Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica

Desenvolvimento de um Sistema Autônomo de Frenagem de Emergência utilizando Controle Preditivo Baseado em Modelo para Veículos de Passeio

Pedro Leoncio da Silva Neto

DISSERTAÇÃO DE MESTRADO

PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS MECATRÔNICOS

Brasília

2026

Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica

Desenvolvimento de um Sistema Autônomo de Frenagem de Emergência utilizando Controle Preditivo Baseado em Modelo para Veículos de Passeio

Pedro Leoncio da Silva Neto

Dissertação de Mestrado submetida ao Departamento de Engenharia Mecânica da Faculdade de Tecnologia da Universidade de Brasília como parte dos requisitos necessários para a obtenção do grau de Mestre

Orientador: Prof. Dr. Evandro Leonardo Silva Teixeira

Brasília
2026

Neto, Pedro Leoncio da Silva.
N478d Desenvolvimento de um Sistema Autônomo de Frenagem de Emergência utilizando Controle Preditivo Baseado em Modelo para Veículos de Passeio / Pedro Leoncio da Silva Neto; orientador Evandro Leonardo Silva Teixeira. -- Brasília, 2026.
108 p.

Dissertação de Mestrado (Programa de Pós-Graduação em Sistemas Mecatrônicos) -- Universidade de Brasília, 2026.

1. Sistema Autônomo de Frenagem de Emergência (AEBS). 2. Sistemas avançados de assistência ao condutor (ADAS). 3. Controle preditivo por modelo (MPC). 4. Dinâmica veicular. I. Teixeira, Evandro Leonardo Silva, orient. II. Título

Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica

Desenvolvimento de um Sistema Autônomo de Frenagem de Emergência utilizando Controle Preditivo Baseado em Modelo para Veículos de Passeio

Pedro Leoncio da Silva Neto

Dissertação de Mestrado submetida ao Departamento de Engenharia Mecânica da Faculdade de Tecnologia da Universidade de Brasília como parte dos requisitos necessários para a obtenção do grau de Mestre

Trabalho aprovado. Brasília, 29 de Maio de 2026:

Prof. Dr. Evandro Leonardo Silva Teixeira, UnB/FT/ENM
Orientador

Prof. Dr. Alessandro Borges de Sousa Oliveira, UnB/FCTE
Examinador interno

Prof. Dr. Max Mauro Dias Santos, UTFPR-PG/DAELE
Examinador externo

Brasília
2026

Dedico este trabalho aos meus pais, Angela e Leoncio, pelo amor, pelo apoio constante e pelos valores que sempre orientaram minha trajetória. Dedico também aos meus amigos Vanessa Lucena e Lucas Neves, cuja presença, apoio e incentivo foram fundamentais ao longo deste caminho.

Agradecimentos

A conclusão desta dissertação representa o resultado de uma trajetória marcada por aprendizado, desafios e perseverança, que não teria sido possível sem o apoio de pessoas fundamentais ao longo deste caminho.

Aos meus pais, Angela e Leoncio, expresso minha mais profunda gratidão. Pelo apoio incondicional, pelos valores transmitidos ao longo da vida e pela confiança constante em meus esforços. Tudo o que conquistei até aqui é, em grande medida, reflexo do amor, da dedicação e do exemplo que sempre me ofereceram.

Ao meu orientador, Evandro Teixeira, registro meu sincero agradecimento pela orientação, pela disponibilidade e pela confiança ao longo do desenvolvimento deste trabalho. Mesmo diante das dificuldades naturais do processo de pesquisa, sua disposição em continuar acreditando no projeto e em minha capacidade foi essencial para que esta dissertação pudesse ser conduzida até sua conclusão.

Aos meus amigos Lucas Neves e Vanessa Lucena, agradeço pelo apoio técnico, pelas discussões produtivas e pela disposição em contribuir com ideias e conhecimentos que enriqueceram o desenvolvimento deste trabalho. Também expresso minha gratidão pelo apoio emocional, compreensão e incentivo constante, especialmente nos momentos mais desafiadores desta jornada.

Agradeço ao Programa SegurAuto e à Fundação de Desenvolvimento da Pesquisa (FUNDEP) pelo apoio financeiro concedido por meio de bolsa, bem como à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), cujo suporte foi essencial para a realização desta pesquisa.

Por fim, agradeço a todos aqueles que, de alguma forma, contribuíram direta ou indiretamente para a realização deste trabalho e para a minha formação ao longo desta trajetória acadêmica.

“Many of life’s failures are people who did not realize how close they were to success when they gave up.”

(Thomas A. Edison)

Resumo

Esta dissertação apresenta o desenvolvimento e a validação de um Sistema Autônomo de Frenagem de Emergência (AEBS) voltado para veículos de passeio, com foco na mitigação de colisões traseiras. O contexto da pesquisa insere-se na necessidade crítica de redução dos índices de sinistralidade viária no Brasil, alinhando-se aos eixos estratégicos do Plano Nacional de Redução de Mortes e Lesões no Trânsito (PNATRANS). A metodologia fundamenta-se na modelagem matemática rigorosa da dinâmica veicular, integrando as equações de movimento longitudinal ao modelo bicicleta para a dinâmica lateral, o que garante um arcabouço modular apto para futuras expansões em manobras evasivas. Como núcleo da estratégia de decisão, foi projetado um controlador preditivo por modelo (MPC) linearizado, escolhido por sua capacidade intrínseca de gerenciar sistemas multivariáveis e incorporar restrições físicas e de conforto - como limites de aderência pneu-pavimento e jerk - diretamente no problema de otimização quadrática. A lógica de ativação do sistema baseia-se nas métricas de Tempo para Colisão (TTC) e Tempo para Igualação de Velocidade (TTMV). O desempenho do controlador foi avaliado por meio de simulações *Model-in-the-Loop* (MIL) e validado em tempo real através de testes *Hardware-in-the-Loop* (HIL) na plataforma Speedgoat, garantindo o determinismo temporal exigido por uma ECU real. Os cenários de teste contemplaram velocidades iniciais de 30, 40, 60 e 80 km/h contra um obstáculo estático. Os resultados demonstraram a eficácia absoluta do sistema, que evitou colisões em todos os cenários, mantendo a força de frenagem e a desaceleração dentro dos limites de segurança e conforto estabelecidos. A convergência total entre os dados MIL e HIL confirma a viabilidade técnica da arquitetura proposta e sua contribuição para o avanço da segurança ativa no contexto da engenharia automotiva nacional.

Palavras-chave: Sistema Autônomo de Frenagem de Emergência (AEBS). Sistemas avançados de assistência ao condutor (ADAS). Controle preditivo por modelo (MPC). Dinâmica veicular.

Abstract

This dissertation presents the development and validation of an Autonomous Emergency Braking System (AEBS) for passenger vehicles, focused on mitigating rear-end collisions. The research is framed by the critical need to reduce road traffic injury rates in Brazil, in alignment with the strategic axes of the National Plan for the Reduction of Deaths and Injuries in Traffic (PNATRANS). The methodology is grounded in rigorous mathematical modeling of vehicle dynamics, integrating longitudinal motion equations with the bicycle model for lateral dynamics, thus ensuring a modular framework suitable for future extensions to evasive maneuvers. As the core decision-making strategy, a linearized Model Predictive Control (MPC) controller was designed, due to its intrinsic ability to manage multivariable systems and incorporate physical and comfort constraints - such as tire-road adhesion limits and jerk - directly into the quadratic optimization problem. The system activation logic is based on Time-to-Collision (TTC) and Time-to-Matching Velocity (TTMV) metrics. Controller performance was assessed through Model-in-the-Loop (MIL) simulations and validated in real time via Hardware-in-the-Loop (HIL) tests on the Speedgoat platform, ensuring the temporal determinism required by a real ECU. Test scenarios included initial speeds of 30, 40, 60, and 80 km/h against a stationary obstacle. Results demonstrated the system's full effectiveness, avoiding collisions in all scenarios while keeping braking force and deceleration within established safety and comfort limits. The complete convergence between MIL and HIL data confirms the technical feasibility of the proposed architecture and its contribution to advancing active safety in the context of Brazilian automotive engineering.

Keywords: Autonomous Emergency Braking System (AEBS). Advanced Driver Assistance Systems (ADAS). Model Predictive Control (MPC). Vehicle dynamics.

Lista de ilustrações

Figura 1 – Arquitetura típica de ADAS, destacando componentes como sensores, módulos de processamento e atuadores (Antony e Whenish, 2021). . . . 23
Figura 2 – Fluxograma do algoritmo AEBS (LEE et al., 2011) 27
Figura 3 – Diagrama de corpo livre - Forças agindo no veículo (Ulsoy, Peng e Çakmakci, 2012) 30
Figura 4 – Modelo Bicicleta 33
Figura 5 – Roda traseira. (Michael, 2020) 35
Figura 6 – Força lateral, F_y, *versus* angulo de deslizamento, $alpha$ 35
Figura 7 – Roda dianteira. (Michael, 2020) 36
Figura 8 – Ciclo básico de controle MPC (MathWorks, 2024) 41
Figura 9 – Diagrama do algoritmo básico de controle MPC 41
Figura 10 – Configuração típica de teste HIL (MathWorks, 2023) 48
Figura 11 – Visão geral do algoritmo TTC utilizado na lógica de ativação. 67
Figura 12 – Velocidade do veículo seguidor em relação a obstáculo parado em diferentes velocidades iniciais 73
Figura 13 – Velocidade do veículo seguidor em relação a obstáculo parado considerando limites de controle 74
Figura 14 – Força de frenagem aplicada em diferentes velocidades iniciais contra obstáculo parado 76
Figura 15 – Variação da força de frenagem em diferentes velocidades iniciais contra obstáculo parado 77
Figura 16 – Desaceleração do veículo em diferentes velocidades iniciais contra obstáculo parado 79
Figura 17 – Variação da desaceleração (*jerk*) em diferentes velocidades iniciais contra obstáculo parado 80
Figura 18 – Posição relativa do veículo seguidor em diferentes velocidades iniciais contra obstáculo parado 82
Figura 19 – Velocidade do veículo de teste em relação ao obstáculo: HIL — 30 km/h 84
Figura 20 – Limites para velocidade do veículo de teste: HIL — 30 km/h 84
Figura 21 – Diferença MIL × HIL: Velocidade — 30 km/h 85
Figura 22 – Força de frenagem aplicada no veículo de teste: HIL — 30 km/h 85
Figura 23 – Diferença MIL × HIL: Força de frenagem — 30 km/h 86
Figura 24 – Variação da força de frenagem aplicada no veículo de teste: HIL — 30 km/h 86
Figura 25 – Diferença MIL × HIL: Variação da força de frenagem — 30 km/h 87
Figura 26 – Desaceleração do veículo de teste: HIL — 30 km/h 87
Figura 27 – Diferença MIL × HIL: Desaceleração — 30 km/h 88

Figura 28 – Variação da desaceleração do veículo de teste: HIL — 30 km/h 88
Figura 29 – Diferença MIL × HIL: Variação da desaceleração — 30 km/h 89
Figura 30 – Distância percorrida pelo veículo de teste: HIL — 30 km/h 89
Figura 31 – Diferença MIL × HIL: Distância percorrida — 30 km/h 90
Figura 32 – Distância crítica de frenagem 91
Figura 33 – Tempo de execução: Atualização dos estados — HIL × MIL 93
Figura 34 – Tempo de execução: Força de frenagem — HIL × MIL 94

Lista de tabelas

Tabela 1 – Hierarquia de automação veicular segundo a SAE J3016 (SAE International, 2021). 24
Tabela 2 – Comparação entre controladores: PID, Lógica Fuzzy, SMC e MPC 39
Tabela 3 – Palavras-chave e fórmula para busca da bibliografia na base de dados . . 51
Tabela 4 – Parâmetros do Controlador MPC adotados. 66
Tabela 5 – Parâmetros de ativação do controlador AEB. 68
Tabela 6 – Parâmetros do veículo 69
Tabela 7 – Cenários de teste 71
Tabela 8 – Métricas de avaliação do desempenho do controlador MPC no AEBS . . 72
Tabela 9 – Resultados temporais do processo de frenagem do sistema AEBS 75
Tabela 10 – Limites de projeto para força de frenagem e sua variação temporal . . . 76
Tabela 11 – Força de frenagem e sua variação temporal nos cenários avaliados . . . 78
Tabela 12 – Limites de projeto para desaceleração e *jerk* 79
Tabela 13 – Desaceleração máxima e variação da desaceleração nos cenários avaliados 81
Tabela 14 – Distância percorrida e margem de segurança nos cenários avaliados . . 82
Tabela 15 – Síntese dos erros residuais MIL × HIL — cenário de 30 km/h 90
Tabela 16 – Distância crítica de frenagem, posição final do veículo e margem de segurança residual nos cenários avaliados. 92
Tabela 17 – Tempos de execução dos blocos funcionais do controlador MPC — MIL vs. HIL 95

Lista de abreviaturas e siglas

ACC	Controle de Cruzeiro Adaptativo	17
ADAS	Sistemas Avançados de Assistência ao Condutor	13
ADMM	Método dos Multiplicadores Direcionais Alternados	48
AEB	Frenagem Autônoma de Emergência	13
AEBS	Sistema Autônomo de Frenagem de Emergência	13
AES	Sistema Autônomo de Desvio	20
ANCAP	*Australian New Car Assessment Programme*	13
BSD	Monitoramento de Ponto Cego	17
CAN	Rede de Área de Controle	18
CAS	Sistema de Evitamento de Colisão	20
CCRb	*Car-to-Car Rear braking*	63
CCRm	*Car-to-Car Rear moving*	63
CCRs	*Car-to-Car Rear stationary*	63
CONTRAN	Conselho Nacional de Trânsito	13
CTB	Código de Trânsito Brasileiro	64
DOF	Graus de Liberdade	25
DSRC	Comunicação Dedicada de Curto Alcance	50
E/S	Entrada/Saída	41
ECU	Unidade de Controle Eletrônico	42
Euro NCAP	*European New Car Assessment Programme*	13
GM	General Motors	16
GNSS	Sistema Global de Navegação por Satélite	18
HIL	*Hardware-in-the-Loop*	40
ISO	Organização Internacional para Padronização	61
JIT	Compilação *Just-in-Time*	86
Latin NCAP	*Latin New Car Assessment Programme*	13
LiDAR	Detecção e Alcance por Luz	16

LIN	Rede de Interconexão Local	18
LKA	Assistência de Manutenção de Faixa	17
LKAS	Sistema de Assistência de Manutenção de Faixa	18
LV	Veículo Líder	60
MDP	Processo de Decisão de Markov	46
MIL	*Model-in-the-Loop*	66
MPC	Controle Preditivo Baseado em Modelo	13
NCAP	*New Car Assessment Programme*	13
NMPC	Controle Preditivo Baseado em Modelo Não Linear	53
PID	Controlador Proporcional-Integral-Derivativo	30
PNATRANS	Plano Nacional de Redução de Mortes e Lesões no Trânsito	13
QP	Programação Quadrática	34
RTOS	Sistema Operacional de Tempo Real	82
SAE	Sociedade de Engenheiros Automotivos	16
SAE J3016	Norma SAE J3016	16
SF	Fórmula de Busca	44
SI	Sistema Internacional de Unidades	62
SIL	*Software-in-the-Loop*	92
SLR	Revisão Sistemática de Literatura	43
SMC	Controle por Modo Deslizante	30
SQP	Programação Quadrática Sequencial	34
SS	String de Busca	44
SV	Veículo em Estudo	60
THW	Intervalo de Tempo entre Veículos	47
TTC	Tempo para Colisão	47
TTMV	Tempo para Igualação de Velocidade	60
V2I	Comunicação Veículo-para-Infraestrutura	18
V2V	Comunicação Veículo-para-Veículo	18
ZOH	Retenção de Ordem Zero	57

Lista de símbolos

(x_1,y_1)	Plano de referência	27
α	Ângulo de deslizamento da roda	28
α_f	Ângulo de deslizamento da roda dianteira	27
α_r	Ângulo de deslizamento da roda traseira	27
δF_x	Variação da força de frenagem entre instantes amostrais	58
δ	Ângulo de esterçamento	27
δ^{max}	Limite superior da variação entrada de controle	40
δ^{min}	Limite inferior da variação entrada de controle	40
δ_f	Ângulo de esterçamento da roda dianteira	27
$\dot{r}$	Derivada da taxa de guinada no tempo	27
$\dot{u}$	Derivada da velocidade longitudinal no tempo	51
$\dot{v}$	Derivada da velocidade lateral no tempo	27
λ	Taxa de escorregamento do pneu	24
μ	Coeficiente de aderência pneu-pavimento	24
Φ_i	Bloco da matriz de predição de estados	38
Π	Matriz de seleção	38
Ψ_i	Bloco da matriz de predição de entradas	38
Ψ_i^T	Transposta do bloco de predição de entradas	57
ρ	Densidade do ar	24
θ	Inclinação da via	23
$\tilde{u}(k)$	Vetor empilhado de entradas futuras	37
$\tilde{x}(k)$	Vetor empilhado de estados previstos	37
$\tilde{y}_r^d$	Conjunto de saídas desejadas do sistema	39
A	Matriz de estados	36
A	Área máxima da seção transversal do veículo	24
a_1	Distância do CG ao eixo dianteiro	27
a_2	Distância do CG ao eixo traseiro	27

A_d Matriz de estados discretizada . . . 57
a_y Aceleração do veículo no eixo lateral . . . 52
a_y Aceleração lateral do veículo . . . 51
A_{lin} Matriz de estados linearizada (Jacobiana) . . . 57
a_{max} Desaceleração máxima admissível . . . 24
a_x Aceleração longitudinal . . . 23
B Matriz de entrada . . . 36
B_d Matriz de entrada discretizada . . . 57
B_{lin} Matriz de entrada linearizada . . . 57
C Matriz de saída . . . 36
C_α inclinação da curva F_y versus α . . . 28
C_d Coeficiente de arrasto aerodinâmico . . . 24
c_f Rigidez lateral da roda dianteira . . . 29
C_r Matriz de saída regulada . . . 39
c_r Rigidez lateral da roda traseira . . . 29
C_c Matriz de saída controlada . . . 39
CG Centro de gravidade . . . 23
D Matriz direta . . . 36
D_A Força de arrasto aerodinâmico . . . 23
D_c Matriz de influência da entrada no valor da saída controlada . . . 39
F Gradiente de custo . . . 57
f Coeficiente de resistência ao rolamento . . . 24
F_1 Termo auxiliar 1 do gradiente de custo . . . 57
F_2 Termo auxiliar 2 do gradiente de custo . . . 57
F_3 Termo auxiliar 3 do gradiente de custo . . . 57
F_f, F_r Força lateral aplicada no pneu dianteiro e traseiro, respectivamente . . . 27
F_y Forças laterais que atuam nas rodas dianteira e traseira do veículo . . . 28
$F_{x_{max}}$ Força de frenagem máxima admissível . . . 58
F_x Força de tração longitudinal . . . 23
F_z Força normal . . . 23

g	Aceleração da gravidade	23
H	Matriz Hessiana do problema de otimização	57
I_z	Momento de inércia em torno do eixo z	27
J	Função custo do problema de otimização	39
$jerk_{max}$	Variação máxima admissível da desaceleração	58
k	Índice de amostragem discreta	37
m	Massa do veículo	23
N	Horizonte de predição	37
n_r	Número de saídas de referência	57
n_u	Número de entradas de controle	38
P_{LV}	Posição longitudinal do veículo líder	60
P_{SV}	Posição longitudinal do veículo em estudo	60
Q_u	Matriz de pesos do esforço de controle	57
Q_y	Matriz de pesos do erro de saída	39
r	Taxa de guinada do veículo	27
r_0	Taxa de guinada no ponto de operação	53
R_{hz}	Força normal que atua no eixo traseiro de acoplamento do veículo	23
R_h	Força de tração proveniente de carga acoplada à traseira do veículo	23
R_x	Força de resistência ao rolamento	23
t	Tempo	36
T_s	Período de amostragem	57
TTC_{min}	Limiar mínimo do tempo para colisão	60
u	Variável de controle	36
u	Velocidade longitudinal do veículo	27
u_0	Velocidade longitudinal no ponto de operação	53
u_d	Entrada de controle desejada	57
u_w	Velocidade do vento	24
v	Velocidade lateral do veículo	27
v_0	Velocidade lateral no ponto de operação	53
V_{LV}	Velocidade longitudinal do veículo líder	60

V_{SV} Velocidade longitudinal do veículo em estudo 60
W Peso do veículo 23
x Vetor de estados 36
y Saída do sistema 36
y_c Saída controlada 39
y_d Saída desejada 57
y_r Saídas reguladas do sistema 39
(B, C, D, E) Fator de rigidez, forma, pico e curvatura da fórmula de Pacejka, respectivamente 25
$F_{\mu max}$ Força de atrito máxima 25
jerk Variação da aceleração 58

Sumário

1 INTRODUÇÃO 20
1.1 Objetivos 21
1.2 Estrutura do Documento 21

2 REVISÃO DA LITERATURA 23
2.1 Sistemas Avançados de Assistência ao Condutor 23
2.2 Sistema Autônomo de Frenagem de Emergência - AEBS 26
2.3 Dinâmica Veicular 29
2.3.1 Dinâmica longitudinal 29
2.3.2 Dinâmica lateral - Modelo bicicleta 32
2.4 Estratégias de Controle 37
2.5 Controle Preditivo Baseado em Modelo - MPC 40
2.5.1 Conceitos básicos sobre o controlador MPC 40
2.5.2 Modelagem matemática do MPC 43
2.6 *Hardware-in-the-Loop* 47

3 ESTADO DA ARTE 50
3.1 Protocolo de pesquisa 50
3.1.1 Planejamento da Revisão 50
3.1.2 Condução de Revisão 51
3.2 Camada de percepção e técnicas de fusão sensorial 52
3.3 Estratégias de Controle 54
3.4 Benefícios e Limitações dos Sistemas AEBS 56

4 PROJETO DO CONTROLADOR PARA SISTEMA AEBS 58
4.1 Dinâmica Veicular 58
4.2 Formulação do Controlador MPC 61
4.3 Estratégia de Ativação do Controlador AEBS 67

5 PROCEDIMENTO EXPERIMENTAL 69
5.1 Características do Automóvel 69
5.2 Ambiente de Simulação e Validação Experimental 69
5.3 Cenários de Teste 70
5.4 Métricas de Avaliação 71

6 RESULTADOS E ANÁLISES 73
6.1 Velocidade do veículo 73

6.2 Força de frenagem 75
6.3 Desaceleração 78
6.4 Distância percorrida 81
6.5 Validação em *Hardware-in-the-Loop* 83
6.6 Distância crítica de frenagem - *Worst Case Scenario* 90
6.7 Análise Comparativa do Desempenho Computacional: QP *Solver* e Modelo de Estados — MIL vs. HIL 92

7 CONCLUSÃO 96

REFERÊNCIAS 100

1 Introdução

Em 2024, o Brasil registrou 37.150 óbitos decorrentes de acidentes de trânsito, configurando uma reversão da tendência de queda observada entre 2010 e 2020 (Akkari, 2026). Em escala global, esses acidentes causam aproximadamente 1,25 milhão de mortes por ano e deixam entre 20 e 50 milhões de feridos (Xiaoxia et al., 2019). Essas ocorrências já figuram como a nona principal causa de óbitos no mundo e podem alcançar a quinta posição até 2030, caso medidas eficazes não sejam implementadas (Sam, Velanganni e Evangelin, 2016).

Em resposta a essa realidade, o Governo Federal brasileiro instituiu, em 2018, o Plano Nacional de Redução de Mortes e Lesões no Trânsito (PNATRANS) , estruturado em cinco eixos estratégicos: (1) gestão da segurança viária, (2) vias mais seguras, (3) veículos mais seguros, (4) usuários mais seguros e (5) respostas aos acidentes (Federal, 2018). A Resolução CONTRAN nº 870 , de 2021, reforçou essas diretrizes ao estabelecer como meta a redução de 50% das mortes no trânsito no período de uma década (Infraestrutura, 2021).

Iniciativas similares têm sido implementadas internacionalmente. O programa Euro NCAP (*European New Car Assessment Programme*) avalia tecnologias embarcadas de segurança ativa, como os Sistemas de Frenagem Autônoma de Emergência (AEB) , com o intuito de prevenir colisões frontais e traseiras (Boda, Lehtonen e Dozza, 2020). Avaliações equivalentes ocorrem na Austrália (ANCAP), nos Estados Unidos (NCAP) e na América do Sul (Latin NCAP), evidenciando a crescente relevância global da segurança veicular baseada em tecnologias inteligentes.

Nesse contexto, os Sistemas Avançados de Assistência ao Condutor (ADAS) emergem como soluções tecnológicas promissoras para mitigar acidentes por meio da automação parcial ou total de funções críticas. Dentre esses sistemas, destaca-se o Sistema Autônomo de Frenagem de Emergência (AEBS) , cuja função é detectar, por meio de sensores e algoritmos, a iminência de uma colisão e, caso o motorista não reaja a tempo, acionar automaticamente os freios do veículo. A eficácia do AEBS depende de diversos fatores, incluindo a robustez da percepção sensorial, o tempo de processamento e, sobretudo, a estratégia de controle implementada para tomada de decisão em tempo real.

Alinhada ao eixo (3) do PNATRANS, voltado à promoção de veículos mais seguros, esta pesquisa propõe o desenvolvimento de um sistema AEBS para veículos de passeio com foco na prevenção de colisões traseiras, integrando modelagem matemática da dinâmica veicular e técnicas de controle, em especial o Controle Preditivo Baseado em Modelo (MPC) . Com isso, busca-se contribuir para o avanço desses sistemas, em consonância com referências internacionais, e fortalecer práticas que acelerem o ciclo de desenvolvimento automotivo seguro por meio da integração entre controle e validação em cenários representativos.

1.1 Objetivos

Este trabalho tem como objetivo principal desenvolver um Sistema Autônomo de Frenagem de Emergência (AEBS) voltado a veículos de passeio, com ênfase na prevenção de colisões traseiras. Para alcançar tal objetivo, definem-se os seguintes objetivos específicos:

1. **Definir a arquitetura do sistema AEBS**, especificando a estratégia de controle e os requisitos operacionais voltados à mitigação de colisões traseiras;
2. **Modelar matematicamente a dinâmica veicular**, considerando as forças envolvidas nos eixos longitudinal e lateral, de forma a subsidiar o projeto do controlador;
3. **Projetar e implementar um algoritmo de controle**, capaz de prever o comportamento do sistema e aplicar a frenagem de maneira segura e eficiente;
4. **Simular e validar o desempenho do sistema**, por meio de cenários padronizados de condução, avaliando critérios técnicos como respostas do sistema, robustez e conforto.

A motivação da pesquisa fundamenta-se em três pilares centrais: (i) a necessidade de reduzir os índices de acidentes e fatalidades no Brasil, alinhando-se às diretrizes do PNATRANS; (ii) o potencial comprovado dos sistemas ADAS na preservação de vidas; e (iii) a demanda por avanços tecnológicos no campo do controle veicular e da automação.

1.2 Estrutura do Documento

Esta dissertação está organizada em sete capítulos, os quais desenvolvem de forma progressiva a concepção e validação de um sistema AEBS com base em controle preditivo.

O **Capítulo 2** apresenta a revisão da literatura sobre os Sistemas Avançados de Assistência ao Condutor (ADAS), com destaque para o funcionamento, arquitetura e desafios do AEBS. São abordados fundamentos teóricos, tecnologias embarcadas e limitações atuais.

O **Capítulo 3** explora o estado da arte em AEBS, com foco nas estratégias contemporâneas de controle e nas técnicas de fusão sensorial. Esta seção visa identificar lacunas tecnológicas e mapear direções promissoras na área de segurança veicular.

O **Capítulo 4** trata do desenvolvimento técnico do sistema proposto. São descritas a modelagem da dinâmica veicular, a linearização do sistema, a formulação do controlador MPC, bem como as métricas de avaliação e os cenários de teste.

O **Capítulo 5** explica a configuração experimental e de simulação. Este capítulo descreve as características físicas do veículo, bem como a plataforma de simulação, os cenários de teste, com base em programas internacionais, e as métricas de desempenho.

O **Capítulo 6** apresenta os resultados obtidos nas simulações computacionais, com base em critérios como segurança, conforto e eficiência. A atuação do controlador será avaliada frente a diferentes situações de risco.

O **Capítulo 7** conclui o trabalho, sintetizando as contribuições alcançadas, discutindo limitações e propondo direções para pesquisas futuras.

Espera-se que os resultados obtidos ao longo deste trabalho contribuam significativamente para o avanço dos sistemas de segurança ativa no contexto da mobilidade inteligente e da engenharia automotiva.

2 Revisão da Literatura

Este capítulo apresenta uma síntese do material estudado com o objetivo de desenvolver um Sistema Autônomo de Frenagem de Emergência (AEBS), parte dos Sistemas Avançados de Assistência ao Condutor (ADAS). Será compilado um conjunto de referências bibliográficas que serão úteis para o desenvolvimento desse sistema, permitindo uma compreensão mais profunda da tecnologia envolvida.

2.1 Sistemas Avançados de Assistência ao Condutor

O avanço tecnológico e as demandas por mobilidade segura e sustentável têm impulsionado o desenvolvimento de Sistemas Avançados de Assistência ao Condutor (ADAS), como destacam (Jiménez, 2018; Antony e Whenish, 2021). Esses sistemas, que incluem desde recursos passivos, como alertas sonoros, até ativos, por exemplo, frenagem autônoma, respondem não apenas a exigências regulatórias globais, mas também à competitividade entre montadoras como GM , Toyota e Tesla (Niranjana, 2024). Tecnicamente, os ADAS integram sensores (câmeras, radar, LiDAR) e algoritmos para funções como detecção de pedestres ou assistência de faixa, conforme ilustrado na Figura 1.

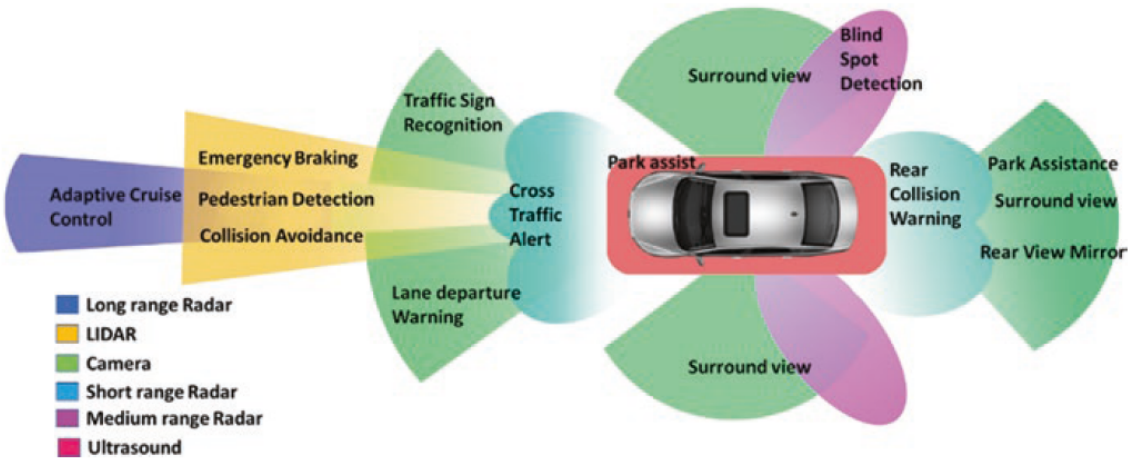


Figura 1 – Arquitetura típica de ADAS, destacando componentes como sensores, módulos de processamento e atuadores (Antony e Whenish, 2021).

Conforme a hierarquia de automação veicular da SAE J3016 , mostrada na Tabela 1, a automação de um veículo é classificada nos níveis de 0 a 5 com base na extensão das funções realizadas sem a intervenção do motorista (SAE International, 2021). Os sistemas ADAS, como o AEBS, correspondem a funcionalidades de níveis 1–3, oferecendo assistência ao condutor, mas não substituindo totalmente o controle humano.

Nível	Nome	Descrição
0	Sem Automação	O motorista humano é responsável por todas as tarefas de direção e controle. Não há assistência automatizada.
1	Assistência ao condutor	Sistemas de assistência ao condutor, como controle de cruzeiro adaptativo (ACC) ou assistência de manutenção de faixa (LKA). O motorista ainda é responsável pelo controle do veículo em todas as situações.
2	Automação parcial	O veículo pode controlar a direção e a aceleração/desaceleração simultaneamente (por exemplo, ACC e LKA funcionando juntos). O motorista deve monitorar o ambiente e estar preparado para assumir o controle a qualquer momento.
3	Automação condicional	O veículo pode gerenciar todas as funções de condução em condições específicas (por exemplo, em rodovias). O motorista deve estar disponível para assumir o controle quando solicitado pelo sistema.
4	Alta automação	O veículo pode operar de forma autônoma em determinadas condições ou áreas geográficas (como em cidades ou zonas de estacionamento). O sistema pode assumir o controle completo sem intervenção do motorista, mas a intervenção pode ser necessária fora dessas condições ou áreas.
5	Automação completa	O veículo é totalmente autônomo e não requer intervenção do motorista em nenhuma condição. Não é necessário um volante ou pedais, e o veículo pode operar sem um condutor a bordo.

Tabela 1 – Hierarquia de automação veicular segundo a SAE J3016 (SAE International, 2021).

Os Sistemas Avançados de Assistência ao Condutor (ADAS) abrangem uma variedade de tecnologias, desde funções básicas, como câmeras de ré e sensores de ponto cego, até sistemas complexos, como controle de cruzeiro adaptativo e estacionamento autônomo (Antony e Whenish, 2021; Niranjana, 2024). Entre as aplicações mais relevantes destacam-se:

- Sistema Autônomo de Frenagem de Emergência (AEBS): Detecta risco de colisão e freia automaticamente se o motorista não reagir a tempo, prevenindo acidentes.
- Controle de Cruzeiro Adaptativo (ACC): Ajusta a velocidade do veículo para manter distância segura em rodovias, utilizando radar ou laser para acelerar, desacelerar ou parar conforme necessário.
- Monitoramento de Ponto Cego (BSD) : Alerta o motorista sobre veículos em áreas não visíveis, auxiliando em ultrapassagens seguras.

- Assistência de Manutenção de Faixa (LKAS) : Utiliza câmeras e sensores para manter o veículo dentro da faixa, corrigindo a direção automaticamente.

Os ADAS baseiam-se em uma cadeia de informações que engloba aquisição, comunicação, processamento e distribuição de dados (Jiménez, 2018). Esses elementos permitem que veículos equipados com ADAS interpretem o ambiente e tomem decisões autônomas (Niranjana, 2024; Antony e Whenish, 2021). Essa cadeia inclui:

- Sensores a bordo, que capturam dados em tempo real;
- Comunicação intraveicular, via barramentos como CAN ou LIN;
- Tecnologias de posicionamento, como balizas ou GNSS;
- Comunicação veículo-veículo (V2V) e veículo-infraestrutura (V2I), essenciais para coordenação em tempo real.

Essas tecnologias dependem de sensores avançados para replicar e ampliar as capacidades humanas. Esses sensores fornecem dados aos algoritmos que controlam freios, acelerador e direção, como no BSD (radar de curto alcance) e no ACC (radares de curto e longo alcance) (Antony e Whenish, 2021). Entre os principais tipos estão:

- Câmeras: Identificam objetos, sinais de trânsito e faixas, mas são sensíveis a condições climáticas.
- Radar: Detecta objetos em longas distâncias, mesmo sob chuva ou neblina, sendo crítico para frenagem autônoma.
- LiDAR: Usa lasers para mapeamento 3D de alta precisão, ideal para detecção de pedestres e obstáculos pequenos.
- Sensores ultrassônicos: Auxiliam em estacionamento e detecção de proximidade, emitindo ondas sonoras.

A eficácia dos ADAS também depende de estratégias e *feedback* que facilitem a interação do motorista com sistemas automatizados. Protocolos avançados de alerta reduzem fadiga ao oferecer avisos intuitivos, sonoros ou visuais, e permitem a troca de informações entre veículos. Além disso, ao delegar tarefas críticas à automação, como frenagem emergencial ou manutenção de faixa, esses mecanismos de aviso aumentam a segurança e a eficiência, preparando o caminho para níveis mais elevados de autonomia. (Niranjana, 2024)

Sistemas ADAS elevam a segurança ao compensar erros humanos (desatenção, imprudência) e proteger motoristas e pedestres (Antony e Whenish, 2021; Niranjana, 2024).

Essas tecnologias oferecem benefícios multifacetados: melhoram a eficiência energética via otimização de frenagem e rotas; aprimoram a gestão de tráfego com dados em tempo real; aumentam o conforto do motorista com funções como estacionamento assistido; previnem acidentes através de sensores (frenagem automática, alerta de ponto cego); e promovem conectividade (integração com smartphones) e acessibilidade (controles por voz).

Estudos comprovam seu impacto, como a redução de até 80% nas mortes e a prevenção de 1,8 milhão de acidentes anuais, com tecnologias específicas (ex., frenagem automática evitando 29% dos acidentes nos EUA) (Niranjana, 2024; Aleksa et al., 2024). A regulamentação progressiva, como a UE 2019/2144, reforça a necessidade de adoção ampla e contínuo aprimoramento desses sistemas para um futuro viário mais seguro.

A implementação desses sistemas enfrenta desafios complexos que abrangem aspectos tecnológicos, sociais e regulatórios (Jiménez, 2018; Niranjana, 2024). Do ponto de vista técnico, persistem limitações como a dependência excessiva dos motoristas em sistemas ADAS (levando à complacência), custos elevados de implantação e manutenção, vulnerabilidade de sensores em condições climáticas adversas, e o risco de erosão de habilidades tradicionais de direção.

Questões éticas também emergem, como a responsabilidade em acidentes envolvendo veículos equipados com ADAS e preocupações sobre privacidade e uso indevido de dados. Politicamente, exige-se maior cooperação entre setores público e privado para estabelecer marcos regulatórios adequados, enquanto desafios sociais incluem a necessidade de adaptação cultural e capacitação multidisciplinar. (Jiménez, 2018; Niranjana, 2024)

Embora os sistemas ADAS enfrentem desafios como a vulnerabilidade de sensores em condições climáticas adversas e o risco de complacência do motorista, sua capacidade de mitigar erros humanos os torna importantes para a segurança viária. O sucesso dessas tecnologias depende do aprimoramento de protocolos avançados de alerta intuitivos e de marcos regulatórios que garantam a proteção de dados dos usuários. Assim, os sistemas ADAS se consolidam como fundamentais para a futura condução autônoma, promovendo mobilidade eficiente e segura.

2.2 Sistema Autônomo de Frenagem de Emergência - AEBS

O sistema AEBS (*Autonomous Emergency Braking System*), é um mecanismo de segurança ativa que intervém automaticamente nos freios em situações de colisão iminente (Yang, W., Liu et al., 2020). Tecnicamente, o AEBS integra sensores de longo e curto alcance, para processar dados dinâmicos e avaliar riscos de impacto traseiro (Hyuck-Kee, Seong-Geun e Dong-Soo, 2017). Ao identificar perigo, o sistema emite alertas e, persistindo a inércia

do condutor, assume o controle para mitigar a severidade do evento ou evitá-lo totalmente (Boda, Lehtonen e Dozza, 2020).

A operação do sistema adapta-se à gravidade do cenário: em situações críticas, reduz a velocidade de impacto para minimizar danos fatais; em cenários passíveis de controle, é capaz de parar o veículo completamente (Senapati, Das e Vora, 2017; Sam, Velanganni e Evangelin, 2016). A ativação depende de algoritmos que monitoram continuamente a iminência de colisão e podem atuar de forma assistiva, ampliando a força de frenagem aplicada pelo motorista, ou totalmente autônoma, operando independentemente de qualquer comando humano para garantir a segurança dos ocupantes e pedestres (Alsuwian, Saeed e Amin, 2022; Basjaruddin, Rakhman e Lawinata, 2021).

O sistema AEB é parte do Sistema de Evitamento de Colisão (CAS) , que engloba também o Sistema Autônomo de Desvio (AES) (Park, Kim, D. e Huh, 2021). Embora suas lógicas de detecção sejam semelhantes, eles se distinguem pelo eixo de atuação: enquanto o AEBS realiza a gestão longitudinal via frenagem, o AES executa manobras laterais quando a parada total é fisicamente impossível (Dong et al., 2024).

A Figura 2 apresenta o fluxograma básico do algoritmo da função AEBS proposto por LEE et al. (2011). Observa-se que esta estrutura exemplifica o paradigma fundamental 'sentir-pensar-agir', comum a diversos sistemas ADAS, em que sensores captam dados do ambiente para processamento e tomada de decisão (Katare e El-Sharkawy, 2018). O veículo utiliza sensores acoplados para captar informações do ambiente externo, que são processadas internamente, resultando em uma ação tomada com base nesses dados. Contudo, a literatura demonstra que a implementação desse fluxo varia conforme a complexidade do controle adotado.

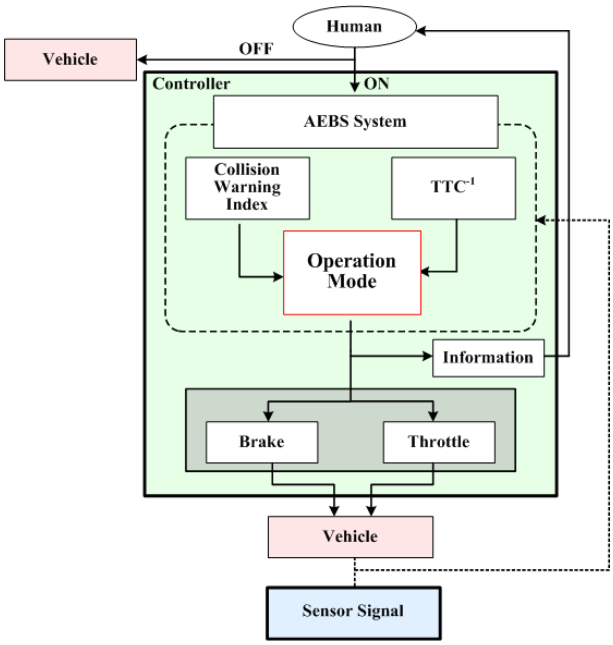


Figura 2 – Fluxograma do algoritmo AEBS (LEE et al., 2011)

Assim como outras funções ADAS, o desenvolvimento da função AEBS envolve a elaboração de um modelo dinâmico do veículo. Modelos dinâmicos de veículos desempenham um papel crucial na pesquisa e no desenvolvimento de veículos (Patil, 2017). Esses modelos servem como protótipos virtuais na fase de desenvolvimento, proporcionando aos engenheiros *insights* sobre a influência dos parâmetros de design no comportamento do veículo.

Pode-se inferir, então, que com o uso de modelos de simulação, é possível testar e otimizar projetos, algoritmos de controle e diversas outras funções veiculares. Tais modelos têm inúmeras aplicações, como em simuladores de condução, simuladores de tempo de volta, design de controladores para direção automatizada e no desenvolvimento de produtos (Patil, 2017).

Sistemas AEBS utilizam arquiteturas hierárquicas para mitigar colisões e proteger usuários vulneráveis (Yang, W., Liu et al., 2020). Essa organização funcional divide-se em três níveis fundamentais: (i) monitoramento passivo do cenário; (ii) alerta de colisão ao condutor; e (iii) intervenção ativa sobre os atuadores de freio (Yang, W., Zhang, X. et al., 2019). Tal estrutura permite ao controlador estimar o estado dinâmico do ambiente e inferir a intenção de condução, ajustando os limiares de decisão e a estratégia de frenagem crítica para maximizar a segurança e evitar falsas ativações (Senapati, Das e Vora, 2017; Zhang, R., Li, K., He et al., 2017; Dong et al., 2024).

A execução técnica inicia-se na percepção para detecção robusta de obstáculos (Alsuwian, Saeed e Amin, 2022). Identificado o risco, o sistema emite alertas e, na ausência de reação, assume o controle longitudinal por meio de uma frenagem em cascata, evoluindo de desaceleração parcial para máxima conforme a urgência (Zhang, R., Li, K., He et al., 2017; Zhang, L. et al., 2023). Essa abordagem modular assegura respostas rápidas e adaptativas, otimizando o compromisso entre a eficácia da segurança ativa, a estabilidade do veículo e o conforto dos ocupantes (Park, Kim, D. e Huh, 2021; Cheng et al., 2020; Zhang, R., Li, K., Wu, Y. et al., 2022).

Então, pode-se definir que o sistema AEBS é projetado para detectar situações de colisão iminente e frear automaticamente o veículo para evitar ou reduzir o impacto. A função opera através de controladores nas camadas de advertência e ação, utilizando dados sensoriais para calcular o risco de colisão e aplicar os freios quando necessário. Para garantir o funcionamento adequado desses controladores, o desenvolvimento de modelos dinâmicos do veículo é essencial, permitindo que as características do automóvel sejam representadas com precisão.

Em síntese, a evolução dos sistemas AEBS aponta para uma integração cada vez mais robusta, na qual a confiabilidade da percepção deve ser assegurada. Além da eficácia na mitigação de colisões, o refinamento contemporâneo dos controladores empregados deve buscar equilibrar a segurança ativa com o conforto dos passageiros. Assim, a convergência

entre modelos dinâmicos precisos e algoritmos de controle estabelece a base necessária para a transição segura rumo a níveis superiores de automação veicular.

2.3 Dinâmica Veicular

Na literatura, existem diversos modelos de dinâmica veicular com diferentes graus de complexidade e tipo de aplicação (Fernández, 2012). Esses modelos são usados em diversas áreas, como simuladores de direção, controle de estabilidade, simulação de tempo de volta e desenvolvimento de produtos (Patil, 2017). Entre os mais comuns encontrados na literatura, pode-se citar:

1. Modelo de Massa Pontual: Simples, considera o veículo como um único ponto com massa. Usado em simulações de trajetórias e cálculo de desempenho básico;
2. Modelo Bicicleta: Aproximação de veículos de quatro rodas usando duas rodas virtuais, uma dianteira e uma traseira. Comum em análises de dinâmica lateral e controle de estabilidade;
3. Modelos Multicorpos: Representam o veículo como um conjunto de corpos rígidos interconectados. São usados para simulações mais precisas, considerando suspensões, pneus, e movimentos tridimensionais;
4. Modelos de Veículo Completo: Utilizam diversos graus de liberdade para simular todos os aspectos do veículo, incluindo suspensão, pneus, motor e sistemas de controle. Empregados em simulações avançadas, como design de controladores de veículos autônomos e análise de conforto;
5. Modelos Inversos: Usados em otimização e controle, focam na solução inversa, em que as forças necessárias para alcançar um comportamento específico são calculadas.

O modelo bicicleta tem sido amplamente utilizado na pesquisa veicular para representar matematicamente a dinâmica de veículos, buscando sempre equilibrar precisão e carga computacional (Patil, 2017). Para descrever completamente o movimento do veículo, complementa-se este sistema com a equação do movimento longitudinal, formando assim uma representação abrangente da dinâmica veicular.

2.3.1 Dinâmica longitudinal

A análise da dinâmica longitudinal foca nas forças que atuam no eixo de simetria do veículo, sendo fundamental para o estudo do desempenho de frenagem (Chen et al., 2019). Em sistemas AEBS, essa modelagem permite quantificar como as variadas forças de resistência e os parâmetros dinâmicos influenciam diretamente a desaceleração e a

distância de parada (Dong et al., 2024). Esse embasamento matemático é indispensável para o desenvolvimento de algoritmos de controle que assegurem a eficácia da intervenção automática e a segurança ativa (Yang, W., Zhang, X. et al., 2019).

A Figura 3 ilustra o diagrama de corpo livre de um veículo de massa (m) operando em uma via com inclinação (θ) , permitindo a identificação das principais forças que regem sua dinâmica longitudinal.

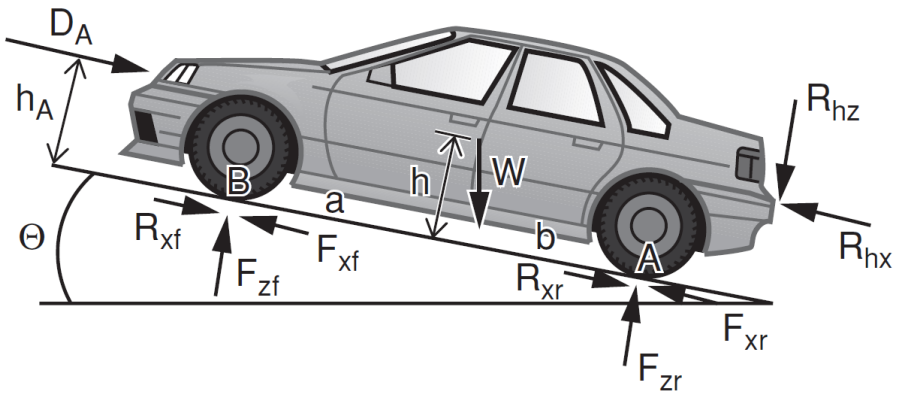


Figura 3 – Diagrama de corpo livre - Forças agindo no veículo (Ulsoy, Peng e Çakmakci, 2012)

Nesse modelo, consideram-se a constante gravitacional (g) , a força de arrasto aerodinâmico (D_A) e a força de tração (R_h) proveniente de possíveis cargas acopladas , além do peso do veículo definido pela relação ($W = mg$) . A interação entre os pneus e o pavimento é representada pela força de tração longitudinal (F_x) , que atua em conjunto com a força de resistência ao rolamento (R_x) para determinar o movimento. Por fim, a força inercial equivalente (ma_x) é aplicada diretamente no centro de gravidade (CG) , compondo o arcabouço necessário para a aplicação da Segunda Lei de Newton na determinação das cargas nos eixos e na análise do desempenho de aceleração e frenagem.

Determinar as cargas nos eixos de um veículo em condições arbitrárias é uma aplicação fundamental da Segunda Lei de Newton (Gillespie, 1993). Este passo inicial é crucial na análise do desempenho de aceleração e frenagem, pois as cargas nos eixos influenciam diretamente o esforço de tração disponível em cada eixo, impactando a aceleração, a capacidade de subida, a velocidade máxima e o esforço na barra de tração.

A aplicação da segunda lei de Newton na direção z (ou seja, sem aceleração vertical) resulta na Equação 2.1. Nessa equação, os termos F_{zf}, F_{zr} e R_{hz} representam, respectivamente, a força normal que atua na roda dianteira, traseira e no eixo traseiro de acoplamento do veículo. E na direção x é dado pela equação 2.2. Nestas equações, os subscritos f e r referem-se às forças de reação dos pneus dianteiros (em B) e traseiros (em A), respectivamente.

$$0 = W cos\theta - F_{zf} - F_{zr} + R_{hz} \tag{2.1}$$

$$ma_x = F_{xr} + F_{xf} - W\sin\theta - R_{xr} - R_{xf} - D_A + R_{hx} \tag{2.2}$$

Para a modelagem completa, a força de resistência total deve decompor-se em arrasto aerodinâmico, resistência ao rolamento e resistência de rampa, sendo esta última dependente do ângulo de inclinação da via (θ) (Dong et al., 2024; Yang, W., Zhang, X. et al., 2019). A literatura ressalta que a desaceleração máxima disponível é limitada não apenas pelos atuadores, mas pelo coeficiente de aderência pneu-pavimento (μ), que define o limite de atrito antes do travamento das rodas (Guo et al., 2020; Zhao, Q. et al., 2022).

A força de arrasto aerodinâmico (D_A) depende da velocidade relativa entre o veículo e o ar circundante e é dada pela relação semi-empírica dada pela equação 2.3 (Ulsoy, Peng e Çakmakci, 2012). Na equação 2.3 o parâmetro ρ define a densidade do ar; o parâmetro C_d representa o coeficiente de arrasto; A é a área máxima da seção transversal do veículo; u representa a velocidade longitudinal do veículo; por sua vez, o parâmetro u_w denota a velocidade do vento (positiva para vento de frente e negativa para vento de cauda).

$$D_A = 0.5\rho C_d A(u + u_w)^2 \tag{2.3}$$

A resistência ao rolamento surge devido ao trabalho de deformação no pneu e na superfície da estrada, e é aproximadamente proporcional à força normal sobre o pneu (Ulsoy, Peng e Çakmakci, 2012). A equação 2.4 define a relação. Nesta equação, o termo f se refere ao coeficiente de resistência ao rolamento, e os termos F_{zf} e F_{zr} representam a força normal sobre a roda dianteira e traseira, respectivamente.

$$R_x = R_{xf} + R_{xr} = f(F_{zf} + F_{zr}) \tag{2.4}$$

O coeficiente de aderência pneu-pavimento (μ) representa o parâmetro fundamental que limita a capacidade de transmissão de forças entre o veículo e a via, determinando o limiar crítico antes do travamento das rodas (Guo et al., 2020). Em termos de dinâmica longitudinal, a desaceleração máxima admissível (a_{max}) que o sistema AEBS pode solicitar sem comprometer a estabilidade é definida pela relação direta entre a adesão e a gravidade (g), conforme a equação 2.5.

$$a_{max} = \mu g \tag{2.5}$$

A literatura ressalta que o valor de μ não é constante, variando de forma não linear conforme a taxa de escorregamento do pneu (λ) (Zhao, Q. et al., 2022; Guo et al., 2020). Para descrever essa característica com precisão, utiliza-se a chamada “Fórmula Mágica” de Pacejka, que modela o coeficiente de aderência longitudinal pela Equação 2.6.

$$\mu(\lambda) = D \sin[C \arctan\{B\lambda - E(B\lambda - \arctan(B\lambda))\}] \tag{2.6}$$

Nesta formulação, os termos B, C, D e E representam fatores de rigidez, forma, valor de pico e curvatura, respectivamente (Zhang, R., Li, K., Wu, Y. et al., 2022). A integração desses limites físicos no controlador é importante para garantir que a intervenção do AEBS ocorra dentro dos limites de atrito disponíveis, otimizando a distância de parada em diferentes superfícies, como asfalto seco ou molhado (Zhao, Q. et al., 2022; Dutra, Gomes e Rodrigues, 2020; Guo et al., 2020).

A capacidade de frenagem de um veículo é fisicamente limitada pela interação pneu-pavimento, sendo definida pela força de atrito máxima, $F_{\mu max}$, que pode ser gerada antes do travamento das rodas (Guo et al., 2020). Essa força representa o limite superior da reação tangencial do solo e é calculada pelo produto entre o coeficiente de aderência longitudinal (μ) e a força normal sobre a roda dianteira e traseira, respectivamente F_{zf} e F_{zr}, conforme a equação 2.7.

$$F_{\mu max} = \mu(F_{zf} + F_{zr}) \tag{2.7}$$

2.3.2 Dinâmica lateral - Modelo bicicleta

A análise da dinâmica lateral é fundamental para descrever integralmente o comportamento do veículo em um plano bidimensional, abrangendo translações laterais e rotações de guinada (Chen et al., 2019; Lai e Yang, H., 2023). No contexto de sistemas de segurança ativa como o AEBS, essa modelagem é indispensável, pois intervenções de frenagem de emergência podem induzir instabilidades direcionais ou deslocamentos laterais excessivos, especialmente quando o veículo opera próximo aos limites físicos de aderência (Cheng et al., 2020; Lai e Yang, H., 2023).

Nesse cenário, o modelo bicicleta, oficialmente chamado de *yaw plane model* (modelo de plano de guinada), destaca-se na literatura por sua ampla utilização em estudos de manuseio e estabilidade (Minaker, 2020; Cheng et al., 2020). Embora a largura do veículo influencie a transferência de peso lateral e o desempenho dos pneus em curvas, tais efeitos são ignorados nesta abordagem em favor de uma menor complexidade computacional (Minaker, 2020; Patil, 2017).

Os movimentos independentes considerados, ou graus de liberdade (DOF) , limitam-se à velocidade lateral v e à velocidade de guinada r do veículo (Minaker, 2020). A velocidade longitudinal u é assumida constante e controlada pelo motorista, sendo tratada como um parâmetro e não como uma variável de estado (Minaker, 2020; Patil, 2017). O movimento

ocorre em uma estrada plana e nivelada, ignorando outros fenômenos como rolagem ou arfagem (*pitch*).

Neste modelo, a velocidade constante é definida como uma restrição não holonômica, ou seja, apesar de o sistema possuir apenas dois graus de liberdade dinâmicos, são necessárias três coordenadas de posição para especificar completamente o estado do veículo: a localização (x, y) do centro de massa e o ângulo de direção δ (Minaker, 2020; Patil, 2017). Mesmo com essa estrutura simplificada, o modelo oferece *insights* significativos sobre o comportamento direcional do automóvel.

A escolha do modelo bicicleta fundamenta-se em sua eficácia para descrever o comportamento do veículo em manobras críticas de direção, como curvas e mudanças de faixa (Cheng et al., 2020; Lai e Yang, H., 2023). O detalhamento das forças laterais geradas permite prever a resposta do automóvel a entradas de esterçamento, garantindo que o sistema AEBS não apenas evite o impacto frontal, mas também mantenha a estabilidade e a trajetória segura frente a condições adversas ou obstáculos em faixas adjacentes (Patil, 2017; Lai e Yang, H., 2023).

Assim, o modelo permite a análise rigorosa da resposta do veículo a entradas de direção e forças laterais, fornecendo o subsídio técnico necessário para o projeto de algoritmos de controle que equilibrem a frenagem de emergência com a segurança dinâmica lateral (Patil, 2017; Cheng et al., 2020). A figura 4 mostra o diagrama de corpo livre do modelo a ser utilizado como base para o desenvolvimento das equações que serão usadas pelo controlador.

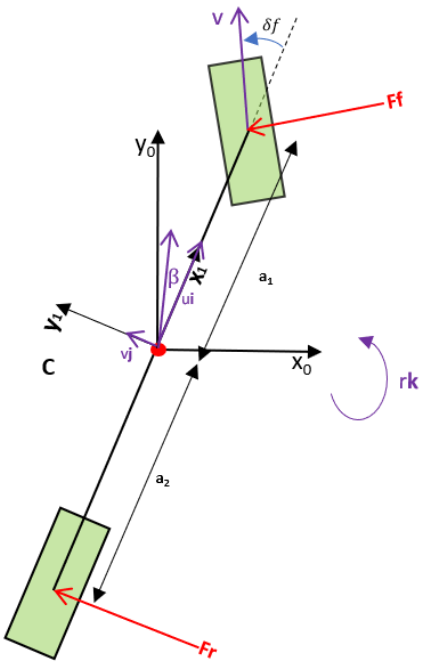


Figura 4 – Modelo Bicicleta

Para a formulação das equações da dinâmica lateral, as seguintes hipóteses são definidas:

1. Como proposto pelo modelo, as rodas da direita e da esquerda são unificadas em uma única roda;
2. O plano de referência (x_1,y_1) é colocado no centro de massa do veículo;
3. O movimento do veículo é restrito ao plano X-Y;
4. O ângulo de esterçamento δ é muito pequeno ($\text{sen}(\delta) = \delta$; $\tan(\delta) = \delta$; $\cos(\delta) = 1$).

Utilizando as equações de movimento da segunda lei de Newton, e considerando as hipóteses levantadas, é possível obter as equações 2.8 e 2.9 que definem o movimento do veículo (Ulsoy, Peng e Çakmakci, 2012).

$$F_f + F_r = m(\dot{v} + ur) \tag{2.8}$$

$$I_z\dot{r} = F_f a_1 - F_r a_2 \tag{2.9}$$

Nestas formulações, considera-se m como massa do veículo, enquanto a_1 e a_2 representam as distâncias do centro de massa C até os pneus dianteiro e traseiro, respectivamente. As variáveis u, v e r representam, respectivamente, a magnitude da velocidade longitudinal do veículo ao longo do eixo x_1, a magnitude da velocidade lateral do veículo ao longo do eixo y_1 e a magnitude da velocidade angular do veículo no sentido anti-horário. Por fim, I_z define o momento de inércia do veículo em torno do eixo z, e os termos F_f e F_r referem-se à força lateral aplicada no pneu dianteiro e traseiro, respectivamente.

A figura 5 mostra o diagrama de corpo livre da roda traseira. Assumindo um ângulo de esterçamento positivo que causa uma curva para a direita e resulta em ângulos de deslizamento positivos sendo estabelecidos nos pneus dianteiros e traseiros, ou seja o ângulo de deslizamento do pneu é definido como o ângulo entre a velocidade do pneu e a direção da orientação do pneu, obtêm-se as equações 2.10 e 2.11 para o ângulo de deslizamento da roda dianteira, α_f, e traseira, α_r. (Ulsoy, Peng e Çakmakci, 2012)

$$\alpha_f = \delta_f - \frac{v - a_1 r}{u} \tag{2.10}$$

$$\alpha_r = -\frac{v - a_2 r}{u} \tag{2.11}$$

As forças laterais que atuam nas rodas dianteira e traseira do veículo estão relacionadas aos ângulos de esterçamento da roda de maneira não linear (Ulsoy, Peng e Çakmakci,

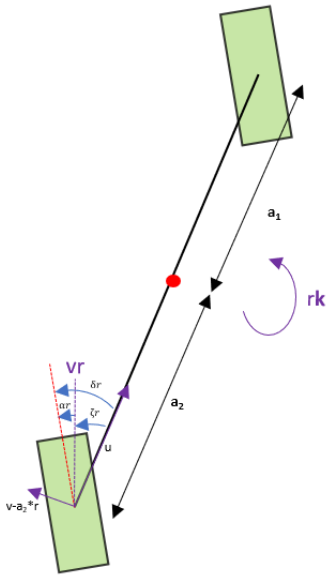


Figura 5 – Roda traseira. (Michael, 2020)

2012). Entretanto, para pequenos ângulos é possível usar a aproximação mostrada na equação 2.12.

$$F_y = C_\alpha \alpha \tag{2.12}$$

Na equação 2.12 a rigidez lateral C_α é definida como a inclinação da curva F_y *versus* α em $\alpha = 0$ e, portanto, é positiva (Ulsoy, Peng e Çakmakci, 2012). Esse comportamento pode ser visualizado na figura 6.

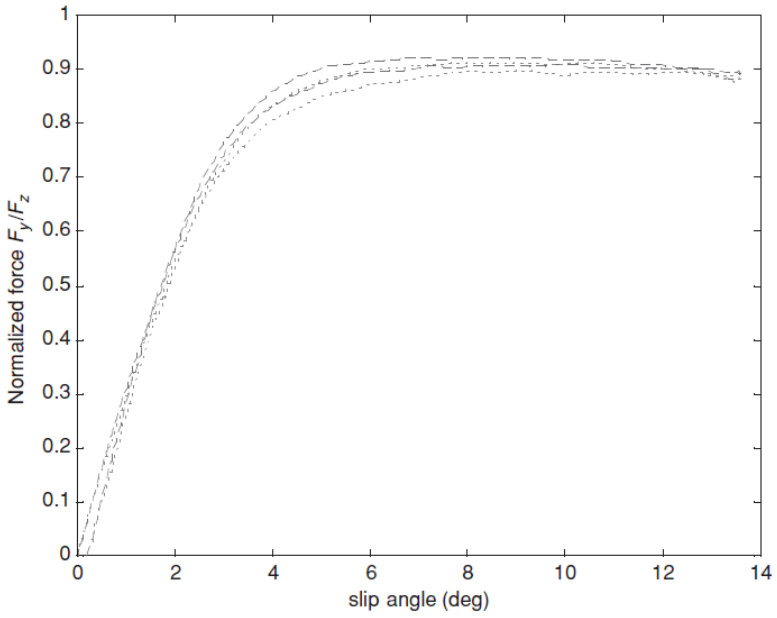


Figura 6 – Força lateral, F_y, *versus* angulo de deslizamento, $alpha$

A partir da relação mostrada por essa equação e fazendo-se as devidas substituições com a equação 2.11, pode ser chegar ao valor da força lateral da roda traseira mostrada na equação 2.13.

$$F_r = -c_r \left(\frac{v - a_2 r}{u} \right) \tag{2.13}$$

Igualmente, para a roda dianteira mostrada na figura 7 é possível obter a equação 2.14. Nesta equação, os termos c_r e c_f se referem à rigidez lateral das rodas traseira e dianteira, respectivamente.

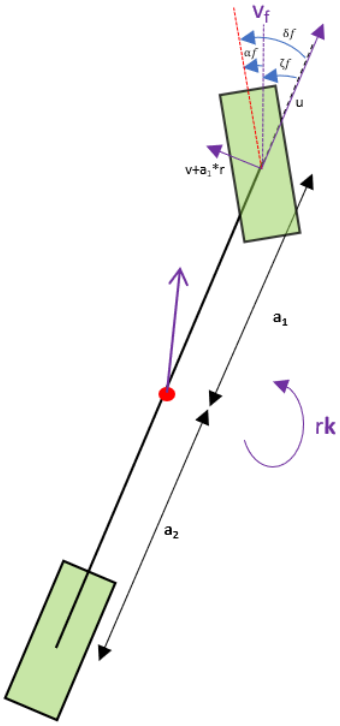


Figura 7 – Roda dianteira. (Michael, 2020)

$$F_f = c_f \left(\delta_f - \frac{v + a_1 r}{u} \right) \tag{2.14}$$

A partir das Equações 2.8, 2.9, 2.13 e 2.14, é possível chegar ao sistema de equações que define o movimento do veículo, mostrado pelas expressões 2.15 e 2.16.

$$\dot{v} = -\left(\frac{c_r + c_f}{mu} \right) v - \left(\frac{c_f a_1 - c_r a_2}{mu} + u \right) r + \frac{c_f}{m} \delta_f \tag{2.15}$$

$$\dot{r} = -\left(\frac{c_f a_1 - c_r a_2}{u I_z} \right) v - \left(\frac{c_f a_1^2 + c_r a_2^2}{u I_z} \right) r + \frac{c_f a_1}{I_z} \delta_f \tag{2.16}$$

As equações 2.15 e 2.16 podem ser, então, reescritas no espaço de estados conforme mostra a equação 2.17.

$$\begin{bmatrix} \dot{v} \\ \dot{r} \end{bmatrix} = \begin{bmatrix} -\left(\frac{c_r+c_f}{mu}\right) & -\left(\frac{c_f a_1 - c_r a_2}{mu} + u\right) \\ -\left(\frac{c_f a_1 - c_r a_2}{uI_z}\right) & -\left(\frac{c_f a_1^2 + c_r a_2^2}{uI_z}\right) \end{bmatrix} \begin{bmatrix} v \\ r \end{bmatrix} + \begin{bmatrix} \frac{c_f}{m} \\ \frac{c_f a_1}{I_z} \end{bmatrix} \delta_f \tag{2.17}$$

2.4 Estratégias de Controle

Um ponto recorrente na literatura sobre AEBS é a divisão do sistema de controle em duas camadas: uma camada superior, que avalia o cenário e calcula métricas de risco, e uma camada inferior, que executa a manobra de frenagem respeitando os limites dinâmicos do veículoo (Zhang, R., Li, K., He et al., 2017; Cui, Ding, Wei et al., 2021). Essa abordagem modular é preferida por facilitar o gerenciamento da complexidade e a implementação do sistema, organizando as funções de segurança em níveis de decisão e execução (Cui, Ding, Wei et al., 2021).

Enquanto o nível superior foca na avaliação estratégica do cenário e no cálculo de métricas de risco, o nível inferior responsabiliza-se pela execução física da manobra, garantindo uma frenagem estável e precisa dentro dos limites dinâmicos do veículo (Zhang, R., Li, K., He et al., 2017; Cui, Ding, Wei et al., 2021). A implementação dessas camadas exige algoritmos de controle cujas capacidades se alinhem aos desafios de cada nível. Entre os controladores mais utilizados na literatura, destacam-se o Proporcional-Integral-Derivativo (PID) , o controlador de lógica fuzzy, o controlador por modo deslizante (SMC) e o controlador preditivo por modelo (MPC).

O controlador PID é amplamente empregado devido à sua simplicidade, robustez e eficiência em diversas aplicações (Nise, 2018). Sua lei de controle é matematicamente fundamentada pela integração de três parâmetros: o ganho proporcional, o integral e o derivativo, os quais atuam sobre o erro detectado entre o estado atual e a variável de referência (Yang, W., Zhang, X. et al., 2019). O ganho proporcional responde ao erro instantâneo, o ganho integral elimina erros em regime permanente e o ganho derivativo atua na antecipação de tendências de erro, proporcionando amortecimento.

Apesar de sua simplicidade e robustez, o PID apresenta limitações em lidar eficazmente com múltiplos objetivos de controle simultâneos em sistemas multivariáveis complexos (Cheng et al., 2020). Além disso, o PID demonstra limitações severas ao enfrentar fenômenos em cenários não-lineares (Alsuwian, Saeed e Amin, 2022). Por fim, sua flexibilidade reduzida em cenários de alta incerteza e sob perturbações significativas restringe sua aplicação frente a métodos de controle mais adaptativos (Alpar e Stojic, 2016).

O controlador de lógica fuzzy baseia-se em regras linguísticas intuitivas para emular o raciocínio humano (Alpar e Stojic, 2016). O funcionamento estrutural é segmentado pelas fases de fuzzificação das entradas numéricas, aplicação de regras de inferência qualitativas e de defuzzificação do resultado para a obtenção de uma ação de controle nítida (Moham-

madzadeh et al., 2023). O uso de funções de pertinência permite a interpretação contínua de riscos, superando a rigidez da lógica binária em cenários dinâmicos, o que assegura tomadas de decisão robustas frente às imprecisões e incertezas inerentes ao ambiente de condução (Mattas et al., 2020).

Tal estratégia confere ao controlador fuzzy uma flexibilidade robusta, tornando-o capaz de gerenciar fenômenos não-lineares sem a necessidade de modelo matemático exato da planta (Alpar e Stojic, 2016; Jiménez, 2018). Entretanto, a subjetividade no projeto das regras e a dificuldade em garantir a estabilidade analítica via critérios clássicos são desvantagens críticas (Hai Quan et al., 2023; Li, G., Yang, Y. et al., 2021). Por fim, sistemas complexos podem exigir alto custo computacional, o que pode limitar a precisão em manobras de alta velocidade quando comparado a modelos dinâmicos rigorosos (Alpar e Stojic, 2016).

O controlador por modo deslizante (SMC) é uma técnica de controle não linear robusta cujo funcionamento baseia-se em forçar o estado do sistema a convergir para uma superfície de deslizamento projetada, onde permanece até atingir o equilíbrio (Zhang, R., Li, K., Wu, Y. et al., 2022; Zhao, Q. et al., 2022). Essa metodologia serve para converter erros dinâmicos em comandos de atuação precisos em sistemas com incertezas (Cui, Ding, Wu, X. et al., 2020; Cui, Ding, Wei et al., 2021). Através dessa abordagem, o sistema torna-se insensível a perturbações externas, garantindo estabilidade e convergência em tempo finito (Zhao, Q. et al., 2022).

As vantagens principais residem na rapidez de resposta e no desempenho consistente sob imprecisões de modelagem (Zhang, R., Li, K., Wu, Y. et al., 2022). No entanto, o SMC clássico apresenta como desvantagem o fenômeno de *chattering*, que gera oscilações de alta frequência capazes de degradar os atuadores (Zhao, Q. et al., 2022). Além disso, o sistema pode apresentar convergência lenta longe do ponto de equilíbrio e dificuldade no ajuste de ganhos (Zhang, R., Li, K., Wu, Y. et al., 2022). Portanto, sintonizações e validações experimentais são essenciais para assegurar a suavidade e a segurança operacional (Zhao, Q. et al., 2022).

O controlador preditivo por modelo (MPC) é uma técnica avançada de controle ótimo que utiliza um modelo matemático interno para prever o comportamento futuro em um horizonte finito e serve para gerenciar sistemas multivariáveis complexos e não lineares que exigem alta precisão e antecipação (Alamir, 2013; Gonzalez et al., 2020). A cada instante amostral, um problema de otimização para minimizar uma função de custo específica é resolvido, e, assim, o sistema antecipa trajetórias para assegurar estabilidade dinâmica e segurança operacional (Gonzalez et al., 2020; Dong et al., 2024).

O controlador destaca-se por sua capacidade de incorporar restrições e otimizar o desempenho ao longo de um horizonte de tempo finito (Zhang, R., Li, K., Wu, Y. et al., 2022; Alamir, 2013). Essa abordagem é ideal para aplicações que exigem controle preciso e adaptativo, como o AEB (Park, Kim, D. e Huh, 2021). O MPC é uma estratégia intuitiva,

alinhada à tomada de decisões baseada em custo-benefício (Alamir, 2013). No entanto, seu alto custo computacional e a necessidade de um modelo preciso do sistema podem limitar sua aplicação em alguns cenários (Dong et al., 2024). Além disso, o controlador é sensível a imprecisões do modelo e à extensão do horizonte de predição (Wu, C. et al., 2014; Dong et al., 2024).

A Tabela 2 resume as principais vantagens e desvantagens dos controladores discutidos.

Controlador	Vantagens	Desvantagens
PID	- Simples implementação - Baixo custo computacional - Amplamente utilizado e conhecido - Boa performance em sistemas lineares	- Desempenho limitado em sistemas não-lineares - Sensível a ruídos e perturbações - Sintonia dos ganhos pode ser complexa
Lógica Fuzzy	- Não requer modelo matemático preciso - Robustez a incertezas e não-linearidades - Linguagem natural facilita interpretação	- Projeto das regras pode ser subjetivo - Alto custo computacional para muitos conjuntos - Dificuldade em garantir estabilidade
SMC	- Alta robustez a perturbações e incertezas - Boa performance em sistemas não-lineares - Projeto sistemático via Lyapunov	- Fenômeno de *chattering* (oscilações indesejadas) - Dificuldade em ajustar os ganhos - Pode exigir alto esforço de controle
MPC	- Considera restrições explicitamente - Ótimo para sistemas complexos, não-lineares e multivariáveis - Previsão futura melhora desempenho	- Alto custo computacional - Requer modelo preciso do sistema - Complexidade cresce com horizonte de predição

Tabela 2 – Comparação entre controladores: PID, Lógica Fuzzy, SMC e MPC

Sistemas AEB exigem um controlador que combine resposta rápida, robustez a incertezas e capacidade de lidar com não-linearidades (Gonzalez et al., 2020). Além disso, o controlador deve ser capaz de otimizar em tempo real, múltiplos objetivos conflitantes como a mitigação de colisão, estabilidade lateral e conforto dos passageiros (Zhang, R., Li, K., He et al., 2017).

Neste contexto, o controlador preditivo por modelo (MPC) consolida-se como a arquitetura preferencial para sistemas AEBS, dada sua capacidade de incorporar restrições físicas e operacionais diretamente no algoritmo de otimização. Tal funcionalidade permite o gerenciamento de variáveis dinâmicas críticas, como os limites de aderência pneu-pavimento,

assegurando a viabilidade de manobras de emergência mesmo sob condições de atrito variável.

Além disso, a natureza antecipatória do MPC possibilita a identificação de trajetórias de colisão iminentes antes da materialização do impacto. Esse mecanismo permite que a intervenção de frenagem seja planejada de forma proativa, otimizando o compromisso entre a mitigação do risco e a estabilidade dinâmica do veículo.

2.5 Controle Preditivo Baseado em Modelo - MPC

O controlador preditivo por modelo (MPC) é uma estratégia de controle avançada que, a cada instante amostral, resolve um problema de otimização para determinar a sequência ótima de ações de controle que minimiza uma função de custo ao longo de um horizonte finito, utilizando um modelo interno da planta e o estado atual estimado do sistema (Rawlings e Mayne, 2009). Apenas a primeira ação desta sequência é implementada, descartando-se as demais, e o processo se repete recursivamente a cada novo período amostral, proporcionando um mecanismo de controle com capacidade de antecipação (Morari e Lee, J. H., 1999; MathWorks, 2024).

2.5.1 Conceitos básicos sobre o controlador MPC

O ciclo básico do Controle Preditivo Baseado em Modelo (MPC) inicia-se em cada instante de amostragem com a aquisição das saídas medidas ou a estimativa do estado atual do sistema (Rawlings e Mayne, 2009). A estratégia consiste em utilizar um modelo interno do processo para prever o comportamento futuro das variáveis de estado e saída, buscando minimizar uma função de custo (ou função de valor) ao longo de um horizonte de predição finito (Rawlings, Mayne e Diehl, 2022). Minimizar a função de custo envolve reduzir o erro entre as saídas futuras da planta e uma trajetória de referência (Morari e Lee, J. H., 1999).

A resolução da função de custo é, normalmente, realizada por um otimizador, que também é responsável por reduzir o esforço de controle respeitando as restrições físicas e de segurança impostas ao controlador (Morari e Lee, J. H., 1999). A figura 8 mostra o ciclo básico em que o controlador recebe as saídas medidas e perturbações da planta, e utiliza um modelo interno de predição da planta para estimar o estado e calcular uma sequência de movimentos de controle que minimizem uma função de custo ao longo de um horizonte dado.

A definição de restrições pode incluir limites na força de tração, ângulos de direção, e velocidades, além de considerar as limitações físicas do veículo, como a aderência dos pneus e a capacidade dos freios (Dong et al., 2024; Zhang, R., Li, K., Wu, Y. et al., 2022). Incorporar essas restrições no controlador auxilia para que as ações de controle geradas sejam viáveis e seguras para a operação real do veículo.

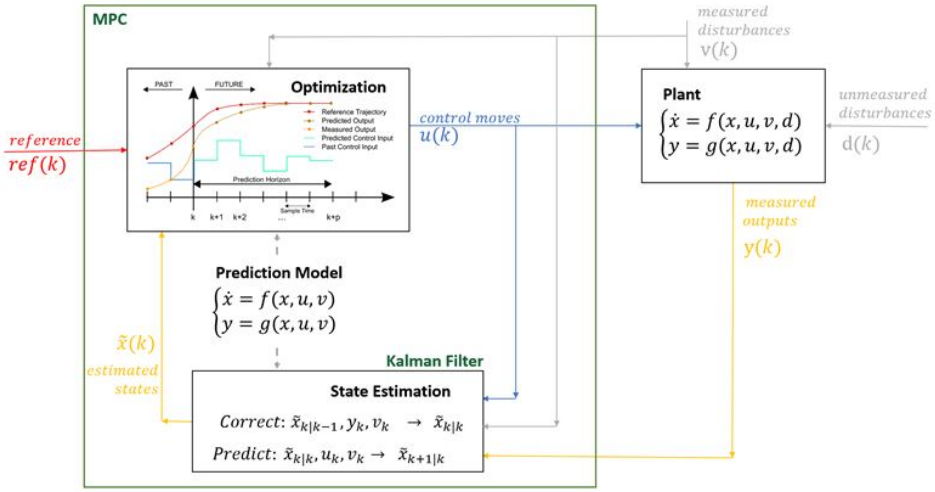


Figura 8 – Ciclo básico de controle MPC (MathWorks, 2024)

O processo de solução do MPC envolve a resolução de um problema de otimização a cada instante de tempo, com base nas previsões do modelo e no estado atual do sistema (Rawlings e Mayne, 2009). Uma vez estabelecida a função de custo que traduz os objetivos de controle, aplicam-se algoritmos numéricos eficientes para garantir a execução em tempo real (Alamir, 2013). Para sistemas lineares, a estratégia recai em problemas de Programação Quadrática (QP) , enquanto abordagens não lineares podem exigir métodos de gradiente ou SQP (Morari e Lee, J. H., 1999). A partir da definição da função de custo, o algoritmo básico para o desenvolvimento da estratégia de controle pode ser definido conforme mostra a figura 9.

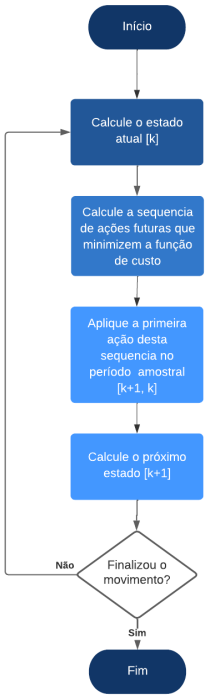


Figura 9 – Diagrama do algoritmo básico de controle MPC

Assim, a estratégia de implementação do controle preditivo pode ser descrita como um processo iterativo executado a cada instante de amostragem. Em cada amostra k, mede-se o estado atual do sistema e, com base no modelo dinâmico, resolve-se um problema de otimização para obter uma sequência ótima de ações de controle sujeitas às restrições físicas e operacionais.

Pelo princípio do horizonte recedente, somente o primeiro elemento dessa sequência é aplicado à planta. Em seguida, o horizonte é atualizado e o procedimento reiniciado com novas medições. Essa estrutura permite incorporar perturbações e variações de operação em tempo real, mantendo o controlador responsivo às mudanças do cenário.

Entre as principais vantagens desse controlador, destacam-se (Park, Kim, D. e Huh, 2021; Cheng et al., 2020; Gonzalez et al., 2020; Cui, Ding, Wu, X. et al., 2020; Kazemi et al., 2018; Zhang, R., Li, K., He et al., 2017):

1. Capacidade de lidar com sistemas complexos e não-lineares, incluindo sistemas com múltiplas entradas e saídas, restrições e perturbações;
2. Permite a incorporação das restrições de entrada e saída diretamente no controlador, o que pode ajudar a evitar a ocorrência de situações indesejáveis;
3. Capacidade de otimizar o desempenho do sistema ao longo de um horizonte de tempo finito, o que pode resultar em um melhor desempenho do sistema em relação a outros controladores;
4. Adaptação a mudanças através da contínua atualização do modelo ou dos parâmetros do controlador.

Entretanto, a estratégia também possui limitações. A exemplo pode-se citar:

1. Computacionalmente intensivo, o que pode tornar o controlador lento e impraticável para alguns sistemas de tempo real;
2. Requer um modelo preciso do sistema controlado, o que pode ser difícil de obter em alguns casos ou pode exigir uma atualização frequente do modelo;
3. Sensibilidade a erros de modelagem ou incertezas do modelo, o que pode levar a um desempenho inferior ou instabilidade do sistema;
4. Pode ser de difícil implementação e exigir um conhecimento mais avançado em matemática e controle.

2.5.2 Modelagem matemática do MPC

O MPC tem suas raízes no controle ótimo (Rawlings, Mayne e Diehl, 2022). O conceito básico desse controlador é usar um modelo dinâmico para prever o comportamento do sistema e otimizar essa previsão para tomar a melhor decisão - a ação de controle no momento atual (Alamir, 2013). Um modelo dinâmico é, geralmente, da forma mostrada na equação 2.18.

$$\dot{x}(t) = f(x(t), u(t)) \tag{2.18}$$

Em que x representa o vetor de estados, u representa a variável de controle, e t é o tempo. Quase todos os sistemas controlados no mundo da engenharia podem ser descritos na forma dessa equação (Alamir, 2013).

A utilização de modelos é um conceito de extrema importância para o MPC (Rawlings, Mayne e Diehl, 2022). Como a ação de controle ótima depende do estado inicial do sistema dinâmico, um segundo conceito fundamental no MPC é utilizar o histórico de medições para determinar o estado inicial mais provável do sistema (Rawlings, Mayne e Diehl, 2022).

O modelo a ser usado no projeto do sistema de controle é um modelo de espaço de estado. Ao usar um modelo de espaço de estado, as informações atuais necessárias para prever o futuro são representadas pela variável de estado no momento atual (Wang, L., 2009). A expressão mostrada na equação 2.18 pode, então, ser reescrita na forma de espaços de estados de acordo com a equação 2.19.

$$\dot{x}(t) = Ax(t) + Bu(t) \tag{2.19}$$

Na equação 2.19, o termo A representa a matriz de estados, que determina como as variáveis de estado interagem entre si, e B representa a matriz de entrada, que define como a entrada do sistema, u, influencia as variáveis de estado, x. A saída do sistema é representada pela equação 2.20. Nesta equação, a Matriz C representa a matriz de saída, que define como as variáveis de estado influenciam as saídas do sistema, e a matriz D é a chamada matriz direta, que mostra como a entrada influencia na saída.

$$y(t) = Cx(t) + Du(t) \tag{2.20}$$

O problema de estimação de estado consiste em examinar o registro de dados passados e reconciliar essas medições com o modelo para determinar o valor mais provável do estado no momento atual. Tanto o problema de regulação, em que uma previsão do modelo é usada para produzir a ação de controle ótima, quanto o problema de estimação, em que o histórico de medições é usado para produzir uma estimativa de estado ótima, envolvem modelos dinâmicos e otimização. (Rawlings, Mayne e Diehl, 2022)

Um método utilizado para previsão do comportamento futuro do sistema é o mapa de um passo a frente. Esse método trabalha com o modelo do sistema discretizado e utiliza a informação do estado atual para previsão do comportamento futuro do sistema. Assim, as equações 2.19 e 2.20 podem ser reescritas em tempo discreto na forma das equações 2.21 e 2.22. Nessas equações, o termo k se refere ao período amostral do sistema. (Alamir, 2013)

$$x(k+1) = Ax(k) + Bu(k) \tag{2.21}$$

$$y(k) = Cx(k) + Du(k) \tag{2.22}$$

Se a taxa de amostragem for escolhida adequadamente, o comportamento entre as amostras pode ser ignorado com segurança, e o modelo descreve exclusivamente o comportamento nos instantes de amostragem (Rawlings, Mayne e Diehl, 2022). Para sistemas de segurança ativa como o AEBS, a literatura recomenda taxas de amostragem que variam tipicamente entre 10 Hz e 100 Hz (Kang e Kum, 2020; Cui, Ding, Wu, X. et al., 2020).

Por extrapolação desse método, é possível desenvolver o mapa de múltiplos passos adiante, ou mapa de N passos adiante (Alamir, 2013). Nesse caso, N se refere à quantidade de estados futuros que estão sendo previstos. Sendo u a variável de entrada, ou seja a ação, a sequência de N ações futuras, $\tilde{u}(k)$, pode ser dada pela equação 2.23. A trajetória de estados, $\tilde{x}(k)$, pode ser vista na equação 2.24.

$$\tilde{u}(k) = \begin{bmatrix} u(k) \\ u(k+1) \\ . \\ . \\ . \\ . \\ u(k+N-1) \end{bmatrix} \tag{2.23}$$

$$\tilde{x}(k) = \begin{bmatrix} x(k+1) \\ u(k+2) \\ . \\ . \\ . \\ . \\ x(k+N) \end{bmatrix} \tag{2.24}$$

Fazendo a aplicação do mapa de N passos adiante para o segundo período amostral, pode-se chegar à forma mostrada na equação 2.25.

$$\begin{aligned} x(k+2) &= Ax(k+1) + Bu(k+1) \\ x(k+2) &= A[Ax(k) + Bu(k)] + Bu(k+1) \\ x(k+2) &= A^2x(k) + ABu(k) + Bu(k+1) \end{aligned} \tag{2.25}$$

O mesmo entendimento mostrado pela equação 2.25 pode ser aplicado para o terceiro período amostral e assim sucessivamente. Então, aplicando para o i-ésimo período amostral, sendo $i \in [1, 2, 3, \dots, N]$, pode-se chegar à equação 2.26.

$$x(k+i) = [A^i]x(k) + [A^{i-1}B, ..., AB, B] \begin{bmatrix} u(k) \\ u(k+1) \\ . \\ . \\ . \\ u(k+i-1) \end{bmatrix} \tag{2.26}$$

Para qualquer $j \in [1, \dots, N]$ tem-se, por definição, a matriz de seleção $\Pi_i^{(n_u,N)}$, que possui a função algébrica de extrair os componentes desejados do vetor global de decisão para que coincidam com o i-ésimo período amostral (Alamir, 2013). Desse modo, o termo para o vetor de entradas mostrado na equação 2.26 pode ser reescrito conforme a equação 2.27.

$$\begin{bmatrix} u(k) \\ . \\ . \\ . \\ u(k+i-1) \end{bmatrix} = \begin{bmatrix} \Pi_1^{(n_u,N)} \\ . \\ . \\ . \\ \Pi_i^{(n_u,N)} \end{bmatrix} \tilde{u}(k) \tag{2.27}$$

Então, a equação 2.26 pode ser reescrita de forma mais compacta na forma mostrada na equação 2.28. Esta equação é então aplicada à equação 2.22, para prever as futuras saídas do sistema. Na equação 2.28, Φ representa a matriz que descreve a influência do estado inicial sobre o estado futuro, e é derivada das potências da matriz de estados A do modelo discretizado; enquanto Ψ representa a matriz que descreve a influência das entradas acumuladas sobre o estado, e condensa a convolução das ações de controle (matriz B) ao longo do tempo.

$$x(k+i) = \Phi_i x(k) + \Psi_i \tilde{u}(k) \tag{2.28}$$

Como mencionado anteriormente, o objetivo da aplicação do MPC é minimizar uma função de custo, isto é, aproximar ao máximo a saída do controlador à saída desejada para o sistema (Alamir, 2013). A sequência de todas as saídas desejadas do sistema, $\tilde{y}$, pode ser visto na equação 2.29.

$$\tilde{y}_r^d(k) = \begin{bmatrix} y_r^d(k+1) \\ ... \\ y_r^d(k+N) \end{bmatrix} \tag{2.29}$$

Vale ressaltar que, devido ao princípio de controle do horizonte recedente, assume-se que a entrada do sistema não afeta a sua saída no mesmo período amostral (Wang, L., 2009). Assim, considera-se que a matriz D tenha valor nulo. Portanto, para o i-ésimo estado futuro, a equação 2.22 pode ser reescrita, utilizando a equação 2.28, e resulta na equação 2.30. Nesta equação, $y_r(k+i)$ se refere às saídas reguladas do sistema, e C_r representa a matriz de saída regulada.

$$y_r(k+i) = C_r\Phi_i x(k) + C_r\Psi_i\tilde{u}(k) \tag{2.30}$$

A equação 2.31 mostra a função que se pretende minimizar. Esta equação representa o valor da função de custo, J, correspondente à sequência de ações futuras, $\tilde{u}$ dado o estado atual do sistema, $x[k]$ e sua saída desejada, $y_r^d(k)$, que é definida dentro de um horizonte de predição $[k, k+N]$. Nesta equação o termo Q_y se refere a uma matriz de peso quadrada simétrica, utilizada para definir uma penalidade ao erro de rastreamento da saída. Essa penalidade ocorre para que excursões muito distantes da resposta desejada sejam penalizadas e, portanto, desconsideradas (Alamir, 2013).

$$J(\tilde{u}|x(k),\tilde{y}_r^d(k)) = \sum_{i=1}^{N} ||C_r\Phi_i x(k) + C_r\Psi_i\tilde{u}(k) - y_r^d(k+i)||_{Q_y}^2 \tag{2.31}$$

O uso de restrições também deve ser levado em consideração ao utilizar-se o controlador MPC. Aliás, como dito anteriormente, esta é uma das grandes vantagens deste controlador, que adiciona as restrições diretamente no seu processo de desenvolvimento. A equação 2.32 define o vetor de saídas restringidas, em que y_c representa as saídas controladas, C_c representa a matriz de saída controlada, e D_c representa a influência da entrada no valor da saída controlada.

$$y_c = C_c x + D_c u \tag{2.32}$$

Pode-se adicionar restrições à saída do sistema, conforme mostra a inequação 2.33. No contexto da dinâmica veicular, as restrições aplicadas às saídas do sistema são essenciais

para garantir que o veículo opere dentro de envelopes de segurança e conforto, limitando variáveis críticas como a velocidade longitudinal e desaceleração máxima admissível (Cui, Ding, Wei et al., 2021).

$$y_c^{min} \leq y_c(k+i) = C_c x(k+i) + D_c u(k+i-1) \leq y_c^{max} \tag{2.33}$$

Nota-se que a matriz D é recolocada na equação. Isso ocorre porque as restrições do sistema também podem ocorrer na sua entrada, conforme mostra a inequação 2.34. Adicionar a matriz D é fundamental para garantir que o problema de otimização resolva a relação instantânea entre a ação de controle e as variáveis limitadas (Alamir, 2013).

$$u^{min} \leq \tilde{u} \leq u^{max} \tag{2.34}$$

É possível também adicionar restrições à variação do valor da variável de entrada. Isso é importante porque, por exemplo, ao ativar o sistema de frenagem de um veículo, a força de frenagem não é aplicada no seu valor máximo de maneira instantânea, isso ocorre em etapas. A inequação 2.35 mostra essa relação.

$$\delta^{min} \leq u(k+i) - u(k+i-1) \leq \delta^{max} \tag{2.35}$$

MPC é geralmente implementado em sistemas digitais que operam em tempo discreto (Re et al., 2010). Os controladores digitais funcionam em uma sequência de amostras de tempo, e por isso, o uso de um modelo discretizado é mais natural e direto para esses sistemas (Mäder, 2010). Essa abordagem facilita o alinhamento das predições futuras com o período de amostragem definido para o hardware (Mäder, 2010).

Assim, as previsões do controlador MPC são feitas em intervalos discretos de tempo, o que significa que um modelo discretizado permite alinhar diretamente a previsão com o tempo de amostragem do sistema. Além disso, a discretização permite que o problema de otimização do MPC seja formulado e resolvido como um problema de programação linear ou quadrática em cada instante de tempo. Isso torna a implementação mais simples e computacionalmente mais eficiente, já que a resolução de problemas de otimização em tempo discreto é mais direta do que em tempo contínuo.

2.6 *Hardware-in-the-Loop*

A simulação em *Hardware-in-the-Loop* (HIL) é uma técnica de validação de sistemas embarcados que combina componentes físicos reais com modelos matemáticos de alta fidelidade para emular, em tempo real, o comportamento dinâmico da planta física e do ambiente. No desenvolvimento automotivo, essa técnica ocupa um papel central no chamado

"Diagrama em V", pois permite testar a integração entre hardware e software antes que o veículo real esteja disponível. (Gao et al., 2020)

A simulação HIL baseia-se na interação entre o controlador físico e um modelo matemático em tempo real da planta, executado em sistemas dedicados (Cui, Ding, Wu, X. et al., 2020). A arquitetura típica de um sistema HIL conecta as interfaces reais de entrada e saída de um controlador a um simulador de tempo real , que processa o modelo do veículo e sensores via conexões que utilizam sinais analógicos, digitais ou protocolos industriais (Cui, Ding, Wei et al., 2021).

Para sistemas de segurança ativa como o AEBS, o HIL é fundamental, pois permite a replicação dinâmica de cenários de colisão iminente e variações críticas de aderência que seriam excessivamente perigosas, custosas ou logisticamente inviáveis em testes de estrada reais (Gao et al., 2020). Além da mitigação de riscos físicos, a plataforma oferece ganhos significativos em eficiência e confiabilidade, encurtando o ciclo de desenvolvimento ao permitir iterações rápidas em software e acesso a sinais internos da planta que seriam impossíveis de medir diretamente em protótipos físicos (Wang, Y. et al., 2019).

A capacidade de testar cenários extremos e inserir falhas programadas sem risco ao hardware é particularmente valiosa para avaliar a robustez do controle frente à degradação de sinais sensoriais e erros de medição (Gao et al., 2020). Um exemplo de configuração pode ser visto na imagem 10, em que o controlador real com interfaces de E/S (entrada/saída) reais é conectado ao sistema de tempo real.

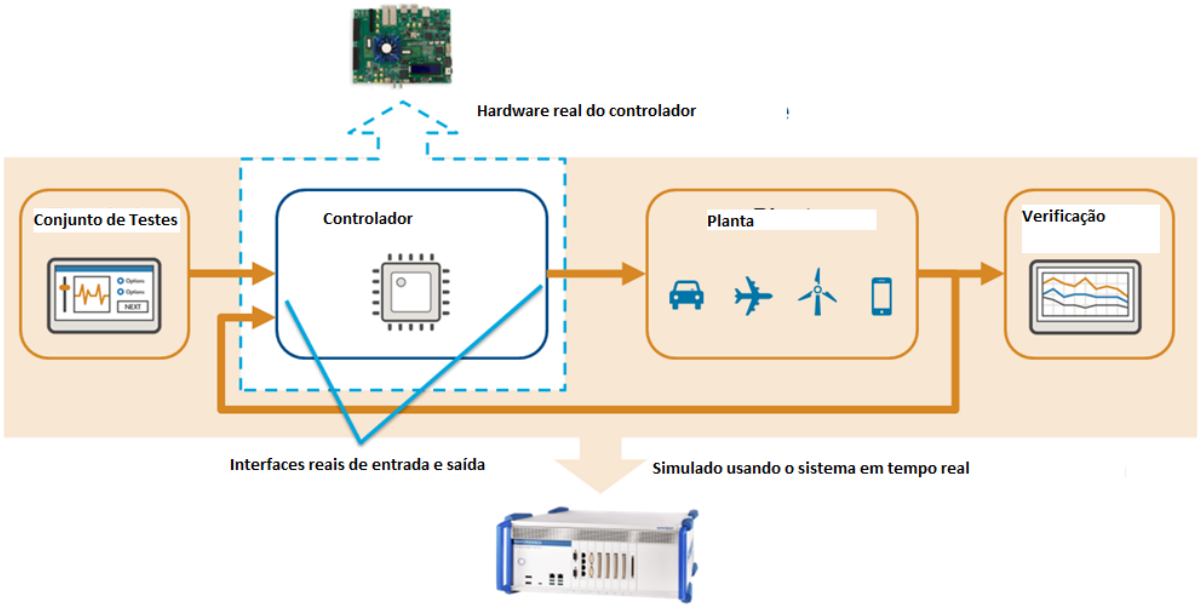


Figura 10 – Configuração típica de teste HIL (MathWorks, 2023)

A simulação *hardware-in-the-loop* envolve inicialmente a modelagem da planta, que consiste na criação de um modelo matemático do sistema físico. Esse modelo reproduz a dinâmica do sistema real. Em seguida, realiza-se a simulação em tempo real. O modelo da

planta é executado em um sistema de teste em tempo real, que simula o comportamento da planta em resposta às entradas provenientes do hardware do controlador. Posteriormente, ocorre a conexão do controlador. (MathWorks, 2023)

O hardware do controlador, que contém os algoritmos de controle, é conectado ao simulador em tempo real, o que permite o controlador interagir com a planta virtual como se estivesse controlando o sistema físico real. Por fim, há a aquisição de dados e a retroalimentação, além das etapas de teste e validação. O sistema adquire continuamente dados do controlador e da planta simulada, utilizando essas informações para fornecer *feedback* ao controlador, permitindo que ele ajuste suas ações com base nas respostas simuladas da planta. (MathWorks, 2023)

No setor automotivo, o HIL é empregado para validar desde unidades de controle de motor até sistemas ADAS complexos, substituindo componentes mecânicos por emuladores de alta precisão (Gao et al., 2020). A capacidade de testar cenários extremos e inserir falhas programadas sem risco ao hardware físico é particularmente valiosa em projetos com componentes de longa aquisição (Wang, Y. et al., 2019).

Adicionalmente, a extensibilidade do sistema HIL facilita a adaptação a novos requisitos ou padrões, como atualizações em ECUs automotivas (Wang, Y. et al., 2019). Além disso, a flexibilidade do sistema permite a injeção programada de falhas e a avaliação da robustez do controle frente à degradação de sinais sensoriais, bem como reduz retrabalhos em fases posteriores, alinhando-se a metodologias ágeis de engenharia (Stöckle et al., 2019).

No setor automotivo, o HIL é empregado para validar desde unidades de controle de motor até sistemas ADAS, substituindo componentes mecânicos por emuladores de alta precisão (Wang, Y. et al., 2019). A qualidade do software de simulação e a escolha do hardware de E/S são determinantes para a eficácia do HIL, permitindo que algoritmos construídos em ambientes como MATLAB/Simulink sejam testados em plataformas de tempo real (Cui, Ding, Wu, X. et al., 2020).

O ambiente HIL deve replicar não apenas as especificações elétricas, mas também a latência e ruídos presentes no sistema real, pois ferramentas que permitem a injeção de falhas e a parametrização rápida de cenários são indispensáveis para cobertura de testes (Gao et al., 2020). A integração contínua de dados, aliada a análises em tempo real, assegura que os algoritmos de controle atendam a requisitos críticos antes da implementação física, o que consolida o HIL como pilar do desenvolvimento de sistemas embarcados modernos.

A capacidade de reproduzir resultados com alta similaridade aos testes reais, mas com superior repetibilidade e segurança, acelera significativamente o ciclo de certificação tecnológica. Portanto, essa metodologia garante que o controlador opere de forma segura sob restrições físicas severas, cumprindo os requisitos fundamentais para a proteção de usuários vulneráveis no trânsito.

3 Estado da Arte

Este capítulo examina os trabalhos mais recentes sobre sistemas AEBS, com base em uma revisão sistemática de literatura. O objetivo é identificar quais tecnologias de sensoriamento e quais estratégias de controle têm sido adotadas pela comunidade científica, bem como mapear os benefícios já documentados e as limitações que ainda persistem. O estudo consolida as bases teóricas necessárias para o desenvolvimento de controladores robustos e eficientes.

3.1 Protocolo de pesquisa

O desenvolvimento desta pesquisa seguiu o método da Revisão Sistemática de Literatura (SLR - *Systematic Literature Review*). Este método, quando conduzido de maneira apropriada, auxilia na obtenção de resultados satisfatórios ao se fazer uma pesquisa para seleção da bibliografia do tema de interesse (Denyer e Tranfield, 2009). Os passos seguidos no desenvolvimento da pesquisa são explicados nos tópicos adiante.

3.1.1 Planejamento da Revisão

A etapa inicial de uma pesquisa científica requer a formulação de questões de pesquisa bem estruturadas. Essas perguntas direcionadoras servem como bússola metodológica, delimitando o escopo do estudo e orientando a busca bibliográfica de forma sistemática.

Ao estabelecer claramente quais problemas precisam ser investigados, o pesquisador pode identificar com precisão as fontes relevantes e otimizar o processo de revisão da literatura. Nesse sentido, para este trabalho, foram feitas as seguintes perguntas de pesquisa:

1. O que é o *Advanced Emergency Braking System* (AEBS)?
2. Para que serve o *Advanced Emergency Braking System* (AEBS)?
3. Como funciona o *Advanced Emergency Braking System* (AEBS)?
4. Quais são os componentes presentes no *Advanced Emergency Braking System* (AEBS)?
5. Quais são as estratégias de controle aplicadas no AEBS?
6. Quais são as técnicas de fusão sensorial aplicadas no AEBS?
7. Quais são os benefícios do AEBS?
8. Quais são as limitações do AEBS?

3.1.2 Condução de Revisão

Com as questões de pesquisa já definidas, o próximo passo consiste em selecionar as bases de dados que melhor cobrem o tema. Em seguida, elabora-se um conjunto de palavras-chave (*Search String* - SS) que reflita cada pergunta, garantindo que os termos incluam sinônimos e variações de ortografia.

A partir dessas SS constrói-se uma fórmula de busca (*Search Formula* - SF) que combina os termos com operadores booleanos de modo a restringir os resultados aos artigos que realmente abordam as questões levantadas. Essa estratégia sistemática assegura que a literatura recuperada seja capaz de fornecer as informações necessárias para que as perguntas de pesquisa sejam respondidas, facilitando a seleção de estudos relevantes e evitando a inclusão de trabalhos que não contribuam para os objetivos do estudo.

Assim, as bases escolhidas para a busca da bibliografia foram a *Scopus*, *IEEE Xplorer* e *Web Of Science*. As SS's foram, conforme mostrado na tabela 3. Os dados dos artigos encontrados são, então, salvos em documento, de modo que os próximos passos para seleção da bibliografia sejam contemplados.

Código	**Fórmula para busca**
SS1	*"AEB" OR "AEBS" OR "AUTOMATIC EMERGENCY BRAKING SYSTEM" OR "AUTONOMOUS EMERGENCY BRAKING SYSTEM" OR "AUTONOMOUS EMERGENCY BRAKE" OR "AUTOMATIC EMERGENCY BRAKE"*
SS2	*"CONTROL" OR "CONTROL STRATEGY" OR "CONTROLLER"*
SS3	*"WORK" OR "OPERATION" OR "BEHAVIOUR" OR "BEHAVIOR" OR "PERFORMANCE"*
SS4	*"COMPONENT*" OR "MODULE*" OR "PART*"*
SS5	*"SENSOR" OR SENSOR FUSION" OR "EQUIPMENT"*
SF	"SS1"AND "SS2"AND "SS3"AND "SS4"AND "SS5"

Tabela 3 – Palavras-chave e fórmula para busca da bibliografia na base de dados

A aplicação sistemática do método permitiu compilar uma base inicial de 638 trabalhos relevantes. O processo de refinamento desta base seguiu três etapas consecutivas de filtragem. Inicialmente, foram eliminados documentos duplicados resultantes das buscas realizadas em múltiplas bases de dados, reduzindo o corpus para 563 publicações únicas. Em seguida, realizou-se uma triagem criteriosa dos títulos, selecionando apenas artigos que mencionavam explicitamente a SS1 ou cuja temática apresentava clara aderência ao objeto de estudo, o que resultou em 269 trabalhos potencialmente relevantes.

Por fim, procedeu-se à análise detalhada dos resumos destas publicações remanescentes, visando assegurar que seu conteúdo abordasse efetivamente o tema central da pesquisa e atendesse aos critérios estabelecidos. Assim, foram obtidos 225 trabalhos com potencial de contribuição para o tema pesquisado. O último passo é fazer uma leitura rápida desses

documentos selecionados, e distinguir os trabalhos mais importantes com base em métricas. Assim, utilizou-se os seguintes critérios de qualificação:

1. Potencial de contribuição;
2. Fundamentação teórica;
3. Metodologia;
4. Análise de dados.

Ao final deste método, foi possível selecionar uma base de dados com 58 documentos que, em tese, possuem o maior potencial de contribuição para o desenvolvimento do tema pesquisado. Os documentos selecionados com base nos passos descritos anteriormente são, assim, utilizados como fonte para o desenvolvimento dessa pesquisa. Os trabalhos se mostraram satisfatórios e a técnica escolhida para formação dessa base de dados foi responsável por identificar, de fato, os melhores documentos.

As próximas seções mostram os resultados obtidos, e respondem as perguntas de pesquisa que foram feitas anteriormente. Elas apresentam os estudos mais recentes relacionados às camadas de percepção e de ação, proporcionando uma visão abrangente sobre o tema, bem como os benefícios e as limitações existentes. Serão discutidos avanços na integração das estratégias de advertência e ação, e suas implicações para o desempenho e a eficácia dos sistemas AEBS.

3.2 Camada de percepção e técnicas de fusão sensorial

Uma análise abrangente das estratégias de detecção em sistemas AEBS revelou que a utilização integrada de múltiplos sensores é predominante. Embora sensores individuais possam fornecer informações valiosas, a aplicação isolada frequentemente resulta em limitações na capacidade de identificação precisa e confiável de obstáculos (Kazemi et al., 2018). Assim, para superar as restrições intrínsecas de cada tipo de sensor, a combinação desses dispositivos em arranjos estratégicos tornou-se uma abordagem amplamente adotada (Jiménez, 2018).

Entre as combinações analisadas, a fusão sensorial composta por LiDAR, radar e câmeras se destaca. Essa configuração é capaz de oferecer um elevado desempenho devido às características complementares desses sensores (Alsuwian, Saeed e Amin, 2022). Destaca-se, no entanto, que cada um desses sensores possui alguma limitação intrínseca a ele. Por exemplo, o radar é falho em classificar objetos pequenos como pedestres, câmeras são vulneráveis a condições de iluminação e clima, e o LiDAR, embora preciso, possui custo elevado e alcance por vezes limitado (Alsuwian, Saeed e Amin, 2022).

Entretanto, o radar apresenta medições robustas de distância e velocidade relativas mesmo em condições climáticas adversas, enquanto o LiDAR contribui com precisão espacial e dimensional superior (Hyuck-Kee, Seong-Geun e Dong-Soo, 2017). Por sua vez, as câmeras aprimoram a capacidade de detecção e classificação dos objetos através de informações visuais detalhadas (Wu, T.-S., 2017). A integração dessas tecnologias permite superar fragilidades individuais, garantindo maior robustez, segurança e eficiência na identificação e monitoramento dos objetos no ambiente veicular (Nataprawira et al., 2021).

Outros estudos exploraram a utilização de radares com sensores auxiliares, como acelerômetro e sensores de velocidade veicular. Nessas abordagens, o radar fornece as informações principais de velocidade e distância relativas, enquanto os sensores adicionais ajudam a considerar condições dinâmicas do veículo e da via, como massa do veículo, coeficiente de atrito pneu-estrada e inclinação da superfície, permitindo decisões mais precisas em termos de frenagem e controle (Lee, S., Lee, S. e Kim, M., 2018; Yang, W., Liu et al., 2020; Zhang, R., Li, K., He et al., 2017).

Uma abordagem menos convencional inclui a combinação de sensores visuais com sensores ligados diretamente aos sistemas internos do veículo, como os sensores de velocidade das rodas ou giroscópios. Essas soluções foram particularmente eficazes em melhorar a precisão da detecção angular e garantir a estabilidade do veículo durante manobras evasivas ou frenagens bruscas, especialmente em trajetórias curvas, onde o risco de colisões longitudinais e laterais simultâneas é alto (Cui, Ding, Wu, X. et al., 2020; Zhang, L. et al., 2023; Kang e Kum, 2020).

A comunicação veicular (V2V e V2I) também apareceu na literatura como uma estratégia complementar valiosa, permitindo que veículos compartilhem informações críticas sobre posição, velocidade e trajetórias. Essa troca de dados não só melhora significativamente o desempenho preditivo dos sistemas AEB como também amplia a capacidade de reação em cenários complexos envolvendo múltiplos veículos ou condições adversas de tráfego (Wang, M. et al., 2021; Yang, W., Liu et al., 2020).

Além das fusões mais tradicionais, alguns estudos inovaram na forma como as informações sensoriais são tratadas. Algoritmos baseados em aprendizado por reforço profundo e técnicas probabilísticas, como Processos de Decisão de Markov (MDP) e filtros de Kalman, têm sido empregados para melhorar a seleção e integração de informações dos sensores (Fang et al., 2019; Li, G., Li, S. et al., 2020). Essas técnicas permitem que os sistemas adaptem sua estratégia de detecção em tempo real, otimizando continuamente a precisão e confiabilidade da identificação de obstáculos (Fang et al., 2019; Wang, M. et al., 2021).

Alguns autores optaram por simplificar a infraestrutura sensorial, empregando apenas um tipo de sensor, como o LiDAR ou a câmera, mas compensando essa simplificação com algoritmos altamente sofisticados para interpretação dos dados coletados. Tais abordagens demonstraram que, embora seja possível alcançar um desempenho razoável com sensores

únicos, a dependência exclusiva em um único tipo de sensor aumenta o risco de falhas ou imprecisões sob determinadas condições operacionais (Gómez, Jiménez e Naranjo, 2015; Hai Quan et al., 2023; Alpar e Stojic, 2016).

Houve também propostas de utilização de sensores específicos menos convencionais, como sensores ultrassônicos e scanners laser, especialmente em cenários onde o custo ou o espaço físico são restritivos. Essas abordagens geralmente focam na medição direta de distâncias curtas, por exemplo, para detecção imediata de obstáculos durante manobras de estacionamento ou frenagem em baixas velocidades, reforçando a importância de adaptar a estratégia sensorial ao contexto específico de uso (Dong et al., 2024; Lai e Yang, H., 2023; Zhao, Y. et al., 2020).

Descoberta: Verifica-se que, embora existam diversas combinações e técnicas para fusão sensorial, a abordagem integrada utilizando múltiplos tipos de sensores é a mais promissora para sistemas AEB. Essas fusões proporcionam resultados superiores em termos de acurácia e robustez na identificação e rastreamento de objetos, especialmente pedestres e veículos. O desenvolvimento futuro dessa área deve considerar não apenas melhorias técnicas individuais, mas também estratégias robustas e adaptativas capazes de lidar eficientemente com a variabilidade das condições reais encontradas no trânsito, aumentando, assim, significativamente a segurança veicular.

3.3 Estratégias de Controle

A arquitetura dos sistemas AEBS é composta por camadas funcionais distintas que atuam em conjunto para evitar ou mitigar colisões (Yang, W., Zhang, X. et al., 2019). No entanto, a literatura evidencia que a divisão entre a camada de advertência e a camada de ação nem sempre é claramente estabelecida, sendo comum a integração dessas funções em módulos unificados de tomada de decisão e controle.

As métricas de segurança são fundamentais para o funcionamento dos AEBS, servindo como parâmetros para a avaliação de riscos e definição das estratégias de controle (Xiaoxia et al., 2019). Entre as mais utilizadas estão o Tempo para Colisão (TTC) , a distância crítica de frenagem, o intervalo de tempo entre veículos (THW) e indicadores baseados em desaceleração (Xiaoxia et al., 2019; Lee, D. et al., 2019). Essas métricas permitem estimar a probabilidade de colisão, orientando tanto alertas ao motorista quanto o acionamento automático da frenagem (Wang, M. et al., 2021; Gómez, Jiménez e Naranjo, 2015; Alsuwian, Saeed e Amin, 2022).

Diversas pesquisas destacam particularmente o TTC devido à sua simplicidade conceitual e capacidade de fornecer uma indicação clara do risco iminente de colisão (Zhang, L. et al., 2023). Entretanto, a combinação de múltiplas métricas, como o TTC com a distância crítica de frenagem, vem sendo explorada para aumentar a precisão dos sistemas e reduzir

falsos positivos, especialmente em situações adversas como vias escorregadias ou cenários urbanos com múltiplos obstáculos (Kazemi et al., 2018; Yang, W., Liu et al., 2020; Zhang, L. et al., 2023).

Na camada de advertência, algoritmos de avaliação de risco utilizam dados obtidos por sensores para calcular indicadores sobre a dinâmica e proximidade de obstáculos (Yang, W., Zhang, X. et al., 2019; Alsuwian, Saeed e Amin, 2022). Esses dados são frequentemente processados por controladores de nível superior, que podem utilizar lógica fuzzy, filtros probabilísticos ou métodos hierárquicos de decisão para determinar o momento apropriado para emitir alertas ao motorista (Zhang, R., Li, K., He et al., 2017; Gonzalez et al., 2020). O uso de modelos probabilísticos e filtros de Kalman é bastante comum nessa etapa, sendo utilizados para melhorar a robustez frente às incertezas dos sensores (Fang et al., 2019; Stöckle et al., 2019).

Já a camada de ação é responsável por executar diretamente as medidas corretivas quando identificado um risco crítico de colisão (Zhang, R., Li, K., He et al., 2017; Sam, Velanganni e Evangelin, 2016). Neste nível, atuadores controlam os freios e, em certos sistemas mais avançados, também a direção, permitindo realizar manobras evasivas (Jiménez, 2018; Wang, Y. et al., 2019). Controladores como PID, Controle por Modo Deslizante (SMC) e Controladores Preditivos por Modelo (MPC) são frequentemente aplicados para garantir que as ações corretivas sejam rápidas, eficazes e seguras, considerando as intenções do motorista e as condições da estrada (Alsuwian, Saeed e Amin, 2022; Zhang, R., Li, K., He et al., 2017; Cui, Ding, Wei et al., 2021).

Entre as estratégias analisadas, o controle preditivo por modelo (MPC) se destaca pela capacidade de prever com alta precisão cenários futuros e adaptar dinamicamente a resposta do sistema (Cheng et al., 2020). Este tipo de controle utiliza modelos matemáticos detalhados, frequentemente integrando métodos avançados de otimização, como o Método dos Multiplicadores Direcionais Alternados (ADMM) , para proporcionar alto desempenho em tempo real, especialmente em situações dinâmicas e complexas com múltiplos obstáculos móveis (Dong et al., 2024; Zhang, R., Li, K., He et al., 2017).

Outra abordagem amplamente encontrada na literatura é o controle baseado em lógica fuzzy, que oferece vantagens ao lidar com incertezas e variações nas condições da estrada e no comportamento dos motoristas (Zhang, R., Li, K., He et al., 2017; Basjaruddin, Rakhman e Lawinata, 2021). Os controladores fuzzy são especialmente atraentes pela simplicidade computacional e pela capacidade de traduzir dados imprecisos, como distância e velocidade relativas, em comandos de frenagem suaves e fáceis de interpretar, favorecendo aplicações em veículos com restrições computacionais (Hai Quan et al., 2023; Alpar e Stojic, 2016; Xiaoxia et al., 2019).

A utilização de técnicas avançadas de predição, como filtros de Kalman e redes neurais, também é evidenciada na literatura como meio eficaz para antecipar o comportamento

dos veículos e usuários da via (Wu, C. et al., 2014). Estas técnicas proporcionam ao sistema maior capacidade preditiva, permitindo intervenções mais antecipadas e seguras, especialmente em contextos urbanos altamente dinâmicos (Wu, C. et al., 2014; Yang, W., Liu et al., 2020).

Também é notável a preferência por arquiteturas hierárquicas de controle, que dividem claramente funções de planejamento de trajetórias, tomada de decisão de frenagem e atuação direta nos sistemas veiculares (Cui, Ding, Wei et al., 2021). Essa abordagem modular facilita tanto a implementação quanto o gerenciamento de complexidade, garantindo respostas rápidas e eficientes, ao mesmo tempo em que mantém o desempenho robusto em cenários variados (Dong et al., 2024; Cui, Ding, Wei et al., 2021; Zhang, R., Li, K., Wu, Y. et al., 2022).

Descoberta: Apesar dos avanços consideráveis nos sistemas AEBS, ainda existem desafios significativos que precisam ser superados. Operações em tempo real sob limitações computacionais, robustez em cenários urbanos complexos e adaptação a comportamentos imprevisíveis de outros usuários são áreas críticas que requerem constante pesquisa e desenvolvimento. Paralelamente, questões relacionadas à aceitação e confiança dos motoristas em sistemas automatizados também permanecem em discussão, exigindo abordagens cuidadosas para garantir a aceitação social dessas tecnologias.

3.4 Benefícios e Limitações dos Sistemas AEBS

A aplicação de sistemas autônomos de frenagem de emergência (AEBS) apresenta, como benefício central, a redução significativa do número de acidentes automobilísticos (Lee, I.-H. e Luan, 2016). Estudos recentes indicam que veículos equipados com essa tecnologia reduzem de forma expressiva as colisões traseiras, sobretudo em cenários urbanos de baixa velocidade (Basjaruddin, Rakhman e Lawinata, 2021). Em velocidades inferiores a 50 km/h, por exemplo, foi observada redução próxima de 40% nesse tipo de ocorrência (Yang, W., Liu et al., 2020).

Com a diminuição da incidência geral de acidentes, outros ganhos tornam-se evidentes, especialmente a redução de fatalidades (Hyuck-Kee, Seong-Geun e Dong-Soo, 2017). Como consequência direta, também se verificam menores danos materiais e menores perdas econômicas associadas aos sinistros, além da redução de gastos públicos com reparos de infraestrutura e de propriedades privadas afetadas (Park, Kim, D. e Huh, 2021).

Apesar dos avanços já consolidados, os sistemas AEBS ainda enfrentam limitações importantes no sensoriamento de obstáculos (Kazemi et al., 2018). Câmeras, radares e LiDAR apresentam restrições de alcance e dificuldades de processamento em cenários dinâmicos (Wang, M. et al., 2021). Além disso, obstruções parciais ou totais do campo de visão podem reduzir significativamente a eficácia da detecção (Wang, M. et al., 2021).

As condições climáticas adversas também representam um desafio crítico para os AEBS atuais, sobretudo para sensores visuais (Wang, M. et al., 2021). Em chuva intensa, neve ou neblina, câmeras perdem desempenho, enquanto radares podem sofrer degradações em eventos extremos (Wang, M. et al., 2021). Outro ponto recorrente é a limitação na precisão de localização dos objetos detectados (Kazemi et al., 2018). Essa imprecisão torna-se ainda mais crítica em aplicações com maior nível de automação veicular, e erros na estimativa da posição relativa podem comprometer decisões de direção e frenagem.

Além dos desafios associados aos sensores, também são reportadas limitações ligadas à modelagem e ao desenvolvimento dos próprios sistemas AEBS. Entre elas, destaca-se a escassez de bases de dados suficientemente representativas para o treinamento de modelos robustos, capazes de generalizar para a diversidade de cenários críticos observados no trânsito real (Boda, Lehtonen e Dozza, 2020).

A modelagem da dinâmica veicular em situações de emergência também permanece como um ponto sensível. Muitos sistemas inicialmente propostos concentram-se apenas no controle de frenagem e deixam em segundo plano aspectos essenciais, como o controle de direção, os acoplamentos dinâmicos do veículo e a influência das respostas do condutor durante eventos críticos (Wu, C. et al., 2014).

Essas limitações têm impulsionado a comunidade científica a desenvolver soluções mais avançadas para superar as restrições técnicas atuais. Uma das abordagens mais promissoras envolve tecnologias de comunicação interveicular, como a comunicação veículo-para-veículo (V2V), com potencial de ampliar a capacidade preditiva e elevar a segurança global dos AEBS por meio do compartilhamento de dados de posição e comportamento dos veículos ao redor (Kazemi et al., 2018).

Entre essas tecnologias, destaca-se a comunicação dedicada de curto alcance (DSRC), por viabilizar troca rápida e confiável de informações entre veículos próximos e mitigar limitações associadas ao campo de visão dos sensores individuais (Kazemi et al., 2018). De forma complementar, técnicas avançadas de fusão sensorial vêm sendo continuamente investigadas para reduzir falhas associadas aos pontos cegos inerentes a cada modalidade de sensor (Gómez, Jiménez e Naranjo, 2015).

Em síntese, embora os sistemas AEBS ainda enfrentem limitações importantes relacionadas a sensoriamento, modelagem e disponibilidade de dados, os benefícios já documentados na redução de acidentes, fatalidades e custos econômicos justificam plenamente sua evolução e adoção crescente. O investimento contínuo em pesquisa tecnológica e integração sensorial tende a reduzir progressivamente essas limitações no curto e médio prazo.

4 Projeto do Controlador para Sistema AEBS

Este capítulo apresenta o projeto do controlador para o sistema autônomo de frenagem de emergência, utilizando a abordagem do Controle Preditivo Baseado em Modelo (MPC). Inicialmente é descrito o modelo da dinâmica do veículo, importante para o desenvolvimento do controlador proposto. Em seguida, é feita a formulação matemática do controlador MPC, com a definição de entradas e saídas, função de custo e restrições. As métricas de segurança são definidas subsequentemente, e, por fim, são descritas as métricas de avaliação e os cenários de teste.

4.1 Dinâmica Veicular

A dinâmica veicular é formulada a partir do modelo bicicleta em conjunto com a equação do movimento longitudinal de veículos, escolha que se fundamenta no compromisso ideal entre precisão física e eficiência computacional para aplicações de segurança ativa (Patil, 2017). Além disso, a adoção desta estrutura provê um arcabouço modular que permite que o sistema, embora focado atualmente na frenagem, seja futuramente estendido para manobras evasivas coordenadas de esterçamento automático (Lai e Yang, H., 2023).

Inicialmente considera-se a equação para o movimento longitudinal do veículo. A aceleração longitudinal é dada pela equação 4.1, em que a_x representa a aceleração longitudinal, no eixo x, o termo $\dot{u}$ representa a derivada da velocidade no eixo longitudinal, e vr representa a velocidade lateral, v, convertida em aceleração devido à rotação, r (Guiggiani, 2014).

$$a_x = \dot{u} - vr \tag{4.1}$$

O somatório de forças no eixo x é dado pela equação 4.2 (Guiggiani, 2014). Nesta equação, $\sum F_x$ representa o somatório das forças no eixo x, m representa a massa e a_x a aceleração longitudinal.

$$\sum F_x = ma_x \tag{4.2}$$

A equação do movimento longitudinal do veículo é dado pela equação 4.3. Na equação, o termo F_x representa a força de tração, contrária ao movimento das rodas; R_x é a força de de resistência ao rolamento, responsável por movimentar o veículo adiante; W é o peso do

veículo; θ é o ângulo de inclinação da pista; D_A representa o arrasto aerodinâmico; e R_{hx} é uma força de tração caso haja algum objeto acoplado ao veículo.

$$ma_x = F_{xr} + F_{xf} - W \sin\theta - R_{xr} - R_{xf} - D_A + R_{hx} \tag{4.3}$$

O arrasto aerodinâmico, D_A, é definido pela equação 4.4. Em que ρ representa a densidade do ar; C_d é o coeficiente de arrasto; A é a área máxima da seção transversal do veículo; u é a velocidade do veículo; e u_w é a velocidade do vento (positiva para vento de frente e negativa para vento de cauda).

$$D_A = 0.5\rho C_d A(u + u_w)^2 \tag{4.4}$$

Desconsiderou-se a força de tração, R_h, já que esta só atua caso o automóvel esteja guinchando outro objeto. Considerou-se que as forças de tração no eixo dianteiro, F_{xf}, e no eixo traseiro, F_{xr}, agem como uma só, F_x, e esta é a força responsável por desacelerar o automóvel em caso de frenagem. Como o foco é a desaceleração do veículo, desconsiderou-se também os termos R_{xf}, resistência ao rolamento no eixo dianteiro, e R_{xr}, resistência ao rolamento no eixo traseiro. Por fim, considerou-se que o veículo faz seu movimento em um caminho plano, sem inclinação, portanto o ângulo de inclinação da pista, θ, é nulo.

Assim, rearranjando-se os termos das equações 4.1, 4.2, 4.3 e 4.4, é possível chegar à equação 4.5, que rege o movimento longitudinal do veículo.

$$\dot{u} = \frac{-0.5\rho C_d A(u + u_w)^2}{m} + \frac{vr}{m} + \frac{F_x}{m} \tag{4.5}$$

A aceleração do veículo no eixo lateral, a_y, é dada pela equação 4.6. Na equação, o termo $\dot{v}$ representa a aceleração no eixo lateral, e o termo ur, a velocidade longitudinal, u, convertida em aceleração devido à rotação r. (Guiggiani, 2014)

$$a_y = \dot{v} + ur \tag{4.6}$$

O somatório de forças neste eixo é dado pela equação 4.7. Nesta equação, o termo $\sum F_y$ representa o somatório das forças no eixo y; m é a massa; e a_y, a aceleração lateral. (Guiggiani, 2014)

$$\sum F_y = ma_y \tag{4.7}$$

A seção 2.3.2 demonstra o processo de desenvolvimento das equação que regem o movimento lateral do veículo. A equação para a aceleração lateral, $\dot{v}$, e taxa de guinada, $\dot{r}$, são mostradas nas expressões 4.8 e 4.9. Os termos c_r e c_f representam a rigidez lateral das rodas traseira e dianteira, respectivamente; a_1 e a_2 são a distância do centro de massa do veículo ao eixo frontal e traseiro, respectivamente; m é a massa do veículo; u, a velocidade

longitudinal; v representa a velocidade lateral; r, a velocidade de rotação; δ_f é o ângulo de esterçamento da roda dianteira; e I_z se refere ao momento de inércia do veículo em torno do eixo z

$$\dot{v} = -\left(\frac{c_r + c_f}{mu}\right)v - \left(\frac{c_f a_1 - c_r a_2}{mu} + u\right)r + \frac{c_f}{m}\delta_f \tag{4.8}$$

$$\dot{r} = -\left(\frac{c_f a_1 - c_r a_2}{uI_z}\right)v - \left(\frac{c_f a_1^2 + c_r a_2^2}{uI_z}\right)r + \frac{c_f a_1}{I_z}\delta_f \tag{4.9}$$

Considerou-se que o automóvel não faz movimentos de desvio, ou seja não há movimento lateral e de rotação do veículo, portanto o valor de δ_f é nulo. Apenas movimento no eixo longitudinal é considerado, visto que o foco desta pesquisa é a frenagem de emergência. Entretanto, mesmo que o estudo atual não considere manobras evasivas, a opção por utilizar o modelo bicicleta deve-se ao fato de deixar aberto para que futuras implementações possam ser estendidas para considerar o controle lateral do veículo.

Assim, unindo-se as equações do movimento longitudinal, equação 4.5, do movimento lateral, equação 4.8, e da taxa de guinada, equação 4.9, é possível chegar ao sistema dinâmico que rege os movimentos do veículo, dado pela equação 4.10.

$$\begin{bmatrix} \dot{u} \\ \dot{v} \\ \dot{r} \end{bmatrix} = \begin{bmatrix} \frac{-\rho C_d A(0.5u+u_w)}{m} & \frac{r}{m} & 0 \\ -r & -\frac{c_r+c_f}{mu} & \frac{c_f a_1 - c_r a_2}{mu} - u \\ 0 & \frac{-(c_r a_2 - c_f a_1)}{uI_z} & \frac{c_f a_1^2 - c_r a_2^2}{uI_z} \end{bmatrix} \begin{bmatrix} u \\ v \\ r \end{bmatrix} + F_x \begin{bmatrix} \frac{1}{m} \\ 0 \\ 0 \end{bmatrix} \tag{4.10}$$

Sobre a equação 4.10 alguns pontos devem ser ressaltados. O primeiro é sobre a escolha da variável de controle. Como essa dissertação trabalha o processo de frenagem do automóvel, viu-se que a melhor escolha deveria ser a força F_x, pois essa será a força aplicada ao veículo para que haja a redução de sua velocidade. Portanto, a matriz de controle, B, e a variável de controle são dadas pela equação 4.11.

$$\begin{bmatrix} \frac{1}{m} \\ 0 \\ 0 \end{bmatrix} F_x \tag{4.11}$$

Além disso, a dinâmica veicular expressa na equação 4.10 apresenta um comportamento intrinsecamente não linear, decorrente tanto do acoplamento entre as variáveis de estado quanto da presença de termos quadráticos. Embora o Controle Preditivo Baseado em Modelo Não Linear (NMPC) possua a capacidade de tratar tais não linearidades de forma nativa, sua aplicação em sistemas AEBS de tempo real é limitada pelo elevado custo compu-

tacional necessário para resolver problemas de otimização não convexos em intervalos de milissegundos (Zhang, R., Li, K., He et al., 2017).

Além disso, a expansão do termo quadrático da equação 4.5 também forma a equação 4.12. Este termo, como pode ser visto, não possui nenhuma das variáveis de estado, portanto foi tratada como ruído e desconsiderada. O termo da resistência ao rolamento, R_x foi desconsiderado pelo mesmo motivo.

$$\frac{0{,}5\rho C_d A u_w^2}{m} \tag{4.12}$$

4.2 Formulação do Controlador MPC

Para contornar o desafio mostrado pela equação 4.10, que mostra um sistema dinâmico não linear, é feita a linearização do modelo dinâmico em torno de um ponto de operação via expansão de Taylor de primeira ordem sobre o vetor de estados $\mathbf{x} = [u\ v\ r]^T$ e a entrada F_x. Essa estratégia viabiliza o uso de um controlador MPC linear, transformando o problema em uma Programação Quadrática (QP) de resolução eficiente, garantindo que o sistema responda com o determinismo temporal exigido para a mitigação de colisões (Dong et al., 2024).

Para um sistema genérico $\dot{\mathbf{x}} = f(\mathbf{x}, F_x)$, a aproximação de primeira ordem é mostrada na equação (4.13).

$$\dot{\mathbf{x}} \approx f(\mathbf{x}_0, F_{x0}) + \underbrace{\left.\frac{\partial f}{\partial \mathbf{x}}\right|_{\mathbf{x}_0, F_{x0}}}_{A_{lin}} (\mathbf{x} - \mathbf{x}_0) + \underbrace{\left.\frac{\partial f}{\partial F_x}\right|_{\mathbf{x}_0, F_{x0}}}_{B_{lin}} (F_x - F_{x0}). \tag{4.13}$$

A matriz A_{lin} é, portanto, a **Jacobiana** de f em relação ao vetor de estados, avaliada no ponto de operação. Sua estrutura é mostrada na equação (4.14).

$$A_{lin} = \left[\begin{array}{ccc} \frac{\partial f_1}{\partial u} & \frac{\partial f_1}{\partial v} & \frac{\partial f_1}{\partial r} \\ \frac{\partial f_2}{\partial u} & \frac{\partial f_2}{\partial v} & \frac{\partial f_2}{\partial r} \\ \frac{\partial f_3}{\partial u} & \frac{\partial f_3}{\partial v} & \frac{\partial f_3}{\partial r} \end{array}\right]\Bigg|_{(u_0, v_0, r_0)}. \tag{4.14}$$

Adotando $\delta_f = 0$ (sem esterçamento) e desconsiderando termos de segunda ordem em u_w, as três equações escalares extraídas das equações (4.5), (4.8) e (4.9) são mostradas nas equações (4.15)–(4.17).

$$f_1 = \dot{u} = -\frac{\rho C_d A}{m} u(0{,}5\,u + u_w) + \frac{v\,r}{m} + \frac{F_x}{m}, \tag{4.15}$$

$$f_2 = \dot{v} = -\frac{c_f + c_r}{m\,u} v - \left(\frac{c_f a_1 - c_r a_2}{m\,u} + u\right) r, \tag{4.16}$$

$$f_3 = \dot{r} = -\frac{c_f a_1 - c_r a_2}{I_z\,u} v - \frac{c_f a_1^2 + c_r a_2^2}{I_z\,u} r. \tag{4.17}$$

Na primeira coluna de A_{lin}, são reunidas as derivadas parciais em relação à variável longitudinal u. Em particular, o elemento (1,1), correspondente a $\partial f_1/\partial u$, é obtido a partir da forma expandida de f_1, mostrada na equação (4.18).

$$f_1 = -\frac{\rho C_d A}{m}\left(0{,}5\,u^2 + u\,u_w\right) + \frac{v\,r}{m} + \frac{F_x}{m}. \tag{4.18}$$

A derivada parcial correspondente é mostrada na equação (4.19).

$$\frac{\partial f_1}{\partial u} = -\frac{\rho C_d A}{m}(u + u_w) \quad \xrightarrow{u=u_0} \quad -\frac{\rho C_d A}{m}(u_0 + u_w). \tag{4.19}$$

A reescrita de f_2 em termos de potências negativas de u é mostrada na equação (4.20).

$$f_2 = -(c_f + c_r)\,m^{-1}\,u^{-1}\,v - (c_f a_1 - c_r a_2)\,m^{-1}\,u^{-1}\,r - u\,r. \tag{4.20}$$

Usando $\dfrac{d}{du}[u^{-1}] = -u^{-2}$, o resultado é mostrado na equação (4.21).

$$\frac{\partial f_2}{\partial u} = \frac{c_f + c_r}{m\,u^2} v + \frac{c_f a_1 - c_r a_2}{m\,u^2} r - r \quad \xrightarrow{u_0, v_0, r_0} \quad \frac{c_f + c_r}{m u_0^2} v_0 + \frac{c_f a_1 - c_r a_2}{m u_0^2} r_0 - r_0. \tag{4.21}$$

De forma análoga, a reescrita de f_3 é mostrada na equação (4.22).

$$f_3 = -(c_f a_1 - c_r a_2)\,I_z^{-1}\,u^{-1}\,v - (c_f a_1^2 + c_r a_2^2)\,I_z^{-1}\,u^{-1}\,r. \tag{4.22}$$

Aplicando a mesma regra, o resultado é mostrado na equação (4.23).

$$\frac{\partial f_3}{\partial u} = \frac{c_f a_1 - c_r a_2}{I_z\,u^2} v + \frac{c_f a_1^2 + c_r a_2^2}{I_z\,u^2} r \quad \xrightarrow{u_0, v_0, r_0} \quad \frac{c_f a_1 - c_r a_2}{I_z u_0^2} v_0 + \frac{c_f a_1^2 + c_r a_2^2}{I_z u_0^2} r_0. \tag{4.23}$$

Na segunda coluna de A_{lin}, são reunidas as derivadas parciais em relação à velocidade lateral v. Em f_1, a variável v aparece exclusivamente no produto vr/m, com r constante, e o resultado é mostrado na equação (4.24).

$$\frac{\partial f_1}{\partial v} = \frac{r}{m} \quad \xrightarrow{r_0} \quad \frac{r_0}{m}. \tag{4.24}$$

Em f_2, v aparece apenas no primeiro termo, e o resultado é mostrado na equação (4.25).

$$\frac{\partial f_2}{\partial v} = -\frac{c_f + c_r}{m\,u} \quad \xrightarrow{u_0} \quad -\frac{c_f + c_r}{m\,u_0}. \tag{4.25}$$

Em f_3, v aparece apenas no primeiro termo, e o resultado é mostrado na equação (4.26).

$$\frac{\partial f_3}{\partial v} = -\frac{c_f a_1 - c_r a_2}{I_z\, u} \quad \xrightarrow{u_0} \quad -\frac{c_f a_1 - c_r a_2}{I_z\, u_0}. \tag{4.26}$$

Na terceira coluna de A_{lin}, são reunidas as derivadas parciais em relação à taxa de guinada r. Em f_1, a variável r aparece exclusivamente no produto vr/m, com v constante, e o resultado é mostrado na equação (4.27).

$$\frac{\partial f_1}{\partial r} = \frac{v}{m} \quad \xrightarrow{v_0} \quad \frac{v_0}{m}. \tag{4.27}$$

Em f_2, r aparece nos dois últimos termos, conforme mostrado na equação (4.28).

$$f_2 = \ldots - \frac{c_f a_1 - c_r a_2}{m\, u}\, r - u\, r. \tag{4.28}$$

O resultado da derivada parcial é mostrado na equação (4.29).

$$\frac{\partial f_2}{\partial r} = -\frac{c_f a_1 - c_r a_2}{m\, u} - u \quad \xrightarrow{u_0} \quad -\left(\frac{c_f a_1 - c_r a_2}{m\, u_0} + u_0\right). \tag{4.29}$$

Em f_3, r aparece apenas no segundo termo, e o resultado é mostrado na equação (4.30).

$$\frac{\partial f_3}{\partial r} = -\frac{c_f a_1^2 + c_r a_2^2}{I_z\, u} \quad \xrightarrow{u_0} \quad -\frac{c_f a_1^2 + c_r a_2^2}{I_z\, u_0}. \tag{4.30}$$

Reunindo os nove elementos calculados nas equações (4.19)–(4.30), a matriz linearizada é mostrada na equação (4.31), que corresponde à matriz linearizada utilizada para desenvolvimento do controlador.

$$A_{lin} = \begin{bmatrix} -\dfrac{\rho C_d A}{m}(u_0 + u_w) & \dfrac{r_0}{m} & \dfrac{v_0}{m} \\ \dfrac{c_f + c_r}{m u_0^2} v_0 + \dfrac{c_f a_1 - c_r a_2}{m u_0^2} r_0 - r_0 & -\dfrac{c_f + c_r}{m u_0} & -\left(\dfrac{c_f a_1 - c_r a_2}{m u_0} + u_0\right) \\ \dfrac{c_f a_1 - c_r a_2}{I_z u_0^2} v_0 + \dfrac{c_f a_1^2 + c_r a_2^2}{I_z u_0^2} r_0 & -\dfrac{c_f a_1 - c_r a_2}{I_z u_0} & -\dfrac{c_f a_1^2 + c_r a_2^2}{I_z u_0} \end{bmatrix}, \tag{4.31}$$

A matriz de entrada B_{lin} é mostrada na equação (4.32) e indica que a força longitudinal F_x atua diretamente apenas sobre a dinâmica de $\dot{u}$.

$$B_{lin} = \begin{bmatrix} \dfrac{1}{m} \\ 0 \\ 0 \end{bmatrix} \tag{4.32}$$

No contexto do AEBS, o controlador MPC é formulado para minimizar uma função de custo definida ao longo de um horizonte de predição (Alamir, 2013; Garcia Montoya, 2024). A função de custo adotada nesta pesquisa é expressa pela equação 4.33.

$$J(k) = \sum_{i=1}^{N} ||y_r(k+i) - y_d(k+i)||{Q_y}^2 + \sum_{i=1}^{N} ||\Pi_i^{(n_u,N)}\tilde{u}(k) - u_d||{Q_u}^2 \tag{4.33}$$

Nessa formulação, Q_y e Q_u são matrizes de ponderação associadas, respectivamente, ao erro de rastreamento da saída e ao esforço de controle. As variáveis y_d e u_d representam os valores desejados para a saída e a entrada. A cada instante k, a função de custo é reformulada na forma quadrática padrão, como mostra a equação 4.34.

$$J(k) = \frac{1}{2}\tilde{u}^T(k)H\tilde{u}(k) + F^T(k)\tilde{u}(k) + Cte \tag{4.34}$$

Nessa equação, H é a matriz Hessiana definida positiva (equação 4.35) e F representa o gradiente do custo (equação 4.36). O termo constante Cte não influencia o valor ótimo da sequência de controle.

$$H = 2\sum_{i=1}^{N}[\Psi_i^T C_r^T Q_y C_r \Psi_i + (\Pi^{(n_u,N)})^T Q_u (\Pi^{(n_u,N)})] \tag{4.35}$$

$$\begin{aligned} F &= F_1 x(k) + F_2 y_d + F_3 u_d \\ F_1 &= 2\sum_{i=1}^{N}[\Psi_i^T C_r^T Q_y C_r \Phi_i] \\ F_2 &= -2\sum_{i=1}^{N}[\Psi_i^T C_r^T Q_y C_r \Pi_i^{(n_r,N)}] \\ F_3 &= 2\sum_{i=1}^{N}[(\Pi_i^{(n_r,N)})^T Q_u] \end{aligned} \tag{4.36}$$

As matrizes Ψ_i, Φ_i e Π_i são construídas a partir da discretização do modelo e representam, respectivamente, as influências acumuladas dos estados iniciais, entradas e saídas ao longo do horizonte preditivo. A resolução do problema de otimização quadrática é realizada por meio do algoritmo de pontos interiores, implementado na função `mpcActiveSetSolver` (Garcia Montoya, 2024).

Com a linearização concluída, o sistema contínuo é discretizado por retenção de ordem zero . O período de amostragem foi definido como 0,2 segundos, garantindo bom equilíbrio entre desempenho e custo computacional. Embora o segurador de primeira ordem possa oferecer maior precisão em alguns casos (Wang, D., 2021), neste estudo não foram observadas melhorias significativas com sua adoção.

A matriz de saída C, apresentada na equação 4.37, foi definida de modo a garantir observabilidade sobre o componente da velocidade longitudinal no vetor de estados.

$$C = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \tag{4.37}$$

Para a definição das restrições, considerou-se que a entrada F_x, sua taxa de variação, a desaceleração e o chamado *jerk* são grandezas críticas para conforto e segurança. A aceleração máxima admissível, a_{max}, pode ser estimada pela Equação 4.38, em que μ representa o atrito entre a estrada e o pneu, e g representa a aceleração da gravidade (Dutra, Gomes e Rodrigues, 2020).

$$a_{max} = \mu g \tag{4.38}$$

Com base nessa aceleração e considerando a equação dinâmica longitudinal (2.2), é possível estimar a força de frenagem máxima admissível, conforme pode ser visto na equação 4.39.

$$F_{xmax} = -m(a_{max} + fg + u_{max}\frac{\rho C_d A(0.5u_{max} + u_w)}{m}) \tag{4.39}$$

A variação máxima da entrada de controle também foi limitada para respeitar limites de conforto associados ao *jerk*, estimado a partir da derivada da equação de força longitudinal (Winkel et al., 2023). Assim, a variação admissível é dada pela equação 4.40.

$$\delta F_x = \pm[jerk_{max}m + \rho C_d A u_{max} + \rho C_d A u_w a_{max}] \tag{4.40}$$

O valor máximo admissível para o *jerk* foi definido em 0,45g, valor que se encontra dentro dos limites ($2{,}5 - 5m/s^3$) estabelecidos em padrões internacionais de conforto para veículos automatizados (Winkel et al., 2023). Essa restrição é incorporada ao MPC para garantir que o envelope de operação respeite a integridade e o conforto dos passageiros, evitando intervenções excessivamente abruptas (Cui, Ding, Wei et al., 2021).

Por fim, impõem-se restrições sobre as saídas controladas para que a manobra de emergência atenda, simultaneamente, aos requisitos de mitigação de risco e de integridade dinâmica (Cheng et al., 2020). Nesse contexto, a saída controlada é definida pela equação 4.41, de modo a representar o conjunto de estados monitorados durante a frenagem.

$$y_c(k) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} u \\ v \\ r \end{bmatrix} + F_x \tag{4.41}$$

Para garantir operação dentro de um envelope fisicamente consistente, adotam-se restrições variantes no tempo sobre y_c. Para sistemas com restrições de saída, os limites são aplicados em cada passo do horizonte de predição, conforme a equação 4.42 (Alamir, 2013).

$$y^c_{min}(k+i) \leq y_c(k+i) \leq y^c_{max}(k+i) \tag{4.42}$$

O limite inferior, y^c_{min}, é definido pela velocidade do obstáculo, evitando que o controlador imponha velocidades abaixo do alvo de segurança. O limite superior, y^c_{max}, é dado por $u(k+i-1)$, velocidade do veículo no instante amostral anterior, o que preserva a monotonicidade da frenagem e inibe comandos que impliquem aceleração durante o evento de emergência.

A Tabela 4 resume os principais parâmetros adotados no controlador.

Parâmetro	**Símbolo**	**Valor**	**Unidade**
Horizonte de predição	N	20	passos
Horizonte de controle	n_u	20	passos
Peso no erro de saída	Q_y	$1{,}5 \times 10^9$	-
Peso no esforço de controle	Q_u	1×10^3	-
Jerk máximo admissível	$jerk_{max}$	0,45g	m/s^3
Período de amostragem	T_s	0,2	s

Tabela 4 – Parâmetros do Controlador MPC adotados.

Além da formulação matemática, a implementação prática do controlador incorpora uma lógica de supervisão que detecta eventos críticos e ajusta o comportamento do MPC em tempo real. Os principais eventos considerados são:

- **Identificação de risco**: verificado a partir das métricas de segurança, quando atingem valores críticos;
- **Aplicação de força**: quando a desaceleração é necessária para evitar a colisão;
- **Sucesso do AEBS**: condição em que o veículo é capaz de parar ou igualar a velocidade do obstáculo com segurança.

A ponderação dos termos da função de custo e das restrições foi definida com base em testes empíricos, de modo a garantir a estabilidade, robustez e realismo do sistema de controle em cenários de frenagem emergencial. Cabe destacar que simplificações foram necessárias, como a suposição de trajetória retilínea. Essas decisões permitem aproximar o controlador teórico de uma implementação viável em simulação.

4.3 Estratégia de Ativação do Controlador AEBS

A ativação do controlador do sistema AEBS desenvolvido baseia-se na utilização de duas métricas distintas. o *Time-to-Collision* (TTC) e o *Time-to-Match-Velocity* ($TTMV$) . O TTC representa o intervalo temporal estimado até que ocorra uma colisão entre o veículo em estudo (*Subject Vehicle – SV*) e um obstáculo à frente (*Lead Vehicle – LV*) , caso as velocidades atuais sejam mantidas. Já o $TTMV$ corresponde ao tempo necessário para que o veículo seguidor desacelere até igualar a velocidade do obstáculo, considerando a máxima desaceleração disponível.

A Figura 11 apresenta uma visão geral do algoritmo que define o cálculo do TTC e sua integração à lógica de ativação do controlador.

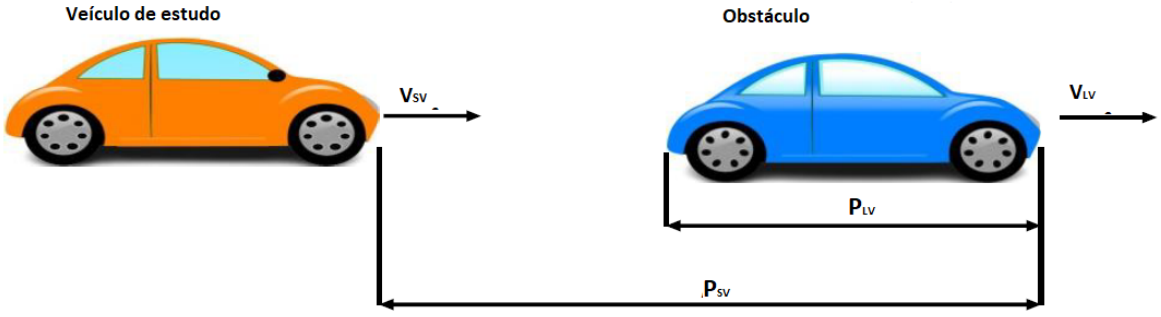


Figura 11 – Visão geral do algoritmo TTC utilizado na lógica de ativação.

O cálculo matemático do TTC pode ser expresso pela equação 4.43 (Alsuwian, Saeed e Amin, 2022). Nesta equação, P_{LV} e P_{SV} representam, respectivamente, as posições longitudinais do obstáculo e do veículo de estudo; V_{SV} e V_{LV} correspondem às velocidades longitudinais atuais.

$$TTC = \frac{P_{LV} - P_{SV}}{V_{SV} - V_{LV}} \tag{4.43}$$

O TTC diminui progressivamente à medida que a distância relativa entre os veículos se reduz. Quando essa métrica atinge um valor limiar crítico (TTC_{min}), o sistema exibe uma mensagem de alerta no painel, indicando risco iminente de colisão.

Adicionalmente, a métrica $TTMV$ avalia a capacidade do veículo seguidor de reduzir sua velocidade até igualar a do obstáculo em tempo hábil. Essa métrica depende da desaceleração máxima admissível (a_{max}), obtida a partir da equação 4.38. O cálculo é dado pela equação 4.44. A métrica $TTMV$ é particularmente útil para quantificar a margem temporal necessária para que o veículo execute uma frenagem confortável e segura, respeitando os limites físicos de atrito pneu-pavimento (Winkel et al., 2023).

$$TTMV = \frac{V_{SV} - V_{LV}}{a_{max}} \tag{4.44}$$

A ativação efetiva do controlador AEB ocorre somente quando o obstáculo é detectado à frente do veículo ($P_{LV} > P_{SV}$). A comparação entre TTC e $TTMV$ é o núcleo da lógica de decisão. O cálculo da métrica $TTMV$ deve levar em consideração o tempo de resposta do motorista e os atrasos do sistema de freios (Yang, W., Liu et al., 2020). Essa lógica de comparação é compatível com práticas recomendadas em sistemas de assistência avançada ao condutor, permitindo que o AEBS atue tanto em cenários de colisão inevitável quanto em situações onde a intervenção pode evitar totalmente o impacto.

Assim, a relação entre as métricas TTC e $TTMV$ foi definida da seguinte forma:

- **Caso 1 – Situação Segura:** se $TTMV < TTC$ e $TTC > 3$s, a distância e o tempo restantes não representam perigo. Nesse cenário, o sistema não é ativado;
- **Caso 2 – Situação Controlável:** se $TTMV \geq TTC$ ou $TTC \leq 3$s, há risco de colisão, porém o veículo possui tempo suficiente para reduzir a velocidade e igualá-la à do obstáculo. O controlador MPC é então ativado, gerando a sequência ótima de frenagem para evitar a colisão.

A norma ISO estabelece que os limiares de ativação para o sistema AEB variam tipicamente entre 2,5 s e 3,5 s (Wang, C. et al., 2020; Guo et al., 2020). Para a modelagem das condições de contorno em pista seca, a literatura técnica fixa o coeficiente de aderência pneu-pista (μ) em 0,8 (Xiaoxia et al., 2019; Guo et al., 2020). Este parâmetro é fundamental para o projeto do controlador preditivo, pois define o limite físico de desaceleração do veículo. Os parâmetros de ativação e as restrições adotadas nas simulações em MATLAB/Simulink e na validação em tempo real via Speedgoat estão consolidados na Tabela 5.

Parâmetro	**Símbolo**	**Valor**	**Unidade**
Tempo mínimo para colisão	TTC_{min}	3,0	s
Desaceleração máxima	a_{max}	0,8g	m/s^2

Tabela 5 – Parâmetros de ativação do controlador AEB.

Uma vez acionado, o MPC assume a responsabilidade de gerar a sequência ótima de forças de frenagem, respeitando as restrições físicas do veículo e os limites de conforto previamente definidos. O uso combinado das métricas TTC e $TTMV$ garante que o controlador seja ativado somente em situações justificadas, evitando atuações desnecessárias e contribuindo para a aceitação do sistema pelo condutor.

5 Procedimento Experimental

Este capítulo descreve o procedimento experimental utilizado para simular e validar o sistema AEBS projetado no capítulo anterior. As características do veículo de teste, a plataforma de simulação escolhida, os cenários de condução testados e as métricas de avaliação serão detalhados nas seções seguintes.

5.1 Características do Automóvel

A tabela 6 mostra os dados do veículo. Ressalta-se que esses dados não estão relacionados a nenhum veículo em específico; tratam-se de valores retirados de diferentes estudos incluídos na bibliografia deste documento.

Descrição	**Valor**	**Unidade (SI)**
Massa	2272	kg
Coeficiente de rigidez lateral dianteiro	182200	N/rad
Coeficiente de rigidez lateral traseiro	182200	N/rad
Distância do centro de massa à roda dianteira	1,11	m
Distância do centro de massa à roda traseira	1,67	m
Momento de inércia do veículo	4600	$kg \cdot m^2$
Coeficiente de resistência ao rolamento	0,01	–
Aceleração da gravidade	9,81	m/s^2
Ângulo de inclinação da estrada	0	rad
Ângulo da curva	0	rad
Densidade do ar	1,202	kg/m^3
Coeficiente de arrasto	0,5	–
Área de contato do ar com o veículo	1,95	m^2
Velocidade do vento	0,0	m/s
Velocidade máxima do carro	170	km/h

Tabela 6 – Parâmetros do veículo

5.2 Ambiente de Simulação e Validação Experimental

O desenvolvimento e validação do sistema de controle proposto foram estruturados em um fluxo incremental de complexidade. Na primeira etapa o ambiente MATLAB foi utilizado para a concepção lógica do controlador e para a geração de métricas de avaliação, fundamentando-se em modelos matemáticos da dinâmica veicular para descrever com precisão as forças envolvidas no movimento. Na segunda etapa, houve a migração para a interface baseada em blocos no Simulink.

O ambiente MATLAB/Simulink atua como a interface de desenvolvimento central, permitindo a implementação da lógica de controle MPC por meio de modelagem baseada em blocos e a posterior conversão do modelo dinâmico em código executável para sistemas de tempo real. A relevância acadêmica e prática desta plataforma reside na sua sinergia com o hardware da Speedgoat, que viabiliza a transição para os testes de *Hardware-in-the-Loop* (HIL).

Essa integração é fundamental para validar o controlador sob condições de determinismo temporal, em que a lógica de segurança do AEBS deve interagir com uma emulação da planta física do veículo executada em tempo real. Tal abordagem permite a verificação experimental do sistema em cenários de colisão iminente que seriam excessivamente perigosos ou inviáveis em testes de pista reais, garantindo que o controlador respeite o período de amostragem definido no projeto e apresente robustez frente às latências intrínsecas.

O sistema é validado para operar rigorosamente dentro do período de amostragem definido no projeto, assegurando que o tempo de computação do algoritmo seja inferior ao passo de tempo de amostragem para evitar instabilidades. A escolha do MATLAB/Simulink como plataforma de simulação justifica-se por sua alta fidelidade e ampla aceitação na pesquisa de controle automotivo, provendo a robustez necessária para que os resultados simulados apresentem alta similaridade com o comportamento físico real do veículo.

5.3 Cenários de Teste

Os testes padronizados para avaliação de sistemas de frenagem automática de emergência (AEBS) contemplam três principais cenários de colisão traseira definidos pelo protocolo *Euro NCAP AEB Car-to-Car* (EURO NCAP, 2024): *Car-to-Car Rear stationary* (CCRs) , em que o veículo alvo encontra-se estático; *Car-to-Car Rear moving* (CCRm) , em que o alvo trafega a velocidade inferior à do veículo em teste; e *Car-to-Car Rear braking* (CCRb) , em que o alvo realiza uma desaceleração brusca à frente do veículo em teste. Esses cenários visam assegurar a robustez e a eficácia do sistema em situações realistas, permitindo uma análise criteriosa da capacidade de detecção de obstáculos, do tempo de resposta e da intensidade da frenagem aplicada (EURO NCAP, 2024).

O cenário CCRs representa o caso de maior severidade dentre os definidos pelo Euro NCAP, pois a velocidade relativa entre o veículo de teste e o obstáculo é igual à velocidade absoluta do veículo de teste, maximizando a energia cinética a ser dissipada e minimizando a janela temporal para atuação. O protocolo Euro NCAP mantém o CCRs como cenário de referência, com faixa de velocidade de 10 km/h a 60 km/h, contemplando as velocidades urbanas adotadas neste trabalho e permitindo extrapolação controlada para o caso de 80 km/h. Adicionalmente, a ausência de movimento do obstáculo isola a contribuição do controlador longitudinal e garante plena repetibilidade entre os perfis de velocidade testados.

A distância inicial de 100 m fundamenta-se nos requisitos do protocolo Euro NCAP, que exige operação plena do sistema antes que o TTC atinja 10 s ou que a distância relativa seja inferior a 250 m (EURO NCAP, 2024). Para o pior caso avaliado, 80 km/h, a distância de 100 m implica TTC inicial de aproximadamente 4,5 s, superior ao limiar crítico de 3 s adotado para ativação do controlador na Tabela 5; para 30 km/h, o TTC inicial é de aproximadamente 12 s, conferindo margem suficiente para estabilização do sistema antes da intervenção.

Com base nesses padrões internacionais, foram definidos quatro grupos de testes baseados em velocidades típicas permitidas no trânsito urbano e rodoviário brasileiro, em conformidade com o artigo 61 do Código de Trânsito Brasileiro (CTB) (Modesto de Araujo, 2017). A Tabela 7 resume os cenários adotados.

Velocidade inicial (km/h)	Distância ao obstáculo (m)
30	100
40	100
60	100
80	100

Tabela 7 – Cenários de teste

5.4 Métricas de Avaliação

A avaliação do desempenho do controlador MPC implementado no sistema AEBS foi conduzida com base em métricas técnicas capazes de representar, simultaneamente, a eficácia da mitigação de colisão e os requisitos de conforto dinâmico dos ocupantes. Nesse contexto, a velocidade do veículo de teste foi analisada para verificar a convergência ao perfil do obstáculo e a manutenção do comportamento esperado ao longo de toda a manobra. Em paralelo, a força de frenagem aplicada pelo controlador foi monitorada para assegurar aderência aos limites admissíveis do sistema, evitando comandos excessivos que pudessem comprometer a estabilidade longitudinal, a segurança operacional e a robustez da atuação em diferentes condições iniciais.

Além da magnitude da força, avaliou-se sua variação temporal, com o objetivo de confirmar que a aplicação do comando ocorre de forma contínua e fisicamente plausível, sem descontinuidades que prejudiquem a dirigibilidade. A desaceleração do veículo também foi quantificada ao longo do tempo, verificando-se sua compatibilidade com os limites impostos no projeto do controlador e com as restrições associadas ao *jerk*. Complementarmente, a variação da desaceleração foi adotada como indicador da suavidade da intervenção, permitindo identificar transientes abruptos que poderiam gerar desconforto aos ocupantes ou ampliar a suscetibilidade a instabilidades em regimes críticos de frenagem.

Como métrica global de desempenho, considerou-se a distância percorrida até a estabilização da velocidade em condição segura frente ao obstáculo, por sintetizar a efetividade

da estratégia de frenagem e o tempo útil de resposta do sistema. A análise conjunta desses indicadores permite avaliar não apenas se o AEBS evita ou mitiga a colisão, mas também se o faz dentro de um envelope de operação compatível com os limites físicos do veículo e com critérios de aceitabilidade para uso real. Dessa forma, o conjunto de métricas adotado assegura uma validação abrangente do controlador, cobrindo desempenho, segurança e conforto em cenários representativos de condução.

A Tabela 8 sintetiza as métricas de avaliação adotadas e sua relevância para a validação do controlador.

Métrica	**Descrição**
Velocidade do veículo de teste	Avalia se o veículo atinge e acompanha a velocidade do obstáculo, permanecendo dentro dos limites aceitáveis durante a frenagem.
Força de frenagem	Verifica se a força de frenagem calculada pelo controlador está dentro da faixa admissível, evitando comandos excessivos que possam comprometer a estabilidade ou o conforto.
Variação da força de frenagem	Analisa se a aplicação da força ocorre de maneira contínua e controlada, evitando variações abruptas que possam representar riscos à dirigibilidade.
Desaceleração do veículo	Mede a desaceleração obtida ao longo do tempo e verifica se esta se mantém dentro dos limites calculados com base no valor máximo de *jerk*.
Variação da desaceleração	Garante que a desaceleração ocorra de forma progressiva, sem mudanças instantâneas que possam provocar desconforto ou instabilidade.
Distância percorrida até estabilização	Quantifica a distância necessária para o veículo atingir uma velocidade segura em relação ao obstáculo, sendo essencial para validar a eficácia da frenagem e o tempo de resposta do sistema.

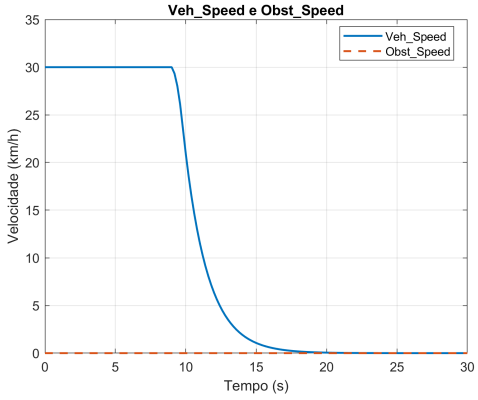
Tabela 8 – Métricas de avaliação do desempenho do controlador MPC no AEBS

6 Resultados e Análises

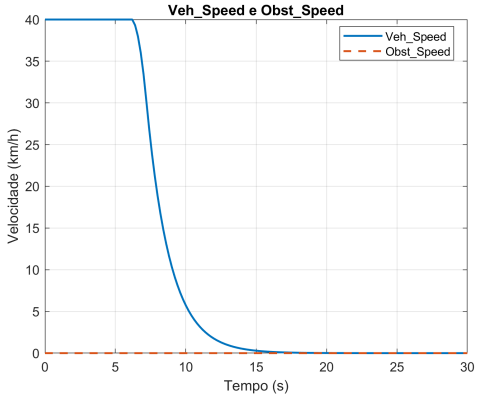
Este capítulo apresenta os resultados da avaliação do controlador desenvolvido no capítulo 4, segundo as métricas definidas no capítulo 5, organizando a validação em MIL (Seções 6.1 a 6.4), HIL (Seção 6.5) e análise de desempenho computacional do MPC (Seção 6.7). Em todos os testes, adota-se o cenário com obstáculo estático a 100 m e velocidades iniciais de 30, 40, 60 e 80 km/h. Busca-se verificar simultaneamente a eficácia da mitigação de colisão, o conforto dinâmico e a viabilidade temporal da implementação em tempo real.

6.1 Velocidade do veículo

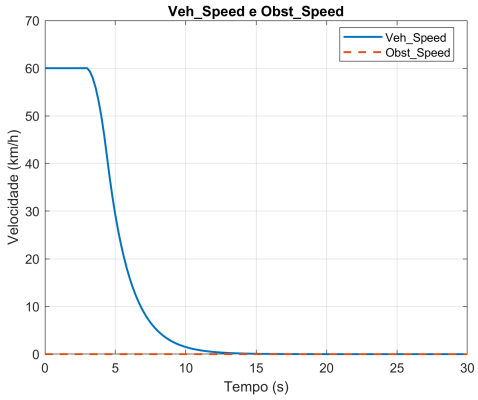
A figura 12 apresenta a evolução temporal da velocidade do veículo de teste nos quatro cenários avaliados. Os gráficos das figuras 12a, 12b, 12c e 12d correspondem, respectivamente, às velocidades iniciais de 30, 40, 60 e 80 km/h.



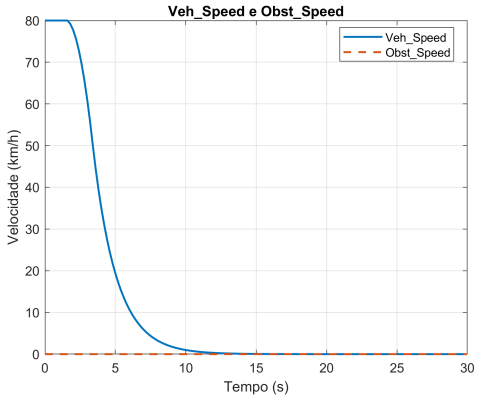
(a) 30 km/h



(b) 40 km/h



(c) 60 km/h



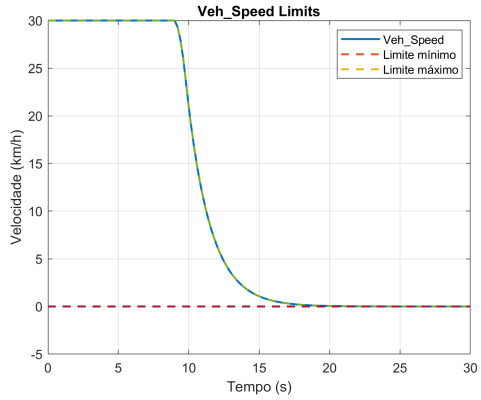
(d) 80 km/h

Figura 12 – Velocidade do veículo seguidor em relação a obstáculo parado em diferentes velocidades iniciais

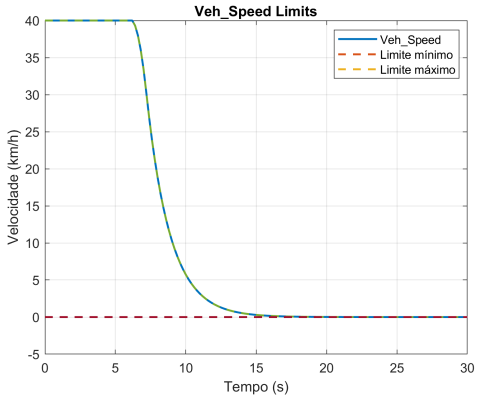
A análise dos perfis de velocidade permite avaliar simultaneamente dois aspectos fundamentais do desempenho do AEBS: (i) a capacidade de reduzir a velocidade do veículo até a condição segura (velocidade nula, dada a natureza estática do obstáculo) e (ii) a suavidade da transição entre o regime de cruzeiro e o regime de frenagem. Em todos os quatro cenários, o controlador MPC conduziu o veículo à parada completa, demonstrando a eficácia absoluta do sistema na prevenção da colisão para a faixa de velocidades avaliada.

Observa-se que o instante de início da frenagem varia de forma inversamente proporcional à velocidade inicial: quanto maior a velocidade, menor o TTC inicial e, consequentemente, mais cedo a lógica de ativação identifica a situação como controlável e aciona o controlador. Para 30 km/h, o TTC inicial de aproximadamente 12 s confere margem ampla, e o sistema intervém apenas em $t \approx 8{,}8$ s; para 80 km/h, com TTC inicial de aproximadamente 4,5 s, a intervenção ocorre já em $t \approx 1{,}4$ s. Essa relação é coerente com a formulação da lógica de ativação apresentada na Seção 4.3, na qual o limiar $TTC_{min} = 3$ s determina a fronteira entre situação segura e situação controlável.

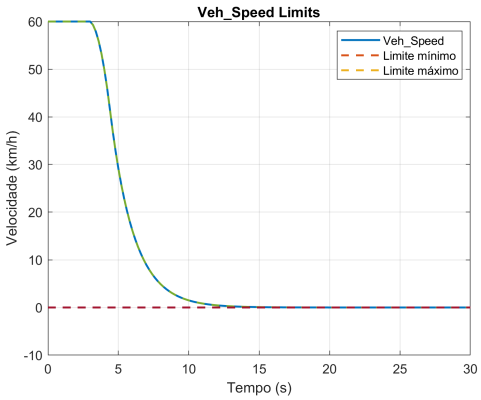
A figura 13 complementa a análise ao apresentar os envelopes de velocidade impostos pelo controlador.



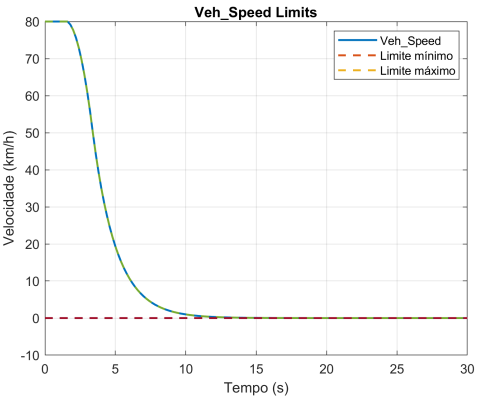
(a) 30 km/h



(b) 40 km/h



(c) 60 km/h



(d) 80 km/h

Figura 13 – Velocidade do veículo seguidor em relação a obstáculo parado considerando limites de controle

Conforme evidenciado nos gráficos, a velocidade permanece integralmente dentro do envelope em todos os cenários, sem nenhuma violação do limite superior. Esse resultado confirma que o *solver* QP resolve o problema de otimização respeitando as restrições de saída, definidas na equação 4.42, em cada instante de amostragem, e que a formulação das restrições variantes no tempo é compatível com a dinâmica do sistema para toda a faixa de velocidades avaliada. Além disso, os estados laterais (v e r) permaneceram dentro dos limites impostos, confirmando que a frenagem longitudinal não introduziu perturbações significativas na estabilidade lateral do veículo.

É possível notar que perfis de velocidade exibem, em todos os cenários, uma transição contínua e sem descontinuidades entre o regime de cruzeiro e o regime de frenagem. Essa suavidade resulta diretamente da formulação do problema de otimização quadrática do controlador MPC, que penaliza simultaneamente o erro de rastreamento (via Q_y) e o esforço de controle (via Q_u), impedindo comandos abruptos de frenagem. A ausência de oscilações ou sobressinais na resposta de velocidade indica, adicionalmente, que a ponderação dos termos da função de custo e os horizontes de predição e controle ($N = n_u = 20$ passos) estão adequadamente dimensionados para a dinâmica do sistema.

Observa-se também que o TTC no instante de ativação converge para o limiar de projeto de 3 s em todos os cenários, o que é consistente com a lógica de ativação definida na Seção 4.3: o controlador é acionado precisamente quando o TTC atinge o valor crítico. A convergência desse indicador confirma a correta implementação da máquina de estados que governa a transição entre o modo de cruzeiro e o modo de frenagem de emergência.

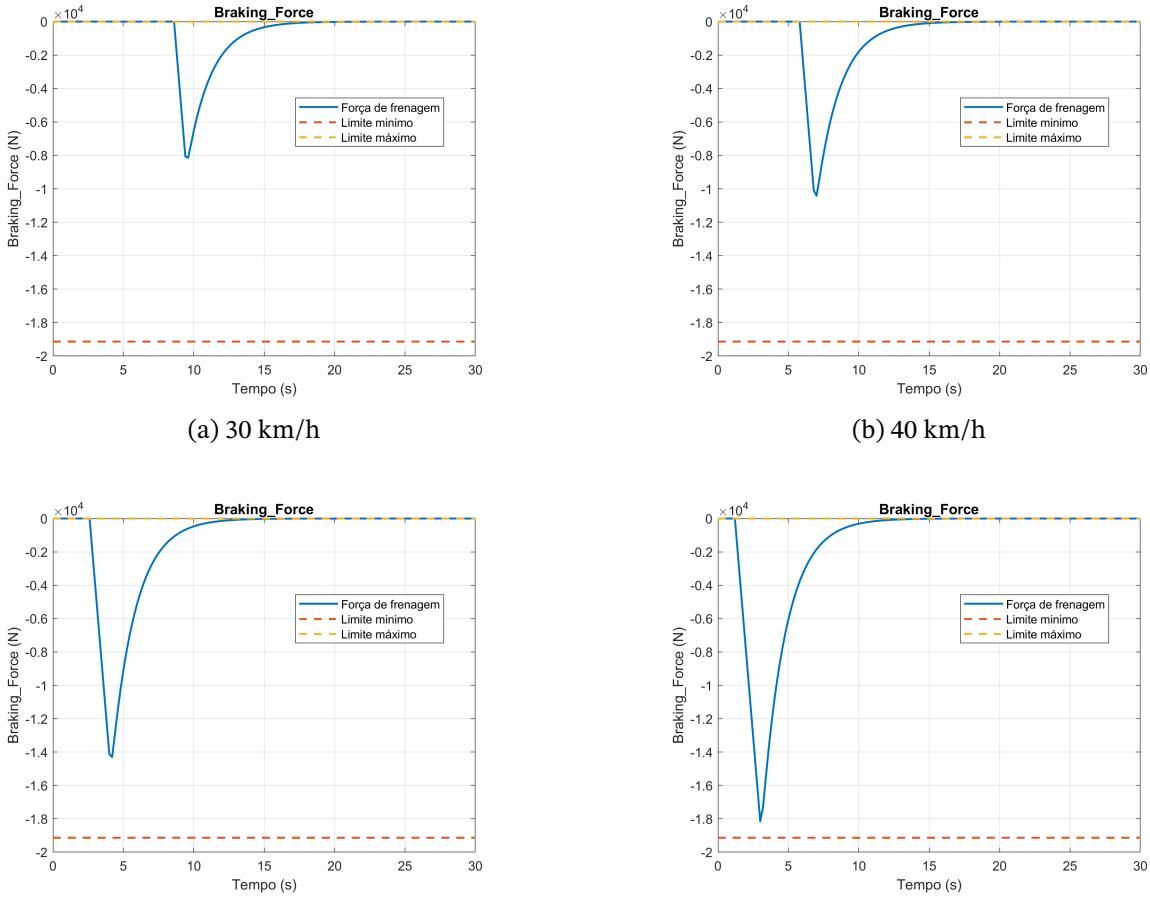
A tabela 9 sintetiza os indicadores temporais do processo de frenagem. A relação entre a velocidade inicial e o tempo total de frenagem é sublinear: um aumento de 167% na velocidade (de 30 para 80 km/h) resulta em um acréscimo de apenas 23% no tempo de frenagem (de 14,6 para 18,0 s). Esse comportamento decorre do aumento proporcionalmente maior da força de frenagem aplicada em cenários de maior criticidade, conforme será detalhado na Seção 6.2.

Velocidade inicial (km/h)	Velocidade final (km/h)	Início da frenagem (s)	Tempo de frenagem (s)	TTC no instante de ativação (s)
30	0	8,8	14,6	$\approx 3{,}0$
40	0	6,0	16,2	$\approx 3{,}0$
60	0	2,8	17,2	$\approx 3{,}0$
80	0	1,4	18,0	$\approx 3{,}0$

Tabela 9 – Resultados temporais do processo de frenagem do sistema AEBS

6.2 Força de frenagem

A figura 14 apresenta a evolução temporal da força de frenagem F_x nos quatro cenários avaliados. As figuras 14a, 14b, 14c e 14d correspondem, respectivamente, às velocidades iniciais de 30, 40, 60 e 80 km/h.



(a) 30 km/h

(b) 40 km/h

(c) 60 km/h

(d) 80 km/h

Figura 14 – Força de frenagem aplicada em diferentes velocidades iniciais contra obstáculo parado

Os limites de projeto para a força de frenagem e sua taxa de variação, derivados das equações 4.39 e 4.40 com os parâmetros da tabela 6, são apresentados na tabela 10. O valor de -19.137 N representa a capacidade física máxima do veículo em aplicar força retardadora contra o pavimento, considerando o coeficiente de aderência $\mu = 0{,}8$, o arrasto aerodinâmico e a resistência ao rolamento. O sinal negativo indica que a força atua no sentido oposto ao movimento. A restrição de variação de ± 2.017 N/s limita a taxa com que a força pode ser incrementada ou decrementada entre instantes amostrais consecutivos, correspondendo ao limite de *jerk* de 0,45g traduzido para o domínio da força via equação 4.40.

Força de frenagem máxima (N)	**Variação da força de frenagem (N/s)**
-19.137	± 2.017

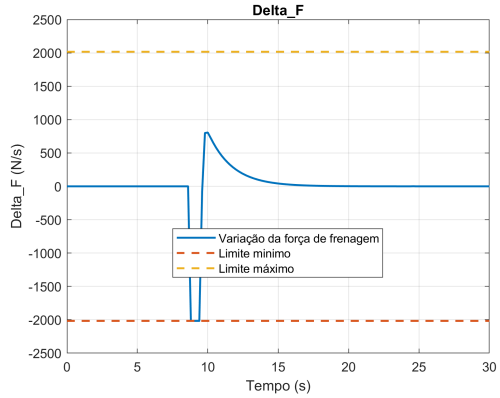
Tabela 10 – Limites de projeto para força de frenagem e sua variação temporal

A análise dos gráficos da figura 14 revela três características fundamentais do comportamento do controlador. Em primeiro lugar, a força de frenagem cresce progressivamente após a ativação do AEBS, sem aplicação instantânea do valor máximo. Esse incremento gradual resulta diretamente da restrição sobre δF_x (equação 4.40), que impede variações abruptas e garante uma frenagem fisicamente plausível e confortável para os ocupantes.

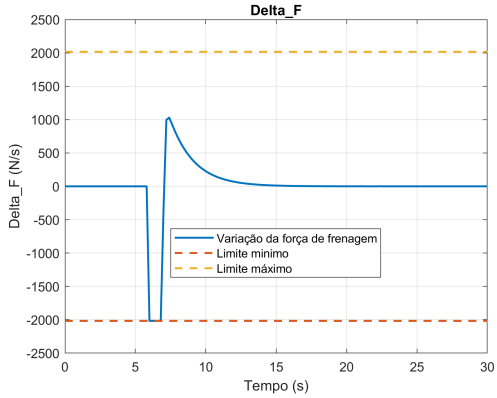
Em segundo lugar, a intensidade máxima da força aplicada é proporcional à criticidade do cenário: quanto maior a velocidade inicial, maior a energia cinética a ser dissipada e, consequentemente, maior o esforço de frenagem demandado pelo otimizador. Em terceiro lugar, em todos os cenários, a força máxima permanece abaixo do limite de projeto de -19.137 N, confirmando que o controlador opera dentro do envelope admissível sem saturação do atuador.

A proporção entre a força máxima aplicada e o limite de projeto quantifica a margem de atuação disponível: 42,6% no cenário de 30 km/h, 54,5% a 40 km/h, 74,7% a 60 km/h e 94,9% a 80 km/h. A redução progressiva dessa margem com o aumento da velocidade evidencia que o cenário de 80 km/h se aproxima do limite operacional do sistema, restando apenas 5,1% de capacidade excedente. Esse resultado sugere que, para velocidades superiores a 80 km/h com a mesma distância inicial de 100 m, o controlador pode não dispor de margem suficiente para evitar a colisão sem violar restrições, reforçando a importância da distância inicial e da calibração dos limiares de ativação.

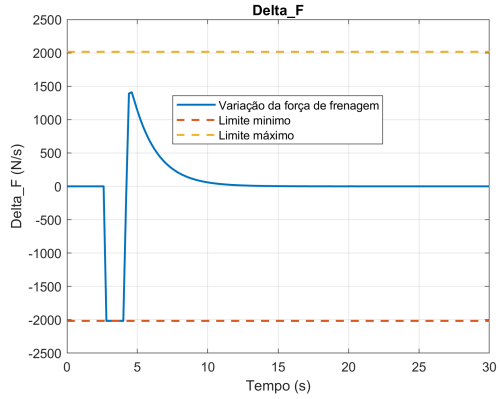
A figura 15 apresenta a variação temporal da força de frenagem (δF_x) nos quatro cenários.



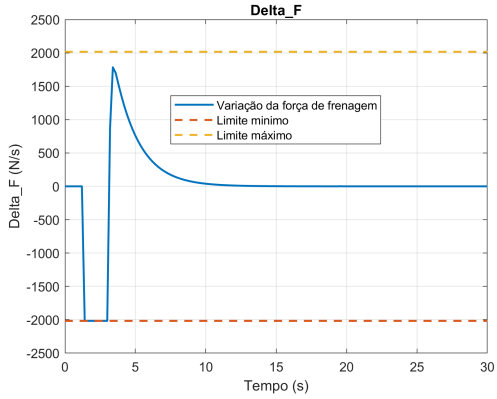
(a) 30 km/h



(b) 40 km/h



(c) 60 km/h



(d) 80 km/h

Figura 15 – Variação da força de frenagem em diferentes velocidades iniciais contra obstáculo parado

A análise revela que o limite inferior de -2.017 N/s é atingido no instante de ativação do AEBS em todos os cenários, correspondendo à rampa máxima de incremento da força de frenagem (em valor absoluto). O limite superior, que governa a taxa de alívio da força, apresenta comportamento assimétrico: os valores positivos observados variam de $+806$ N/s (30 km/h) a $+1.785$ N/s (80 km/h), indicando que o alívio da frenagem ocorre de forma mais gradual nos cenários de menor criticidade.

Essa assimetria é coerente com a lógica do otimizador. Em cenários de baixa velocidade, a frenagem necessária é menor e o controlador pode adotar uma estratégia mais suave para retornar à condição de repouso. Já em cenários de alta velocidade, a proximidade ao limite de força exige variações mais intensas durante a fase de alívio.

Observa-se que, no instante de transição entre o modo de cruzeiro e o modo de frenagem, a variação da força apresenta um pico que coincide com o limite de -2.017 N/s. Esse comportamento decorre da transição abrupta no ponto de operação do QP: na passagem de força nula para frenagem de emergência, o conjunto de restrições ativas do problema de otimização é reconstruído, o que demanda a taxa máxima de incremento para convergir rapidamente à trajetória ótima. A partir do segundo ciclo amostral da fase de frenagem, a variação se estabiliza em valores inferiores, refletindo o mecanismo de *warm start* do *solver*.

A tabela 11 consolida os valores de força máxima e variação máxima observados em cada cenário, juntamente com a margem percentual em relação ao limite de projeto.

Vel. inicial (km/h)	Força máxima (N)	Margem (%)	Variação máxima (N/s)	Limite (N/s)
30	$-8.144{,}3$	57,4	-2.017 / $+806{,}4$	± 2.017
40	$-10.418{,}0$	45,5	-2.017 / $+1.029{,}8$	± 2.017
60	$-14.298{,}0$	25,3	-2.017 / $+1.409{,}4$	± 2.017
80	$-18.153{,}0$	5,1	-2.017 / $+1.784{,}5$	± 2.017

Tabela 11 – Força de frenagem e sua variação temporal nos cenários avaliados

6.3 Desaceleração

A desaceleração do veículo durante a frenagem constitui um indicador simultâneo de eficácia e de conforto: valores elevados de desaceleração indicam capacidade de reduzir rapidamente a velocidade, porém podem comprometer a estabilidade longitudinal e gerar desconforto aos ocupantes se ultrapassarem os limites admissíveis. De forma complementar, a taxa de variação da desaceleração (*jerk*) quantifica a suavidade da transição de frenagem, sendo um dos parâmetros mais relevantes para a aceitabilidade de sistemas AEBS em aplicações reais.

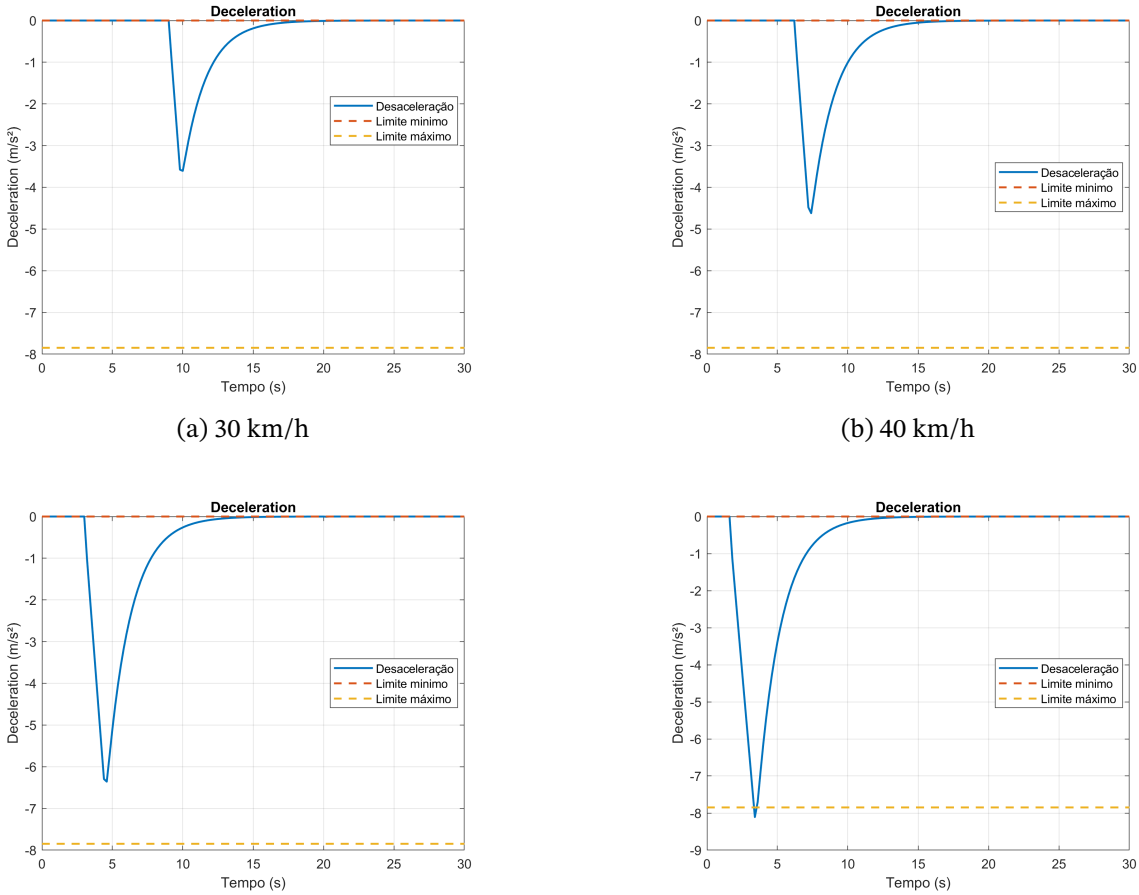
Os limites de projeto para essas grandezas, derivados da equação 4.38 e do critério proposto por Winkel et al. (2023), são apresentados na tabela 12. O valor de desaceleração máxima de 7,848 m/s^2 corresponde ao produto $\mu g = 0{,}8 \times 9{,}81$, representando a capacidade

de frenagem limitada pela aderência pneu-pavimento em pista seca. O limite de *jerk* de $\pm 4{,}4145$ m/s^3 (0,45g) situa-se dentro da faixa recomendada pela literatura (2,5 a 5 m/s^3) para veículos automatizados, conforme referenciado por Winkel et al. (2023).

Desaceleração máxima (m/s^2)	***Jerk* máximo (m/s^3)**
$-7{,}848$	$\pm 4{,}4145$

Tabela 12 – Limites de projeto para desaceleração e *jerk*

A figura 16 apresenta os perfis de desaceleração nos quatro cenários.



(a) 30 km/h

(b) 40 km/h

(c) 60 km/h

(d) 80 km/h

Figura 16 – Desaceleração do veículo em diferentes velocidades iniciais contra obstáculo parado

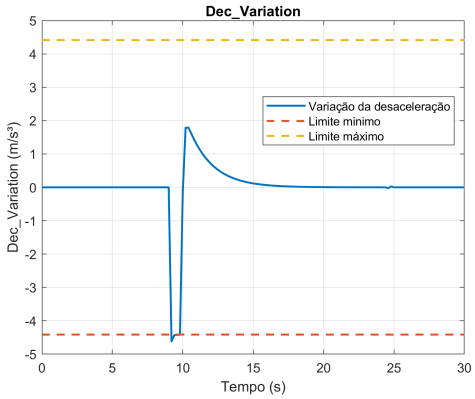
A análise dos perfis revela um padrão consistente: a desaceleração cresce de forma progressiva após a ativação do AEBS, atinge um pico e decresce gradualmente à medida que o veículo se aproxima da parada. Essa forma de sino é coerente com o comportamento esperado de um controlador MPC que pondera erro de rastreamento e esforço de controle: nos instantes iniciais, a distância ao obstáculo é grande e o controlador prioriza suavidade; à medida que a distância diminui e o risco aumenta, o peso do termo de erro Q_y domina e o controlador demanda maior desaceleração; próximo à parada, a velocidade já é baixa e a força necessária decresce proporcionalmente.

Nos cenários de 30 a 60 km/h, a desaceleração máxima permanece dentro do limite de projeto: 3,7 m/s^2 (47,2% do limite), 4,7 m/s^2 (59,9%) e 6,5 m/s^2 (82,8%), respectivamente. A margem progressivamente menor reflete a maior demanda de frenagem com o aumento da energia cinética inicial.

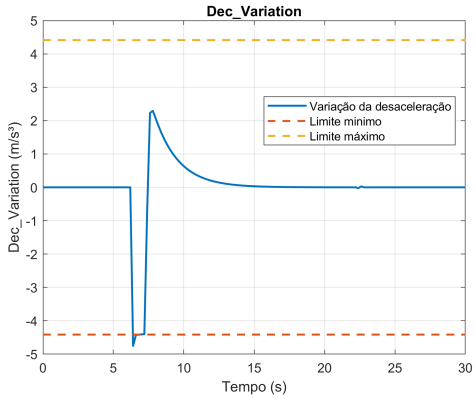
No cenário de 80 km/h, observa-se pico de desaceleração de 8,1 m/s^2, excedendo o limite de 7,848 m/s^2 em aproximadamente 3,2%. Essa violação pontual é prevista na teoria de MPC com restrições competitivas. Conforme Liuping Wang (2009), quando múltiplas restrições estão simultaneamente ativas e a região viável do QP se reduz, o *solver* pode relaxar uma restrição de menor prioridade para satisfazer as demais.

No presente caso, o controlador priorizou a manutenção da distância de segurança e o cumprimento das restrições de força de frenagem, relaxando pontualmente a restrição de desaceleração; como a violação é breve e de baixa magnitude, não compromete a estabilidade dinâmica do veículo. Esse resultado, contudo, sinaliza que o cenário de 80 km/h se encontra próximo ao limite operacional da arquitetura proposta para a distância inicial de 100 m.

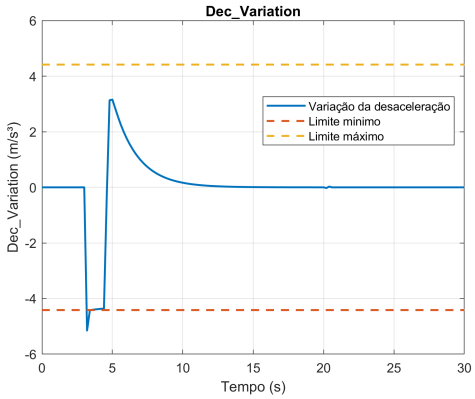
A figura 17 apresenta os perfis de variação da desaceleração (*jerk*).



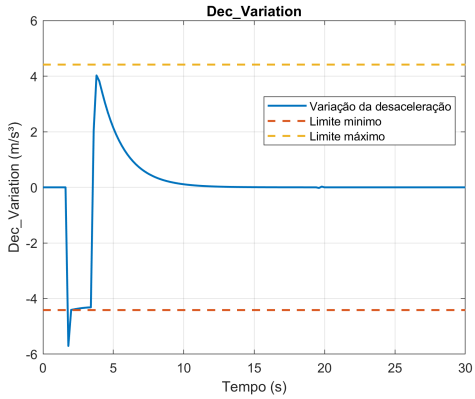
(a) 30 km/h



(b) 40 km/h



(c) 60 km/h



(d) 80 km/h

Figura 17 – Variação da desaceleração (*jerk*) em diferentes velocidades iniciais contra obstáculo parado

A análise do *jerk* revela que os picos negativos (correspondentes ao aumento da intensidade de frenagem) excedem o limite de $-4{,}4145$ m/s^3 em todos os cenários, com valores variando de $-4{,}5$ m/s^3 (30 km/h, excesso de 1,9%) a $-5{,}8$ m/s^3 (80 km/h, excesso de 31,4%). Essas violações pontuais ocorrem no instante de transição entre o modo de cruzeiro e o modo de frenagem, quando a mudança abrupta no ponto de operação exige uma taxa elevada de variação da desaceleração para convergir à trajetória ótima. Em contrapartida, os picos positivos (alívio da frenagem) permanecem dentro dos limites em todos os cenários, variando de $+1{,}9$ m/s^3 (30 km/h) a $+4{,}0$ m/s^3 (80 km/h).

A assimetria entre os picos negativos e positivos do *jerk* é um resultado relevante do ponto de vista de conforto: o início da frenagem de emergência, que é inerentemente mais abrupto, concentra as violações, enquanto o alívio da frenagem, que ocorre de forma mais gradual à medida que o veículo se aproxima da parada, respeita os limites estabelecidos. Nos intervalos entre a transição inicial e a parada completa, o *jerk* permanece dentro da faixa admissível, confirmando que a formulação do MPC com restrições sobre δF_x é eficaz em controlar a suavidade da frenagem durante o regime sustentado.

A tabela 13 consolida os valores de desaceleração máxima e variação da desaceleração observados em cada cenário.

Vel. inicial (km/h)	a_{max} **(m/s^2)**	**Margem desac. (%)**	***Jerk* (m/s^3)**	**Limite *jerk* (m/s^3)**
30	3,7	52,8	$-4{,}5$ / $+1{,}9$	$\pm 4{,}4145$
40	4,7	40,1	$-4{,}8$ / $+2{,}2$	$\pm 4{,}4145$
60	6,5	17,2	$-5{,}0$ / $+3{,}0$	$\pm 4{,}4145$
80	8,1	$-3{,}2^*$	$-5{,}8$ / $+4{,}0$	$\pm 4{,}4145$

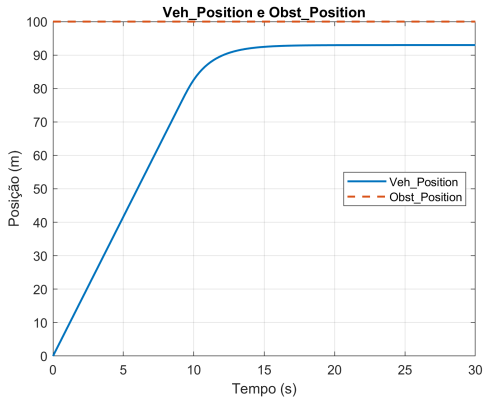
*Violação pontual: 8,1 > 7,848 m/s^2 (excesso de 3,2%). Ver análise no texto.

Tabela 13 – Desaceleração máxima e variação da desaceleração nos cenários avaliados

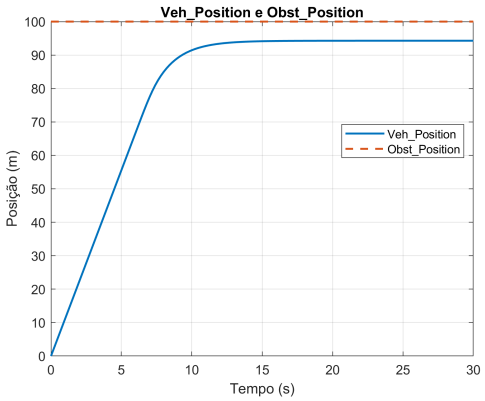
6.4 Distância percorrida

A distância percorrida até a parada completa constitui a métrica global de desempenho do sistema AEBS, por sintetizar a efetividade da estratégia de frenagem e o tempo útil de resposta do controlador. A figura 18 apresenta a evolução temporal da posição do veículo nos quatro cenários, juntamente com a posição fixa do obstáculo a 100 m. O resultado central desta análise é inequívoco: em todos os quatro cenários, o veículo atinge a parada completa antes de atingir a posição do obstáculo, confirmando a eficácia absoluta do sistema AEBS na prevenção da colisão para a faixa de velocidades avaliada.

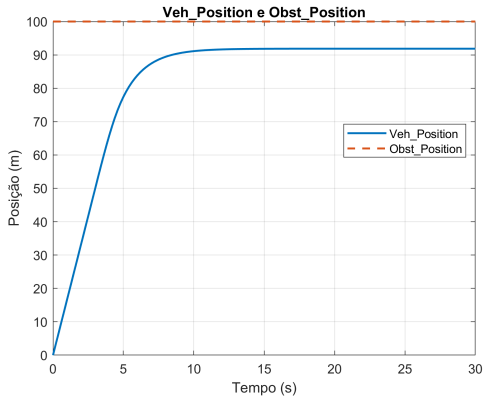
A Tabela 14 apresenta a distância percorrida e a margem de segurança residual (diferença entre a posição do obstáculo e a posição final do veículo) em cada cenário. Sua análise revela um comportamento não monotônico da distância percorrida em relação à velocidade inicial, que merece atenção.



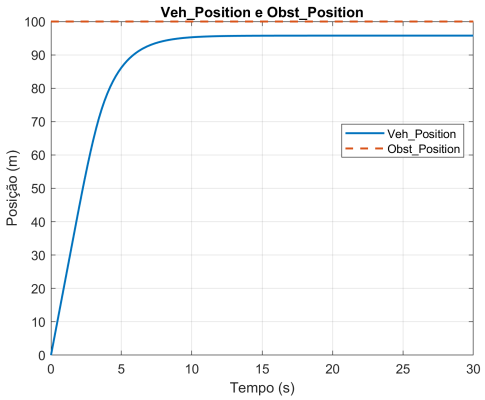
(a) 30 km/h



(b) 40 km/h



(c) 60 km/h



(d) 80 km/h

Figura 18 – Posição relativa do veículo seguidor em diferentes velocidades iniciais contra obstáculo parado

Vel. inicial (km/h)	Distância percorrida (m)	Margem de segurança (m)
30	92,80	7,20
40	94,28	5,72
60	91,86	8,14
80	95,77	4,23

Tabela 14 – Distância percorrida e margem de segurança nos cenários avaliados

Enquanto seria esperado, numa primeira análise, que a distância percorrida fosse estritamente crescente com a velocidade inicial (dado o aumento da energia cinética a ser dissipada), o cenário de 60 km/h apresenta a menor distância percorrida (91,86 m) e, consequentemente, a maior margem de segurança (8,14 m). Esse comportamento resulta da interação entre dois fatores concorrentes na formulação do MPC: (i) em cenários de maior velocidade, o controlador é ativado mais cedo (TTC atinge 3 s mais rapidamente), dispondo de mais tempo útil para aplicar a frenagem; (ii) a intensidade da força de frenagem cresce proporcionalmente à criticidade, mas é limitada pelas restrições de δF_x e $F_{x_{max}}$.

No cenário de 60 km/h, a combinação entre o instante de ativação ($t = 2{,}8$s) e a capacidade de frenagem disponível (74,7% do limite de força) resulta em uma dissipação

particularmente eficiente da energia cinética. No cenário de 80 km/h, embora o controlador seja ativado ainda mais cedo ($t = 1{,}4$s), a proximidade ao limite de força (94,9%) e a violação pontual da desaceleração indicam que o otimizador opera com margens muito estreitas, o que limita a capacidade de otimização da trajetória.

O pior caso observado corresponde ao cenário de 80 km/h, com margem residual de 4,23 m. Embora suficiente para evitar a colisão, essa margem indica que, para distâncias iniciais menores ou velocidades significativamente superiores, o sistema poderia não garantir a prevenção total do impacto. Esse resultado reforça a importância da calibração dos limiares de ativação e da distância mínima de operação para a integridade funcional do AEBS.

6.5 Validação em *Hardware-in-the-Loop*

Esta seção apresenta a validação do sistema AEBS em ambiente de tempo real, conduzida na plataforma Speedgoat Baseline para o cenário de 30 km/h com obstáculo estático a 100 m. O objetivo é verificar se o controlador MPC, após geração automática e compilação em código C para o *target* embarcado, reproduz o comportamento observado no ciclo MIL, confirmando o determinismo temporal e a viabilidade de implementação em ECU (*Electronic Control Unit*) veicular.

A arquitetura experimental utiliza a Speedgoat Baseline como emulador da planta (dinâmica veicular e ambiente) e, simultaneamente, como unidade de execução do controlador MPC. A comunicação entre o *target* e o computador *host* (MATLAB/Simulink) foi realizada via Ethernet, com período de amostragem de $T_s = 0{,}2$s, conforme definido no projeto. A cadeia de geração de código seguiu o fluxo Simulink Coder → compilação cruzada → *target* embarcado, com operação em modo *External* do Simulink Real-Time para aquisição de dados em tempo real.

Os resultados em HIL demonstraram que o AEBS manteve eficácia na prevenção da colisão, reproduzindo, em todas as métricas avaliadas, o comportamento observado no ciclo MIL. Além da convergência dos perfis dinâmicos, não foram observadas violações das restrições de segurança durante a execução em tempo real. Esse resultado reforça a consistência entre os ambientes de validação e confirma a robustez da implementação embarcada para aplicações automotivas.

A figura 19 apresenta a evolução temporal da velocidade do veículo no ambiente HIL. O perfil de velocidade é qualitativa e quantitativamente indistinguível do resultado MIL (figura 12a): o veículo inicia a 30 km/h, mantém velocidade constante durante a fase de cruzeiro, e a partir de $t \approx 8{,}8$ s o sistema AEBS inicia a intervenção autônoma, reduzindo progressivamente a velocidade até a parada completa. A transição entre os regimes de cruzeiro e frenagem ocorre de forma contínua e sem descontinuidades, confirmando que a estrutura do problema de otimização é preservada na implementação embarcada.

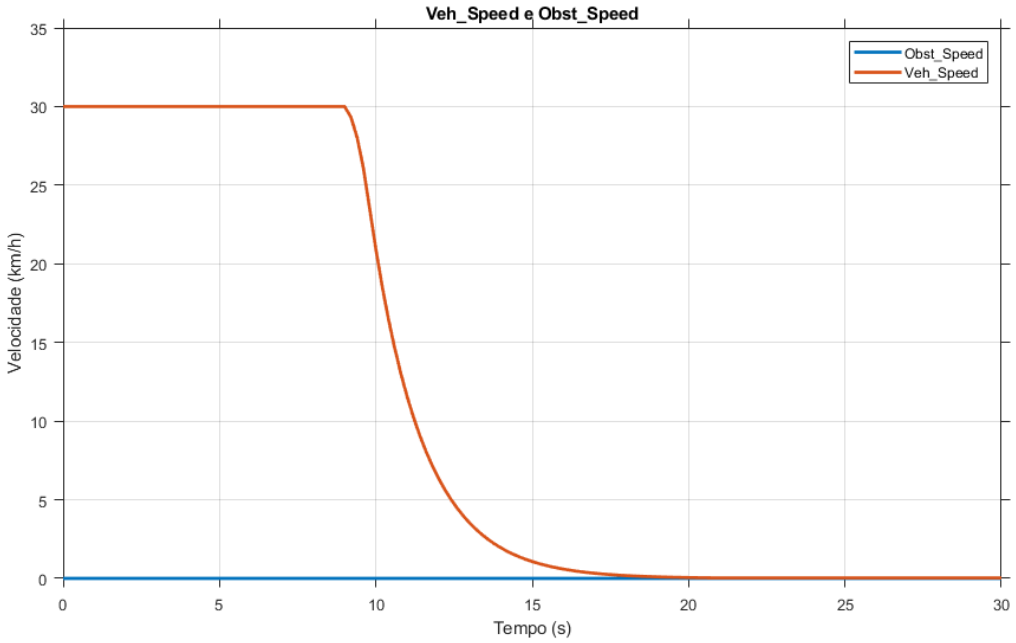


Figura 19 – Velocidade do veículo de teste em relação ao obstáculo: HIL — 30 km/h

A figura 20 confirma que a trajetória de velocidade permanece dentro do envelope de restrições no ambiente HIL. Após o início da frenagem, a velocidade apenas diminui ou permanece constante, sem aceleração durante a fase de intervenção. Esse resultado é relevante porque, no ambiente embarcado, efeitos como arredondamento numérico em ponto flutuante de precisão finita e latências de comunicação poderiam introduzir perturbações nos estados do sistema. A ausência dessas perturbações confirma a robustez da implementação.

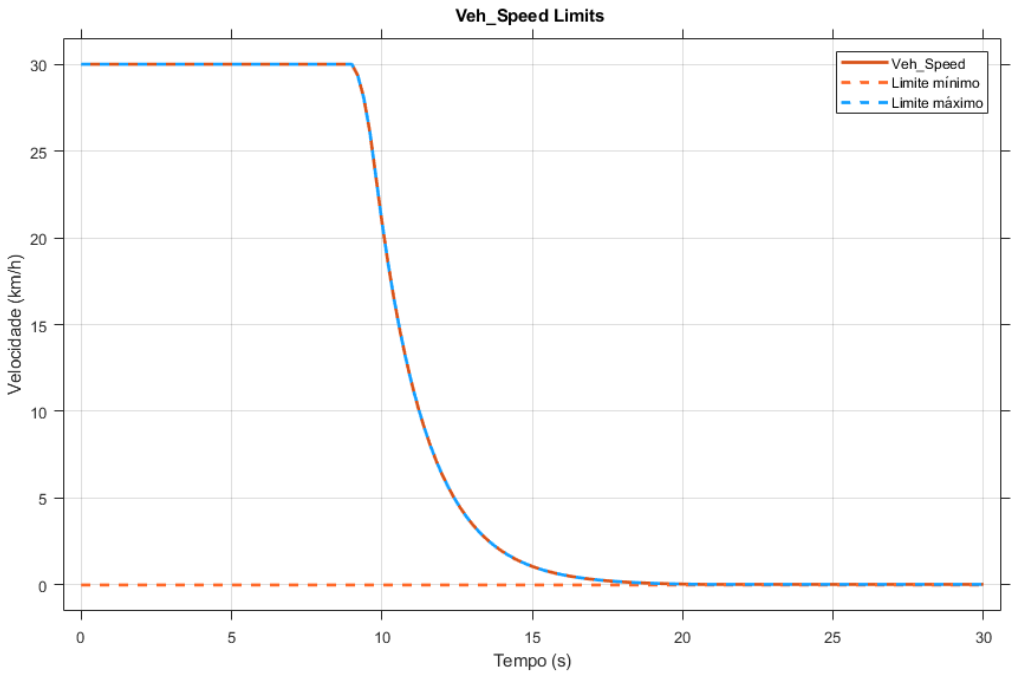


Figura 20 – Limites para velocidade do veículo de teste: HIL — 30 km/h

A figura 21 mostra a diferença MIL–HIL da velocidade, com erro residual da ordem de 10^{-15} km/h. Essa convergência indica, simultaneamente, que a discretização do modelo e a geração automática de código não introduziram erros numéricos relevantes, que a plataforma de *hardware* resolve o QP no período de amostragem sem truncamentos ou simplificações, e que a comunicação Ethernet entre *host* e *target* não introduziu latências que comprometam a correção temporal dos estados.

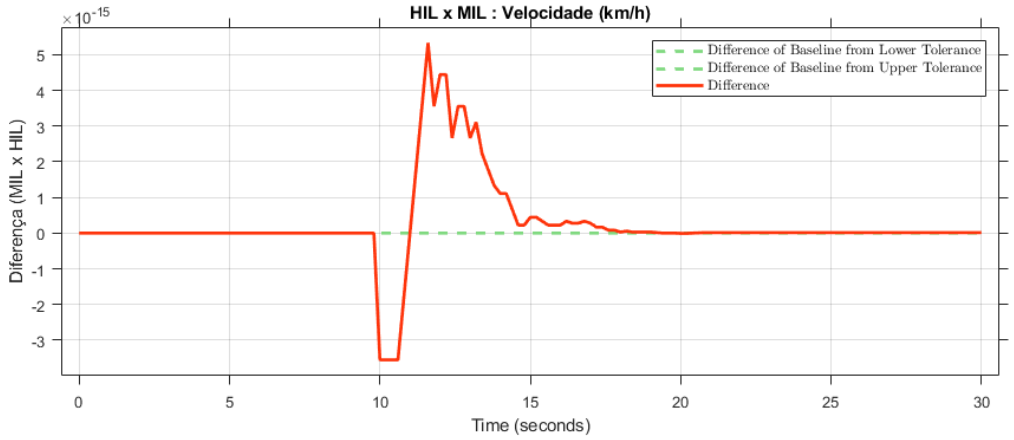


Figura 21 – Diferença MIL × HIL: Velocidade — 30 km/h

A figura 22 mostra, no HIL, o mesmo perfil de força de frenagem observado no MIL: crescimento progressivo após a ativação do AEBS, pico de −8.144,3 N e decréscimo gradual na fase final. Como o valor máximo permanece bem abaixo do limite de −19.137 N, confirma-se que o controlador opera dentro do envelope admissível no cenário de 30 km/h.

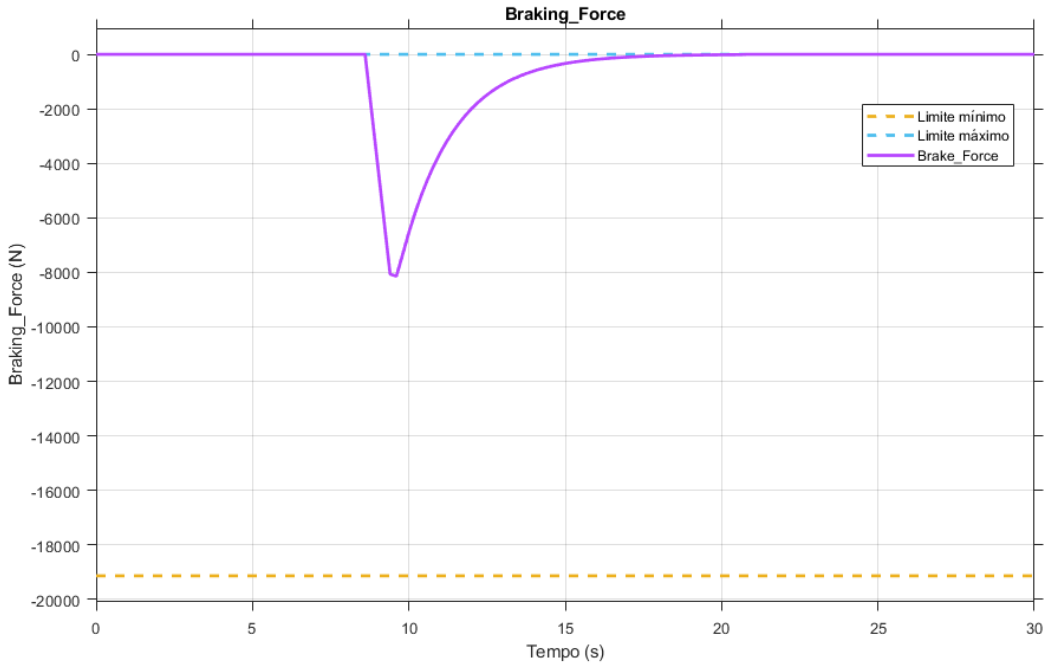


Figura 22 – Força de frenagem aplicada no veículo de teste: HIL — 30 km/h

A figura 23 quantifica a diferença entre os ambientes MIL e HIL para a força de frenagem. O erro residual situa-se na ordem de 10^{-12} N, valor numericamente desprezível e inferior em mais de nove ordens de grandeza à força máxima aplicada. Essa concordância confirma que a cadeia de geração de código preserva integralmente a formulação do problema de otimização, incluindo a construção das matrizes Hessianas e dos vetores de gradiente.

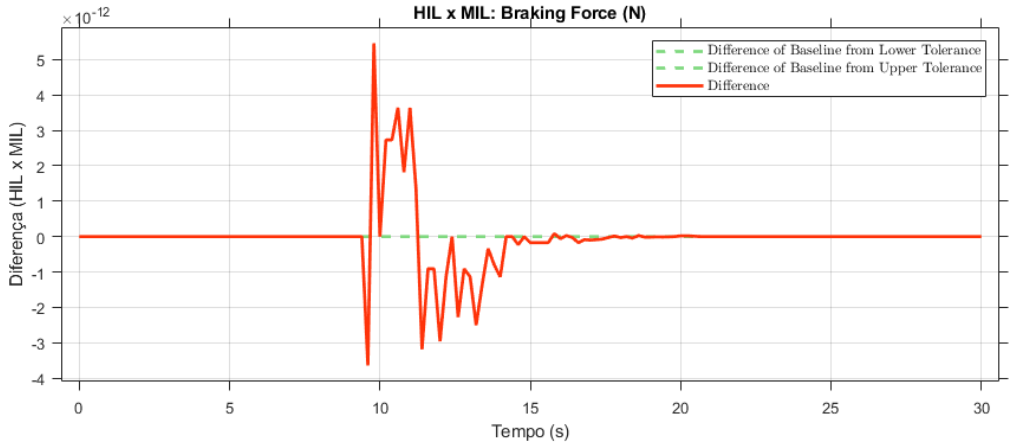


Figura 23 – Diferença MIL × HIL: Força de frenagem — 30 km/h

A figura 24 apresenta a variação temporal da força de frenagem no HIL. Os valores permanecem dentro do envelope de ± 2.017 N/s, com perfil temporal indistinguível do resultado MIL. Observam-se picos apenas nos instantes de ativação e de transição entre regimes, sem qualquer saturação da restrição de taxa. Durante a frenagem sustentada, a variação converge para valores próximos de zero, indicando aplicação progressiva de força.

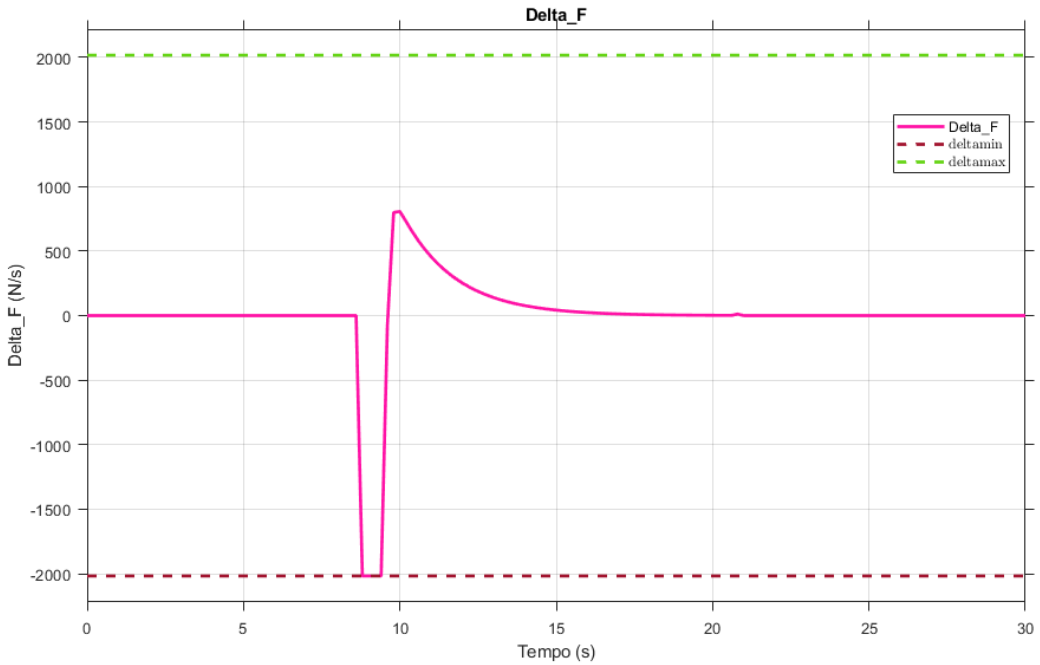


Figura 24 – Variação da força de frenagem aplicada no veículo de teste: HIL — 30 km/h

A figura 25 confirma a convergência, com erro residual na ordem de 10^{-12} N/s. Essa concordância valida o determinismo temporal da plataforma Speedgoat Baseline: o sistema processa o otimizador MPC, calcula as correções de força e aplica os comandos dentro do período de amostragem de 0,2 s, sem degradação de desempenho dinâmico. Nota-se que as maiores discrepâncias concentram-se apenas nos instantes de transição da frenagem, quando a taxa de variação de força muda de sinal e pequenas diferenças de arredondamento se propagam para ΔF_x. Fora desses trechos transitórios, o erro permanece praticamente nulo e sem tendência acumulativa, reforçando a equivalência dinâmica entre MIL e HIL.

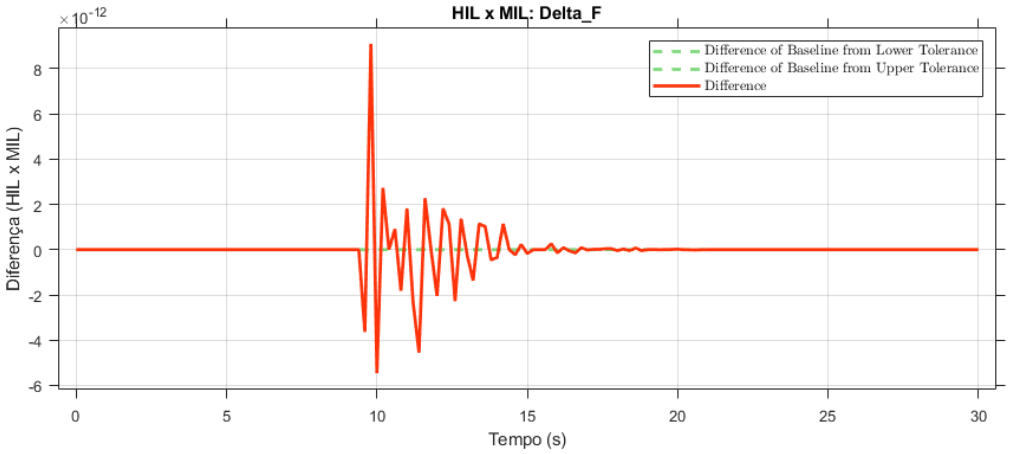


Figura 25 – Diferença MIL × HIL: Variação da força de frenagem — 30 km/h

A figura 26 apresenta o perfil de desaceleração no ambiente HIL. O pico de 3,7 m/s^2 é idêntico ao obtido no MIL, representando 47,2% do limite de aderência (7,848 m/s^2). A suavidade da curva confirma que as restrições de força e de taxa de variação são respeitadas adequadamente pelo *solver* QP no ambiente embarcado, resultando em uma frenagem progressiva e sem transições abruptas. Observa-se ainda uma rampa inicial de desaceleração após a ativação do AEBS, coerente com a limitação de ΔF_x e com a ausência de comandos instantâneos de frenagem. Na fase final, a desaceleração retorna gradualmente a zero com a aproximação da parada, sem oscilações residuais relevantes.

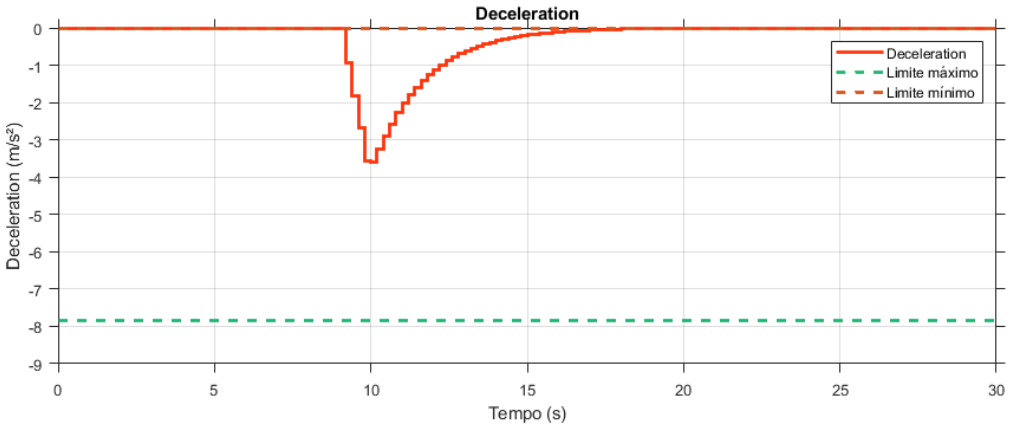


Figura 26 – Desaceleração do veículo de teste: HIL — 30 km/h

A figura 27 apresenta a diferença numérica de desaceleração entre os ambientes. O erro residual de 10^{-15} m/s^2 é tecnicamente nulo, evidenciando a ausência de efeitos de latência, quantização ou arredondamento que pudessem comprometer a fidelidade da resposta de frenagem. Nota-se que as pequenas variações remanescentes aparecem apenas nas transições de regime e não apresentam tendência acumulativa ao longo do tempo.

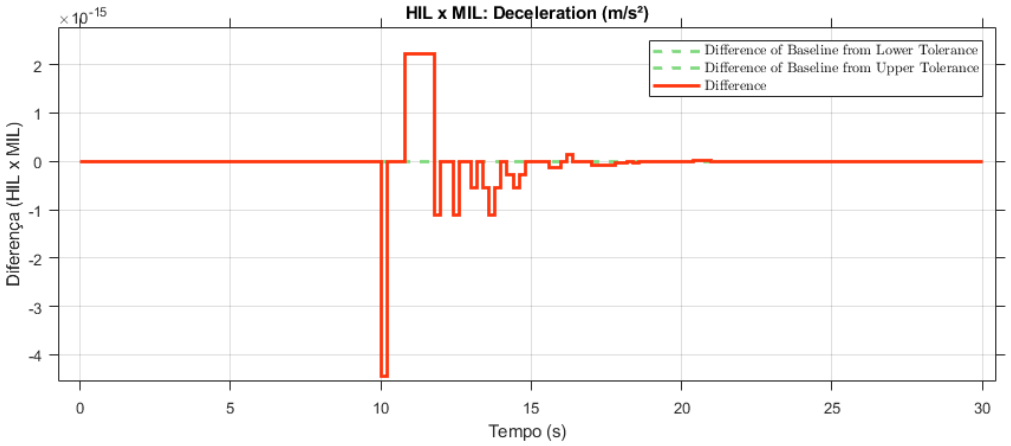


Figura 27 – Diferença MIL × HIL: Desaceleração — 30 km/h

A figura 28 apresenta o perfil de *jerk* no HIL. O sistema controla a evolução da desaceleração de maneira progressiva, com a taxa de variação permanecendo dentro da faixa observada no MIL ($-4{,}5/+1{,}9$ m/s^3). A formulação explícita de restrições sobre δF_x no problema de otimização traduz-se diretamente na limitação do *jerk*, garantindo conforto dos ocupantes durante a intervenção.

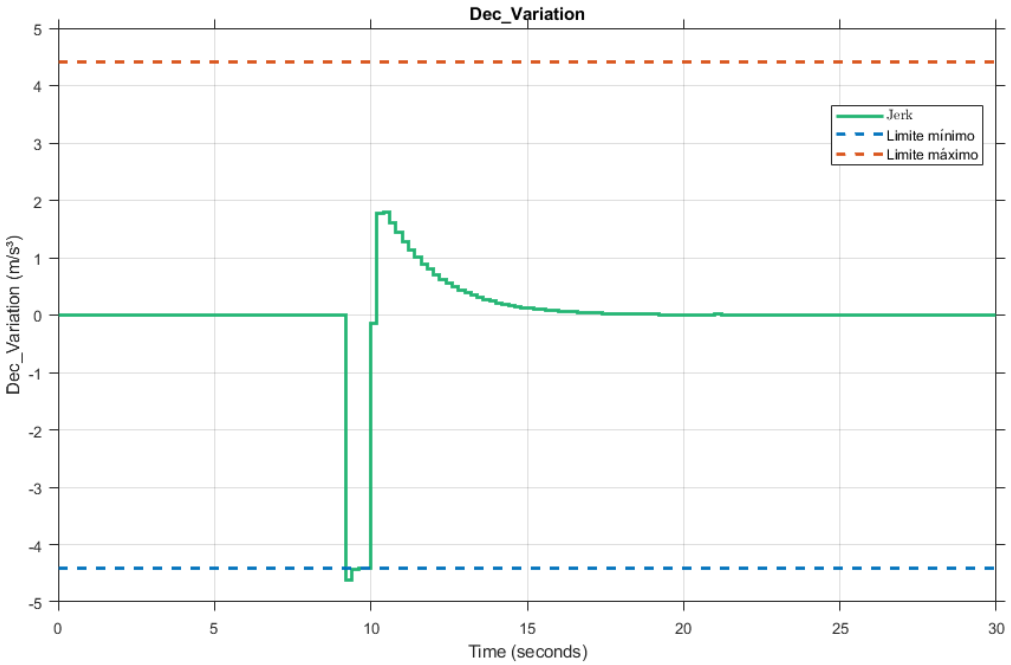


Figura 28 – Variação da desaceleração do veículo de teste: HIL — 30 km/h

A figura 29 quantifica a diferença MIL–HIL para o *jerk*. O erro residual de 10^{-14} m/s^3 confirma a consistência dinâmica da implementação em tempo real. A baixa discrepância descarta efeitos expressivos de *jitter* do escalonador RTOS , latência de comunicação ou arredondamento numérico capazes de degradar a qualidade da resposta temporal de frenagem.

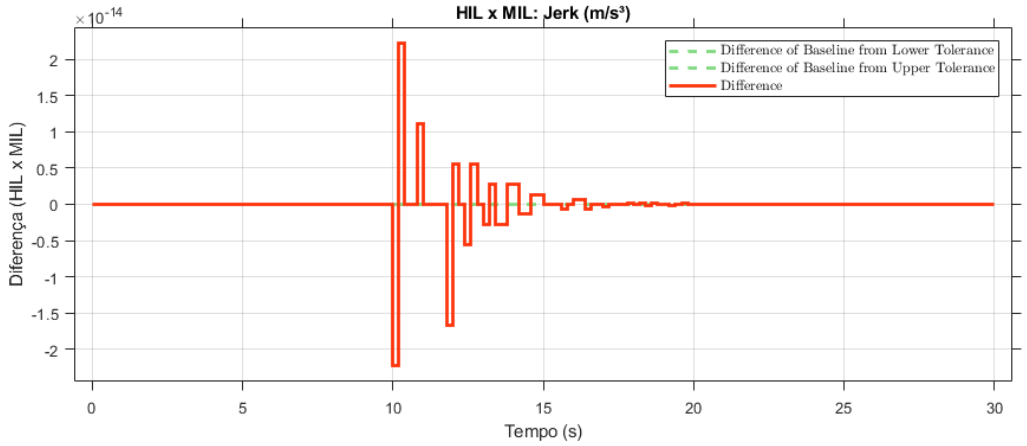


Figura 29 – Diferença MIL × HIL: Variação da desaceleração — 30 km/h

A figura 30 apresenta a trajetória de posição do veículo no HIL. O veículo percorre 92,80 m até a parada completa, valor idêntico ao MIL, mantendo uma margem de segurança de 7,20 m em relação ao obstáculo. Esse resultado confirma que a estratégia de controle MPC, quando transposta para o ambiente embarcado, preserva integralmente sua capacidade de evitar a colisão.

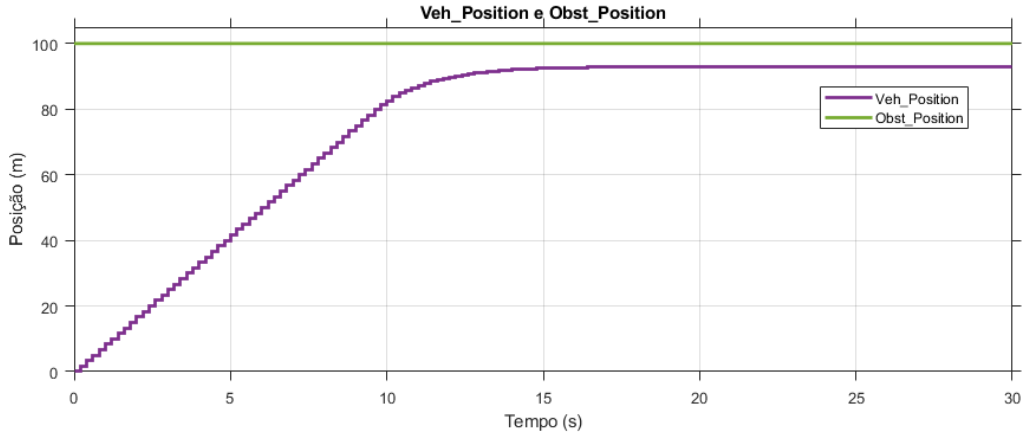


Figura 30 – Distância percorrida pelo veículo de teste: HIL — 30 km/h

A figura 31 apresenta a diferença numérica da distância percorrida entre os ciclos MIL e HIL. O erro residual é da ordem de 10^{-14} m, confirmando a convergência total entre os ambientes. Essa concordância assegura que a lógica de segurança desenvolvida no ambiente de simulação é transposta para a ECU sem perdas de desempenho, garantindo o determinismo necessário para a mitigação de colisões traseiras em aplicações embarcadas.

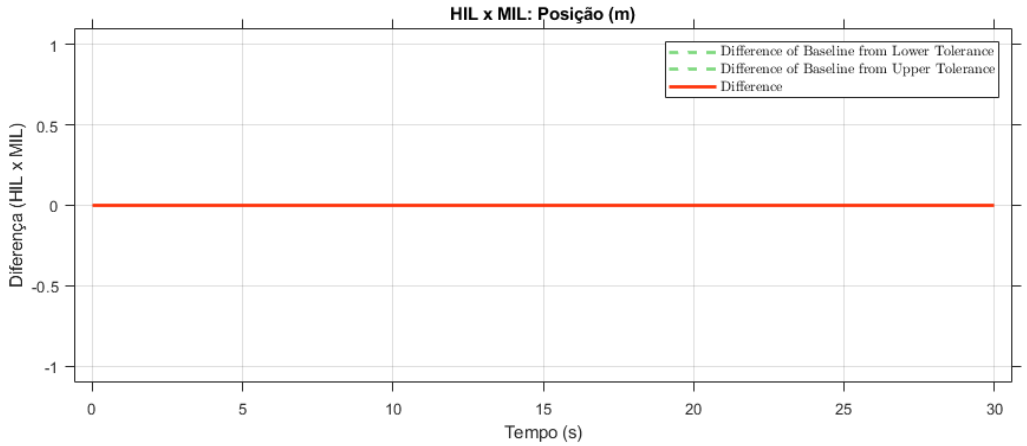


Figura 31 – Diferença MIL × HIL: Distância percorrida — 30 km/h

A tabela 15 consolida os erros residuais MIL–HIL para todas as variáveis avaliadas no cenário de 30 km/h. Todos os erros residuais situam-se na ordem de 10^{-12} a 10^{-15}, valores muito próximos ao ϵ de máquina ($2{,}2 \times 10^{-16}$), confirmando que as diferenças observadas decorrem de efeitos de arredondamento numérico, e não de divergências algorítmicas, latências computacionais ou erros de implementação. A convergência total MIL–HIL constitui evidência robusta de que a cadeia de desenvolvimento adotada — Simulink Coder → compilação cruzada → *target* Speedgoat — é adequada para a prototipagem de controladores MPC destinados a aplicações automotivas de segurança ativa.

Variável	**Ordem do erro residual**	**Unidade**
Velocidade	10^{-15}	km/h
Força de frenagem	10^{-12}	N
Variação da força	10^{-12}	N/s
Desaceleração	10^{-15}	m/s^2
Jerk	10^{-14}	m/s^3
Distância percorrida	10^{-14}	m

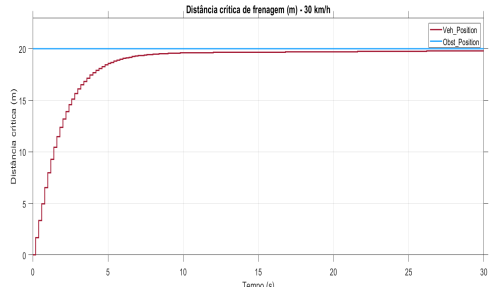
Tabela 15 – Síntese dos erros residuais MIL × HIL — cenário de 30 km/h

6.6 Distância crítica de frenagem - *Worst Case Scenario*

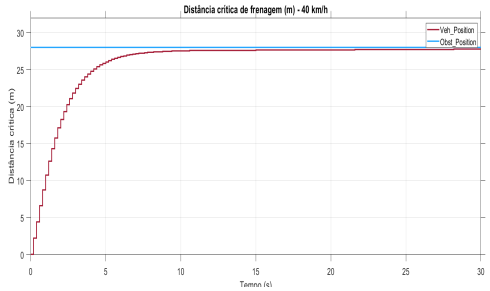
A análise apresentada na Seção 6.4 adota a configuração nominal do procedimento de teste, ou seja, verifica a distância percorrida pelo veículo de teste até a parada sem colidir com o obstáculo estático posicionado a 100 m. Embora essa abordagem seja adequada para verificar a eficácia do controlador na prevenção da colisão, ela não permite identificar seu limite operacional. Assim, para preencher essa lacuna, esta seção investiga a distância crítica de frenagem, definida como a distância inicial mínima entre o veículo e o obstáculo para a qual o controlador ainda assegura a parada completa sem colisão.

Do ponto de vista físico, a distância crítica de frenagem representa o pior caso admissível para cada velocidade de aproximação, delimitando a fronteira entre o domínio da prevenção, no qual o impacto é evitado, e o domínio da mitigação, no qual há apenas redução da velocidade de impacto. Do ponto de vista normativo, essa distância está diretamente relacionada à janela temporal mínima exigida pela regulamentação 152 das Nações Unidas, que estabelece as provisões uniformes para sistemas AEBS em veículos (UNITED NATIONS ECONOMIC COMMISSION FOR EUROPE, 2023).

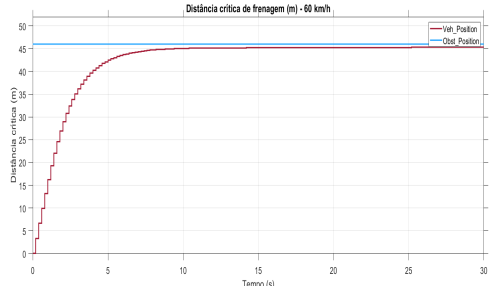
O procedimento consistiu em reduzir progressivamente a distância inicial do obstáculo ao veículo, mantendo-se todas as outras condições idênticas de características do controlador, pista e veículo, até identificar, para cada velocidade inicial, a distância mínima na qual o veículo de teste atinge a parada completa com margem residual praticamente nula. Os gráficos da figura 32 mostram os resultados obtidos.



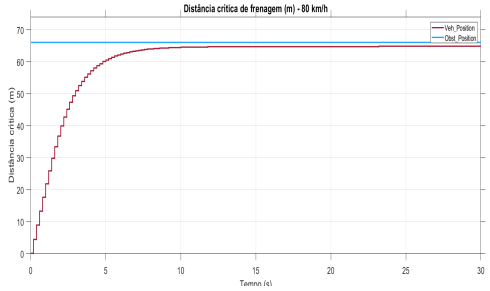
(a) 30 km/h



(b) 40 km/h



(c) 60 km/h



(d) 80 km/h

Figura 32 – Distância crítica de frenagem

Em todos os quatro cenários, conforme mostra a figura 32, a curva de posição do veículo de teste aproxima-se assintoticamente da reta que representa o obstáculo sem cruzá-la, confirmando que o controlador MPC evita o impacto mesmo nas distâncias críticas identificadas. A estabilização da curva vermelha imediatamente abaixo da curva azul, mantida ao longo de todo o intervalo de 30s simulado, evidencia que a parada é definitiva e que não há reaproximação residual.

Os resultados indicam que a distância crítica cresce de forma não linear com a velocidade inicial. Quando a velocidade aumenta de 30 para 80 km/h, o que corresponde a um acréscimo de aproximadamente 167%, a distância crítica passa de 20 para 66 m, representando um aumento de 230%. Esse comportamento é coerente com a física da frenagem, na qual a

distância necessária para dissipar a energia cinética varia com o quadrado da velocidade.

Observa-se ainda que a margem de segurança residual, embora reduzida em todos os casos por se tratar precisamente da condição-limite, cresce com a velocidade inicial. Esse resultado decorre da lógica de ativação baseada em TTC. Em velocidades mais elevadas, o limiar de TTC de três segundos é alcançado a distâncias absolutas maiores, conferindo ao controlador uma janela espacial proporcionalmente mais ampla para a aplicação progressiva da frenagem. Em contraste, a 30 km/h, a baixa velocidade relativa faz com que o sistema seja acionado a uma distância absoluta pequena, comprimindo a margem disponível para a otimização da trajetória.

A Tabela 16 consolida, para cada velocidade inicial, a distância crítica de frenagem (posição do obstáculo), a posição final do veículo de teste e a margem de segurança residual resultante. Os valores foram extraídos diretamente dos gráficos da figura 32.

Velocidade inicial v_0 (km/h)	**Distância crítica ao obstáculo (m)**	**Posição final do veículo (m)**	**Margem de segurança (m)**
30	20,0	19,8	0,2
40	28,0	27,7	0,3
60	46,0	45,3	0,7
80	66,0	64,7	1,3

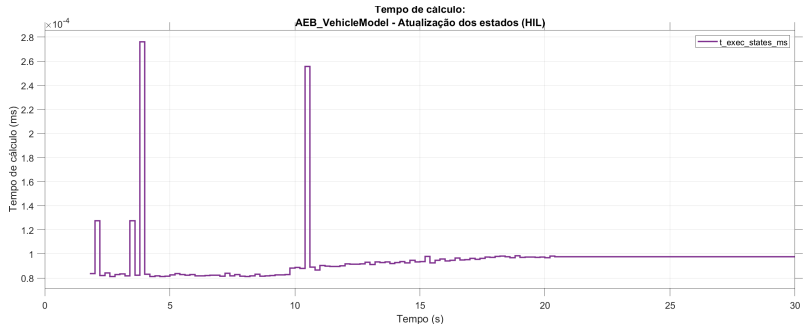
Tabela 16 – Distância crítica de frenagem, posição final do veículo e margem de segurança residual nos cenários avaliados.

É essencial situar esses valores no contexto normativo. A Regulamentação n.º 152 das Nações Unidas não especifica uma "distância mínima" até o obstáculo como critério de aprovação. Em vez disso, ela define a velocidade de aproximação e o resultado esperado — evitar ou mitigar a colisão —, estabelecendo que o ensaio seja iniciado a uma distância correspondente a um TTC de pelo menos 4 s.

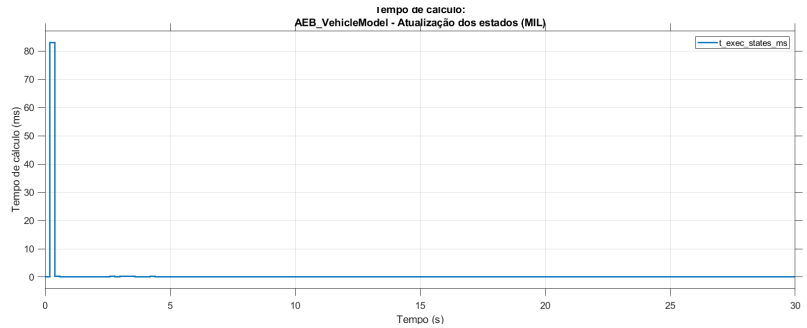
6.7 Análise Comparativa do Desempenho Computacional: QP *Solver* e Modelo de Estados — MIL vs. HIL

A figura 33 apresenta a comparação do tempo de execução do bloco responsável pela propagação dos estados do veículo (`AEB_VehicleModelDiscrete`). A discretização é realizada por meio do retentor de ordem zero (ZOH), utilizando a exponencial matricial $e^{A \cdot T_s}$ para obtenção das matrizes discretizadas A_d e B_d a partir do modelo contínuo do veículo.

Conforme a figura 33a, no HIL o tempo de cálculo desse bloco permanece na ordem de 10^{-5} ms, com valores típicos entre $0{,}8 \times 10^{-5}$ ms e $1{,}0 \times 10^{-5}$ ms e picos de até $2{,}8 \times 10^{-5}$ ms. Os picos ocorrem na ativação do controlador e nas transições do AEBS, associados à inicialização



(a) Tempo de execução: Atualização dos estados — HIL



(b) Tempo de execução: Atualização dos estados — MIL

Figura 33 – Tempo de execução: Atualização dos estados — HIL × MIL

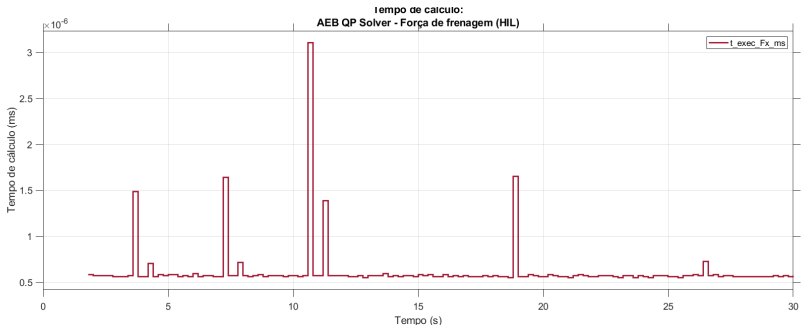
interna e ao cálculo da exponencial matricial no primeiro ciclo de cada fase. Nos ciclos seguintes, com A_d e B_d já armazenadas em memória estática, o custo computacional se reduz à operação de multiplicação matricial $\mathbf{x}_{k+1} = A_d.\mathbf{x}_k + B_d.\mathbf{u}_k$, estabilizando o tempo em patamares bem inferiores aos picos transitórios.

Em contraste, a figura 33b mostra que, no MIL, esse bloco opera em dezenas de milissegundos, com pico inicial de aproximadamente 80 ms e posterior redução para a faixa de 5 a 10 ms. A diferença de aproximadamente três ordens de grandeza em relação ao HIL decorre da natureza dos ambientes: no *target* Speedgoat, o código é compilado em C com otimizações estáticas e executado em RTOS determinístico; no MATLAB/Simulink, a execução interpretada incorpora *overhead* de simulação, compilação JIT (*just-in-time*), gestão dinâmica de memória, verificação de tipos e instrumentação para depuração.

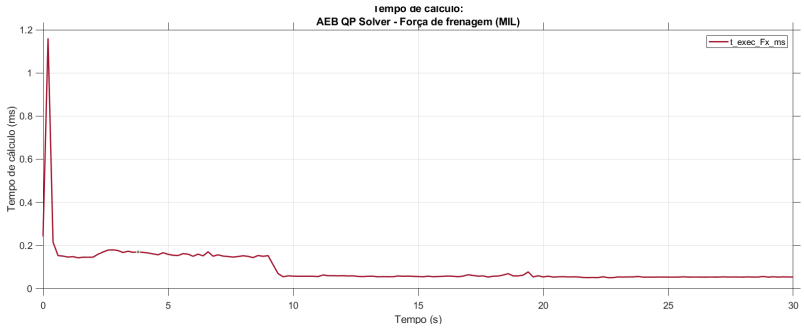
O pico inicial elevado no MIL é consistente com o fenômeno de *cold start* do interpretador MATLAB, no qual a primeira execução de uma *MATLAB Function block* envolve a compilação JIT, a alocação de memória e a construção do grafo de dependências — custos de inicialização amortizados nos ciclos subsequentes. No ambiente HIL, esse efeito é inexistente, uma vez que o código já se encontra integralmente compilado e alocado estaticamente antes do início da execução.

A figura 34 apresenta a análise correspondente para o bloco responsável pelo cálculo da força de frenagem ótima (`AEB_QPSolver_FirstAction`). A frenagem é obtida por meio da resolução do problema QP com horizonte de predição $N = 20$ passos, utilizando o *solver*

de conjunto ativo (`mpcActiveSetSolver`).



(a) Tempo de execução: Força de frenagem — HIL



(b) Tempo de execução: Força de frenagem — MIL

Figura 34 – Tempo de execução: Força de frenagem — HIL × MIL

Conforme a figura 34a, no HIL o *solver* QP opera na ordem de 10^{-4} ms, com picos de até $3{,}5\times10^{-4}$ ms nos instantes de ativação do controlador e nas transições de frenagem. Esses picos decorrem da reconstrução do conjunto de restrições ativas do QP: na passagem de cruzeiro (força nula) para frenagem de emergência, a mudança no ponto de operação altera o conjunto ativo, exigindo mais iterações do método de conjunto ativo para convergência.

Após a fase transitória, o tempo estabiliza entre $1{,}0\times10^{-4}$ ms e $1{,}5\times10^{-4}$ ms durante o regime de frenagem sustentada, refletindo o mecanismo de *warm start* implícito do *solver*, que reutiliza a solução do ciclo anterior como ponto de partida. No regime pós-parada, quando a lógica de supervisão detecta a condição de sucesso do AEBS, o *solver* deixa de ser invocado e o tempo cai para valores próximos de zero.

A figura 34b mostra que, no MIL, o *solver* QP executa entre 0,1 ms e 0,8 ms, com pico inicial e decaimento progressivo. O decaimento resulta da combinação do *warm start* com a redução da complexidade efetiva do subproblema QP à medida que o veículo se aproxima da parada (menor número de restrições ativas). Assim como na figura 33b, o pico inicial reflete o custo de *cold start* do MATLAB, mais pronunciado pela maior complexidade algorítmica do *solver* QP.

A disparidade entre os tempos MIL e HIL, longe de representar uma limitação, evidencia a superioridade do ambiente de execução embarcado para aplicações de tempo real. Os tempos elevados no MIL não comprometem a validade dos resultados da simulação, uma vez

que o ambiente MIL opera em tempo simulado: o motor de simulação do Simulink aguarda a conclusão de cada passo de cálculo antes de avançar o relógio de simulação, garantindo a correção numérica independentemente da duração da execução. Contudo, essa observação reforça a importância fundamental da etapa HIL para verificação do cumprimento dos requisitos temporais, que não pode ser inferida a partir do MIL.

A tabela 17 sintetiza o desempenho computacional dos blocos funcionais do controlador MPC. Em HIL, o bloco de maior custo computacional (`AEB_VehicleModel`) apresenta tempo máximo de 0,0271 ms, correspondendo a 0,014% do período de amostragem de 200 ms. O *solver* QP, embora seja o gargalo algorítmico, opera com tempo máximo de 0,0006 ms, representando 0,0003% de T_s.

Bloco funcional	**Ambiente**	**Tempo médio (ms)**	**Tempo máximo (ms)**	**Margem (%)**
`AEB_QPSolver`	MIL	0,0955	0,8538	—
	HIL	0,0005	0,0006	> 99,99
`AEB_VehicleModel`	MIL	0,7172	94,7235	—
	HIL	0,0200	0,0271	> 99,98

Tabela 17 – Tempos de execução dos blocos funcionais do controlador MPC — MIL vs. HIL

A margem temporal combinada dos dois blocos é superior a 99,98%, confirmando que o sistema atende com folga aos requisitos de determinismo temporal exigidos para aplicações automotivas de segurança ativa. Essa margem ampla indica, adicionalmente, que a arquitetura proposta possui capacidade computacional excedente para incorporar, em desenvolvimentos futuros, blocos adicionais, como estimadores de estado e algoritmos de fusão sensorial, sem comprometer o cumprimento do período de amostragem.

A cadeia Simulink Coder → compilação cruzada → *target* embarcado demonstra-se, portanto, uma abordagem eficaz para a prototipagem rápida de controladores MPC em aplicações automotivas. A convergência total MIL–HIL, aliada às margens temporais observadas, confirma a viabilidade técnica da arquitetura proposta para futura implementação em ECU veicular.

7 Conclusão

Esta dissertação apresentou o desenvolvimento, a implementação e a validação de um Sistema Autônomo de Frenagem de Emergência (AEBS) para veículos de passeio, fundamentado na integração entre Controle Preditivo Baseado em Modelo (MPC), modelo bicicleta para a dinâmica lateral e modelagem longitudinal do veículo. O objetivo central — mitigar colisões traseiras em cenários de aproximação crítica a obstáculos estáticos — foi plenamente atingido em todos os cenários avaliados, em consonância com as diretrizes de segurança viária do Plano Nacional de Redução de Mortes e Lesões no Trânsito (PNATRANS) e com protocolos internacionais de avaliação de segurança ativa, como o Euro NCAP.

A modelagem matemática da dinâmica veicular adotou o modelo bicicleta combinado à equação do movimento longitudinal, resultando em um sistema de três estados — velocidade longitudinal (u), velocidade lateral (v) e taxa de guinada (r) — com a força de frenagem (F_x) como variável de controle. Embora o estudo atual não contemple manobras evasivas laterais, a opção por essa formulação confere ao sistema um arcabouço modular e escalável, apto a incorporar, em desenvolvimentos futuros, o controle de esterçamento automático sem necessidade de reformulação estrutural do controlador.

A linearização de primeira ordem (Taylor) do modelo não linear em torno do cruzeiro retilíneo ($v_0 \approx 0, r_0 \approx 0$) permitiu formular o problema como Programação Quadrática (QP), com resolução eficiente e determinismo temporal. A discretização por retenção de ordem zero (ZOH), via exponencial matricial $e^{A_{lin} \cdot T_s}$, gerou A_d e B_d com $T_s = 0{,}2$ s. O QP foi resolvido pelo *solver* de conjunto ativo (`mpcActiveSetSolver`), com horizonte $N = n_u = 20$ e restrições explícitas de força de frenagem ($|F_x| \leq 19\,137$ N), taxa de variação ($|\delta F_x| \leq 2\,017$ N/s), desaceleração máxima ($a_{max} = \mu g = 7{,}848$ m/s^2, $\mu = 0{,}8$) e *jerk* ($\pm 4{,}4145$ m/s^3, equivalente a $0{,}45g$).

A arquitetura proposta evidenciou que a combinação entre otimização em tempo real e métricas de risco permite intervenções eficazes de frenagem com preservação da estabilidade direcional. A lógica de ativação, que aciona o MPC quando $TTMV \geq TTC$ ou $TTC \leq 3$ s, mostrou-se adequada para distinguir situações seguras daquelas que demandam intervenção autônoma, evitando atuações desnecessárias e favorecendo a aceitação pelo condutor. Para sistemas AEBS, o MPC mostrou-se mais adequado por incorporar restrições físicas e operacionais de forma explícita no horizonte de predição, antecipando a dinâmica do veículo e otimizando simultaneamente segurança e conforto.

No conjunto de testes em MATLAB/Simulink (MIL), com obstáculo estático a 100 m, o controlador foi avaliado para 30, 40, 60 e 80 km/h, cobrindo faixas urbanas e rodoviárias do CTB (Art. 61) e do protocolo Euro NCAP. Em todos os cenários houve parada completa sem

colisão, com tempos de frenagem de 14,6s a 18,0s, início da frenagem entre 8,8s (30 km/h) e 1,4s (80 km/h), força máxima de 18 153 N (abaixo do limite de 19 137 N) e margem final de segurança de 4,23 m (pior caso, 80 km/h) a 8,14 m (60 km/h).

Em termos de conforto, o *jerk* permaneceu próximo ao limite de projeto de 4,4145 m/s^3, com violações pontuais nos picos de transição, e a desaceleração manteve-se dentro do limite de 7,848 m/s^2 nos cenários de 30 a 60 km/h; no caso crítico de 80 km/h, observou-se pico de 8,1 m/s^2, excedendo pontualmente o limite, o que caracteriza o *trade-off* da otimização QP, na qual o *solver* relaxa temporariamente a restrição de conforto para preservar a distância de segurança e as demais restrições, conforme previsto na teoria de MPC com restrições competitivas.

A validação em *Hardware-in-the-Loop* (HIL), conduzida na plataforma Speedgoat Baseline para o cenário de 30 km/h, confirmou a viabilidade da implementação embarcada do controlador. A comunicação entre o *target* e o computador *host* foi realizada via protocolo Ethernet, e o modelo do veículo e o controlador MPC foram executados integralmente no hardware de tempo real.

Os resultados demonstraram convergência total entre os ambientes MIL e HIL, com erros residuais da ordem de 10^{-15} km/h para a velocidade, 10^{-12} N para a força de frenagem, 10^{-15} m/s^2 para a desaceleração, 10^{-14} m/s^3 para o *jerk* e 10^{-14} m para a distância percorrida. Esses valores são numericamente desprezíveis e confirmam que o processo de discretização, a geração automática de código (Simulink Coder) e a compilação cruzada para o *target* embarcado foram realizados sem introdução de erros significativos de quantização, arredondamento ou latência.

A análise comparativa do desempenho computacional mostrou que, em HIL, o bloco de atualização de estados opera com tempo médio de 0,0200 ms e pico de 0,0271 ms, enquanto o *solver* QP (`mpcActiveSetSolver`) apresenta média de 0,0005 ms e pico de 0,0006 ms. Em MIL, os picos sobem para 94,72 ms no bloco de estados e 0,85 ms no QP, diferença de cerca de três ordens de grandeza atribuída ao *overhead* do ambiente interpretado (compilação JIT, gestão de memória e verificação de tipos).

Essa disparidade confirma a superioridade do ambiente embarcado para tempo real: em HIL, os blocos críticos mantêm margem temporal superior a 99,8% frente ao período de amostragem de 200 ms, atendendo aos requisitos de determinismo de uma ECU. No MIL, o pico inicial elevado é coerente com o *cold start* do MATLAB, e o decaimento progressivo dos tempos de execução do *solver* é explicado pelo *warm start*, que reutiliza a solução do ciclo anterior e reduz as iterações de convergência.

As principais contribuições deste trabalho podem ser sintetizadas em quatro pontos:

(i) **Arquitetura AEBS orientada a risco:** definição de uma lógica de decisão estruturada com base nas métricas TTC e TTMV, capaz de discriminar situações seguras de

situações que demandam intervenção autônoma;

(ii) **Controlador MPC com restrições explícitas:** formulação e implementação de um controlador preditivo linearizado que incorpora restrições de segurança e conforto — força de frenagem, desaceleração, *jerk* e envelopes de velocidade — diretamente no problema de otimização quadrática;

(iii) **Modelagem dinâmica modular:** integração dos modelos longitudinal e lateral (modelo bicicleta) em um arcabouço de espaço de estados que permite análise dinâmica consistente e extensibilidade para futuras manobras evasivas;

(iv) **Validação em dois níveis de fidelidade:** avaliação do sistema por meio de simulações MIL com métricas abrangentes de segurança, desempenho e conforto, seguida de validação HIL em plataforma Speedgoat que confirmou convergência total dos resultados e viabilidade da implementação embarcada.

Em síntese, os resultados confirmam que a arquitetura AEBS proposta, baseada em MPC linearizado com restrições explícitas e lógica de ativação por métricas de risco, é tecnicamente viável para segurança ativa veicular. A convergência total entre MIL e HIL, aliada à ampla margem temporal computacional na plataforma embarcada, demonstra que a cadeia de desenvolvimento é eficaz e reprodutível para a prototipagem rápida de controladores automotivos. A continuidade da pesquisa, com maior aproximação das condições reais de operação, pode contribuir para o avanço da segurança viária no Brasil, em alinhamento com os eixos estratégicos do PNATRANS e com os protocolos internacionais, como o Euro NCAP.

Apesar dos resultados positivos, reconhecem-se limitações que delimitam o escopo de validade das conclusões apresentadas. O modelo de contato pneu–pavimento adota coeficiente de aderência constante ($\mu = 0{,}8$), não contemplando as não linearidades inerentes ao comportamento real do pneu, que poderiam ser representadas, por exemplo, pela *Magic Formula* de Pacejka. Os ensaios foram restritos ao cenário com obstáculo estático, não incorporando cenários com alvos móveis ou em desaceleração. Além disso, não foram avaliadas variações de inclinação da via, fator que pode alterar a demanda de frenagem e a margem de segurança disponível.

A camada de percepção foi idealizada, sem considerar degradação sensorial, oclusões, ruído de medição ou latências de comunicação entre sensores e atuadores. Além disso, o modelo não contempla incertezas paramétricas em tempo real, como variações de massa, distribuição de carga e condições de superfície, nem a variabilidade do comportamento do condutor. A validação HIL foi conduzida para o cenário de 30 km/h; embora a convergência total MIL–HIL obtida forneça forte evidência de que os demais cenários também seriam reproduzidos com a mesma fidelidade, a extensão experimental para todas as velocidades é recomendável para consolidação definitiva dos resultados.

Como trabalhos futuros, propõem-se as seguintes linhas de desenvolvimento:

(i) **Ampliação dos cenários de teste:** inclusão dos cenários do protocolo Euro NCAP com alvos móveis, múltiplos agentes e variação das condições iniciais, de modo a avaliar a robustez do controlador em situações mais representativas do tráfego real;

(ii) **Estimação de estados e parâmetros:** incorporação de observadores de estado, como o Filtro de Kalman Estendido, para estimação em tempo real de variáveis não diretamente mensuráveis e de parâmetros variantes, aumentando a robustez a incertezas;

(iii) **Controle robusto e adaptativo:** avaliação de formulações de MPC robusto (*Nonlinear MPC*, MPC estocástico) ou adaptativo, capazes de lidar com incertezas paramétricas e variações nas condições de operação;

(iv) **Modelos de aderência variável:** substituição do coeficiente μ constante por modelos não lineares de interação pneu–pavimento, como a *Magic Formula* de Pacejka, permitindo representação mais fiel das condições de aderência em cenários de pista molhada, degradada ou heterogênea;

(v) **Integração de camada de percepção realista:** inclusão de modelos de sensores com ruído, latência e campo de visão limitado, bem como algoritmos de fusão sensorial, para aproximar o sistema das condições operacionais de um veículo instrumentado;

(vi) **Extensão para controle lateral:** aproveitamento da escalabilidade do modelo bicicleta para incorporação de manobras evasivas coordenadas de esterçamento, com ativação do ângulo de esterçamento δ_f como segunda variável de controle;

(vii) **Validação experimental progressiva:** realização de testes em ambientes SIL /HIL avançados com modelos de planta de maior fidelidade, seguida de testes controlados com veículo real instrumentado em pista de testes.

Referências

[1] M. Akkari. *Alerta: após anos em queda, mortes no trânsito voltam a crescer no Brasil*. Disponível em: https://saude.abril.com.br/coluna/com-a-palavra/alerta-apos-anos-em-queda-mortes-no-transito-voltam-a-crescer-no-brasil/. Acesso em: 2 mar. 2026. Veja Saúde, fev. de 2026. URL: https://saude.abril.com.br/coluna/com-a-palavra/alerta-apos-anos-em-queda-mortes-no-transito-voltam-a-crescer-no-brasil/ (acesso em 2 de mar. de 2026) (ver p. 20).

[2] X. Xiaoxia, W. Meng, C. Yingfeng, C. Long, F. Haneen e H. Marjan. "A forward collision avoidance algorithm based on driver braking behavior". Em: *Accident Analysis & Prevention* 129 (2019), pp. 30–43. ISSN: 0001-4575. DOI: 10.1016/j.aap.2019.05.004. URL: https://www.sciencedirect.com/science/article/pii/S0001457519300703 (ver pp. 20, 54, 55, 68).

[3] D. Sam, C. Velanganni e T. E. Evangelin. "A vehicle control system using a time synchronized Hybrid VANET to reduce road accidents caused by human error". Em: *Vehicular Communications* 6 (2016), pp. 17–28. ISSN: 2214-2096. DOI: 10.1016/j.vehcom.2016.11.001. URL: https://www.sciencedirect.com/science/article/pii/S2214209615300139 (ver pp. 20, 27, 55).

[4] G. Federal. *Lei nº 13.614, de 11 de janeiro de 2018*. Planalto.gov.br, jan. de 2018. URL: http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/L13614.htm (acesso em 9 de nov. de 2021) (ver p. 20).

[5] M. D. Infraestrutura. *Plano Nacional De Redução De Mortes E Lesões No Trânsito (PNATRANS)*. Ministério Da Infraestrutura, set. de 2021. URL: https://www.gov.br/infraestrutura/pt-br/assuntos/transito/conteudo-denatran/plano-nacional-de-reducao-de-mortes-e-lesoes-no-transito-pnatrans (acesso em 9 de nov. de 2021) (ver p. 20).

[6] C.-N. Boda, E. Lehtonen e M. Dozza. "A Computational Driver Model to Predict Driver Control at Unsignalised Intersections". Em: *IEEE Access* 8 (2020), pp. 104619–104631. DOI: 10.1109/ACCESS.2020.2999851 (ver pp. 20, 27, 57).

[7] F. Jiménez. "Chapter 1 - Introduction". Em: *Intelligent Vehicles*. Ed. por F. Jiménez. Butterworth-Heinemann, 2018, pp. 1–20. ISBN: 978-0-12-812800-8. DOI: 10.1016/B978-0-12-812800-8.00001-1. URL: https://www.sciencedirect.com/science/article/pii/B9780128128008000011 (ver pp. 23, 25, 26, 38, 52, 55).

[8] M. M. Antony e R. Whenish. “Advanced Driver Assistance Systems (ADAS)”. Em: *Automotive Embedded Systems: Key Technologies, Innovations, and Applications*. Ed. por M. Kathiresh e R. Neelaveni. EAI/Springer Innovations in Communication and Computing. Cham, Switzerland: Springer Cham, 2021, pp. 213–232. ISBN: 978-3-030-59897-6. DOI: 10.1007/978-3-030-59897-6_9. URL: https://doi.org/10.1007/978-3-030-59897-6_9 (ver pp. 23–25).

[9] R. Niranjana. *Beginner’s ADAS Guide: Advanced Driver Assistance System 2023*. Logic Fruit Technologies, jun. de 2024. URL: https://www.logic-fruit.com/blog/fpga/adas-advanced-driver-assistance-system/ (acesso em 23 de ago. de 2024) (ver pp. 23–26).

[10] SAE International. *Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles*. en. Standard J3016. Documento técnico que estabelece uma taxonomia e definições para sistemas de automação de direção em veículos rodoviários. SAE International, abr. de 2021. URL: https://www.sae.org/standards/content/j3016_202104/ (ver pp. 23, 24).

[11] M. Aleksa, A. Schaub, I. Erdelean, S. Wittmann, A. Soteropoulos e A. Fürdös. “Impact analysis of Advanced Driver Assistance Systems (ADAS) regarding road safety – computing reduction potentials”. Em: *European Transport Research Review* 16.39 (2024), pp. 1–13. DOI: 10.1186/s12544-024-00654-0. URL: https://doi.org/10.1186/s12544-024-00654-0 (ver p. 26).

[12] W. Yang, J. Liu, K. Zhou, Z. Zhang e X. Qu. “An Automatic Emergency Braking Model considering Driver’s Intention Recognition of the Front Vehicle”. Em: *Journal of Advanced Transportation* 2020 (2020), p. 15. ISSN: 0197-6729. DOI: 10.1155/2020/5172305. URL: https://doi.org/10.1155/2020/5172305 (ver pp. 26, 28, 53, 55, 56, 68).

[13] L. Hyuck-Kee, S. Seong-Geun e K. Dong-Soo. “DESIGN OF EMERGENCY BRAKING ALGORITHM FOR PEDESTRIAN PROTECTION BASED ON MULTI-SENSOR FUSION”. Em: *International Journal of Automotive Technology* 18 (2017), pp. 1067–1076. ISSN: 1976-3832. DOI: 10.1007/s12239-017-0104-7 (ver pp. 26, 53, 56).

[14] P. R. R. Senapati, S. Das e P. B. Vora. “Intelligent Braking and Maneuvering System for an Automobile Application”. Em: *Symposium on International Automotive Technology 2017*. 2017, p. 8. DOI: 10.4271/2017-26-0080. URL: https://doi.org/10.4271/2017-26-0080 (ver pp. 27, 28).

[15] T. Alsuwian, R. B. Saeed e A. A. Amin. “Autonomous Vehicle with Emergency Braking Algorithm Based on Multi-Sensor Fusion and Super Twisting Speed Controller”. Em: *Applied Sciences* 12.17 (2022). ISSN: 2076-3417. DOI: 10.3390/app12178458. URL: https://www.mdpi.com/2076-3417/12/17/8458 (ver pp. 27, 28, 37, 52, 54, 55, 67).

[16] N. C. Basjaruddin, E. Rakhman e L. I. Lawinata. “DEVELOPING AN AUTOMATIC BRAKING SYSTEM BASED ON SENSOR FUSION”. Em: *ICIC Express Letters* 15 (2021), pp. 307–318. ISSN: 1881-803X. DOI: 10.24507/icicel.15.03.307 (ver pp. 27, 55, 56).

[17] J. Park, D. Kim e K. Huh. “Emergency Collision Avoidance by Steering in Critical Situations”. Em: *International Journal of Automotive Technology* 22 (2021), pp. 173–184. ISSN: 176-3832. DOI: 10.1007/s12239-021-0018-2. URL: https://doi.org/10.1007/s12239-021-0018-2 (ver pp. 27, 28, 38, 42, 56).

[18] D. Dong, H. Ye, W. Luo, J. Wen e D. Huang. “Collision Avoidance Path Planning and Tracking Control for Autonomous Vehicles Based on Model Predictive Control”. Em: *Sensors* 24.16 (2024). ISSN: 1424-8220. DOI: 10.3390/s24165211. URL: https://www.mdpi.com/1424-8220/24/16/5211 (ver pp. 27, 28, 30, 31, 38–40, 54–56, 61).

[19] T. LEE, K. YI, J. KIM e J. LEE. “Development and Evaluations of Advanced Emergency Braking System Algorithm for the Commercial Vehicle”. Em: *22nd International Technical Conference on the Enhanced Safety of Vehicles (ESV)*. Paper Number 11-0290. National Highway Traffic Safety Administration. Washington, D.C.: National Highway Traffic Safety Administration, 13–16 de jun. de 2011, p. 7. URL: http://www-esv.nhtsa.dot.gov/Proceedings/22/isv7/main.htm (ver p. 27).

[20] D. Katare e M. El-Sharkawy. “Collision warning system: embedded enabled (RTMaps with NXP BLBX2)”. Em: *2018 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*. 2018, pp. 1–6. DOI: 10.1109/ISSPIT.2018.8705101 (ver p. 27).

[21] V. Patil. “Generic and complete vehicle dynamic models for open-source platforms”. Supervisor: Dr. Ola Benderius, MSc. Pär Pettersson, MSc. Arpit Karsolia. Examiner: Prof. Dr. Bengt Jacobson. Master’s Thesis. SE-412 96 Gothenburg: Chalmers University of Technology, 2017 (ver pp. 28, 29, 32, 33, 58).

[22] W. Yang, X. Zhang, Q. Lei e X. Cheng. “Research on Longitudinal Active Collision Avoidance of Autonomous Emergency Braking Pedestrian System (AEB-P)”. Em: *Sensors* 19.21 (out. de 2019), p. 4671. ISSN: 1424-8220. DOI: 10.3390/s19214671. URL: https://doi.org/10.3390/s19214671 (ver pp. 28, 30, 31, 37, 54, 55).

[23] R. Zhang, K. Li, Z. He, H. Wang e F. You. “Advanced Emergency Braking Control Based on a Nonlinear Model Predictive Algorithm for Intelligent Vehicles”. Em: *Applied Sciences* 7 (mai. de 2017), p. 504. DOI: 10.3390/app7050504 (ver pp. 28, 37, 39, 42, 53, 55, 61).

[24] L. Zhang, Z. Yu, X. Xu e Y. Yan. “Research on Automatic Emergency Braking System Based on Target Recognition and Fusion Control Strategy in Curved Road”. Em:

Electronics 12.16 (2023). ISSN: 2079-9292. DOI: 10.3390/electronics12163490. URL: https://www.mdpi.com/2079-9292/12/16/3490 (ver pp. 28, 53–55).

[25] S. Cheng, L. Li, H.-Q. Guo, Z.-G. Chen e P. Song. "Longitudinal Collision Avoidance and Lateral Stability Adaptive Control System Based on MPC of Autonomous Vehicles". Em: *IEEE Transactions on Intelligent Transportation Systems* 21.6 (2020), pp. 2376–2385. DOI: 10.1109/TITS.2019.2918176 (ver pp. 28, 32, 33, 37, 42, 55, 65).

[26] R. Zhang, K. Li, Y. Wu, D. Zhao, Z. Lv, F. Li, X. Chen, Z. Qiu e F. Yu. "A Multi-Vehicle Longitudinal Trajectory Collision Avoidance Strategy Using AEBS With Vehicle-Infrastructure Communication". Em: *IEEE Transactions on Vehicular Technology* 71.2 (2022), pp. 1253–1266. DOI: 10.1109/TVT.2021.3132558 (ver pp. 28, 32, 38, 40, 56).

[27] J. G. Fernández. "A Vehicle Dynamics Model for Driving Simulators". Master's Thesis. SE-412 96 Göteborg: Chalmers University of Technology, 2012 (ver p. 29).

[28] M. Chen, X. Zhan, X. Zhang e W. Pan. "Localisation-based autonomous vehicle rear-end collision avoidance by emergency steering". Em: *IET Intelligent Transport Systems* 13.7 (2019), pp. 1078–1087. DOI: 10.1049/iet-its.2018.5348. URL: https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/iet-its.2018.5348 (ver pp. 29, 32).

[29] T. Ş. Ulsoy, H. Peng e M. Çakmakci. *Automotive Control Systems*. Cambridge: Cambridge University Press, 2012. ISBN: 978-1-107-00282-4 (ver pp. 30, 31, 34, 35).

[30] T. D. Gillespie. *Fundamentals of Vehicle Dynamics*. Society of Automotive Engineers, 1993 (ver p. 30).

[31] C. Guo, X. Wang, L. Su e Y. Wang. "Safety distance model for longitudinal collision avoidance of logistics vehicles considering slope and road adhesion coefficient". Em: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* (2020), pp. 1–15. ISSN: 0954-4070. DOI: 10.1177/0954407020959744 (ver pp. 31, 32, 68).

[32] Q. Zhao, H. Zheng, C. Kaku, F. Cheng e C. Zong. "Safety Spacing Control of Truck Platoon Based on Emergency Braking under Different Road Conditions". Em: *SAE International Journal of Vehicle Dynamics, Stability, and NVH* 7 (out. de 2022). DOI: 10.4271/10-07-01-0005 (ver pp. 31, 32, 38).

[33] P. R. G. Dutra, F. S. Gomes e R. F. N. Rodrigues. "Avaliação dinâmica de frenagem de um veículo envolvido num acidente considerando a atuação de um sistema de freio equipado com sistema de antibloqueio de freio - ABS". Em: *Anais do IV Simpósio Nacional de Ciências e Engenharias - SINACEN*. Vol. 5. 1. Anápolis: Centro Universitário de Anápolis - UniEVANGÉLICA, 2020, pp. 80–93. URL: http://anais.unievangelica.edu.br/index.php/SINACEN/ (ver pp. 32, 65).

[34] F. Lai e H. Yang. “Integrated Longitudinal and Lateral Control of Emergency Collision Avoidance for Intelligent Vehicles under Curved Road Conditions”. Em: *Applied Sciences* 13.20 (2023). ISSN: 2076-3417. DOI: 10.3390/app132011352. URL: https://www.mdpi.com/2076-3417/13/20/11352 (ver pp. 32, 33, 54, 58).

[35] B. P. Minaker. *Fundamentals of Vehicle Dynamics and Modelling: A Textbook for Engineers with Illustrations and Examples*. Automotive Series. Hoboken, NJ: John Wiley & Sons Ltd, 2020. ISBN: 978-1-118-98009-5 (ver pp. 32, 33).

[36] Michael. *Vehicle Dynamics: The Dynamic Bicycle Model*. The F1 Clan | An F1 Community created by the Fans for the Fans, dez. de 2020. URL: https://thef1clan.com/2020/12/23/vehicle-dynamics-the-dynamic-bicycle-model/ (acesso em 3 de jun. de 2023) (ver pp. 35, 36).

[37] Q. Cui, R. Ding, C. Wei e B. Zhou. “A hierarchical framework of emergency collision avoidance amid surrounding vehicles in highway driving”. Em: *Control Engineering Practice* 109 (abr. de 2021), p. 104751. DOI: 10.1016/j.conengprac.2021.104751 (ver pp. 37, 38, 47, 48, 55, 56, 65).

[38] N. S. Nise. *Engenharia de Sistemas de Controle*. Português. 6ª ed. Título original: *Control Systems Engineering*. Rio de Janeiro: LTC, 2018. 880 pp. ISBN: 978-85-216-2940-4 (ver p. 37).

[39] O. Alpar e R. Stojic. “Intelligent collision warning using license plate segmentation”. Em: *Journal of Intelligent Transportation Systems* 20.6 (2016), pp. 487–499. ISSN: 1547-2450. DOI: 10.1080/15472450.2015.1120674. URL: https://www.sciencedirect.com/science/article/pii/S1547245022000810 (ver pp. 37, 38, 54, 55).

[40] A. Mohammadzadeh, M. H. Sabzalian, C. Zhang, O. Castillo, R. Sakthivel e F. F. M. El-Sousy. *Modern Adaptive Fuzzy Control Systems*. Inglês. Vol. 421. Studies in Fuzziness and Soft Computing. Volume 421 da série *Studies in Fuzziness and Soft Computing*. Cham, Switzerland: Springer, 2023. xvi, 300. ISBN: 978-3-031-17393-6. DOI: 10.1007/978-3-031-17393-6 (ver p. 37).

[41] K. Mattas, M. Makridis, G. Botzoris, A. Kriston, F. Minarini, B. Papadopoulos, F. Re, G. Rognelund e B. Ciuffo. “Fuzzy Surrogate Safety Metrics for real-time assessment of rear-end collision risk. A study based on empirical observations”. Em: *Accident Analysis & Prevention* 148 (2020), p. 105794. ISSN: 0001-4575. DOI: 10.1016/j.aap.2020.105794. URL: https://www.sciencedirect.com/science/article/pii/S0001457520316146 (ver p. 38).

[42] V. Hai Quan, N. Anh Ngoc, L. Quynh, N. Khoa e M. T. Nguyen. “MODELLING AND SIMULATION OF AUTOMATIC BRAKE SYSTEM OF VEHICLE”. Em: *ARPN Journal of Engineering and Applied Sciences* 18.7 (abr. de 2023), pp. 874–880. ISSN: 1819-6608. DOI: 10.59018/0423116 (ver pp. 38, 54, 55).

[43] G. Li, Y. Yang, T. Zhang, X. Qu, D. Cao, B. Cheng e K. Li. “Risk assessment based collision avoidance decision-making for autonomous vehicles in multi-scenarios”. Em: *Transportation Research Part C: Emerging Technologies* 122 (2021). Disponível em: https://doi.org/10.1016/j.trc.2020.102820. Acesso em: 23 maio 2024, p. 102820. DOI: 10.1016/j.trc.2020.102820 (ver p. 38).

[44] Q. Cui, R. Ding, X. Wu e B. Zhou. “A new strategy for rear-end collision avoidance via autonomous steering and differential braking in highway driving”. Em: *Vehicle System Dynamics* 58.6 (2020), pp. 955–986. DOI: 10.1080/00423114.2019.1602732. eprint: https://doi.org/10.1080/00423114.2019.1602732. URL: https://doi.org/10.1080/00423114.2019.1602732 (ver pp. 38, 42, 44, 48, 49, 53).

[45] M. Alamir. *A Pragmatic Story of Model Predictive Control: Self-Contained Algorithms and Case-Studies*. CreateSpace Independent Publishing Platform, 2013. ISBN: 1489541349 (ver pp. 38, 39, 41, 43–47, 63, 66).

[46] L. Gonzalez, J. A. Matute-Peaspan, J. P. Rastelli e I. Calvo. “Longitudinal Collision Avoidance Based on Model Predictive Controllers and Fuzzy Inference Systems”. Em: *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*. 2020, pp. 1–6. DOI: 10.1109/ITSC45102.2020.9294584 (ver pp. 38, 39, 42, 55).

[47] C. Wu, L. Peng, Z. Huang, M. Zhong e D. Chu. “A method of vehicle motion prediction and collision risk assessment with a simulated vehicular cyber physical system”. Em: *Transportation Research Part C: Emerging Technologies* 47 (2014). Special Issue: Emerging Technologies Special Issue of ICTIS 2013 – Guest Editors: Liping Fu and Ming Zhong and Special Issue: Visualization & Visual Analytics in Transportation – Guest Editors: Patricia S. Hu and Michael L. Pack, pp. 179–191. ISSN: 0968-090X. DOI: 10.1016/j.trc.2014.07.002. URL: https://www.sciencedirect.com/science/article/pii/S0968090X14002046 (ver pp. 39, 56, 57).

[48] J. B. Rawlings e D. Q. Mayne. *Model Predictive Control: Theory and Design*. Nob Hill Publishing, 2009. ISBN: 978-0-9727402-2-9 (ver pp. 40, 41).

[49] M. Morari e J. H. Lee. “Model Predictive Control: Past, Present and Future”. Em: *Computers and Chemical Engineering* 23.4-5 (1999), pp. 667–682. DOI: 10.1016/S0098-1354(98)00301-9 (ver pp. 40, 41).

[50] MathWorks. *What Is Model Predictive Control?* Acessado em: 24/07/2024. 2024. URL: https://www.mathworks.com/help/mpc/gs/what-is-mpc.html (ver pp. 40, 41).

[51] J. B. Rawlings, D. Q. Mayne e M. M. Diehl. *Model Predictive Control: Theory, Computation, and Design*. 2nd. Santa Barbara, CA: Nob Hill Publishing, LLC, 2022 (ver pp. 40, 43, 44).

[52] H. Kazemi, H. Nourkhiz Mahjoub, A. Tahmasbi-Sarvestani e Y. Fallah. “A Learning-Based Stochastic MPC Design for Cooperative Adaptive Cruise Control to Handle Interfering Vehicles”. Em: *IEEE Transactions on Intelligent Vehicles* PP (fev. de 2018), pp. 266–275. DOI: 10.1109/TIV.2018.2843135 (ver pp. 42, 52, 55–57).

[53] L. Wang. *Model Predictive Control System Design and Implementation Using MATLAB*. Advances in Industrial Control. London: Springer-Verlag London Limited, 2009. ISBN: 978-1-84882-330-3. DOI: 10.1007/978-1-84882-331-0 (ver pp. 43, 46, 80).

[54] D. Kang e D. Kum. “Camera and Radar Sensor Fusion for Robust Vehicle Localization via Vehicle Part Localization”. Em: *IEEE Access* 8 (2020), pp. 75223–75236. DOI: 10.1109/ACCESS.2020.2985075 (ver pp. 44, 53).

[55] L. del Re, F. Allgöwer, L. Glielmo, C. Guardiola e I. Kolmanovsky, ed. *Automotive Model Predictive Control: Models, Methods and Applications*. Vol. 402. Lecture Notes in Control and Information Sciences. Berlin Heidelberg: Springer-Verlag, 2010. ISBN: 978-1-84996-070-0 (ver p. 47).

[56] U. D. Mäder. “Augmented Models in Estimation and Control”. Dissertation ETH Zurich No. 19278. Tese (Doutorado em Ciências). Zurich: Eidgenössische Technische Hochschule (ETH) Zurich, 2010. ISBN: 978-1-4538-4261-4 (ver p. 47).

[57] Y. Gao, Z. Xu, X. Zhao, G. Wang e Q. Yuan. “Hardware-in-the-Loop Simulation Platform for Autonomous Vehicle AEB Prototyping and Validation”. Em: *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*. 2020, pp. 1–6. DOI: 10.1109/ITSC45102.2020.9294704 (ver pp. 48, 49).

[58] Y. Wang, G. Yin, Y. Li, S. Ullah, W. Zhuang, J. Wang, N. Zhang e K. Geng. “Self-learning control for coordinated collision avoidance of automated vehicles”. Em: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* (2019), pp. 1–15. DOI: 10.1177/0954407019887884 (ver pp. 48, 49, 55).

[59] MathWorks. *Hardware-in-the-Loop (HIL) Testing*. Acesso em: 10 out. 2023. MathWorks, 2023. URL: https://www.mathworks.com/discovery/hardware-in-the-loop-hil.html (ver pp. 48, 49).

[60] C. Stöckle, W. Utschick, S. Herrmann e T. Dirndorfer. “Robust Function and Sensor Design Considering Sensor Measurement Errors Applied to Automatic Emergency Braking”. Em: *Proceedings of the 2019 IEEE Intelligent Vehicles Symposium (IV)*. Apresentado no evento realizado de 9 a 12 de junho de 2019. Paris, France, jun. de 2019 (ver pp. 49, 55).

[61] D. Denyer e D. Tranfield. “Producing a systematic review”. Em: *The SAGE Handbook of Organizational Research Methods*. Ed. por D. A. Buchanan e A. Bryman. London: SAGE Publications Ltd, 2009, pp. 671–689 (ver p. 50).

[62] T.-S. Wu. “Pedestrian and Vehicle Recognition Based on Radar for Autonomous Emergency Braking”. Em: *SAE Technical Paper*. SAE International, mar. de 2017, p. 5. DOI: 10.4271/2017-01-1405 (ver p. 53).

[63] J. Nataprawira, Y. Gu, I. Goncharenko e S. Kamijo. “Pedestrian Detection Using Multispectral Images and a Deep Neural Network”. Em: *Sensors* 21.7 (2021), p. 2536. ISSN: 1424-8220. DOI: 10.3390/s21072536 (ver p. 53).

[64] S. Lee, S. Lee e M. Kim. “Development of a Driving Behavior-Based Collision Warning System Using a Neural Network”. Em: *International Journal of Automotive Technology* 19 (out. de 2018), pp. 837–844. DOI: 10.1007/s12239-018-0080-6 (ver p. 53).

[65] M. Wang, X. Chen, B. Jin, P. Lv, W. Wang e Y. Shen. “A Novel V2V Cooperative Collision Warning System Using UWB/DR for Intelligent Vehicles”. Em: *Sensors* 21.10 (2021). ISSN: 1424-8220. DOI: 10.3390/s21103485. URL: https://www.mdpi.com/1424-8220/21/10/3485 (ver pp. 53, 54, 56, 57).

[66] Y. Fang, H. Zhao, H. Zha, X. Zhao e W. Yao. “Camera and LiDAR Fusion for On-road Vehicle Tracking with Reinforcement Learning”. Em: *2019 IEEE Intelligent Vehicles Symposium (IV)*. 2019, pp. 1723–1730. DOI: 10.1109/IVS.2019.8814028 (ver pp. 53, 55).

[67] G. Li, S. Li, S. Li, Y. Qin, D. Cao, X. Qu e B. Cheng. “Deep Reinforcement Learning Enabled Decision-Making for Autonomous Driving at Intersections”. Em: *Automotive Innovation* 3 (2020), pp. 374–385. ISSN: 2522-8765. DOI: 10.1007/s42154-020-00113-1. URL: https://doi.org/10.1007/s42154-020-00113-1 (ver p. 53).

[68] Ó. Gómez, F. Jiménez e J. Naranjo. “Autonomous collision avoidance system based on accurate knowledge of the vehicle surroundings”. Em: *IET Intelligent Transport Systems* 9 (fev. de 2015), pp. 105–117. DOI: 10.1049/iet-its.2013.0118 (ver pp. 54, 57).

[69] Y. Zhao, X. Zhou, X. Xu, Z. Jiang, F. Cheng, J. Tang e Y. Shen. “A Novel Vehicle Tracking ID Switches Algorithm for Driving Recording Sensors”. Em: *Sensors* 20 (jun. de 2020), p. 3638. DOI: 10.3390/s20133638 (ver p. 54).

[70] D. Lee, S. Tak, S. Choi e H. Yeo. “Development of Risk Predictive Collision Avoidance System and Its Impact on Traffic and Vehicular Safety”. Em: *Transportation Research Record Journal of the Transportation Research Board* 2673 (jul. de 2019), pp. 454–465. DOI: 10.1177/0361198119836972 (ver p. 54).

[71] I.-H. Lee e B.-C. Luan. “Design of Autonomous Emergency Braking System Based on Impedance Control for 3-Car Driving Scenario”. Em: *SAE 2016 World Congress and Exhibition*. 2016, p. 6. DOI: 10.4271/2016-01-1453. URL: https://doi.org/10.4271/2016-01-1453 (ver p. 56).

[72] M. Guiggiani. *The Science of Vehicle Dynamics: Handling, Braking, and Ride of Road and Race Cars*. Library of Congress Control Number: 2013958104. Dordrecht, Heidelberg, New York, London: Springer, 2014. ISBN: 978-94-017-8532-7. URL: https://doi.org/10.1007/978-94-017-8533-4 (ver pp. 58, 59).

[73] J. D. Garcia Montoya. "Análise compreensiva do controle preditivo baseado em modelo aplicado em sistemas de assistência a manutenção de faixa". Programa de Pós-Graduação em Sistemas Mecatrônicos. Orientador: Evandro Leonardo Silva Teixeira. Coorientador: André Murilo de Almeida Pinto. Dissertação de Mestrado. Brasília: Universidade de Brasília, 2024 (ver pp. 63, 64).

[74] D. Wang. "Stochastic Model Predictive Control for Autonomous Emergency Integrated Braking and Steering System". Aprovado em 14 de setembro de 2021. Examinador: Ulf Olofsson. Supervisor: Kaveh Nazem Tahmasebi. Examensarbete TRITA-ITM-EX 2021:535. Stockholm: KTH Royal Institute of Technology, 2021. URL: https://kth.diva-portal.org/smash/get/diva2:1594736/FULLTEXT01.pdf (ver p. 64).

[75] K. N. de Winkel, T. Irmak, R. Happee e B. Shyrokau. "Standards for passenger comfort in automated vehicles: Acceleration and jerk". Em: *Applied Ergonomics* 106 (2023), p. 103881. ISSN: 0003-6870. DOI: 10.1016/j.apergo.2022.103881. URL: https://www.sciencedirect.com/science/article/pii/S0003687022002046 (ver pp. 65, 67, 78, 79).

[76] C. Wang, Q. Sun, Z. Li e H. Zhang. "Human-Like Lane Change Decision Model for Autonomous Vehicles that Considers the Risk Perception of Drivers in Mixed Traffic". Em: *Sensors* 20.8 (abr. de 2020). Disponível em: https://doi.org/10.3390/s20082259, p. 2259. ISSN: 1424-8220. DOI: 10.3390/s20082259 (ver p. 68).

[77] EURO NCAP. *AEB Car-to-Car*. Disponível em: https://www.euroncap.com/en/car-safety/the-ratings-explained/safety-assist/aeb-car-to-car/. Acesso em: 21 jul. 2025. 2024 (ver pp. 70, 71).

[78] J. Modesto de Araujo. *Art. 61 – Capítulo III – Das normas gerais de circulação e conduta*. Atualizado em 20/09/2017. CTB Digital. 2017. URL: https://www.ctbdigital.com.br/artigo/art61 (acesso em 4 de nov. de 2025) (ver p. 71).

[79] UNITED NATIONS ECONOMIC COMMISSION FOR EUROPE. *UN Regulation No. 152: uniform provisions concerning the approval of motor vehicles with regard to the Advanced Emergency Braking System (AEBS) for M1 and N1 vehicles*. 02 series of amendments. Documento E/ECE/TRANS/505/Rev.3/Add.151/Rev.2. Disponível em: https://unece.org/sites/default/files/2024-04/R152r2E.pdf. Acesso em: 6 jun. 2026. UNECE. Geneva, 2023 (ver p. 91).