenhuma estrutura específica, podendo ser implementada tanto nos veículos como, por exemplo, no veículo líder quanto na infraestrutura.

Figura 11 – Platooning baseado em CACC



Fonte: O autor (2024)

A arquitetura apresentada na Figura 11 consiste em uma estratégia de controle por camadas. A primeira camada, o CC convencional, mantém a velocidade do veículo de acordo com a referência. A camada acima, o ACC, tem como função manter a distância desejada entre os veículos e é de extrema importância para a segurança do platooning, uma vez que, em caso de perda de comunicação, esse controlador entra em ação para garantir que os veículos não

colidam. Por fim, a camada do topo consiste em um controlador CACC que, quando o sistema possui comunicação, toma decisões de controle para cada veículo, levando em consideração o comportamento geral do platooning. Este controlador tem como função manter uma distância adequada entre os veículos dentro do raio de comunicação (RESTIVO, 2022).

Em SHLADOVER et al. (2018) os autores propõem uma solução de controle CACC descentralizada onde cada veículo se encontra equipado com um sistema CC, ACC e CACC. Inicialmente, um veículo viajando fora de um *platooning* é controlado por CC, à velocidade definida pelo seu condutor. Se o veículo se deparar com outro veículo com o qual não consegue comunicar, passa a ser controlado por ACC e segue-o. No entanto, se conseguir comunicar com o veículo à sua frente, passa a ser controlado por CACC e se integra ao *platooning*. Esse veículo começa a comunicar também com o líder do *platooning* e com o veículo que o precede, de forma a manter o intervalo definido entre os veículos.

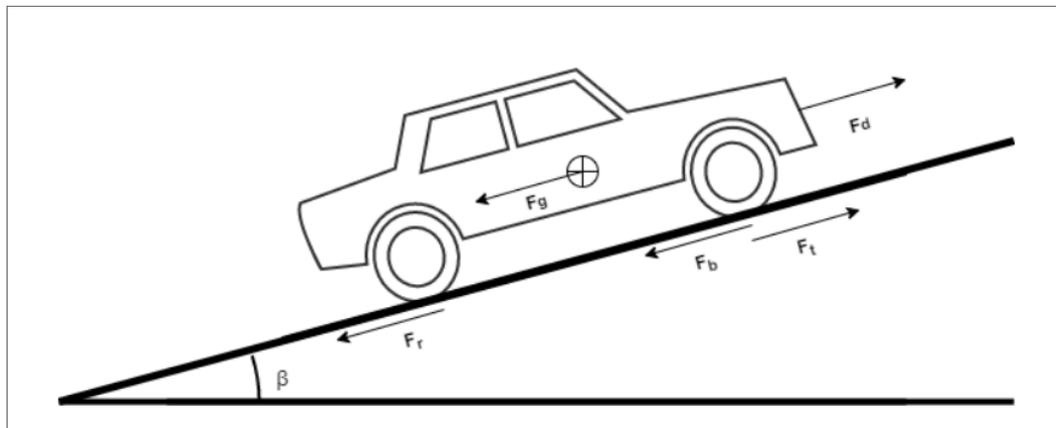
### 3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, serão apresentados os fundamentos teóricos que servem de base para a pesquisa, com as definições necessárias para a compreensão geral do trabalho. Na Seção 3.1, é apresentado o modelo de dinâmica longitudinal de veículos. Na Seção 3.2, será descrito como é feita a identificação desses sistemas dinâmicos para obter um modelo computacional. Na Seção 3.3, são apresentados conceitos e definições sobre sistemas de controle. Os conceitos de um controlador Fuzzy serão abordados na Seção 3.4. Por fim, na Seção 3.5, são descritas as métricas de avaliação da resposta temporal dos controladores.

#### 3.1 DINÂMICA LONGITUDINAL DE VEÍCULOS

Um veículo em movimento encontra-se sujeito a diversas forças para além das produzidas pelo seu motor e sistema de freios. Uma visão geral das forças que atuam longitudinalmente sobre um veículo podem ser observadas na Figura 12.

Figura 12 – Representação das forças longitudinais



Fonte: RESTIVO (2022)

Aplicando a segunda lei de Newton pode-se obter a dinâmica do veículo por meio da equação 3.1.

$$m_i \dot{v}_i = \vec{F}_{t,i} + \vec{F}_{b,i} + \vec{F}_{r,i} + \vec{F}_{d,i} \quad (3.1)$$

Em que  $\vec{F}_t$  e  $\vec{F}_b$  representam as forças geradas pelos atuadores, respectivamente as forças de tração e de frenagem,  $\vec{F}_d$  e  $\vec{F}_r$  representam as forças de atrito do ar e de rolagem,  $\vec{F}_g$  representa a força gravitacional e  $i$  representa o índice de posição do veículo no *platooning*.

### 3.1.1 Força de Tração/Frenagem

A força de tração representa a força fornecida aos pneus do veículo de forma a o movimentar. Essa força é gerada pelo motor do veículo e pode ser reduzida/amplificada pelo sistema de *PowerTrain*. Já a força de frenagem é a força contrária ao movimento que faz com que o veículo desacelere mais rapidamente. Essa força é proveniente do sistema de frenagem e pode perder capacidade de acordo com o desgaste das pastilhas que entram em contato com o pneu. De forma a simplificar o modelo, ambas as forças são representadas pela equação 3.2:

$$\vec{F}_{t,i} + \vec{F}_{b,i} = m_i \vec{\xi}_i \quad (3.2)$$

Em que  $\xi_i$  representa a aceleração do motor/freios.

### 3.1.2 Força Gravitacional

A força gravitacional resulta da atuação da aceleração da gravidade no eixo longitudinal. Esta força pode resistir ou assitir ao movimento de acordo com a inclinação da rodovia. Assim, ela é representada pela equação 3.3:

$$\vec{F}_{g,i}(\alpha) = m_i \vec{g}_i \quad (3.3)$$

### 3.1.3 Força de Rolagem

A força de rolagem resulta do atrito entre os pneus do veículo e a superfície da rodovia. Trata-se de uma força resistiva que se deve, principalmente, à deformação dos penus durante a compressão e expansão dos mesmos. Esta força é aproximadamente proporcional à carga vertical e é representada pela equação 3.4.

$$\vec{F}_{r,i}(\alpha) = -c_r m_i g_a \quad (3.4)$$

Em que  $c_r$  representa o coeficiente de rolamento do veículo  $i$ , e depende da temperatura, pressão e dimensões dos pneus. Desta Forma, a fim de estudos pode-se considerar que não há variação de nenhum destes fatores, logo a força de rolamento pode ser considerada constante.

### 3.1.4 Força de Resistência Aerodinâmica

A força de resistência aerodinâmica resulta do deslocamento do ar causado em consequência do movimento do veículo. Desta forma esta força resistiva não se comporta como as restantes que são independentes da velocidade do veículo. A força de atrito aerodinâmico é representada pela equação 3.5.

$$\vec{F}_{d,i} = \frac{1}{2} \rho_i v^2 c_{d,i} A_i \quad (3.5)$$

Em que  $\rho$  representa a densidade do fluido pelo qual o corpo em movimento se encontra envolvido,  $v$  representa a velocidade do corpo,  $A$  representa área do corpo e  $c_d$  representa o coeficiente de resistência aerodinâmica

## 3.2 IDENTIFICAÇÃO DE SISTEMAS

A modelagem de sistemas é uma forma imperativa de explorar e compreender os processos físicos e é a base para o projeto de controle baseado em modelos para prever o comportamento futuro de plantas dinâmicas (CHRISTUDAS; DHANRAJ, 2021).

A identificação de sistemas é uma prática crucial na modelagem matemática, permitindo a aproximação do comportamento real de um sistema por meio de diferentes métodos. Os métodos de identificação de sistemas são variados e segundo PATIL; DATAR; PATIL (2018) podem ser divididos em três categorias distintas:

- Identificação Caixa Branca: Esta abordagem se baseia no conhecimento das leis físicas que regem o sistema, como na modelagem de um circuito eletrônico no qual os componentes e conexões são conhecidos.
- Identificação Caixa Cinza: Esta metodologia combina conhecimento prévio do sistema com medidas da resposta aos sinais de entrada e saída.
- Identificação Caixa Preta: Nesta técnica, o foco está nos estímulos de entrada do sistema e na sua resposta a cada estímulo, sem considerar o conhecimento interno do sistema.

A identificação de sistemas por modelos computacionais é possível devido as diversas ferramentas computacionais oferecidas atualmente, como o system identification do Matlab. A ampla oferta destes pacotes permite a modelagem em mais de uma técnica, permitindo a

comparação e a seleção do modelo mais eficiente. Entretanto, para a realização deste tipo de modelagem é necessário uma grande disponibilidade de dados amostrais de toda região de operação do sistema, que devem ser obtidos através de ensaios experimentais da planta (MOREIRA, 2020). Dentre os modelos mais utilizados estão os paramétricos e os inteligentes.

Segundo MOREIRA (2020) há algumas estruturas de modelos padrões utilizadas na identificação paramétrica, que normalmente são estruturas de modelos discretos. Dentre os diferentes modelos utilizados, destacam-se: Box-Jenkins (BJ), Output Error (OE), Auto Regressivo com Entradas Exógenas (ARX), Auto Regressivo com Média Móvel e Entradas Exógenas (ARMAX) e estrutura de Espaço de Estados (SS).

Técnicas de inteligência artificial, como as redes neurais, são também utilizadas para a identificação de sistemas, devido a sua capacidade de relacionar variáveis de entrada para saídas com características não-lineares.

### 3.2.1 Modelos Paramétricos

Os modelos paramétricos consistem em um extenso conjunto de técnicas matemáticas usadas para representar o comportamento de um sistema. Os dois modelos mais utilizados para representar a dinâmica dos sistemas são o modelo de Função de Transferência e o de Espaço de Estados.

A função de transferência é um conceito fundamental em controle, utilizado para descrever a relação matemática entre a entrada e a saída de um sistema linear e invariante no tempo (LTI) (DUARTE; FIGUEIREDO, 2022). Essa relação é expressa na forma de uma fração polinomial no domínio da frequência, com o numerador representando os zeros do sistema e o denominador representando os polos, admitindo-se as condições iniciais nulas conforme pode ser visto na Eq. 3.6.

$$H(s) = \frac{b_0 + b_1s + \dots + b_ms^2}{a_0 + a_1s + \dots + a_ns^n} \quad (3.6)$$

A função de transferência simplifica a análise e o projeto de sistemas de controle, permitindo a utilização de técnicas como a resposta em frequência e o lugar das raízes para determinar a estabilidade e o desempenho do sistema. Além disso, ela é essencial na modelagem de sistemas dinâmicos em diversas áreas da engenharia e ciências aplicadas (MATSUURA; AFONSO, 2020). Segundo MATHWORKS (2024), as funções de transferência podem ser usadas para representar

sistemas tanto contínuos quanto discretos, sendo definidas pelos coeficientes dos polinômios que descrevem seus numeradores e denominadores. Isso facilita a criação de modelos para análise e sintonia de controladores, além de permitir a simulação de diferentes condições operacionais.

Por sua vez, a abordagem de Espaço de Estados é uma abordagem típica da teoria de controle moderno, pois é uma abordagem aplicada a sistemas de entradas e de saídas múltiplas, que podem ou não ser lineares, variantes ou não no tempo (OGATA, 2011). Um estado de um sistema dinâmico é o menor conjunto de variáveis que, junto com o conhecimento da entrada, determina completamente o comportamento do sistema (OGATA, 2011). A análise no espaço de estados envolve três tipos de variáveis que estão presentes na modelagem de sistemas dinâmicos: variáveis de entrada, variáveis de saída e variáveis de estado. A representação de dado sistema no espaço de estados não é única, mas o número de variáveis de estado é o mesmo para qualquer uma das diferentes representações do mesmo sistema no espaço de estados (OGATA, 2011).

Um sistema de espaço de estados pode ser representado como:

$$\dot{x}(t) = Ax(t) + Bu(t) \quad (3.7)$$

$$y(t) = Cx(t) + Du(t) \quad (3.8)$$

Em que,  $x(t)$  é o vetor de estados,  $u(t)$  o vetor de entradas,  $y(t)$  o vetor de saídas,  $\mathbf{A}$  é chamada matriz de estado,  $\mathbf{B}$  de matriz de entrada,  $\mathbf{C}$  de matriz de saída e  $\mathbf{D}$  de matriz de transmissão direta.

### 3.2.2 Modelos Inteligentes

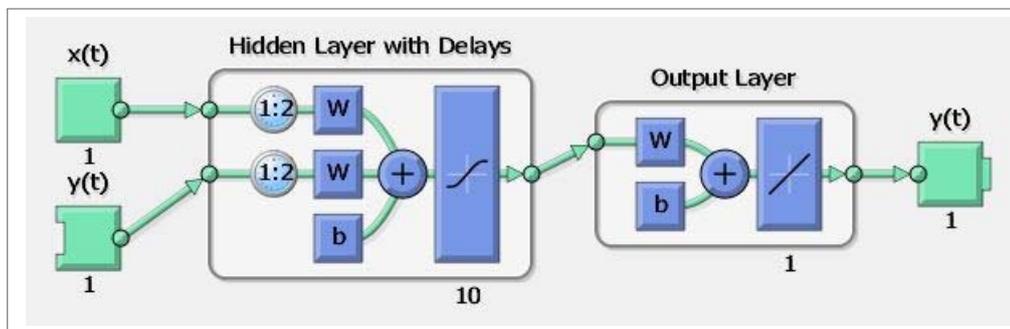
As técnicas computacionais progrediram muito nos últimos anos e estão tomando o lugar da matemática clássica na modelagem e no projeto de muitos sistemas dinâmicos (MOREIRA; GOMES; VILLANUEVA, 2019). De certo, sistemas muito complexos e com não-linearidades severas são melhor representados por modelos computacionais, principalmente por modelos inteligentes, como as redes neurais, modelos de *deep learning* e *Neuro-Fuzzy* (MOREIRA, 2020).

A rede NARX, ou *Nonlinear AutoRegressive with eXogenous inputs*, é um tipo de modelo de Rede Neural Recorrente (*Recurrente Neural Network*, RNN) amplamente utilizado em pro-

blemas de previsão e modelagem de séries temporais (AGUIRRE, 2015). O que a torna distinta é sua capacidade de capturar relações complexas e não-lineares entre variáveis, incorporando tanto os valores passados da própria série temporal quanto entradas externas relevantes. A estrutura NARX permite que a rede aprenda a relação entre os dados passados e futuros, possibilitando a previsão de valores futuros com base em um histórico de observações.

A Figura 13 apresenta a arquitetura da rede NARX que consiste em alguns neurônios na camada escondida com a função de ativação tangente hiperbólica, passando para um neurônio na camada de saída com função de ativação Purelin, além disso apresenta o valor de *delay* que representa quantos valores de recorrência serão considerados para a previsão.

Figura 13 – Arquitetura da rede NARX



Fonte: CHRISTUDAS; DHANRAJ (2021)

### 3.2.3 Avaliação dos Modelos

A utilização de indicadores é necessária para avaliar quantitativamente os modelos desenvolvidos por técnicas de identificação de sistemas (MOREIRA, 2020). De acordo com MOREIRA (2020), as principais métricas para avaliação dos modelos são:

- Raiz do Erro Médio Quadrático, do inglês Root Mean Squared Error (RMSE): apresentada na equação 3.9 quantifica a média das diferenças entre as previsões do modelo e os valores reais, com a peculiaridade de elevar essas diferenças ao quadrado.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3.9)$$

A validade da RMSE na avaliação de modelos tem sido amplamente discutida na literatura recente. Segundo HYNDMAN; ATHANASOPOULOS (2021), a RMSE é uma das métricas mais recomendadas para a avaliação de modelos de previsão devido à sua simplicidade e eficiência em refletir a precisão do modelo. Da mesma forma, um estudo

conduzido por CHAI; DRAXLER (2014) destacou que a RMSE é uma métrica robusta para a avaliação de modelos ambientais, dado que ela captura tanto a variabilidade quanto a tendência dos erros de previsão.

- Raiz do Erro Médio Quadrático Normalizada, do inglês Normalized Root Mean Squared Error (NRMSE): apresentada na equação 3.10 considera a escala dos dados ao normalizar o erro pela amplitude dos valores reais.

$$NRMSE = \frac{1}{y_{max} - y_{min}} * RMSE \quad (3.10)$$

- Ajuste (Fit): apresentada na equação 3.11 refere-se à capacidade de um modelo se ajustar aos dados observados. Seu valor é dado em porcentagem e indica quão próximo dos dados reais o modelo está ajustado.

$$Fit = \left(1 - \frac{\|\hat{y}_i - y_i\|}{\|\hat{y}_i - \text{mean}(\hat{y}_i)\|}\right) * 100 \quad (3.11)$$

Onde:

- $n$  é o número total de amostras
- $\hat{y}_i$  é a saída desejada
- $y_i$  é a saída observada
- $\|\cdot\|$  indica a norma-2 de um vetor.

### 3.3 SISTEMAS DE CONTROLE

O objetivo básico de um sistema de controle consiste em aplicar sinais adequados na entrada do processo de modo a que o sinal de saída satisfaça certas especificações e/ou apresente um comportamento particular (BAYER; ARAÚJO, 2011). O sistema a ser controlado, comumente chamado de processo ou planta, é o dispositivo ou fenômeno sobre o qual se deseja controlar. Ele é representado por uma ou mais variáveis de entrada, uma ou mais variáveis de saída e a relação entre essas variáveis. A entrada do processo é chamada de variável de controle ou variável manipulada, e a saída do processo é chamada de variável controlada ou variável de processo. Um distúrbio ou perturbação é caracterizado por um sinal que tende a afetar de modo adverso o valor da variável de saída de um sistema (ABREU, 2020).

Neste contexto, um Sistema de Controle pode ser dividido em dois tipos: Sistema de Controle em Malha Aberta (SCMA) e Sistema de Controle em Malha Fechada (SCMF). O SCMA consiste em aplicar um sinal de controle pré-determinado pela entrada, esperando-se que, ao final de um determinado tempo, a variável controlada atinja um valor específico ou apresente um comportamento determinado. As principais desvantagens do SCMA é a sensibilidade às perturbações e a falta de habilidade para corrigir seus efeitos. Isso ocorre pelo fato do sinal de saída não exercer nenhuma ação de controle no sistema. Isso significa que, em um SCMA, o sinal de saída não é medido nem realimentado para comparação com a entrada. Dessa forma, a precisão do sistema depende de uma calibração inicial (NISE, 2017).

Por outro lado, o SCMF compensa o efeito das perturbações utilizando informações sobre como a saída de controle está evoluindo a partir de uma realimentação. Essas informações são usadas para determinar o sinal de controle que deve ser aplicado ao processo em um instante específico. O sinal de saída é comparado com um sinal de referência e o desvio (erro) entre estes dois sinais é utilizado para determinar o sinal de controle que deve efetivamente ser aplicado ao processo (ABREU, 2020). Assim, o sinal de controle é determinado de forma a corrigir este desvio entre a saída e o sinal de referência. O dispositivo que utiliza o sinal de erro para determinar ou calcular o sinal de controle a ser aplicado à planta é chamado de controlador ou compensador (DORF; BISHOP, 2018).

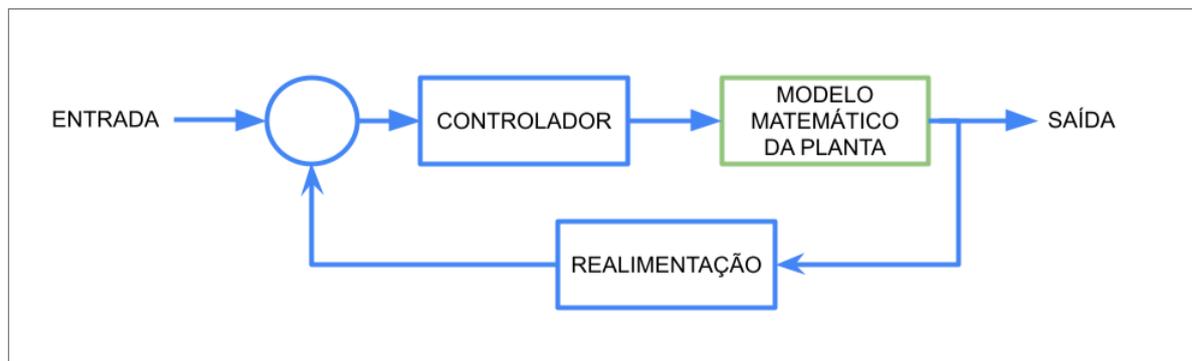
Uma vantagem dos sistemas de controle a malha fechada é o fato de que o uso da realimentação torna a resposta do sistema relativamente insensível a perturbações externas e a variações internas de parâmetros do sistema, sendo possível a utilização de componentes baratos e sem muita exatidão para obter o controle preciso de um determinado processo, o que não é possível com o controle à malha aberta. Entretanto, do ponto de vista da estabilidade, é mais fácil construir sistemas a malha aberta porque a estabilidade destes sistemas é menos problemática (OGATA, 2011). Por outro lado, a estabilidade em sistemas de controle em malha fechada é sempre um grande problema pela tendência em corrigir erros além do necessário, o que pode ocasionar oscilações de amplitude constante ou crescente com o tempo. Deve-se enfatizar que, para sistemas onde as entradas são conhecidas antecipadamente no tempo e não há distúrbios é aconselhável o uso de controle a malha aberta (OGATA, 2011).

As malhas convencionais de controle têm sido utilizadas na maioria dos processos automatizados no meio industrial. Entre os motivos pode-se mencionar: estrutura simples, robustez, reduzido número de parâmetros configurados, conhecimento intuitivo sobre o desempenho destas técnicas de controle, e requerimento mínimo de conhecimento matemático e técnico

(NISE, 2017). Entretanto, na teoria de controle convencional, os objetivos de projeto dos controladores são fixos e definidos pelo projetista. Conseqüentemente, a abordagem convencional de controle é limitada para muitas situações complexas, devido ao fato que estas requerem algumas formas de autonomia e as estratégias convencionais de controle oferecem um número reduzido de graus de liberdade. Estas complexidades caracterizam processos com modelos matemáticos "pobres", elevados níveis de ruído, rigorosos índices de desempenho, presença de não-linearidades, sensores distribuídos e a necessidade da tomada de decisões (ABREU, 2020).

Para obtenção de modelo matemático da planta, com o objetivo de se projetar o controlador, inicialmente é realizado o processo de identificação da planta, podendo ser usados métodos como caixa preta, branca e cinza. Desse modo, o projeto do controlador é realizado a partir das especificações desejadas para um bom desempenho do sistema. Apesar de o sistema de retroalimentação manter estabilidade para futuras variações e incertezas, algumas variações são tão amplas e com efeitos significativos sobre o comportamento dinâmico que um ganho de realimentação linear e com coeficientes constantes é incapaz de fornecer a flexibilidade necessária para atender às especificações de desempenho (ABREU, 2020). Sendo assim, passa a ser necessário medir continuamente estas variações e então ajustar devidamente os parâmetros de controle ("ganhos não-lineares"). A Figura 14 apresenta o diagrama de blocos típico de uma estrutura de controle clássico.

Figura 14 – Filosofia de controle clássico



Fonte: O autor (2024)

Com o objetivo de aperfeiçoar o desempenho dos controladores convencionais, diversas técnicas de controle moderno vêm sendo desenvolvidas nos últimos anos. O desenvolvimento da teoria do controle ótimo, robusto e adaptativo, tem expandido de forma significativa o conceito de automação e ampliado à factibilidade de controle automático na prática. No entanto, as técnicas envolvidas geralmente dependem da existência de um modelo matemático para a planta e para o controlador, além de requerer formas estruturadas de representação

e lógica clássica (CRUIZ, 2018). Técnicas de controle inteligente, por sua vez, buscam gerar ações de controle efetivas sem recorrer a tais hipóteses. Neste contexto, o controle *fuzzy* tem se mostrado uma alternativa viável ao controle clássico com parâmetros variantes no tempo, não-lineares e com informações imprecisas (Júnior, 2018).

### 3.4 CONTROLADORES FUZZY

A lógica *fuzzy* é uma técnica que tenta emular sistematicamente e matematicamente o raciocínio humano e as tomadas de decisão. A lógica *fuzzy* permite que os conhecimentos empíricos e heurísticos sejam representados por regras e então transferidos para um bloco de funções. Assim, a lógica *fuzzy* fornece uma maneira clara e intuitiva de implementar sistemas de controle, tomada de decisão e sistemas de diagnóstico em vários ramos da indústria (Júnior, 2018). Uma apresentação detalhada pode ser encontrada em SIMÕES; SHAW (2007) e em YEN; LANGARI (1999).

A literatura classifica os sistemas *fuzzy* considerando as características do método de tomada de decisão que eles empregam (SILVA, 2021). Nos modelos linguísticos as equações diferenciais, que normalmente caracterizam os sistemas dinâmicos, são substituídas por um conjunto de regras cuja construção abrange predicados e, muitas vezes, conhecimentos heurísticos. O método de inferência determina a forma operacional do modelo linguístico (SILVA, 2021).

Um dos métodos mais divulgados, pela sua simplicidade e por se adaptar muito bem aos controladores *fuzzy*, é o método de Mamdani, que tem como base a regra de composição de inferência max-min (SILVA, 2021). Este método considera uma função de pertinência na saída com certo perfil, de modo que uma saída dita defuzzyficada pode ser obtida por meio das propriedades de área das saídas agregadas de todas as regras (FUJIMOTO, 2005; SILVA, 2021).

Outro método utilizado para controladores *fuzzy*, é o método de Sugeno, ou TSK (Takagi, Sugeno e Kang), que consiste em uma simplificação do controlador de Mamdani, onde a saída das regras é definida como uma função das variáveis linguísticas de entrada (MOREIRA, 2020). Dessa forma, no modelo de Sugeno o processo de defuzzyficação é ignorado (HAMAM; GEORGANAS, 2008).

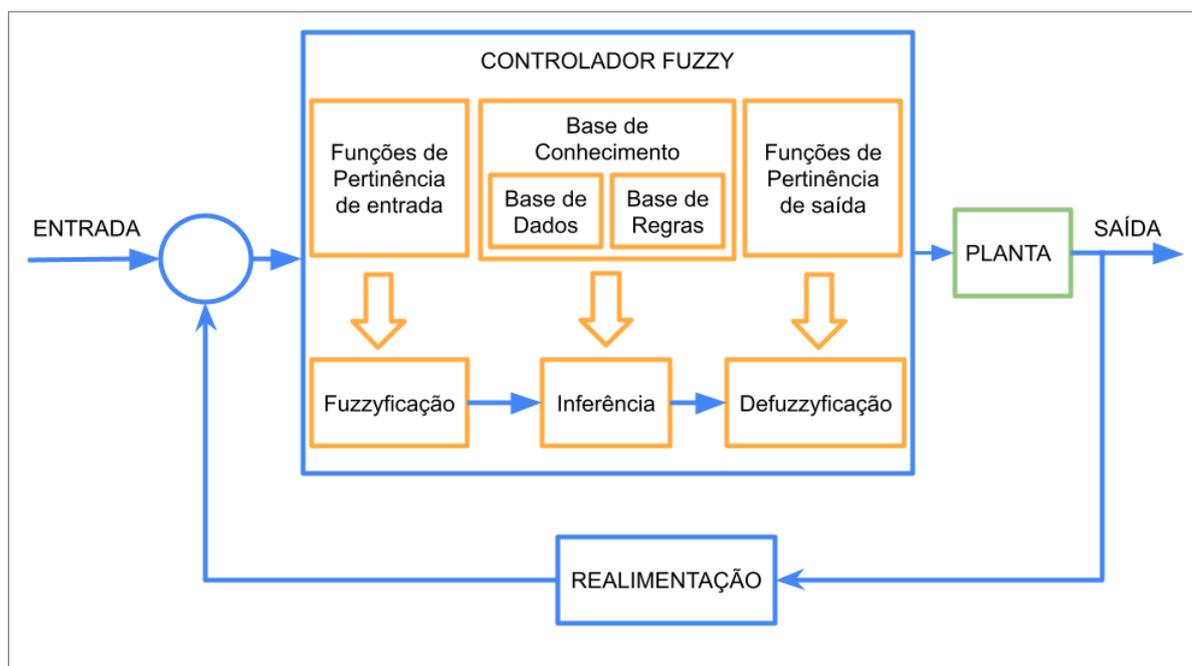
De acordo com HAMAM; GEORGANAS (2008) o método de Mamdani apresenta as seguintes vantagens em relação ao Sugeno:

- Fácil interpretabilidade;
- Resultados razoáveis com estrutura relativamente simples;
- Pode ser utilizado para sistemas com múltiplas entradas e múltiplas saídas;
- Natureza intuitiva e interpretável da base de regras. Por esta razão, o Mamdani é amplamente utilizado, em particular para aplicações de suporte à decisão;
- Maior flexibilidade na criação de regras, com saídas que podem ser conjuntos *fuzzy* complexos. Isso o torna ideal para sistemas onde a relação entre entrada e saída não é linear e requer uma modelagem mais detalhada.

### 3.4.1 Controladores *Fuzzy* Mamdani

De acordo com SIMÕES; SHAW (2007) pode-se construir um sistema *fuzzy Mamdani* utilizando os seguintes blocos básicos: fuzzyficação, base de regras, tomada de decisões e defuzzyficação. Na Figura 15 é apresentada a estrutura de um sistema de inferência *fuzzy*.

Figura 15 – Filosofia de controle Fuzzy

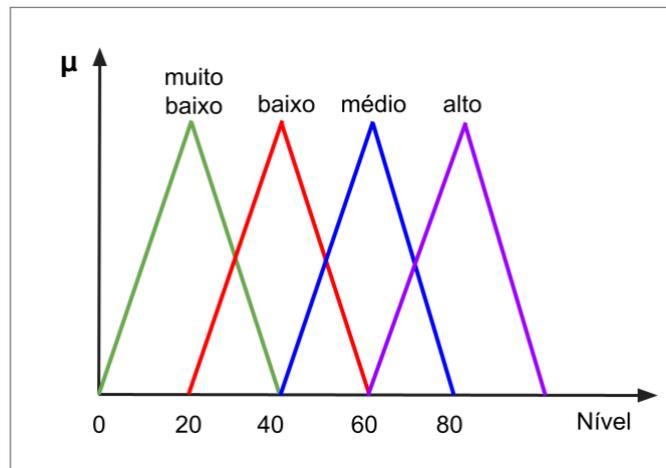


Fonte: O autor (2024)

Uma variável linguística  $x$  no universo de discurso  $X$  é definida em um conjunto de termos, nomes ou rótulos,  $A = \{x, \mu(x) \mid x \in X\}$ , com cada valor sendo um número *fuzzy* definido em  $X$  (SIMÕES; SHAW, 2007)(SENA, 2015). Um universo de discurso é um conjunto de valores

finitos que a variável linguística pode assumir. A função de pertinência,  $\mu_A(x)$ , associa a um dado componente do universo de discurso, o seu respectivo grau de pertinência a um determinado conjunto *fuzzy*. Em particular,  $\mu_A(x) = 0$  e  $\mu_A(x) = 1$ , indicam, respectivamente, a não pertinência e a pertinência completa de  $x$  ao conjunto *fuzzy*  $A$ . A Figura 16 apresenta um exemplo de variáveis linguísticas dentro de uma função de pertinência do tipo triangular, considerando  $x$  o nível de líquido de um determinado tanque que apresenta o conjunto de termos muito baixo, baixo, médio, alto, muito alto, em um universo de discurso  $X = [20, 200]$ .

Figura 16 – Funções de pertinência tipo triangular para variável nível com as devidas variáveis linguísticas



Fonte: Adaptado de (SIMÕES; SHAW, 2007)

A função de pertinência é uma função numérica gráfica ou tabulada em que se atribuem valores de pertinência *fuzzy* para valores discretos de uma variável, em um universo de discurso. Essas funções representam os aspectos fundamentais de todas as ações teóricas e práticas de um sistema *fuzzy* (SIMÕES; SHAW, 2007; SENA, 2015). Para aplicações de controle e modelagem utilizando a filosofia *fuzzy*, as mais conhecidas funções que são aplicadas são as de pertinência quadrática, linear por partes (triangular ou trapezoidal), gaussiana e sino. As funções lineares por partes são as mais populares devido à simplicidade dessas funções e ao fato de que o custo computacional adicional exigido pelos outros tipos de função não refletem, em geral, em uma melhoria significativa na qualidade dos valores de saída dos sistemas (YEN; LANGARI, 1999; SENA, 2015). O valor limiar  $\alpha$  define a sensibilidade do sistema *fuzzy*, de modo que um resultado após as operações lógicas abaixo deste valor é considerado como sendo nulo. O valor limiar é escolhido baseado em conhecimentos empíricos (SENA, 2015).

A lógica *fuzzy*, de maneira análoga à lógica clássica, pode ser descrita em termos de orações que relacionam causa e consequência, normalmente expressas na forma (*if* <antecedente> *then* <consequente>) denominadas regras de inferências. O antecedente é composto por um

conjunto de condições que, quando satisfeitas (mesmo parcialmente), determinam o processamento do conseqüente da regra por um mecanismo de inferência *fuzzy*, processo este denominado disparo de uma regra. As regras de controle difusas são declarativas, e não sequenciais, de forma que a ordem em que se expressam não é importante. De modo análogo à lógica clássica, na lógica *fuzzy* existem os operadores de conjunto união, intersecção e complemento; ou na nomenclatura booleana, ou (*or*), e (*and*) e negação (*not*), respectivamente. O análogo ao operador *and* na lógica *fuzzy* é conhecido como T-norm, e o análogo ao operador *or* como S-norm ou T-conorm. Existem diversas funções que são utilizadas para estes operadores, tais como: Zadeh, Mean, Yager, Zysno, e Dubois. As mais utilizadas são às funções de máximo e de mínimo (Zadeh) para os operadores *or* e *and*, respectivamente (FUJIMOTO, 2005; SENA, 2015), onde dados os conjuntos *fuzzy* **A** e **B** de **X**, a união e a intersecção são conjuntos *fuzzy* com funções de pertinência definidas pelas seguintes equações, respectivamente:

$$\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x)), \quad \forall x \in X \quad (3.12)$$

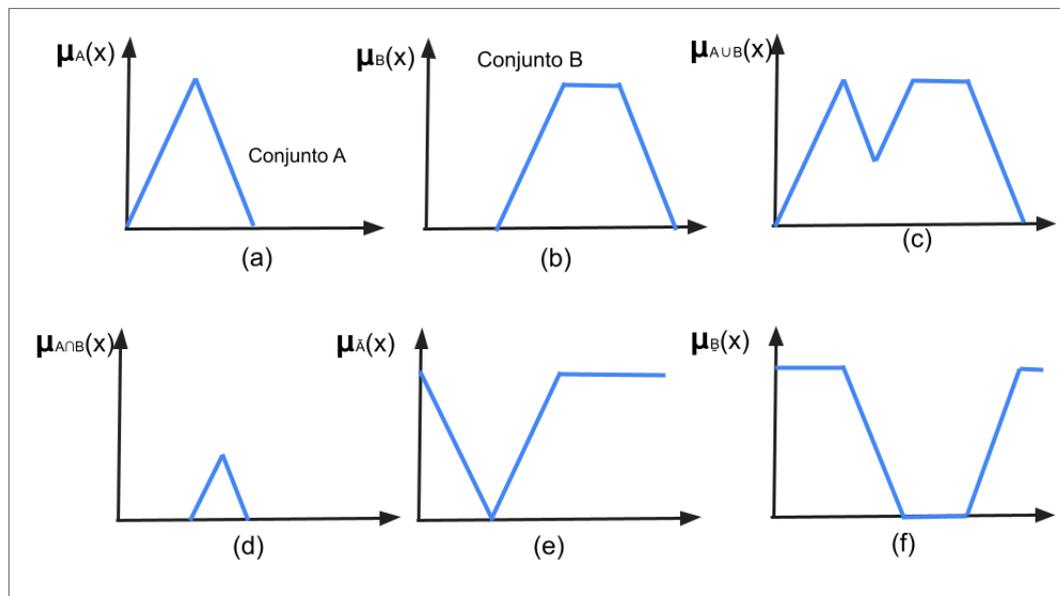
$$\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x)), \quad \forall x \in X \quad (3.13)$$

Semelhantemente, para operação complemento existem diversas variações tais como: Zadeh, Yager e threshold, sendo a mais utilizada à definição de Zadek (FUJIMOTO, 2005) da Eq.3.14.

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x), \quad \forall x \in X \quad (3.14)$$

Na Figura 17 estão representadas graficamente as operações de união, intersecção e complemento.

Figura 17 – Representações gráficas: (a) conjunto A de função triangular, (b) conjunto B de função trapezoidal, (c) operação de união entre A e B, (d) operação de intersecção entre A e B, (e) operação de complemento de A e (f) operação de complemento de B



Fonte: SENA (2015)

Existem diversos tipos de inferência para relacionar as entradas e saídas do conjunto de regras. Eles diferem pelo tipo de operador utilizado e pelos tipos de antecedentes e consequentes. As regras podem ser constituídas por uma única entrada e uma única saída (SISO, do inglês *Single-Input/Single-Output*) ou múltiplas saídas (SIMO, do inglês *Single-Input/Multiple-Output*), bem como, por múltiplas entradas e uma única saída (MISO, do inglês *Multiple-Input/Single-Output*) ou múltiplas saídas (MIMO, do inglês *Multiple-Input/Multiple-Output*) (SENA, 2015). Uma regra de inferência tipo MISO pode ser representada pela sintaxe **Se**  $x$  é  $A$  **e/ou**  $y$  **não é**  $B$  **e/ou**... .. $w$  é  $F$  **então**  $u$  é  $G$ .

O operador *then* (então) define a implicação de cada regra sobre uma dada variável linguística da saída, podendo ser definido pela função mínimo da Eq.3.15.

Onde  $\mu_{CFR}$  é a função de pertinência de saída da regra de inferência após aplicação do operador,  $\mu_{PT}$  é o grau de veracidade da oração antecedente da regra de inferência e  $\mu_{CFS}$  é a função de pertinência da oração consequente (FUJIMOTO, 2005; SENA, 2015).

$$\mu_{CFR}[X_i] \leftarrow \min(\mu_{pt}, \mu_{cfs}[X_i]) \quad (3.15)$$

O operador de agregação de regras une a influência de todas as regras obtidas após aplicação do operador *then* sobre o resultado final, apresentando a consequência do sistema como um todo devido às entradas do sistema *fuzzy* (SENA, 2015). Este operador pode ser definido pela função máximo da Eq.3.16.

$$\mu_{CFR}[X_i] \leftarrow \max_{j=1}^n (\mu_{CFR_j}[X_i]) \quad (3.16)$$

De acordo com OSIRO (2013) os métodos de defuzzyficação podem ser classificados em duas aplicações práticas distintas: melhor compromisso (centro de área e centro do máximo) e resultado mais plausível (média do máximo).

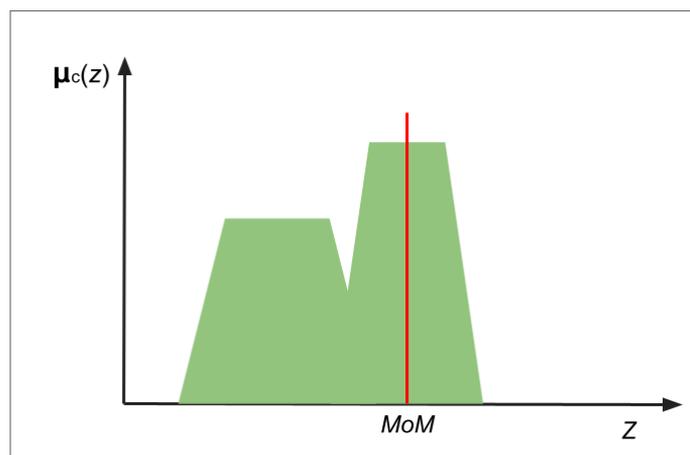
O método de defuzzyficação da Média do Máximo (MoM) calcula a média de todos os valores de saída que tenham os maiores graus de possibilidade. A Eq.3.17 determina a média do máximo, sendo  $M$  a quantidade de pontos com o mesmo valor máximo de  $\mu_C(Z)$  e  $Z_k$  são os valores correspondentes de  $Z$  onde  $\mu_C(Z)$  tem valor máximo (YAGER; FILEV, 1993)(SENA, 2015).

$$MoM = \frac{1}{M} \sum_{k=1}^M Z_k \quad (3.17)$$

A principal limitação do método MoM é que ele não considera a forma total do conjunto *fuzzy* de saída. Sendo assim, duas distribuições de possibilidades que apresentem diferentes formas, porém o mesmo conjunto de valores com grau de pertinência máximo, quando defuzzyficados fornecerá o mesmo valor clássico, o que é contra intuitivo (SENA, 2015).

Na Figura 18 apresenta a MoM para a variável de saída  $C$ . A linha MoM divide ao meio a região onde  $\mu_C(Z)$  tem valor máximo.

Figura 18 – Defuzzyficação pela média do máximo



Fonte: Adaptado de (OSIRO, 2013)

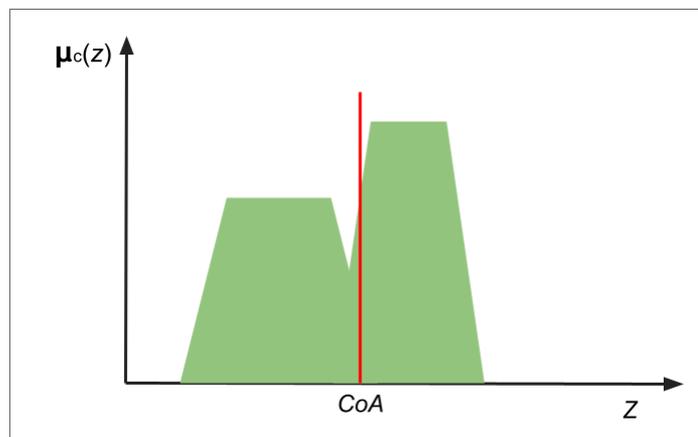
No método de centro de área (CoA) também denominado método do centro de gravidade (CoG) ou ainda centróide, a partir da área na variável de saída, obtida pela agregação dos consequentes de todas as regras. Diferentemente do MoM, a técnica do Centro de Área

para calcular o valor clássico representativo considera toda a distribuição de possibilidade de saída do modelo (SENA, 2015). O procedimento é similar ao usado para calcular o centro de gravidade em física, se consideramos a função de pertinência  $\mu_C(Z)$  como a densidade de massa de  $Z$ . Por outro lado, o método do Centro de Área pode ser compreendido como uma média ponderada, onde  $\mu_C(Z)$  funciona como o peso do valor  $Z$ . Se  $Z$  é discreto, então a defuzzyficação da conclusão fuzzy  $C$  é dada por:

$$CoA = \frac{\sum_{k=1}^N \mu_c(Z_k) Z_k}{\sum_{k=1}^N \mu_c(Z_k)} \quad (3.18)$$

A variável  $N$  é a quantidade de funções de pertinência da variável de saída. Esse tipo de defuzzyficação além de necessitar de um considerável esforço computacional, apresenta limitações quando aplicada em um processo no qual as funções de pertinência não possuem sobreposição ou quando mais de uma regra possuir a mesma saída *fuzzy*, o que caracteriza uma sobreposição de área (SENA, 2015). O método denominado de centro do máximo (CoM) apresenta um cálculo mais simples ao ignorar as áreas das funções de pertinência ao considerar apenas seus respectivos picos (OSIRO, 2013)(SENA, 2015). Na Figura 19 a centroide ou centro de gravidade da região em verde está na linha CoA.

Figura 19 – Defuzzyficação pelo Centro de Área



Fonte: Adaptado de (OSIRO, 2013)

### 3.5 AVALIAÇÃO DE CONTROLADORES

Segundo OGATA (2011) a resposta temporal de um sistema de controle consiste em duas partes: a resposta transitória e a resposta estacionária. Por resposta transitória, entende-se aquela que vai do estado inicial ao estado final. Por resposta estacionária, entendemos o

comportamento do sinal de saída do sistema na medida em que  $t$  tende ao infinito. Assim, a resposta  $c(t)$  do sistema pode ser escrita como:

$$c(t) = c_{tr}(t) + c_{ss}(t) \quad (3.19)$$

onde  $c_{tr}(t)$  é a resposta transitória e  $C_{ss}(t)$  é a resposta estacionária. De acordo com OGATA (2011) as características de desempenho de um sistema de controle são especificadas em termos de resposta transitória a uma entrada em degrau unitário, já que se trata de entrada suficientemente brusca e gerada com facilidade. Além disso quando a resposta a uma entrada em degrau é conhecida, é possível calcular matematicamente a resposta a qualquer tipo de sinal de entrada.

A resposta transitória de um sistema a uma entrada em degrau unitário varia conforme as condições iniciais. Para facilitar a comparação entre as respostas transitórias de diferentes sistemas, é comum adotar uma condição inicial padrão, onde o sistema está inicialmente em repouso. Isso significa que o valor da variável de saída e todas as suas derivadas em relação ao tempo são iguais a zero. Dessa forma, as características de resposta dos diversos sistemas podem ser comparadas de maneira mais fácil.

Quando o sistema é subamortecido, antes de atingir o regime permanente, a resposta transitória apresenta, frequentemente, oscilações amortecidas. Assim, é possível definir algumas características da resposta do sistema, entre elas:

1. Tempo de atraso,  $t_d$
2. Tempo de subida,  $t_r$
3. Tempo de pico,  $t_p$
4. Máximo sobressinal (ou apenas sobressinal),  $M_p$
5. Tempo de acomodação,  $t_s$

Essas características são definidas a seguir e podem ser visualizadas na Figura 20.

1. Tempo de atraso: trata-se do tempo requerido para que a resposta alcance metade de seu valor final pela primeira vez.
2. Tempo de subida: é o tempo requerido para que a resposta passe de 10 a 90%, ou de 5% a 95%, ou de 0% a 100% do valor final. Para sistemas de segunda ordem

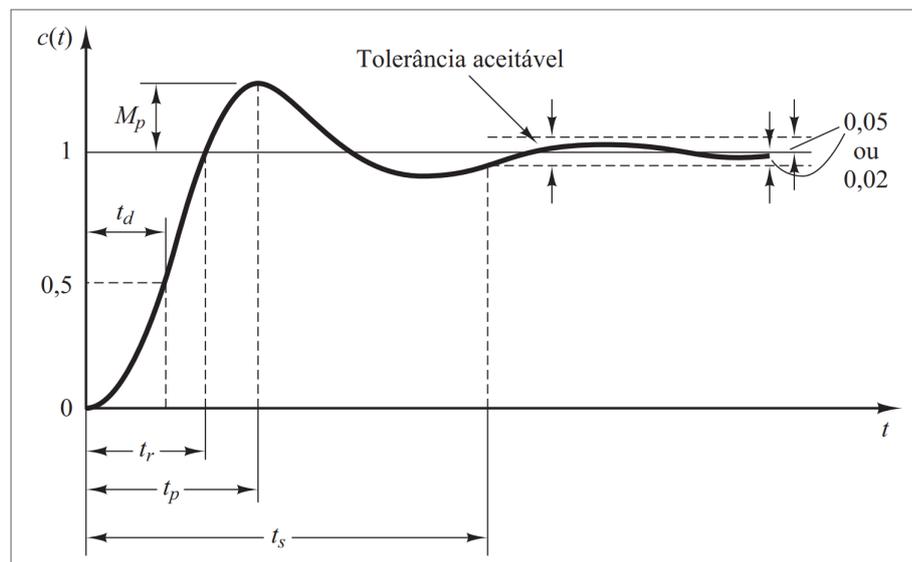
subamortecidos, o tempo de subida de 0% a 100% é o normalmente utilizado. Para os sistemas superamortecidos, o tempo de subida de 10% a 90% é o mais comumente utilizado.

3. Tempo de pico: é o tempo para que a resposta atinja o primeiro pico de sobressinal.
4. Máximo sobressinal (em porcentagem): é o valor máximo de pico da curva de resposta, medido a partir da unidade. Se o valor final da resposta em regime permanente diferir da unidade, então é comum utilizar porcentagem máxima de sobressinal, definida por:

$$M_p = \frac{c(t_p) - c(\infty)}{c(\infty)} * 100\% \quad (3.20)$$

5. Tempo de acomodação: é o tempo necessário para que a curva de resposta alcance valores em uma faixa (geralmente de 2% ou 5%) em torno do valor final, aí permanecendo indefinidamente. O tempo de acomodação está relacionado à maior constante de tempo do sistema de controle. Pode-se determinar qual porcentagem deve ser utilizada no critério de erro a partir dos objetivos do projeto do sistema em questão.

Figura 20 – Curva de resposta em degrau unitário



Fonte: OGATA (2011)

## 4 METODOLOGIA

Este capítulo apresenta o sistema experimental utilizado no trabalho, mostrando o veículo de escala reduzida utilizado para a realização dos ensaios experimentais e testes relacionados ao controlador FM-ACC. São detalhados, também, os procedimentos metodológicos utilizados para obter o modelo computacional do sistema em caixa preta, bem como é apresentado a arquitetura proposta CNN-REI. Por fim, é apresentado a arquitetura de controle proposto para este trabalho.

### 4.1 SETUP EXPERIMENTAL

Durante o trabalho é utilizado a ferramenta do MATLAB/Simulink para o desenvolvimento dos modelos de identificação de sistemas, para o projeto dos controladores e para geração de resultados simulados.

O MATLAB é um ambiente de computação técnica e uma linguagem de programação de alto nível. Ele é amplamente utilizado para análise de dados, desenvolvimento de algoritmos e criação de modelos. Com uma vasta gama de toolboxes, o MATLAB permite que os usuários realizem tarefas complexas de maneira eficiente.

Por sua vez, o Simulink é uma plataforma de simulação e modelagem multidomínio integrada ao MATLAB. Ele oferece um ambiente gráfico para a construção de modelos de sistemas dinâmicos, permitindo simulações rápidas e precisas. Simulink é amplamente utilizado em engenharia, ciência e em várias áreas da indústria para projetar, simular, testar e implementar sistemas.

Durante o desenvolvimento do trabalho, foi necessária a utilização de algumas *toolboxes* que fornecem funcionalidades extras ao oferecido pelo MATLAB/Simulink. As *toolboxes* utilizadas foram:

- **System Identification Toolbox:** oferece funções para criar modelos matemáticos de sistemas dinâmicos a partir de dados medidos. Suas principais funcionalidades incluem:
  - **Importação de Dados:** Ferramentas para importar e preparar dados de entrada e saída.
  - **Modelagem de Sistemas:** Funções para estimar modelos de sistemas lineares e não lineares, incluindo modelos de funções de transferência e espaço de estados.

- 
- **Validação de Modelos:** Ferramentas para comparar o desempenho de diferentes modelos e validar a precisão usando dados de validação.
  - **Análise de Modelos:** Ferramentas para analisar a resposta do modelo e a estabilidade do sistema.
  - **Control System Toolbox:** fornece algoritmos e ferramentas para projetar, analisar e ajustar sistemas de controle. Suas funcionalidades incluem:
    - **Modelagem de Sistemas de Controle:** Funções para criar modelos de controle em espaços de estados, funções de transferência e sistemas em malha fechada.
    - **Projeto de Controladores:** Ferramentas para projetar controladores PID, LQR, e outros tipos de controladores.
    - **Análise de Sistemas:** Ferramentas para analisar a estabilidade, resposta em frequência e desempenho de sistemas de controle.
    - **Simulação de Sistemas:** Ferramentas para simular a resposta de sistemas de controle a diferentes entradas e perturbações.
  - **Fuzzy Logic Toolbox:** oferece ferramentas para a modelagem e simulação de sistemas baseados em lógica *fuzzy*. Suas principais funcionalidades incluem:
    - **Criação de Sistemas Fuzzy:** Ferramentas para definir conjuntos *fuzzy*, regras *fuzzy* e funções de pertinência.
    - **Simulação de Sistemas Fuzzy:** Ambiente para simular a resposta de sistemas *fuzzy* a diferentes entradas.
    - **Análise e Ajuste:** Ferramentas para ajustar e otimizar regras *fuzzy* e funções de pertinência com base em dados experimentais.
    - **Integração com Simulink:** Blocos para integrar sistemas fuzzy em modelos Simulink.
  - **Deep Learning Toolbox:** oferece um conjunto completo de ferramentas para o *design*, treinamento e implementação de redes neurais profundas. Suas funcionalidades incluem:
    - **Projeto de Redes Neurais:** Ferramentas para criar arquiteturas de redes neurais, incluindo CNNs, RNNs e GANs.

- **Treinamento de Redes Neurais:** Funções para treinar redes neurais usando GPUs para acelerar o processo.
- **Avaliação e Validação:** Ferramentas para avaliar a precisão e generalização das redes neurais treinadas.
- **Implementação e Deploy:** Ferramentas para implementar redes neurais em diferentes plataformas, incluindo dispositivos embarcados.

#### 4.2 VEÍCULO DE ESCALA REDUZIDA

O veículo de escala reduzida, apresentado na Figura 21, é utilizado para gerar o *dataset*, que é empregado na criação do modelo em caixa preta e na validação do controlador proposto em um estudo de caso. Este veículo, um modelo Jeep Bandeirantes Wrangler, possui tração traseira nas rodas e permite o esterçamento do volante para ambos os lados.

Figura 21 – Veículo de Escala Reduzida

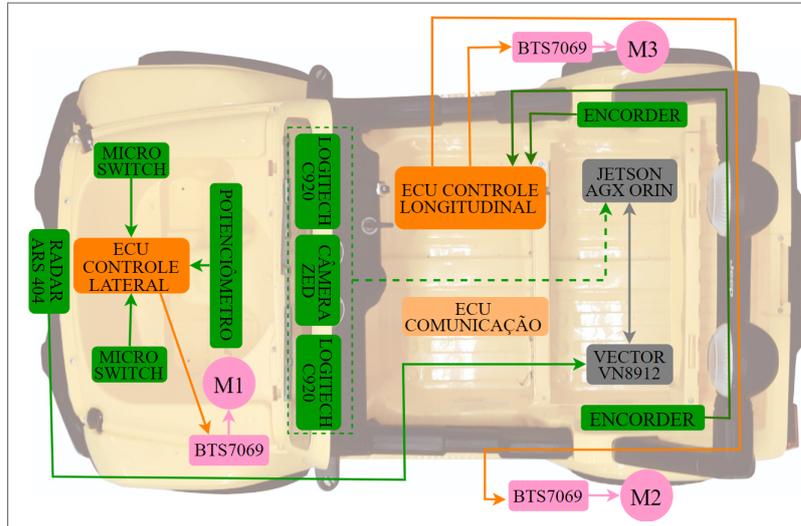


Fonte: O autor (2024)

COELHO (2023) desenvolveu a arquitetura de sensoriamento para o veículo de escala reduzida apresentado na Figura 22. A tração do veículo é realizada pelas duas rodas traseiras, por meio de dois motores elétricos acionados por módulos de potência do modelo BTS7069. O veículo conta com uma Unidade de Controle Eletrônico (Electronic Control Unit - ECU) para o controle longitudinal, responsável pela aceleração e frenagem do veículo. A câmera ZED2i, instalada no veículo, é um sensor estereoscópico 3D, que permite a medição de distâncias por

meio do mapa de profundidade gerado. Além disso, a ZED2i possui outros sensores integrados, como giroscópio, acelerômetro e magnetômetro, possibilitando a medição de variáveis dinâmicas do veículo, como a velocidade longitudinal.

Figura 22 – Arquitetura de sensoriamento do Veículo de Escala Reduzida



Fonte: COELHO (2023)

Apesar de o veículo possuir um radar em sua estrutura, durante o desenvolvimento deste trabalho foi utilizado o mapa de profundidade gerado pela ZED2i para a medição da distância de objetos. Isso ocorreu porque o radar ARS404 é um radar automotivo comercial e não possui resolução suficiente para a detecção dos veículos de escala reduzida. Informações adicionais sobre os demais sensores equipados ao veículo de escala reduzida podem ser encontradas em COELHO (2023).

### 4.3 MODELAGEM EM CAIXA PRETA

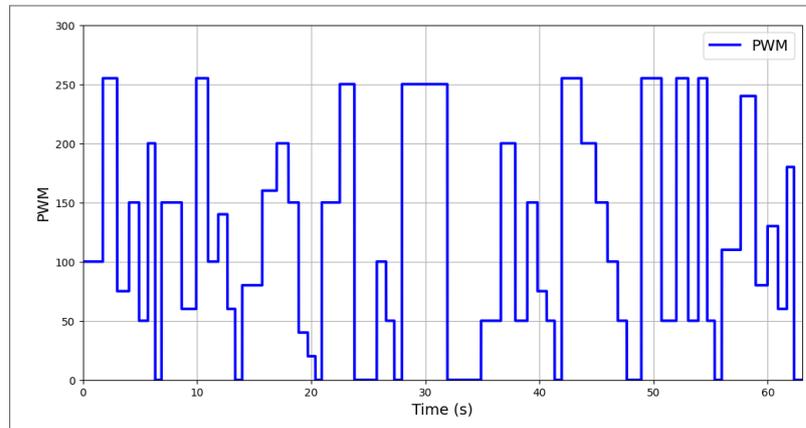
Nesta seção é apresentado o *dataset* utilizado para o treinamento e validação do modelo computacional em caixa preta do sistema de dinâmica longitudinal do veículo de escala reduzida. Além disso, é apresentado a arquitetura do modelo inteligente proposto baseado em CNN.

#### 4.3.1 *Dataset*

O conjunto de dados utilizado é composto por 7674 amostras coletadas a uma frequência de  $122Hz$ . A variável de controle empregada é o valor do Controle por Modulação de Pulso

(PWM) aplicado aos motores elétricos responsáveis pela força de tração do veículo. O sinal PWM varia de 0 a 255, representando 0 a 5V, respectivamente. A Figura 23 apresenta os valores do PWM.

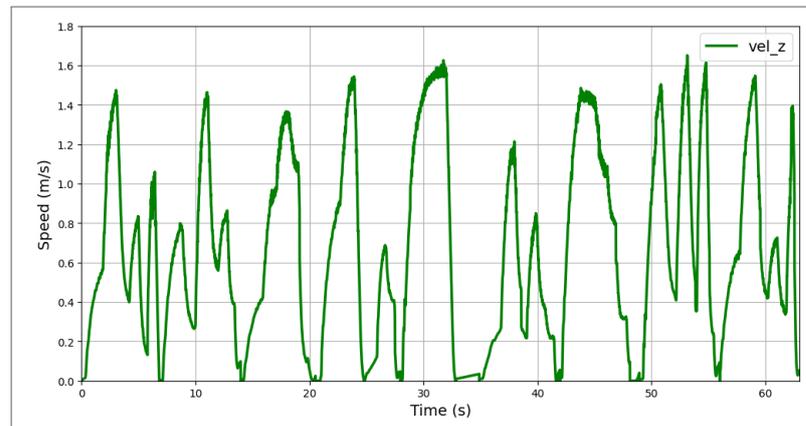
Figura 23 – Sinal de entrada



Fonte: O autor (2024)

Como saída, temos a velocidade longitudinal do veículo apresentada em m/s. A Figura 24 apresenta os valores coletados do veículo. Os valores de velocidade foram obtidos baseado nos dados coletados pela IMU da câmera ZED2i.

Figura 24 – Sinal de saída



Fonte: O autor (2024)

### 4.3.2 Arquitetura de Modelo Inteligente (CNN-REI)

A utilização de redes desenvolvidas para séries temporais sem entradas exógenas, como o modelo de CNN proposto por KIRISCI; YOLCU (2022), não pode ser aplicada diretamente à identificação de sistemas, uma vez que esses modelos são baseados apenas nas saídas passadas e não consideram nenhuma influência externa. Dessa forma, são propostas alterações na rede

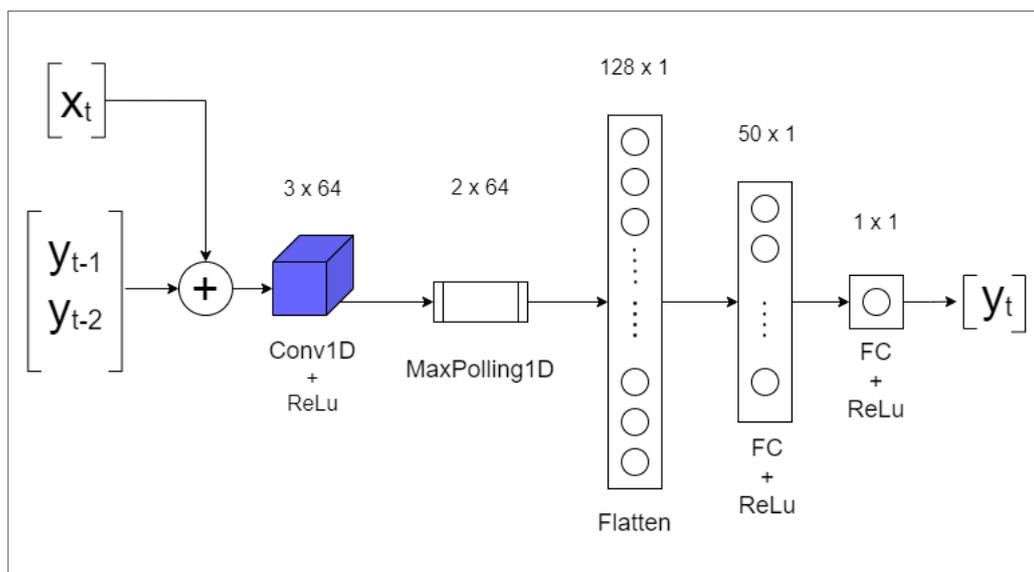
desenvolvida por KIRISCI; YOLCU (2022), com o objetivo de adaptar um modelo de CNN para a identificação de sistemas, resultando na criação da CNN-REI.

A CNN-REI é uma rede neural convolucional com entradas exógenas recorrentes. Por se tratar de um rede convolucional, sua utilização em modelos de identificação de sistemas dinâmicos é particularmente inovadora, visto que tradicionalmente as redes neurais convolucionais são comumente utilizadas em processamento de imagens. Isso se deve ao fato de a operação de convolução possuir a característica de extrair informações e preservar a relação espacial entre pixels, o que é essencial para tarefas de visão computacional (GOODFELLOW; BENGIO; COURVILLE, 2016). Além disso, a convolução é capaz de reduzir a dimensionalidade da imagem de forma controlada, mantendo informações relevantes e descartando redundâncias. Isso é especialmente importante em imagens de alta resolução, onde a redução da dimensionalidade ajuda a diminuir a carga computacional e a prevenir o sobreajuste (GOODFELLOW; BENGIO; COURVILLE, 2016).

A recorrência presente na CNN-REI é um elemento fundamental para seu desempenho na modelagem de sistemas dinâmicos, uma vez que permite que a rede capture as dependências e padrões que se repetem ao longo do tempo.

A Figura 25 apresenta a arquitetura de rede CNN-REI proposta no trabalho.

Figura 25 – Arquitetura CNN-REI proposta



Fonte: O autor (2024)

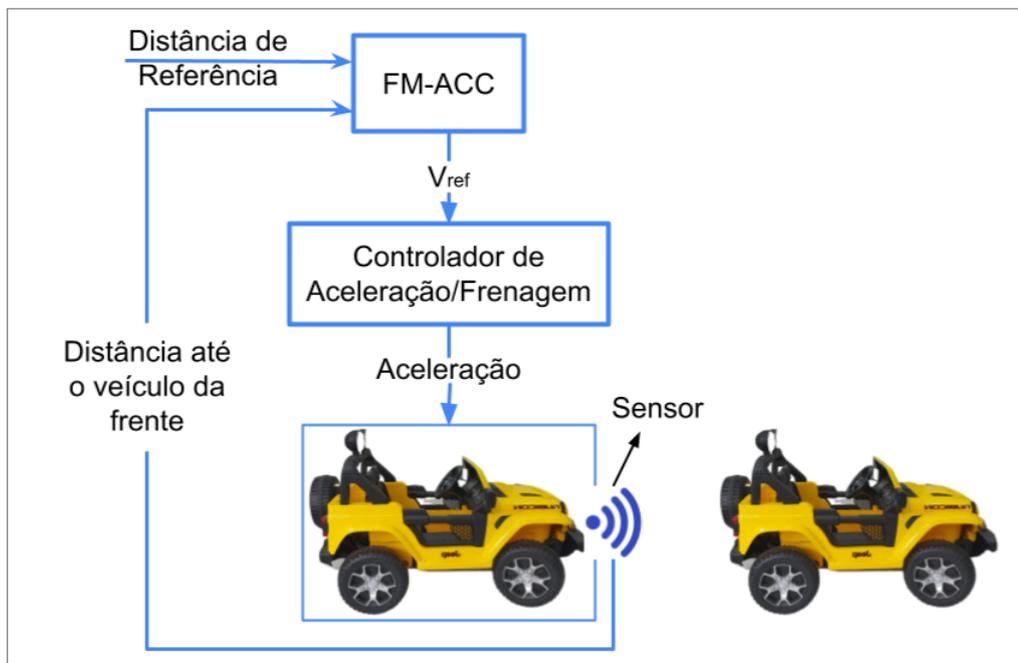
A entrada da rede CNN-REI é formada por uma entrada exógena e duas saídas atrasadas, que caracterizam a recorrência do sistema. A camada de convolução 1D é composta por 64 *kernels* de tamanho 2, utilizando a função de ativação *Rectified Linear Unit* (ReLU). A camada

de MaxPooling 1D, é utilizada no objetivo de reduzir a dimensão espacial dos dados sem perder informações, para isso é utilizado um Pool Size de 2. A camada totalmente conectada é constituída de 50 neurônios que utilizam a função de ativação ReLU, e por fim o último neurônio é utilizado para ponderar as informações extraídas da rede e definir o valor da saída.

#### 4.4 ARQUITETURA DE CONTROLE PROPOSTA

A arquitetura de controle proposta é apresentada na Figura 26. Esta arquitetura utiliza dois controladores: o controlador de aceleração/frenagem e o FM-ACC. A configuração em cascata desses controladores cria uma dependência temporal entre o controlador de aceleração/frenagem e o FM-ACC. O controlador de aceleração/frenagem, também chamado de controlador de baixo nível, tem a função de controlar a aceleração e a frenagem do veículo de escala reduzida para manter uma velocidade constante. Por outro lado, o FM-ACC atua como um controlador de alto nível, com o objetivo de gerar um plano de velocidades que garanta a distância de referência adequada para o veículo de escala reduzida à frente.

Figura 26 – Arquitetura de controle proposta



Fonte: O Autor (2024)

#### 4.4.1 Controlador de Aceleração/Frenagem

A forma de controlar a velocidade do veículo proposta neste trabalho baseia-se na diferença entre a velocidade atual e a velocidade de referência ( $e(t)$ ), controlando a aceleração e a frenagem do veículo de escala reduzida. O controlador utilizada é o PID (Proporcional-Integral-Derivativo) que consiste em calcular um valor de atuação sobre o processo a partir das informações de um valor desejado e do valor real da variável obtido por um sistema de medição. Este valor de atuação é transformado em sinal de controle adequado para um determinado atuador, buscando garantir o desempenho desejado pelo projetista. Este controlador é bastante popular em função de sua simplicidade e aplicabilidade em diversos sistemas. Outra vantagem destes controladores, é que regras empíricas podem ser aplicadas, tais como Ziegler-Nichols, permitindo o ajuste dos parâmetros do controlador sem a necessidade do conhecimento do modelo matemático do sistema, apesar de ser possível aplicar as regras de sintonia à sistemas cujas dinâmicas são conhecidas (OGATA, 2011).

As regras de sintonização de Ziegler-Nichols utilizam o controlador PID no formato apresentado na eq. 4.1. Onde,  $K_p$  é o ganho proporcional,  $T_i$  é o tempo integral e  $T_d$  é o tempo derivativo. O método consiste em encontrar os valores de  $K_p$ ,  $T_i$  e  $T_d$  que proporcionam uma operação estável do sistema.

$$\frac{Y(s)}{U(s)} = K_p \left( 1 + \frac{1}{T_i s} + T_d s \right) \quad (4.1)$$

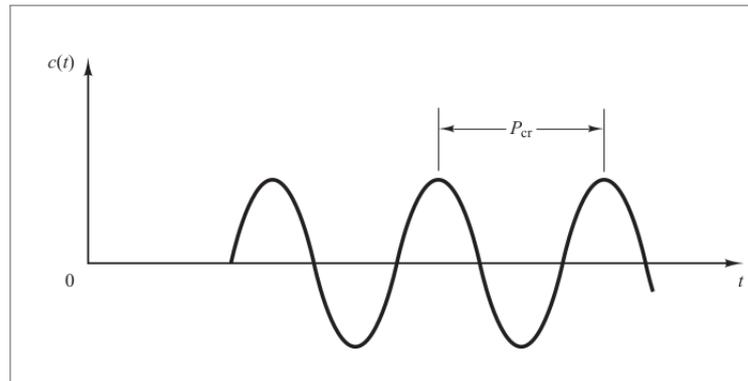
Segundo (OGATA, 2011) o método de sintonização por Ziegler-Nichols é composto pelas seguintes etapas:

- Inicialmente, define-se que  $T_i = \infty$  e  $T_d = 0$ .
- Considerando apenas a ação de controle proporcional, deve se encontrar o valor de  $K_p$  que irá exibir na saída do sistema uma oscilação sustentada, tal qual o sistema marginalmente estável. Esse valor será considerado o ganho crítico  $K_{cr}$ .
- Com base na resposta do sistema, pode-se determinar o período de oscilação  $P_{cr}$  conforme a Figura 27.

Tabela 2 – Sintonização Ziegler-Nichols

Controlador	$K_p$	$T_i$	$T_d$
P	$0.5K_{cr}$	$\infty$	0
PI	$0.45K_{cr}$	$\frac{1}{1.2}P_{cr}$	0
PID	$0.6K_{cr}$	$0.5P_{cr}$	$0.125P_{cr}$

Fonte: OGATA (2011)

Figura 27 – Oscilação sustentada com período  $P_{cr}$ 

Fonte: OGATA (2011)

- Com os valores de  $K_{cr}$  e  $P_{cr}$  definidos, é determinado os valores de  $K_p$ ,  $T_i$  e  $T_d$  de acordo com a Tabela 2.

Uma das dificuldades na implementação do controle PID, é a sintonização experimental dos valores dos ganhos proporcional, integral e derivativo. Apesar da maioria dos processos serem intrinsecamente não-lineares, o uso deste tipo de controlador se baseia na consideração de que, em torno do ponto típico de operação, o sistema se comporta de maneira aproximadamente linear. Esta premissa funciona bem em grande parte dos processos, para uma determinada janela de tempo e operação, a partir da qual normalmente se faz necessária uma ressintonia do controlador.

#### 4.4.2 FM-ACC

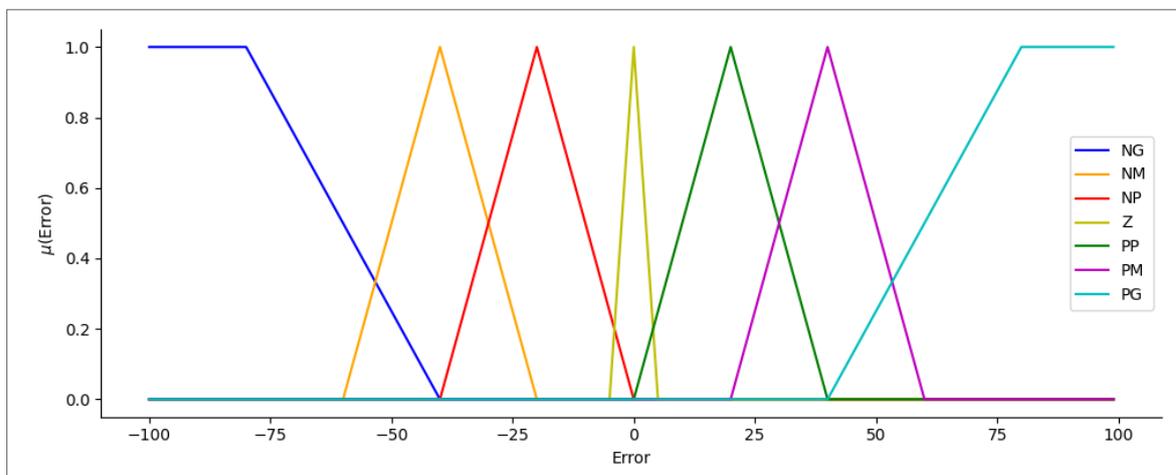
De acordo com os princípios dos sistemas *fuzzy* de serem baseados na experiência e nos padrões de raciocínio dos operadores humanos, o modelamento dos controladores foi realizado a partir de um estudo prévio e experimental do comportamento desejado para os regimes transitório e permanente dos atuadores.

Inicialmente, as funções de pertinência e regras *fuzzy* foram baseadas nas sugestões de

SIMões; SHAW (2007), SILVA (2021) e RESTIVO (2022), mas a posteriori, foram modificadas a partir do conhecimento adquirido do comportamento do veículo nos testes simulados.

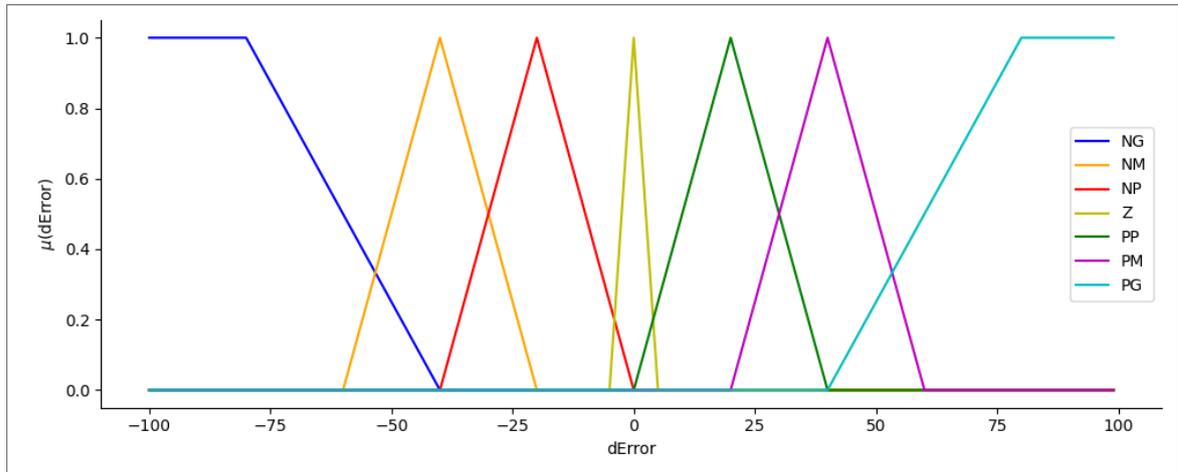
No bloco de fuzzificação foram criadas duas variáveis linguísticas denominadas ERRO e dERRO (derivada do erro). A variável linguística ERRO representa o desvio entre o sinal de entrada (distância de referência) e o sinal de realimentação (distância atual) fornecida pelos sensores, já a variável linguística dERRO representa a taxa de variação desse desvio no tempo. O universo de discurso das variáveis ERRO e dERRO abrangem o intervalo  $[-100, 100]$ , representando os valores máximos e mínimos, em centímetros, que o sistema pode apresentar. As variáveis são compostas por sete funções de pertinência com os termos linguístico denominados: Negativo Grande (NG), Negativo Médio (NM), Negativo Pequeno (NP), Zero (Z), Positivo Pequeno (PP), Positivo Médio (PM) e Positivo Grande (PG). Para as variáveis NG e PG foram utilizadas funções trapezoidais, e para as demais foram utilizadas funções triangulares. A Figura 28 apresenta a variável linguística de entrada Erro com suas funções de pertinência e termos linguísticos correspondentes, enquanto a Figura 29 apresenta a variável de entrada dErro. Na Tabela 3 é apresentado os parâmetros de cada função de pertinência.

Figura 28 – Função de Pertinencia da variável de entrada Erro do FM-ACC



Fonte: O autor (2024)

Figura 29 – Função de Pertinência da variável de entrada dErro do FM-ACC



Fonte: O autor (2024)

Na defuzzificação foi criada uma variável linguística denominada *vel*, que representa o sinal de controle que atuará sobre o sinal de velocidade. O universo de discurso desta variável abrange o intervalo  $[-100;100]$ . Para a variável *vel*, foram associadas sete funções de pertinência, definidas pelos termos NG, NM, NP, Z, PP, PM e PG. Para as variáveis NG e PG foram utilizadas funções trapezoidais, e para as demais foram utilizadas funções triangulares. O método utilizado para realizar a defuzzificação é o Centro de Área (CoA). O sinal de controle irá atuar sobre o plano de velocidade de acordo com a Eq.4.2.

$$V_i = V_{atual} + \mu_i \quad (4.2)$$

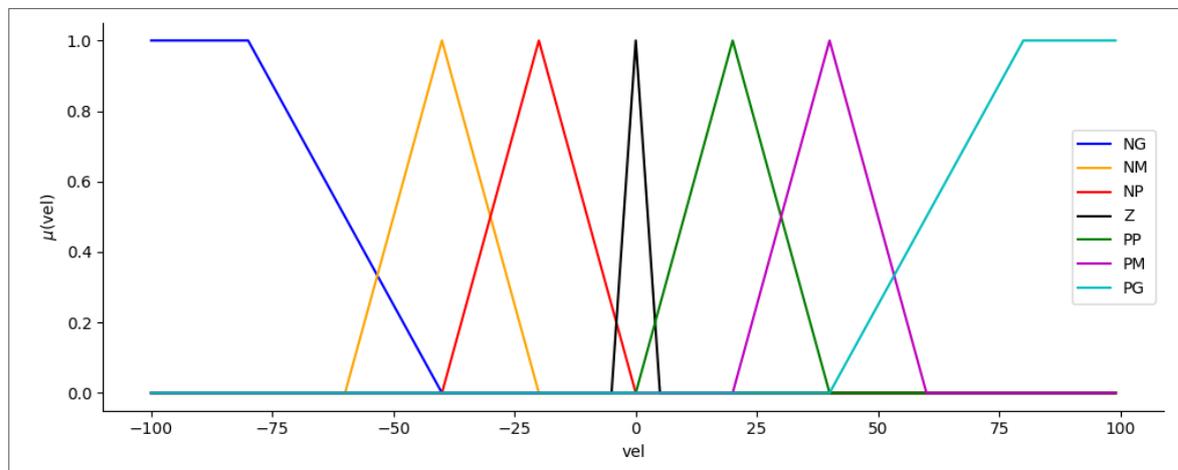
Onde  $V_i$  representa o plano de velocidade que será disponibilizada para o controlador de baixo nível,  $V_{atual}$  é a velocidade atual do veículo e  $\mu_i$  o sinal de controle da saída do controlador FM-ACC. As variáveis linguísticas de saída do controlador FM-ACC é apresentada na Figura 30. Na Tabela 3 são apresentados os parâmetros de cada função de pertinência.

Tabela 3 – Parâmetros das funções de pertinência do controlador FM-ACC

Variável	FM-ACC	
ERRO	NG (trapezoidal)	[-100, -100, -80, -40]
	NM (triangular)	[-60, -40, -20]
	NP (triangular)	[-40, -20, 0]
	Z (triangular)	[-5, 0, 5]
	PP (triangular)	[0, 20, 40]
	PM (triangular)	[20, 40, 60]
	PG (trapezoidal)	[40, 80, 100, 100]
dErro	NG (trapezoidal)	[-100, -100, -80, -40]
	NM (triangular)	[-60, -40, -20]
	NP (triangular)	[-40, -20, 0]
	Z (triangular)	[-5, 0, 5]
	PP (triangular)	[0, 20, 40]
	PM (triangular)	[20, 40, 60]
	PG (trapezoidal)	[40, 80, 100, 100]
vel	NG (trapezoidal)	[-100, -100, -80, -40]
	NM (triangular)	[-60, -40, -20]
	NP (triangular)	[-40, -20, 0]
	Z (triangular)	[-5, 0, 5]
	PP (triangular)	[0, 20, 40]
	PM (triangular)	[20, 40, 60]
	PG (trapezoidal)	[40, 80, 100, 100]

Fonte: O autor (2024)

Figura 30 – Função de Pertinência da variável de saída do FM-ACC



Fonte: O autor (2024)

As regras do controlador *Fuzzy* utilizado são do tipo SE-ENTÃO conforme a Eq. 4.3, e são apresentadas na Tabela 4. As regras foram elaboradas baseada em RESTIVO (2022) e

Tabela 4 – Regras Fuzzy para o FM-ACC

		Erro						
		NG	NM	NP	Z	PP	PM	PG
dErro	NG	NG	NG	NG	NG	PG	PG	PG
	NM	NG	NM	NM	NM	PM	PM	PG
	NP	NG	NM	NP	NP	PP	PM	PG
	Z	NG	NM	NP	Z	PP	PM	PG
	PP	NG	NM	NP	PP	PP	PM	PG
	PM	NG	NM	NM	PM	PM	PM	PG
	PG	NG	NG	NG	PG	PG	PG	PG

Fonte: O autor (2024)

adaptadas de acordo com o conhecimento do funcionamento do sistema, durante a validação do controlador em modo de simulação.

$$IF\ e(t) = \dots\ AND\ \frac{de(t)}{dt} = \dots\ THEN\ vel = \dots \quad (4.3)$$

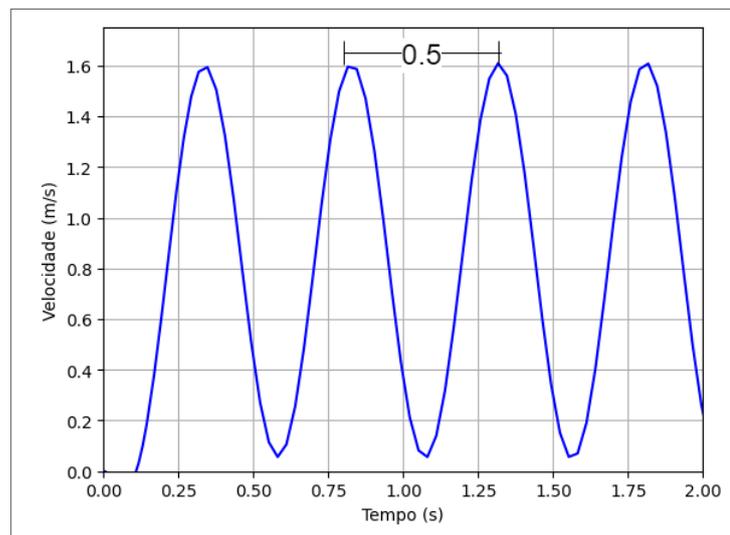
## 5 PROJETO DOS CONTROLADORES

Este capítulo apresenta o projeto dos controladores de baixo e alto nível. O controlador de baixo nível é um controlador PID, sintonizado pelo método de Ziegler-Nichols. Para o controlador de alto nível, são projetados dois controladores: um ACC-PI, também sintonizado pelo método de Ziegler-Nichols, e o FM-ACC que é foco deste trabalho.

### 5.1 CONTROLADOR BAIXO NÍVEL

O projeto do controlador de aceleração e frenagem foi realizado de acordo com o método de sintonização de Ziegler-Nichols apresentado em 4.4.1. O projeto do controlador foi desenvolvido por meio da plataforma Matlab/Simulink. Inicialmente, é encontrado o valor de  $K_{cr} = 733$  que leva o sistema a um ponto de oscilação sustentada, conforme mostra a Figura 31. Após analisar a resposta do sistema em oscilação sustentada, é encontrado o valor do período de oscilação,  $P_{cr} = 0.5$ . Conhecendo os dois valores, é possível encontrar os ganhos do controlador PID por meio das regras de sintonização de Ziegler-Nichols, os valores encontrado dos ganhos do controlador são apresentados na Tabela 5.

Figura 31 – Resposta do Sistema para um  $K_{cr} = 733$



Fonte: O autor (2024)

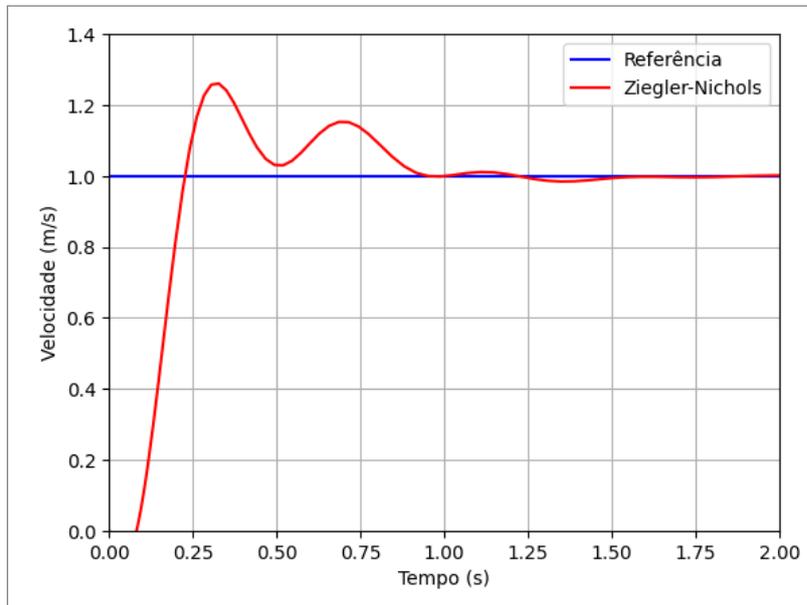
Tabela 5 – Sintonização Ziegler-Nichols - *Cruise Control*

Controlador	$K_p$	$T_i$	$T_d$
PID	439.5	0.25	0.0625

Fonte: O autor (2024)

Com o controlador sintonizado por meio das regras de Ziegler-Nichols, é possível avaliar o controlador quando o sistema é submetido a uma entrada do tipo degrau. A Figura 32 apresenta a curva de resposta do sistema para o controlador sintonizado.

Figura 32 – Resposta ao degrau para o controlador sintonizado por Ziegler-Nichols



Fonte: O autor (2024)

Devido à natureza experimental dos controladores sintonizados pelo método de Ziegler-Nichols, é necessário realizar um ajuste fino nos ganhos, com o objetivo de melhorar a resposta do sistema. Dessa forma, na Tabela 6 são apresentados os novos ganhos do controlador.

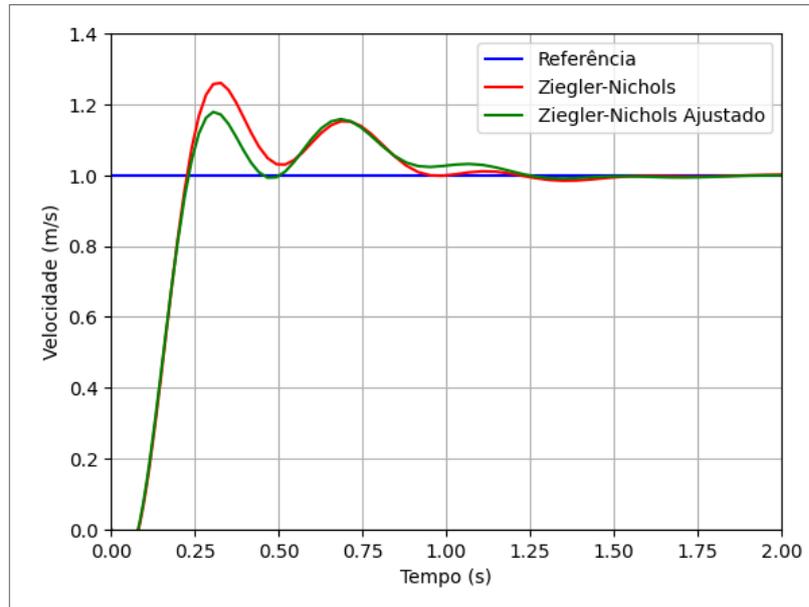
Tabela 6 – Sintonização Ziegler-Nichols Modified - *Cruise Control*

Controlador	$K_p$	$T_i$	$T_d$
PID	423.4	0.2739	0.0685

Fonte: O autor (2024)

A Figura 33 apresenta a resposta a uma entrada degrau do sistema com o controlador ajustado. É possível observar que, com o ajuste, o sistema passou a apresentar um menor sobresinal e um menor tempo de pico. Entretanto, a mudança não altera os tempos de atraso, de subida e de acomodação do sistema.

Figura 33 – Resposta ao degrau para o controlador ajustado



Fonte: O autor (2024)

O sistema foi avaliado de acordo com as métricas apresentadas na Seção 3.5. Para o tempo de subida, foi considerado o valor de 0% a 100% que é normalmente utilizado para sistemas subamortecidos. Para o tempo de acomodação foi utilizado o critério de oscilação de 5% em torno do valor final. O desempenho dos controladores pode ser observado na Tabela 7.

Tabela 7 – Desempenho dos controladores PID de Baixo Nível

	PID Ziegler-Nichols	PID Ziegler-Nichols (Ajustado)
Tempo de atraso ( $T_d$ )	0.15	0.15
Tempo de subida ( $T_r$ )	0.23	0.23
Tempo de pico ( $T_p$ )	0.33	0.30
Sobresinal ( $M_p$ )	26.03%	17.85%
Tempo de acomodação ( $T_s$ )	0.84	0.84

Fonte: O autor (2024)

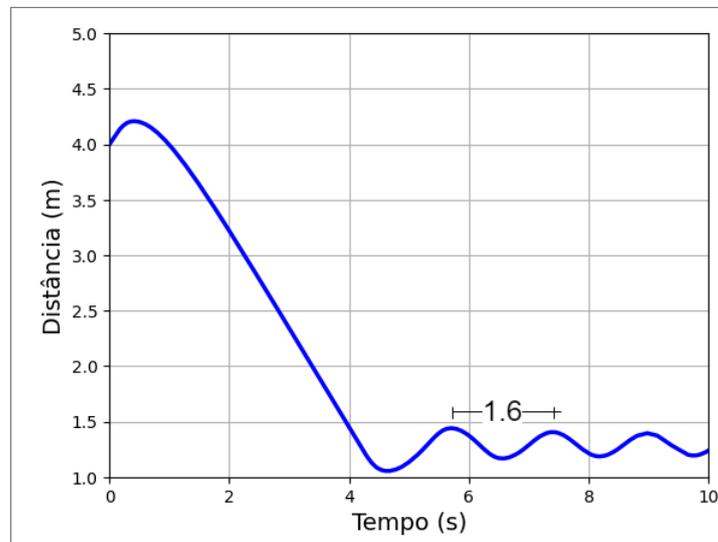
## 5.2 CONTROLADOR DE ALTO NÍVEL

Com o objetivo de realizar uma comparação entre o desempenho do controlador FM-ACC e outros controladores, nesta seção é projetado um controlador ACC-PI sintonizado pelas regras de Ziegler-Nichols.

### 5.2.1 ACC-PI

Seguindo o método de sintonização de Ziegler-Nichols, o sistema é levado para condição de oscilação sustentada utilizando um  $K_{cr} = 1300$ , em seguida é determinado o período de oscilação  $P_{cr} = 1.6$ , conforme mostra a Figura 34. Por fim, os ganhos do controlador são determinados de acordo com a tabela de sintonização Tabela 2. Os valores dos ganhos podem ser encontrados na Tabela 8.

Figura 34 – Resposta do Sistema para um  $K_{cr} = 1300$



Fonte: O autor (2024)

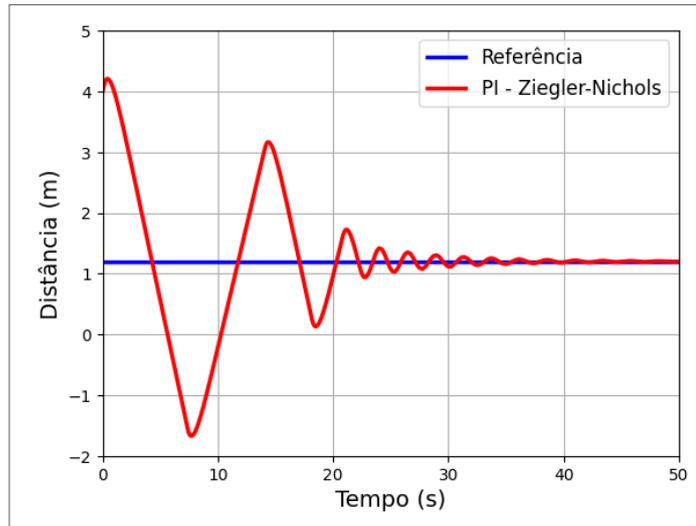
Tabela 8 – Sintonização Ziegler-Nichols - ACC-PI

Controlador	$K_p$	$T_i$	$T_d$
PI	585	1.33	0

Fonte: O autor (2024)

A Figura 35 apresenta a resposta do controlador ACC-PI. Com base nos resultados, é possível observar que, apesar de o controlador conseguir estabilizar a distância entre os veículos, durante o seu sobresinal ele apresenta uma distância negativa, o que indica que, antes de o sistema se estabilizar, ocorreria uma colisão entre os veículos. Dessa forma, foi realizado um ajuste nos ganhos do controlador para melhorar seu desempenho. Os novos ganhos podem ser observados na Tabela 9.

Figura 35 – Resposta do controlador PI



Fonte: O autor (2024)

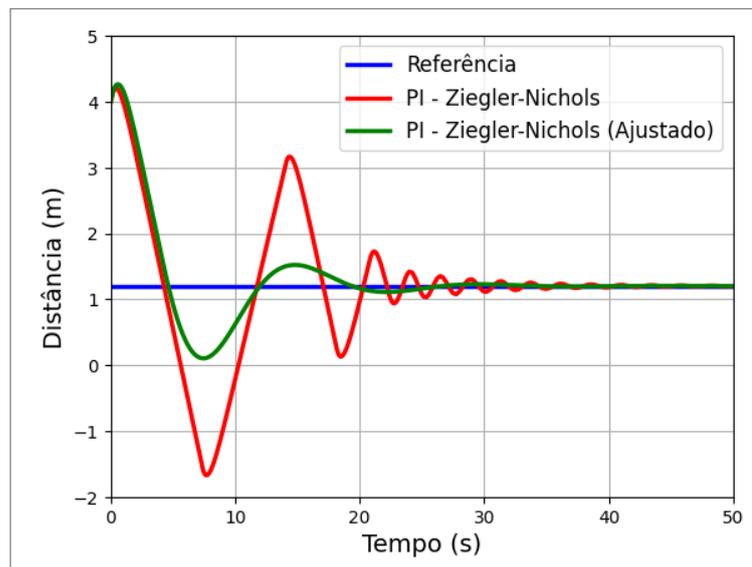
Tabela 9 – Ajuste da sintonia Ziegler-Nichols - *Cruise Control*

Controlador	$K_p$	$T_i$	$T_d$
PI	58.5	2.33	0

Fonte: O autor (2024)

Com base nos novos valores de sintonização do controlador, a Figura 36 apresenta o desempenho do controlador modificado. É possível observar que com as modificações o valor do sobresinal é reduzido e possui um valor positivo, o que indica que não ocorreu nenhuma colisão entre os veículos, além disso o sistema apresenta um tempo de acomodação menor que o anterior.

Figura 36 – Resposta do controlador PI ajustado



Fonte: O autor (2024)

O sistema foi avaliado de acordo com as métricas apresentadas na Seção 3.5. Para o tempo de subida, foi considerado o valor de 0% a 100% que é normalmente utilizado para sistemas subamortecidos. Para o tempo de acomodação foi utilizado o critério de oscilação de 5% em torno do valor final. O desempenho dos controladores pode ser observado na Tabela 10.

Tabela 10 – Desempenho do controlador ACC-PI

	ACC-PI Ziegler-Nichols	ACC-PI Ziegler-Nichols (ajustado)
Tempo de atraso ( $T_d$ )	2.85	2.98
Tempo de subida ( $T_r$ )	4.32	4.59
Tempo de pico ( $T_p$ )	7.62	7.49
Sobresinal ( $M_p$ )	233%	91.45%
Tempo de acomodação ( $T_s$ )	31	25.11

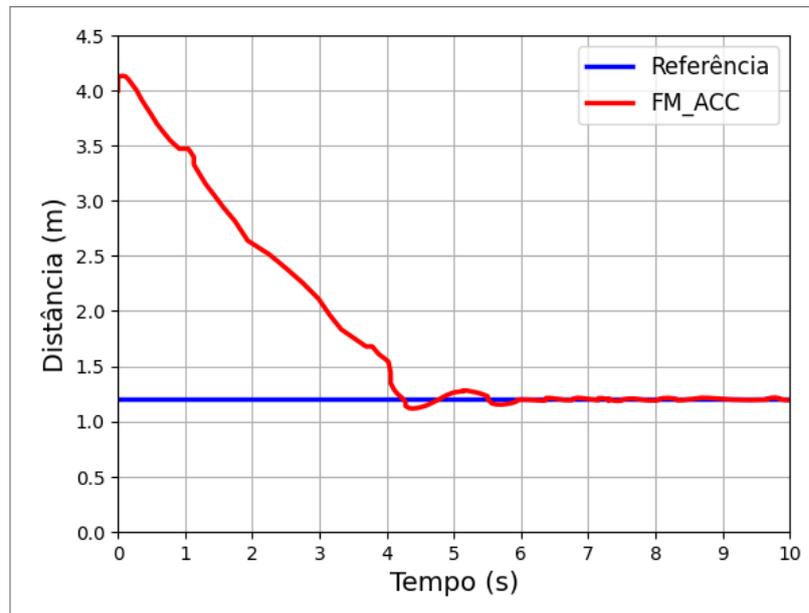
Fonte: O autor (2024)

### 5.2.2 FM-ACC

O controlador Fuzzy é implementado pelo método Mamdani através do *Fuzzy Logic Toolbox* do Matlab/Simulink. De acordo com os princípios dos sistemas Fuzzy, que são baseados na experiência e nos padrões de raciocínio dos operadores humanos, o modelamento do controlador foi realizado a partir dos estudos de prévio e experimental do comportamento desejado para os regimes transitório e permanente do sistema, e foi apresentado na Seção 4.4.2 deste trabalho.

A Figura 37 apresenta a resposta do sistema para o controlador FM-ACC. É possível observar que o controlador apresenta um baixo sobresinal e com pouca oscilação subamortecida, o que faz com que o tempo de acomodação do sistema seja próximo do tempo de subida e do tempo de pico.

Figura 37 – Resposta do controlador FM-ACC



Fonte: O autor (2024)

O sistema foi avaliado de acordo com as métricas apresentadas na Seção 3.5. Para o tempo de subida, foi considerado o valor de 0% a 100% que é normalmente utilizado para sistemas subamortecidos. Para o tempo de acomodação foi utilizado o critério de oscilação de 5% em torno do valor final. O desempenho dos controladores pode ser observado na Tabela 11.

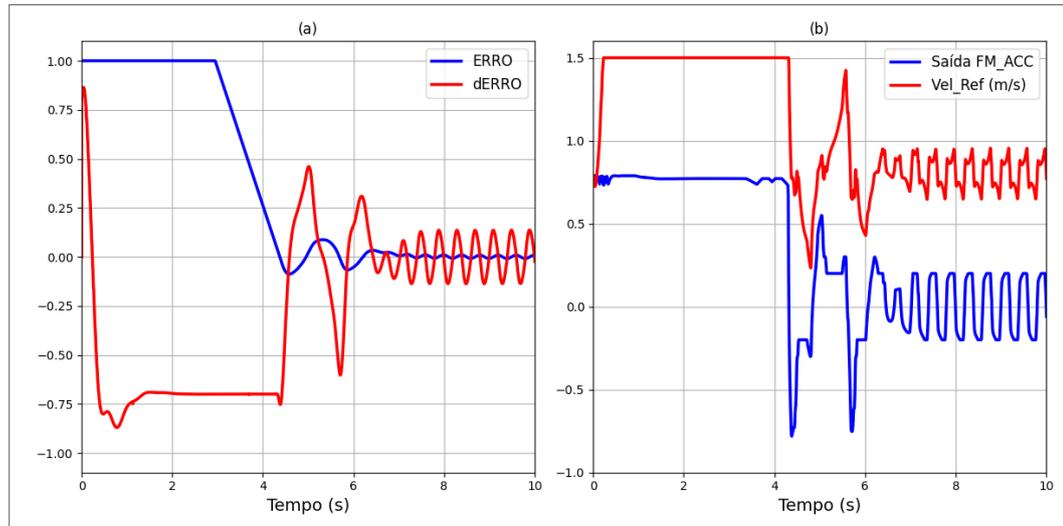
Tabela 11 – Desempenho do controlador FM-ACC

	FM-ACC
Tempo de atraso ( $T_d$ )	1.93
Tempo de subida ( $T_r$ )	4.23
Tempo de pico ( $T_p$ )	4.38
Sobresinal ( $M_p$ )	7.08%
Tempo de acomodação ( $T_s$ )	5.71

Fonte: O autor (2024)

Na Figura 38 é possível observar o comportamento do controlador FM-ACC durante a simulação. Em (a), é mostrado o comportamento dos sinais de entrada do controlador, e em (b), verifica-se o comportamento da saída do mesmo. Observa-se que, no início, devido ao grande erro do sistema, a saída do controlador indica a velocidade de referência máxima de  $1.5m/s$ . À medida que o erro vai diminuindo, o valor da velocidade de referência também diminui, até que atinge um estado constante, com uma pequena oscilação final.

Figura 38 – (a) entrada FM-ACC (b) Saída



Fonte: O autor (2024)

## 6 RESULTADOS

Este capítulo é dividido em três partes. A primeira seção aborda a identificação do sistema estudado, com uma comparação entre os modelos analisados. A segunda seção apresenta a comparação entre os controladores de alto nível desenvolvidos no Capítulo 5. Na última seção, são apresentados dois estudos de caso: o controlador FM-ACC aplicado em um veículo escala reduzida e o sistema de *platooning* simulado no Simulink.

### 6.1 IDENTIFICAÇÃO DE SISTEMAS

Nesta seção, são apresentados os resultados da modelagem computacional do sistema de dinâmica longitudinal. Foram desenvolvidos quatro modelos que abrangem: Função de Transferência, Espaço de Estados, NARX e CNN-REI.

Para melhor exposição destes resultados, a seção é dividida em cinco partes: uma para cada modelo proposto e, ao final, na última parte, é apresentada uma comparação de desempenho dos modelos.

#### 6.1.1 Função de Transferência

Para obter o modelo em caixa preta do sistema, considerando a função de transferência, foi utilizada a *toolbox System Identification* do Matlab. Foi realizado um estudo sobre o número de polos e zeros contidos no modelo, cujo resultado é apresentado na Tabela 12. Como métrica para selecionar o melhor modelo, foi utilizado o FIT, que representa o grau de ajuste dos dados do modelo com os dados reais.

Tabela 12 – Fit do modelo de Função de Transferência de acordo com o número de polos e zeros

FIT (%)		Número de polos				
		1	2	3	4	5
Número de Zeros	0	61.8	65.6	66.13	66.15	-8.33
	1	65.61	66.33	66.33	65.61	6.83
	2		66.39	66.49	<b>68.74</b>	66.97
	3			68.71	66.41	67.49
	4				67.68	66.84

Fonte: O autor (2024)

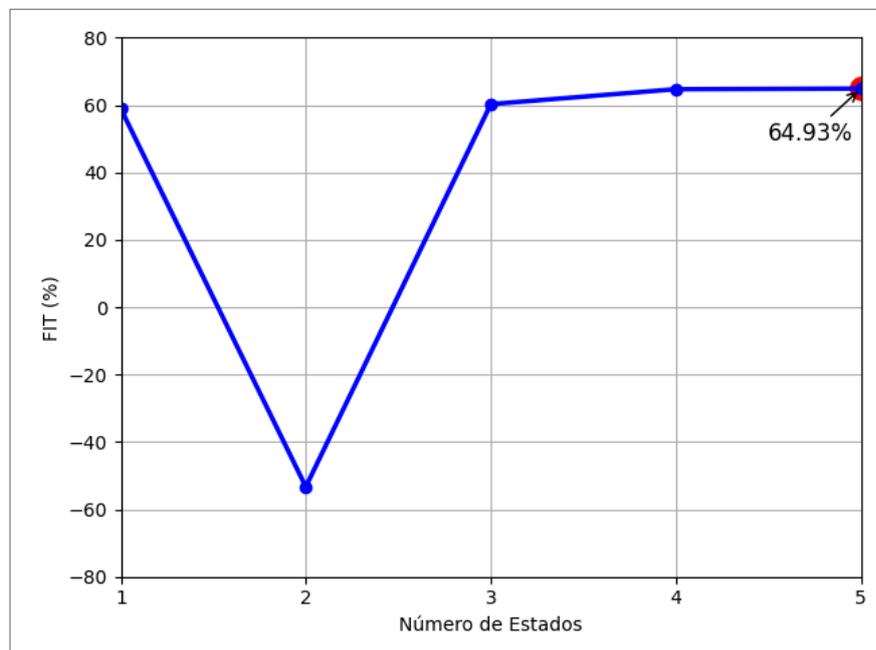
Conforme observado na Tabela 12 o modelo que apresenta o melhor ajuste aos dados é o modelo com quatro polos e dois zeros, com um fit de 68.74%. A função de transferência identificada para esse modelo, é apresentada na Eq. 6.1. Apesar de o modelo encontrado apresentar o maior valor de FIT, este valor ainda pode ser considerado baixo, isso ocorre devido as limitações da função de transferência em representar modelos não lineares.

$$\frac{Y(s)}{U(s)} = \frac{-0.1433s^2 + 3.175s + 0.04697}{s^4 + 17.12s^3 + 268.2s^2 + 481.8s + 7.317} \quad (6.1)$$

### 6.1.2 Espaço de Estado

Para obter o modelo em caixa preta do sistema, considerando a representação de estados, foi utilizada a *toolbox systemIdentification* do Matlab. Foi analisado qual o melhor número de estado que representa o sistema. A Figura 39 apresenta o desempenho dos modelos, considerando o FIT, de acordo com o número de estados proposto.

Figura 39 – Ajuste de acordo com o número de estados



Fonte: O autor (2024)

Conforme é observado pela Figura 39 o modelo que apresentou o maior ajuste aos dados foi a representação com 5 estados, tendo um FIT de 64.93%. O modelo é representado por meio das equações de estados, de acordo com as Eq. 3.7 e 3.8. Os valores das matrizes que representam o sistema são apresentadas nas Eq. 6.2 e 6.3. Onde, **A** é a matriz de estado, **B**

é a matriz de entrada, **C** é a matriz de saída e **D** é a matriz de transmissão direta.

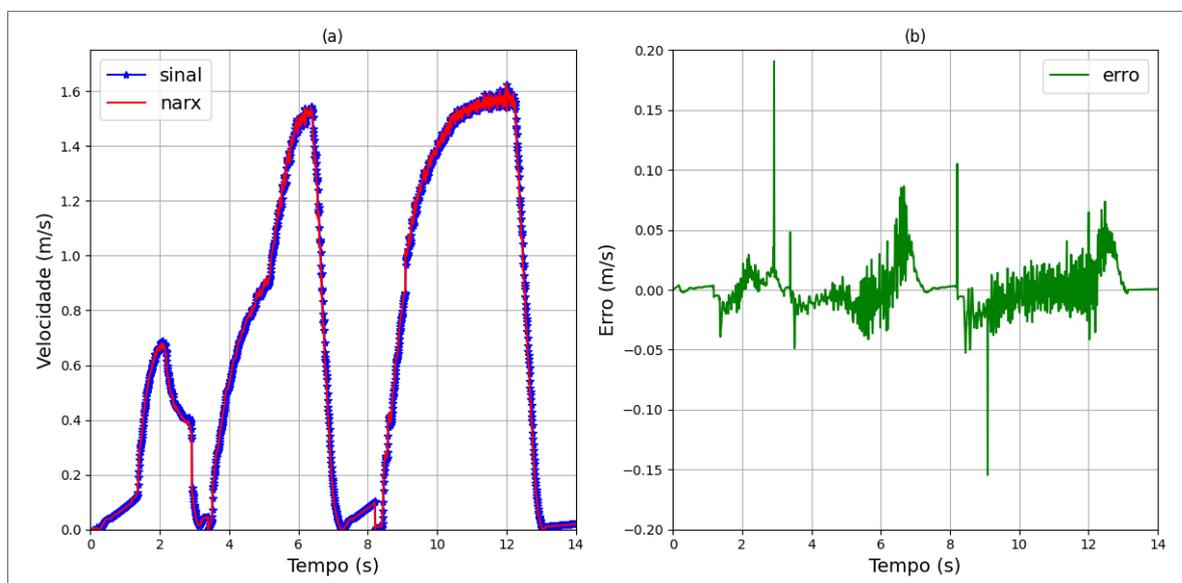
$$A = \begin{bmatrix} -1.362 & 2.007 & -1.023 & 5.706 & 10.63 \\ -2.926 & -2.693 & 20.18 & -32.19 & -159.3 \\ -0.2781 & -5.432 & -3.099 & 175 & 42.91 \\ -1.152 & 0.7027 & -132.3 & -76.15 & -336.2 \\ 1.815 & 4.012 & 8.365 & 58.16 & -997.3 \end{bmatrix} \quad B = \begin{bmatrix} 0.0001804 \\ -0.001696 \\ 0.00179 \\ -0.003208 \\ -0.01361 \end{bmatrix} \quad (6.2)$$

$$C = \begin{bmatrix} 37.6 & -0.1395 & 0.1612 & -0.3759 & -1.016 \end{bmatrix} \quad D = \begin{bmatrix} 0 \end{bmatrix} \quad (6.3)$$

### 6.1.3 NARX

Para implementação da rede NARX, é utilizado a *toolbox Deep Learning* do Matlab. A estrutura da rede NARX proposta é composta por 10 neurônios com a função de ativação (*tansig*) nas camadas escondidas e 1 neurônio com a função de ativação (*purelin*) na camada de saída. O número de *delays* utilizado é 2 e o algoritmo utilizado para treinamento é o Levenberg-Marquardt com uma taxa de aprendizagem de 0.001. Após o treinamento, a rede NARX apresentou um ótimo desempenho no conjunto de validação, conforme mostra a Figura 40.

Figura 40 – (a) Ajuste dos dados de saída da rede NARX com os dados coletados; (b) Erro entre os dados coletados e previstos pela rede



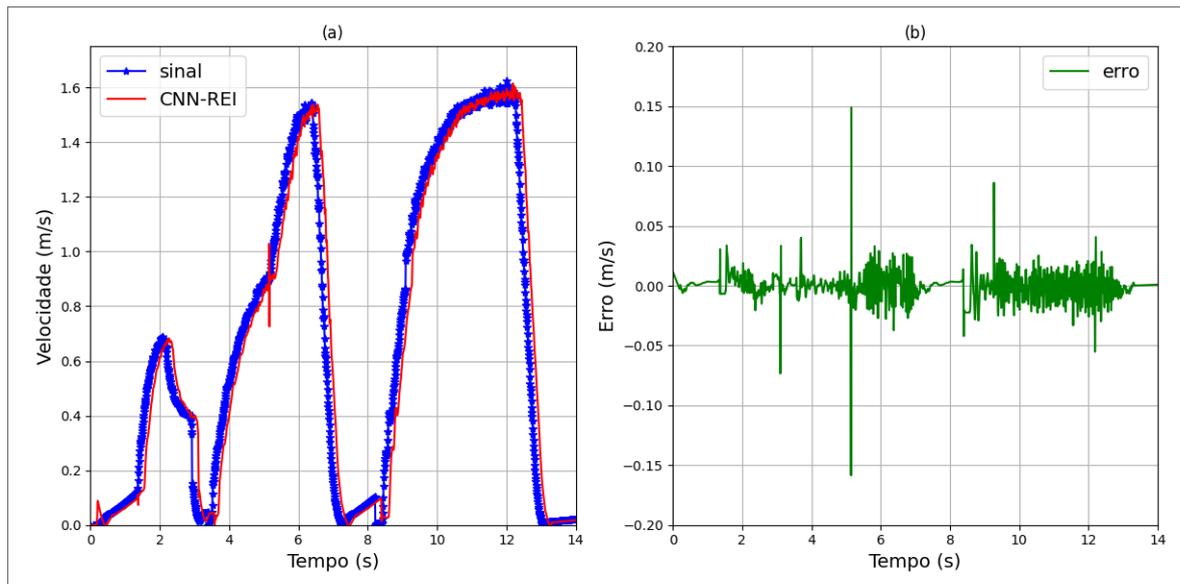
Fonte: O autor (2024)

É possível observar que o modelo apresenta um excelente ajuste aos dados coletados. O maior valor de erro do modelo é no valor de 0.187 que representa uma baixo erro de predição. Isso é possível pois a rede NARX, como a maioria dos modelos inteligentes, possui uma melhor capacidade de se adequar as não linearidades do sistema.

#### 6.1.4 CNN-REI

O modelo CNN-REI foi implementado utilizando a *toolbox Deep Learning* do Matlab. Foi realizado o treinamento da rede durante 2000 épocas utilizando um otimizador Adam e com taxa de aprendizagem de 0.001. A Figura 41 mostra o desempenho da rede CNN-REI no conjunto de validação.

Figura 41 – (a) Ajuste dos dados de saída da rede CNN-REI com os dados coletados; (b) Erro entre os dados coletados e previstos pela rede



Fonte: O autor (2024)

É possível observar que o modelo conseguiu ter um ótimo ajuste aos dados coletados, com o maior valor de erro de predição sendo  $-0.158$ . O modelo CNN-REI se mostrou muito eficiente para sua utilização em identificação de sistemas, tendo apenas cinco momentos em que o erro de predição foi superior a 0.05. Isso demonstra sua robustez e sua capacidade de se adequar às não linearidades do sistema.

### 6.1.5 Desempenho dos Modelos

A Tabela 13 resume os resultados dos indicadores de performance dos modelos, os valores apresentam a média e o desvio padrão ( $\sigma$ ) para dez repetições. Os valores apresentados entre parênteses representam os indicadores para o conjunto de treinamento, enquanto os valores fora dos parênteses correspondem ao conjunto de validação. É notável que o desempenho dos modelos inteligentes é superior ao dos modelos paramétricos. Os modelos inteligentes apresentam menores valores de RMSE e NRMSE, além de um melhor ajuste (Fit). Destaca-se o desempenho do modelo CNN-REI, que obteve os melhores resultados em todos os indicadores analisados, comprovando sua capacidade de aprender o comportamento dinâmico do sistema.

Tabela 13 – Desempenho dos Modelos

Modelo	RMSE	$\sigma$	NRMSE	$\sigma$	FIT(%)	$\sigma$
TF	0.2	0	0.1209	0	68.74	0
	(0.17)	(0)	(0.1043)	(0)	(71.04)	(0)
EE	0.1712	0	0.1035	0	64.93	0
	(0.1311)	(0)	(0.0804)	(0)	(77.66)	(0)
NARX	0.0216	0.00029	0.0128	0.0009	95.53	0.0554
	(0.0181)	(0.00042)	(0.011)	(0.000226)	(96.90)	(0.0732)
CNN-REI	<b>0.0195</b>	0.0070	<b>0.0117</b>	0.0042	<b>95.99</b>	1.4458
	<b>(0.0138)</b>	(0.0063)	<b>(0.0083)</b>	(0.0038)	<b>(97.68)</b>	(0.9793)

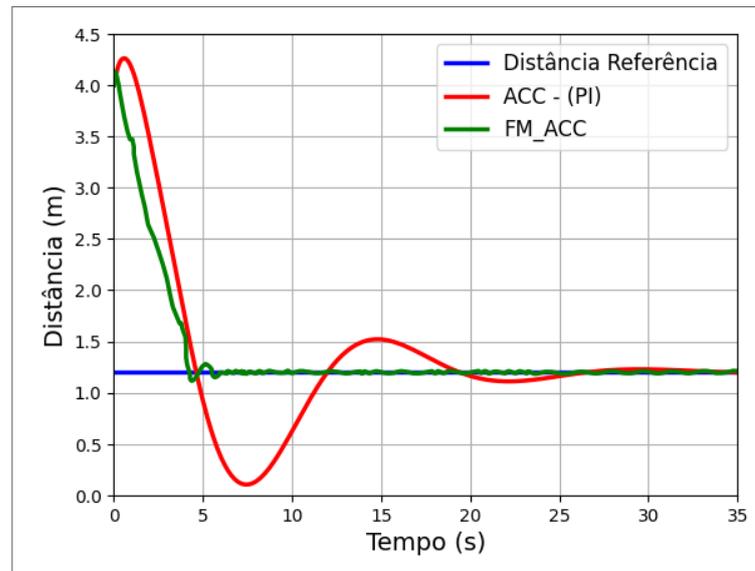
Fonte: O autor (2024)

## 6.2 COMPARAÇÃO DOS CONTROLADORES DE ALTO NÍVEL

A Figura 42 apresenta a resposta do sistema para os controladores ACC-PI e FM-ACC.

O sistema foi avaliado de acordo com as métricas apresentadas na Seção 3.5. Para o tempo de subida, foi considerado o valor de 0% a 100%, normalmente utilizado para sistemas subamortecidos. Para o tempo de acomodação, foi utilizado o critério de oscilação de 5% em torno do valor final. O desempenho dos controladores pode ser observado na Tabela 14. É possível perceber que o controlador proposto FM-ACC apresenta um desempenho muito superior ao do controlador ACC-PI, destacando-se em todas as métricas de avaliação, especialmente no ótimo valor de sobresinal e tempo de acomodação do sistema.

Figura 42 – Resposta dos controladores ACC-PI e FM-ACC



Fonte: O autor (2024)

Tabela 14 – Desempenho dos controladores ACC

	ACC-PI (ajustado)	FM-ACC
Tempo de atraso ( $T_d$ )	2.98	1.93
Tempo de subida ( $T_r$ )	4.59	4.23
Tempo de pico ( $T_p$ )	7.49	4.38
Sobresinal ( $M_p$ )	91.45%	7.08%
Tempo de acomodação ( $T_s$ )	25.11	5.71

Fonte: O autor (2024)

### 6.3 ESTUDO DE CASO

Nesta seção, são apresentados dois estudos de caso para o controlador FM-ACC desenvolvido. O primeiro será a aplicação do controlador em um veículo de escala reduzida, com o objetivo de validar o controlador num ambiente real. O segundo será a aplicação do sistema de controle proposto em um *platooning*, com um veículo líder que possui apenas o *Cruise Control* e seis veículos seguidores com o FM-ACC.

#### 6.3.1 Veículos em Escala Reduzida

A Figura 43 apresenta o cenário real do estudo de caso, mostrando os dois veículos utilizados para os testes. Os veículos foram desenvolvidos pela equipe do LIVE-UFPE dentro do projeto de pesquisa SegurAuto.

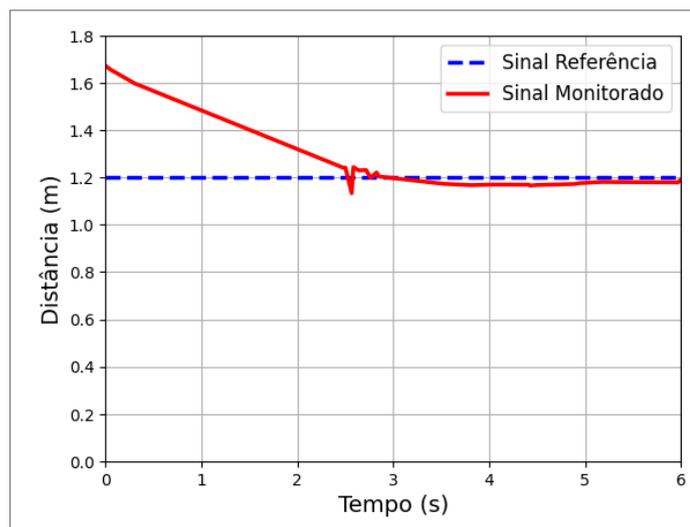
Figura 43 – Veículos na pista de teste



Fonte: O autor (2024)

Nesta configuração, o veículo líder segue com uma velocidade de cruzeiro de  $0.47m/s$ , e o veículo 1 se aproxima com uma velocidade de cruzeiro de  $0.628m/s$ . Com uma distância de ativação de  $1.7m$ , o FM-ACC é ativado e o veículo 1 tende a se aproximar do veículo líder buscando manter uma distância de referência de  $1.2m$ . O resultado deste cenário pode ser visualizado na Figura 44.

Figura 44 – Desempenho do FM-ACC em um veículo de pequena escala real

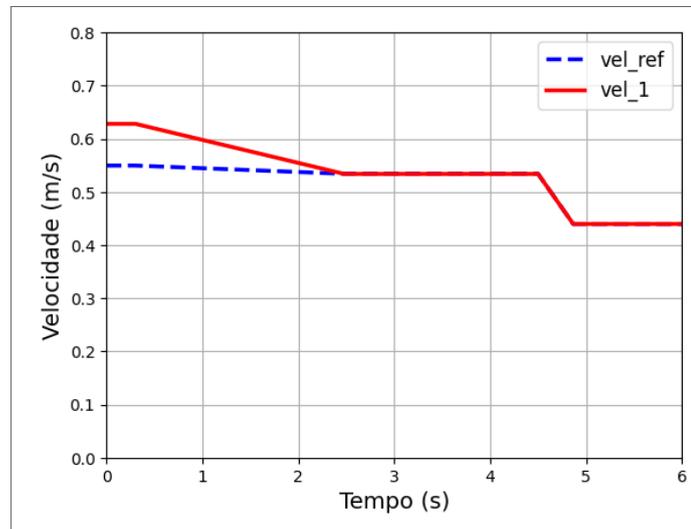


Fonte: O autor (2024)

Na Figura 45 é apresentado o comportamento da velocidade do veículo 1 durante o teste. Inicialmente, o veículo apresenta um erro entre a velocidade de referência gerada na saída do FM-ACC e a velocidade atual do veículo, mas logo em seguida o *Cruise Control* atua no

veículo fazendo com que a velocidade do veículo siga a velocidade de referência.

Figura 45 – Desempenho do FM-ACC em um veículo de pequena escala real



Fonte: O autor (2024)

O teste foi avaliado de acordo com as métricas apresentadas na Seção 3.5. Para o tempo de subida, foi considerado o valor de 0% a 100% que é normalmente utilizado para sistemas subamortecidos. Para o tempo de acomodação foi utilizado o critério de oscilação de 5% em torno do valor final. O desempenho dos controladores pode ser observado na Tabela 15. É possível observar que, assim como nos resultados simulados, os valores dos tempos de subida, pico e acomodação se apresentam próximos entre si. Da mesma forma, o sistema real apresentou um baixo valor de sobresinal, indicando que o modelo simulado está muito próximo da realidade.

Tabela 15 – Desempenho do controlador FM-ACC em veículo real

	FM-ACC
Tempo de atraso ( $T_d$ )	1.42
Tempo de subida ( $T_r$ )	2.58
Tempo de pico ( $T_p$ )	2.63
Sobresinal ( $M_p$ )	5.5%
Tempo de acomodação ( $T_s$ )	2.65

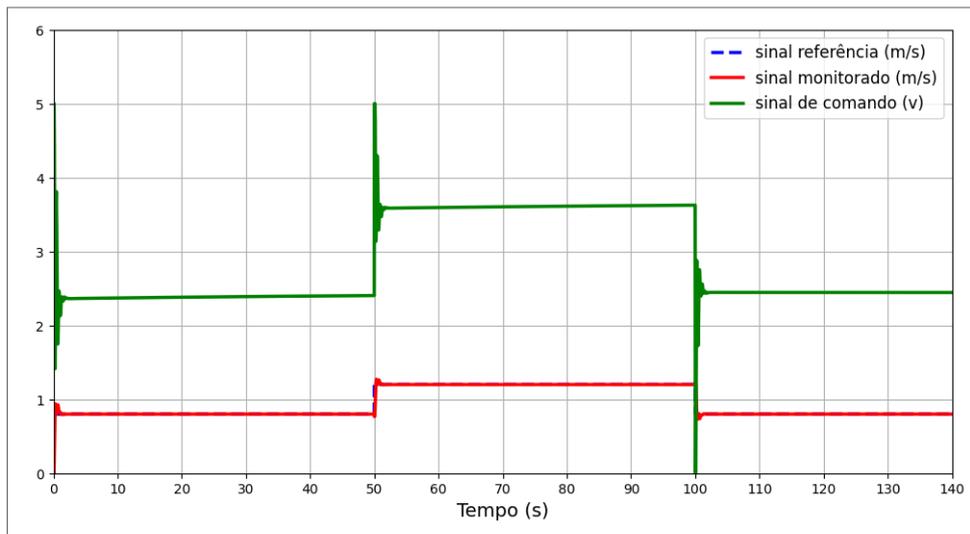
Fonte: O autor (2024)

### 6.3.2 Platooning

O segundo estudo de caso apresentado neste trabalho é a aplicação do sistema proposto para um *platooning* com sete veículos. Na Figura 46 é apresentado o comportamento do veículo

líder, que possui apenas o controlador de aceleração e frenagem, para manter a velocidade do *platooning* constante. O valor do PWM representa o sinal de controle do veículo. Dessa forma, é possível observar que, nos instantes de alteração de velocidade, o veículo sofre uma aceleração, mas rapidamente se estabiliza e mantém sua velocidade constante.

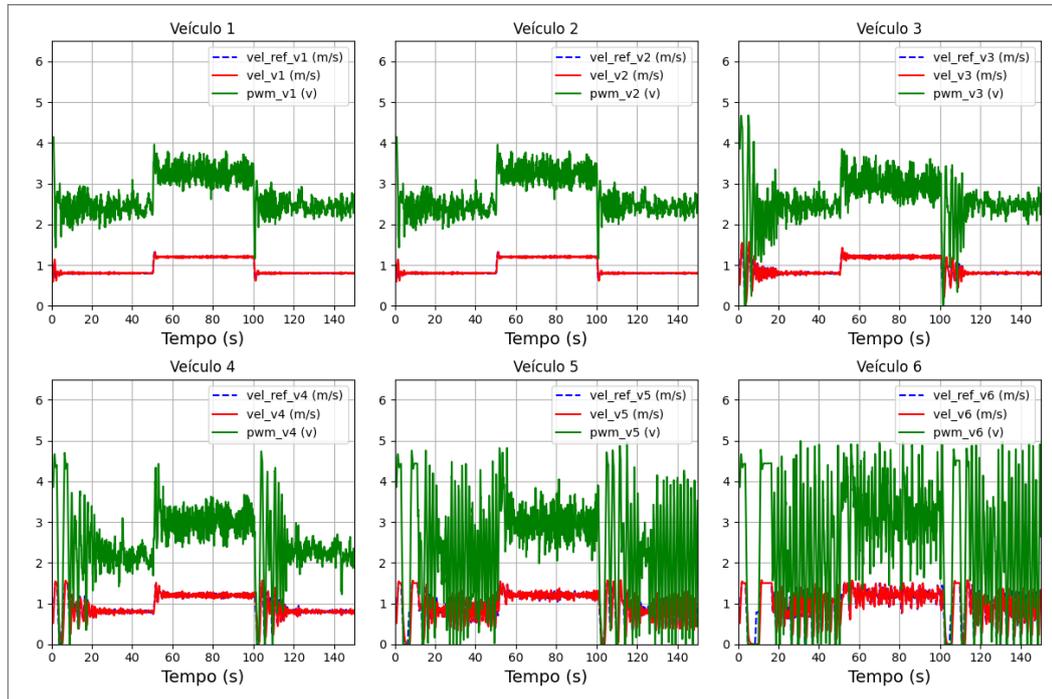
Figura 46 – Velocidades e Sinais de comando do Líder



Fonte: O autor (2024)

A Figura 47 apresenta os valores de velocidade e sinal de controle para os seis veículos seguidores do *platooning*. É possível inferir que o sinal de controle sofre uma perturbação maior nos veículos ao final do *platooning*, principalmente nos veículos 5 e 6. Isso ocorre devido ao fato de essas perturbações se propagarem ao longo do *platooning*. Além disso, essas perturbações fazem com que os últimos veículos apresentem várias oscilações em suas velocidades, não conseguindo acompanhar a velocidade constante do veículo líder.

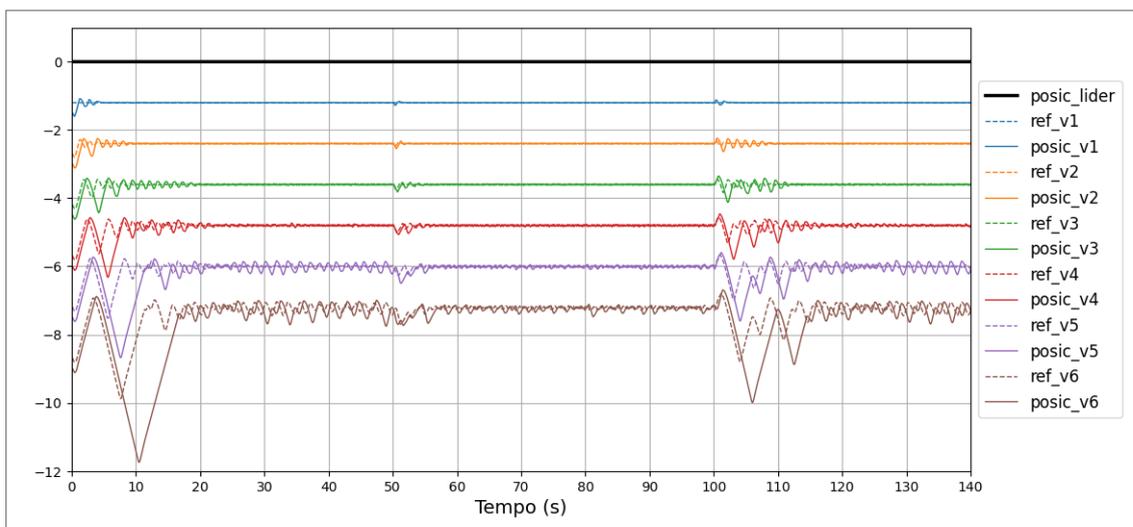
Figura 47 – Velocidades e Sinais de comando dos veículos



Fonte: O autor (2024)

A Figura 48 apresenta a posição de cada veículo de acordo com a posição do líder. É possível observar que, com a propagação das perturbações, os veículos 5 e 6 apresentam uma instabilidade para o *platooning*. No entanto, mesmo com essa instabilidade, não ocorre nenhuma colisão entre os veículos.

Figura 48 – Posição dos veículos em relação ao veículo líder

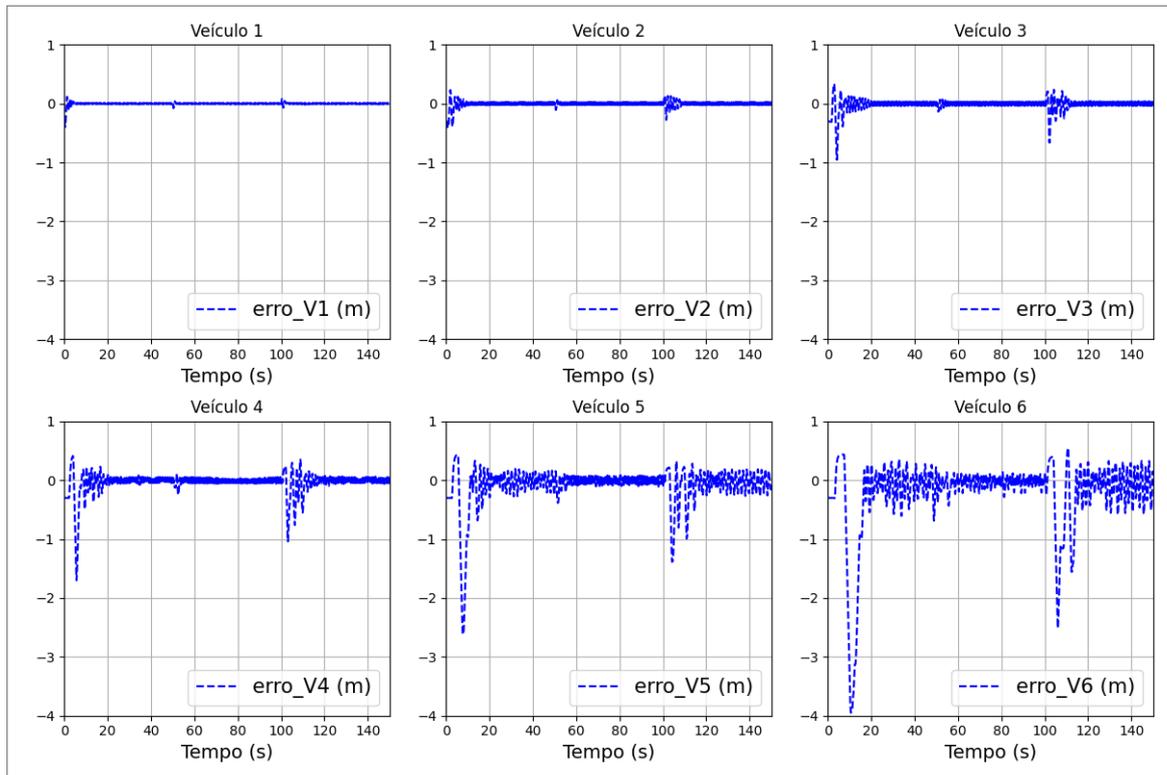


Fonte: O autor (2024)

A Figura 49 apresenta o erro de distância em relação ao veículo à sua frente. É possível observar que os veículos 1 e 2 conseguem corrigir e praticamente não apresentam erro de

distância. Entretanto, os veículos no final do *platooning* apresentam uma grande instabilidade, possuindo grandes erros de distância, como é o caso dos veículos 5 e 6. Isso ocorre devido ao acúmulo de erro que se propaga pelo *platooning*.

Figura 49 – Erro de distância do veículo a frente e a  $dist_{ref}$



Fonte: O autor (2024)

## 7 CONCLUSÃO

O cenário atual das rodovias é marcado por grande insegurança, sendo o erro humano a principal causa de acidentes. Nos últimos anos, tem crescido o interesse pelo desenvolvimento de tecnologias que possam reduzir esses números e garantir mais segurança para passageiros e pedestres. Nesse contexto, o desenvolvimento de um sistema de controle que assegure uma distância de segurança entre os veículos e respeite os limites de velocidade das vias se mostra viável e eficaz para tornar as rodovias mais seguras.

Nesta dissertação, propõe-se um sistema de controle para veículos de pequena escala aplicado a *platooning*, com o objetivo de manter uma distância de segurança entre os veículos. O sistema é baseado na arquitetura de controle por camadas, sendo projetados dois controladores distintos: um de baixo nível para o controle de velocidade de cruzeiro e outro de alto nível para o controle de distância.

Inicialmente, foi desenvolvido um modelo matemático em caixa preta que representa a dinâmica longitudinal do veículo de pequena escala. O modelo CNN-REI proposto apresentou desempenho superior aos modelos paramétricos de função de transferência e espaço de estados, bem como ao modelo inteligente NARX, demonstrando ser uma arquitetura extremamente robusta e capaz de aprender e se adequar às não linearidades do sistema.

Foi possível melhorar o desempenho de um ACC aplicado a um *platooning* de veículos autônomos em escala reduzida, otimizando a resposta do sistema e reduzindo os tempos de reação, utilizando uma arquitetura de controle em cascata com um controlador do tipo *fuzzy* na função de um ACC. Foi projetado um controlador de baixo nível seguindo o método de projeto de Ziegler-Nichols, que apresentou um bom desempenho com baixos valores para os tempos de resposta do sistema. O controlador FM-ACC de distância proposto é do tipo *Fuzzy Mamdani*, baseando-se nos valores do erro de distância e sua taxa de variação, gerando como saída uma velocidade de referência. O controlador apresentou um excelente desempenho, superando em todas as métricas um controlador PI desenvolvido pelo método de Ziegler-Nichols, apresentando uma redução de 92.25% de sobressinal, 77.26% de tempo de acomodação, 41.52% de tempo de pico, 7.84% de tempo de subida e 35.23% de tempo de atraso. Além disso, foi implementado em um veículo de escala reduzida, apresentando desempenho semelhante aos resultados simulados, demonstrando que o modelo de identificação de sistema está muito próximo do comportamento real do sistema. Dessa forma, o controlador

proposto se mostrou mais adequado para o controle de distância entre veículos, devido à sua capacidade de se adequar às não linearidades do sistema e apresentar melhores resultados em termos de resposta temporal.

Por fim, o sistema foi aplicado ao controle de um *platooning* com sete veículos, onde o veículo líder possuía apenas o controlador de aceleração e os veículos seguintes utilizavam o FM-ACC. Os resultados mostram que o sistema apresenta um *platooning* estável com até cinco veículos, enquanto os veículos 5 e 6 apresentam muita instabilidade e não conseguem manter uma distância de referência em relação aos veículos à frente. É importante ressaltar que a estratégia de controle utilizada não envolve comunicação entre os veículos, o que torna o efeito da propagação de perturbações mais visível.

## 7.1 LIMITAÇÕES

Os resultados apresentados mostram que o sistema proposto apresenta uma limitação clara no número de veículos que formam o *platooning*. Neste trabalho, o sistema é capaz de manter o *platooning* estável com até cinco veículos. Esse resultado deve-se ao fato de o sistema não contar com comunicação entre os veículos, o que faz com que o acúmulo de perturbações inviabilize o crescimento do *platooning*.

## 7.2 TRABALHOS FUTUROS

A seguir, são apresentados os próximos passos deste trabalho, baseados nos resultados alcançados nesta pesquisa:

- **Desevolvimento de um controlador com comunicação:** Será implementado um controlador com comunicação do tipo CACC com o objetivo de reduzir a propagação de perturbações pelo sistema, para tornar o *platooning* mais estável e consequentemente aumentar o número de veículos.
- **Modelo matemático mais realista:** Será desenvolvido um modelo matemático mais realista do sistema, introduzindo variações na dinâmica longitudinal, como a influência do atrito aerodinâmico e a inclinação das vias.
- **Considerações sobre o consumo:** Será desenvolvido um estudo sobre a influência do controlador FM-ACC na redução do consumo de energia dos veículos em *platooning*.

Esses são os próximos passos deste trabalho, visando contribuir com o desenvolvimento de soluções mais avançadas e eficientes para a mobilidade veicular, trazendo benefícios significativos para a sociedade e o meio ambiente.

## REFERÊNCIAS

- ABREU, J. L. M. C. e. a. Embedded system for the position control of a low-cost linear delta linear robot. In: IIDV. *Anais do IV COINTER PDVGT*. Recife-PE, Brasil, 2020.
- AGUIRRE, L. A. *Introdução à Identificação de Sistemas: Técnicas Lineares e Não Lineares: Teoria e Aplicação*. [S.l.]: Editora UFMG, 2015.
- BAYER, F. M.; ARAÚJO, O. C. B. d. *Controle Automático de Processos*. 3. ed. Santa Maria-RS, Brasil: Universidade Federal Santa Maria : Colégio Técnico Industrial de Santa Maria, 2011.
- CAO, W.; YUNO, T.; KAWABE, T. Pulse and glide strategy analysis based on engine operating point during pulse mode. *European Journal of Control*, 2022.
- CHAI, T.; DRAXLER, R. R. Root mean square error (rmse) or mean absolute error (mae)? – arguments against avoiding rmse in the literature. *Geosci. Model Dev.*, v. 7, p. 1247–1250, 2014.
- CHRISTUDAS, F.; DHANRAJ, V. System identification using long short term memory recurrent neural networks for real time conical tank system. *Romanian Journal Of Information Sciene and Technology*, v. 23, p. 57–77, 2021.
- CNT, C. N. d. T. *Painel CNT de Consultas Dinâmicas de Acidentes Rodoviários 2023*. 2023. Disponível em: <<https://www.cnt.org.br/painel-acidente>>. Acesso em: 03 jul. 2024.
- COELHO, A. F. *SAVIPS - Uma infraestrutura Veicular Autônoma em Pequena Escala para Platoon*. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal de Pernambuco, Recife-PE, Brasil, 2023.
- CRUIZ, J. A. G. *Monitoração e Análises da Penetração do Cordão de Solda Através da Observação da Oscilação da Poça de Fusão no Processo GMAW-S*. Tese (Doutorado em Engenharia Mecânica) — Universidade de Brasília, 2018.
- DONJAROENNON, N.; NUCHKUM, S.; LEETON, U. Mathematical model construction of dc motor by closed-loop system identification technique using matlab/simulink. *International Electrical Engineering Congress*, Pattaya, Thailand, 2021.
- DORF, R.; BISHOP, R. *Sistemas de Controle Modernos*. 13. ed. Rio de Janeiro-RJ, Brasil: Editora LTC, 2018.
- DUARTE, J. V. C.; FIGUEIREDO, P. H. L. *Desenvolvimento de Arquitetura Eletroeletrônica para Veículos de Pequena Escala*. Monografia (Graduação em Engenharia Automotiva) — Bacharelado em Engenharia Automotiva, Faculdade UnB Gama, Universidade de Brasília, Brasília, 2022.
- FUJIMOTO, R. Y. *Diagnóstico Automático de Defeitos em Rolamentos Baseado em Lógica Fuzzy*. Dissertação (Mestrado em Engenharia Mecânica) — Escola Politécnica da Universidade de São Paulo, 2005.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>.

- HAMAM, A.; GEORGANAS, N. D. A comparison of mamdani and sugeno fuzzy inference systems for evaluating the quality of experience of haptic-audio-visual applications. *IEEE International Workshop on Haptic Audio Visual Environments and their Applications*, Ottawa, Canada, 2008.
- HELLSRTOM, E.; IVARSSON, M.; ASLUND, J.; NIELSEN, L. Look-ahead control for heavy trucks to minimize trip time and fuel consumption. *Control Engineering Practice*, v. 17, p. 245–254, 2009.
- HYNDMAN, R.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. [S.l.]: OTexts: Melbourne, Australia, 2021. <OTexts.com/fpp3>. Acesso em: 11 jul. 2024.
- JÚNIOR, M. P. *Aplicação, de Controlador Fuzzy Supervisório em um secador na Indústria de Fertilizantes*. Dissertação (Mestrado em Controle e Automação de Processos de Mineração) — Universidade Federal de Ouro Preto, Ouro Preto-MG, Brasil, 2018.
- KIRISCI, M.; YOLCU, O. C. A new cnn-based model for financial time series: Taiex and ftse stocks forecasting. *Neural Processing Letters*, v. 54, p. 3357–3374, 2022.
- LU, X.-Y.; HEDRICK, J. Practical string stability for longitudinal control of automated vehicles. *Vehicle System Dynamics*, v. 41, n. 4, 2004.
- MATHWORKS. *Transfer function mode*. 2024. Disponível em: <<https://www.mathworks.com/help/control/ref/tf.html>>. Acesso em: 11 jul. 2024.
- MATSUURA, J. P.; AFONSO, R. J. M. *Controle de Sistemas no Plano-s*. 2020. Disponível em: <<https://www.coursera.org/learn/control-de-sistemas-no-plano-s>>. Acesso em: 11 jul. 2024.
- MOREIRA, H. A. M. *CONTROLE NEURO-FUZZY PARA EFICIÊNCIA ENERGÉTICA DE SISTEMAS DE ABASTECIMENTO DE ÁGUA COM DEMANDA VARIÁVEL*. Dissertação (Mestrado em Engenharia Mecânica) — Universidade Federal da Paraíba, João Pessoa-PB, Brasil, 2020.
- MOREIRA, H. A. M.; GOMES, G. P.; VILLANUEVA, J. M. “fuzzy – mandani controller for a supply system. Uberlândia-MG, Brasil, 2019.
- NAUNG, Y.; SCHAGIN, S.; OO, H. L.; YE, K. Z.; KHAING, Z. M. Implementation of data driven control system of dc motor by using system identification process. *IEEE NW Russia Young Researchers in Electrical and Electronic Engineering Conference*, Russia, 2018.
- NISE, N. S. *Engenharia de Sistemas de Controle*. 7. ed. Rio de Janeiro: LTC, 2017.
- OGATA, K. *Engenharia de Controle Moderno*. 5. ed. São Paulo: Pearson Prentice Hall, 2011. ISBN 978-85-4301-375-6.
- OHLSEN, R.; STEN, E. *Optimal Platooning of Heavy-Duty Vehicles*. Dissertação (Master of Science Thesis in Electrical and Mechanical Engineering) — Linköping University, Linköping, Sweden, 2018.
- OMS, W. *OMS.(2023) Global status report on road safety 2023*. 2023.
- OSIRO, L. *Uso da Lógica Fuzzy para Avaliação e Desenvolvimento de Fornecedores Baseado em Modelos de Portfólio*. Tese (Doutorado em Engenharia de Produção) — Universidade de São Paulo, 2013.

- 
- PATIL, n.; DATAR, R. G.; PATIL, D. D. R. System identification of a temperature control process using open loop and closed loop methods. *ICCMC - International Conference on Computing Methodologies and Communication*, 2018.
- RAJAMANI, R.; ZHU, C. Semi-autonomous adaptive cruise control systems. *IEEE Transactions on Vehicular Technology*, v. 51, n. 5, 2002.
- RESTIVO, F. A. C. *Controlador difuso para veículos em platooning*. Dissertação (Mestrado em Engenharia Eletrotécnica e de Computadores) — Universidade do Porto, Porto, Portugal, 2022.
- SENA, A. P. C. *Diagnóstico de Avarias em Transmissão por Engrenagens Baseado na Corrente do Motor de INdução e Entropia Wavelet*. Tese (Doutorado em Engenharia Mecânica) — Universidade Federal da Paraíba, João Pessoa-PB, Brasil, 2015.
- SHLADOVER, S.; LU, X.-Y.; YANG, S.; RAMEZANI, H.; SPRING, J.; NOWAKOWSKI, C.; NELSON, D.; THOMPSON, D.; KAILAS, A.; MCAULIFFE, C. Cooperative adaptive cruise control (cacc) for partially automated truck platooning. In: *Final report*,. [S.l.: s.n.], 2018.
- SILVA, A. S. e. a. Lógica fuzzy aplicada ao controle de posição de um robô delta. In: IIDV. *Congresso Internacional do Programa Despertando Vocações Tecnológicas*. Recife-PE, Brasil, 2021.
- SIMÕES, M. G.; SHAW, I. S. *Controle e Modelagem Fuzzy*. 2. ed. São Paulo: Editora Blucher, 2007.
- ULSOY, G. A.; PENG, H.; ÇAKMAKCI, M. *Automotive Control Systems*. 1. ed. New York, NY-USA: Cambridge University Press, 2012. ISBN 978-1-107-01011-6.
- XU, S.; LI, S. E.; ZHANG, X.; CHENG, B.; PENG, H. Fuel-optimal cruising strategy for road vehicles with step-gear mechanical transmission. *IEEE Transactions on Intelligent Transportation Systems*, IEEE, v. 1, 2015.
- YAGER, R.; FILEV, D. A simple adaptive defuzzification method. *IEEE Transactions On Fuzzy Systems*, IEEE, v. 1, n. 1, p. 69–78, 1993.
- YEN, J.; LANGARI, R. *Fuzzy Logic: Intelligence, Control and Information*. EUA: Prentice Hall, 1999.