



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Mecânica

Fabício Leonardo Silva

**Aprendizagem de máquinas aplicada à
estratégia de gerenciamento de potência em
veículos elétricos**

CAMPINAS
2023

Fabício Leonardo Silva

Aprendizagem de máquinas aplicada à estratégia de gerenciamento de potência em veículos elétricos

Tese de doutorado apresentada à Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Doutor em Engenharia Mecânica, na Área de Mecânica dos Sólidos e Projeto Mecânico.

Orientadora: Prof.^a Dr.^a Ludmila Corrêa de Alkmin e Silva

ESTE EXEMPLAR CORRESPONDE À VERSÃO
FINAL DA TESE DEFENDIDA PELO ALUNO
FABÍCIO LEONARDO SILVA, E ORIENTADA
PELA PROF.^a DR.^a LUDMILA CORRÊA DE A. E
SILVA

.....
ASSINATURA DO ORIENTADOR

CAMPINAS
2023

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Elizangela Aparecida dos Santos Souza - CRB 8/8098

Si38a Silva, Fabrício Leonardo, 1993-
Aprendizagem de máquinas aplicada à estratégia de gerenciamento de potência em veículos elétricos / Fabrício Leonardo Silva. – Campinas, SP : [s.n.], 2023.

Orientador: Ludmila Corrêa de Alkmin e Silva.
Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Sistemas de gestão de energia. 2. Aprendizado de máquina. 3. Redes neurais (Computação). 4. Veículos a motor - Dinâmica. 5. Veículos elétricos. I. Silva, Ludmila Corrêa de Alkmin e, 1981-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. III. Título.

Informações Complementares

Título em outro idioma: Machine learning applied to power management strategy in electric vehicles

Palavras-chave em inglês:

Energy management systems

Machine learning

Neural networks (Computation)

Motor vehicles - Dynamics

Electric vehicles

Área de concentração: Mecânica dos Sólidos e Projeto Mecânico

Titulação: Doutor em Engenharia Mecânica

Banca examinadora:

Ludmila Corrêa da Alkmin e Silva

Angel Pontin Garcia

Tárcio André dos Santos Barros

Marcelo Becker

José Ricardo Sodré

Data de defesa: 17-02-2023

Programa de Pós-Graduação: Engenharia Mecânica

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0003-0799-7803>

- Currículo Lattes do autor: <https://lattes.cnpq.br/9430080955564123>

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA

TESE DE DOUTORADO

**Aprendizagem de máquinas aplicada à
estratégia de gerenciamento de potência em
veículos elétricos**

Autor: Fabrício Leonardo Silva

Orientadora: Prof.^a Dr.^a Ludmila Corrêa de Alkmin e Silva

A Banca Examinadora composta pelos membros abaixo aprovou esta Tese:

Prof.^a Dr.^a Ludmila Corrêa de Alkmin e Silva, Presidente
Universidade Estadual de Campinas - UNICAMP

Prof. Dr. Angel Pontin Garcia
Universidade Estadual de Campinas - UNICAMP

Prof. Dr. Tércio André dos Santos Barros
Universidade Estadual de Campinas - UNICAMP

Prof. Dr. Marcelo Becker
Escola de Engenharia de São Carlos - EESC USP

Prof. Dr. José Ricardo Sodré
Aston University

A Ata da defesa com as respectivas assinaturas dos membros encontra-se no processo de vida acadêmica do aluno.

Campinas, 17 de fevereiro de 2023.

Dedicatória

Dedico este trabalho aos meus pais e ao meu irmão

Agradecimentos

Agradeço, primeiramente, aos meus pais, Adélia Maria Alves e Fabio Batista da Silva por sempre incentivarem meus estudos. Muito obrigado por todo apoio, amor e carinho.

Agradeço ao meu irmão, Wellington Oliveira de Souza Junior, que apesar da distância sempre esteve ao meu lado me apoiando.

Agradeço a minha namorada Eloane Mendes Silva por todo apoio emocional nos momentos difíceis e por compreender a minha ausência.

Agradeço à minha orientadora, Prof.^a Ludmila Corrêa de Alkmin e Silva, não só pela orientação neste trabalho, mas, também, pela confiança em meu trabalho, pela oportunidade de integrar esse notável grupo de pesquisa formado pelo Laboratório de Sistemas Integrados da Unicamp (LabSIn) e principalmente pela amizade.

Agradeço a todos os colegas do LabSIn, em especial à Maria Augusta Lourenço, ao Jony Eckert, ao Matheus Henrique Rodrigues Miranda, Samuel Filgueira da Silva e ao Áquila Chagas de Carvalho pela grande parceria nos diversos projetos, artigos e testes que produzimos juntos.

Aos técnicos Rosângelo Ferreira, Mauro Romera e Maurício de Sant'Anna por todo o suporte técnico, que auxiliaram no desenvolvimento deste e muitos outros trabalhos desenvolvidos pelo Laboratório de Sistemas Integrados.

Agradeço à PETROBRAS pelo apoio financeiro provido ao longo do período de desenvolvimento deste projeto, através do convênio nº 5445.1.

*Se tenho as mãos macias
Eu devo tudo a meu pai
Que teve as mãos calejadas
No tempo que longe vai
Cada viagem que fazia
Naquelas manhãs de inverno
Era um pingo do meu pranto
Nas folhas do meu caderno*

Sulino e José Fortuna

Resumo

SILVA, Fabrício Leonardo. Aprendizagem de máquinas aplicada à estratégia de gerenciamento de potência em veículos elétricos. 2023. 102p. Tese (Doutorado). Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas.

Este trabalho tem como objetivo desenvolver uma estratégia de gerenciamento de potência, por meio de aprendizado de máquinas, para um veículo elétrico com tração nas quatro rodas. Para atingir esse objetivo, um gerador de ciclos de condução foi elaborado a partir de um método evolucionário de operadores genéticos, capaz de produzir um ciclo de treinamento, que simule os desafios reais encontradas em vias urbanas e rodoviárias, a partir de ciclos de conduções padrões e ciclos reais. Posteriormente, um modelo de rede neural artificial de multicamadas com arquitetura genérica foi desenvolvido, dessa maneira, durante o treinamento evolucionário genético multiobjetivo, a melhor configuração para a arquitetura da rede neural seja determinada, assim como a quantidade de camadas, o número de neurônios e as suas funções de ativação. Em seguida, a rede é aplicada no gerenciamento de potência de um veículo elétrico e o seu treinamento visa maximizar a autonomia do veículo, minimizar a massa do sistema de potência elétrica (motores e baterias), minimizar o tempo total de recarga da bateria e minimizar os custos envolvidos com a bateria. Após o treinamento, a solução com maior fator de desempenho apresentou uma autonomia de 157,8 km, massa do sistema elétrico de 295,4 kg, uma expectativa de vida útil da bateria de 205.000 km, um valor RMSE de 0,172 km/h para a variação máxima de 3,986 km/h. Por fim, a rede neural artificial foi implementada em um microcontrolador ATmega 328p e uma simulação hardware-in-the-loop é desenvolvida para avaliar a rede atuando em condições reais. Os resultados obtidos na simulação mostram que o microcontrolador conseguiu gerenciar a distribuição de potência do veículo elétrico adequadamente, obtendo um erro RMSE da velocidade do veículo em comparação com o ciclo de treinamento de 0,188 km/h e um erro máximo das velocidades de 3,986 km/h. O tempo de processamento gasto pelo microcontrolador para processar o comando de atuação variou entre 0,012 s e 0,018 s, com tempo médio de 0,015 s.

Palavras-chave: Estratégia de gerenciamento de potência. Aprendizado de máquinas. Rede neural artificial. Dinâmica veicular.

Abstract

SILVA, Fabrício Leonardo. Machine learning applied to power management strategy in electric vehicles. 2023. 102p. PhD's Thesis. School of Mechanical Engineering, University of Campinas, Campinas.

This work aims to develop a power management strategy by machine learning for a four-wheel-drive electric vehicle. A model is developed to reproduce the planar (longitudinal and lateral) dynamic behavior of vehicles. To achieve this objective, a driving cycle generator was developed based on an evolutionary method of genetic operators, generating a training cycle that simulates the real conditions of urban roads and highways, based on standard driving cycles and real cycles. Subsequently, a multilayer artificial neural network model with generic architecture was developed, in this way, during the multi-objective genetic evolutionary training, the best configuration for the neural network architecture is determined, such as the number of layers, the number of neurons and their activation functions. Then, the network is applied in the power management of an electric vehicle and its training aims to maximize the vehicle's autonomy, minimize the mass of the electric power system (motors and batteries), minimize the total battery recharge time and minimize the costs involved with the battery. The training aims to maximize the vehicle's autonomy, minimize the electric power system mass (motors and batteries), the battery recharge time, and the battery cost. After training, the solution with the highest fitness value had a autonomy of 157.8 km, electrical system mass of 295.4 kg, a battery life expectancy of 205,000 km, an RMSE value of 0.172 km/h for the maximum variation of 3.986 km/h. Finally, the best artificial neural network was implemented in an ATmega 328p microcontroller and a hardware-in-the-loop simulation evaluates the neural network performing under real conditions. The results obtained in the simulation indicate that the microcontroller adequately managed the power distribution of the electric vehicle, obtaining an RMS error of the vehicle speed compared to the training cycle of 0.188 km/h and a maximum speed error of 3.986 km/h. The processing time spent by the microcontroller to process the actuation command varied between 0.012 s and 0.018 s, with an average time of 0.015 s.

Keywords: Power management strategy. Machine learning. Artificial neural network. Vehicle dynamics.

Lista de Ilustrações

1.1	Fluxograma do trabalho proposto.	27
2.1	Tipos de configurações de veículos elétricos.	33
2.2	Forças atuando no veículo no plano longitudinal-vertical.	35
2.3	Comportamento de um veículo em curva para baixas velocidades.	38
2.4	Comportamento de um veículo em curva para baixas velocidades.	39
2.5	Ângulo de escorregamento lateral do veículo.	40
2.6	Transferência de carga do veículo longitudinalmente.	41
2.7	Detalhamento do comportamento dinâmico do pneu descrito no modelo de Pacejka.	42
2.8	Mapas de eficiências do motor elétrico e do inversor.	47
2.9	Exemplo de aplicação do método de máquina de vetor suporte.	52
2.10	Exemplo do método da floresta aleatória.	53
2.11	Exemplo do método de redes neurais.	54
2.12	Ciclo de condução FTP-75.	55
2.13	Ciclo de condução US06.	56
2.14	Ciclo de condução HWFET.	57
2.15	Ciclo de condução WLTC.	58
3.1	Histograma do ciclo de condução FTP-75.	65
3.2	Histograma do ciclo de condução HWFET.	66
3.3	Histograma do ciclo de condução WLTC.	66
3.4	Histograma dos ciclos reais.	67
3.5	Ciclo de condução real.	68
3.6	Fluxograma do algoritmo evolucionário genético para a geração dos ciclos de condução.	69
3.7	Interface gráfica do gerador de ciclos desenvolvido.	71
3.8	Exemplos de ciclos gerados.	72
3.9	Ciclo definido para o treinamento da RNA.	73
4.1	Modelo de neurônio.	74
4.2	Desenho esquemático da rede neural artificial com arquitetura genérica.	78
4.3	Exemplo do método de redes neurais.	79
4.4	Resposta de modelos RNA da descarga da bateria.	81
4.5	Desenho esquemático do controle de troca de marcha.	82
4.6	Fronteira de Pareto para o treinamento da estratégia RNA para a troca de machar.	85
4.7	Resposta de modelos RNA na troca de marcha.	86
5.1	Estratégia de controle de potência proposta.	89
5.2	Fronteira de Pareto para o treinamento da estratégia RNA de gerenciamento de potência.	94

5.3	Tempo de processamento das RNAs da Fronteira de Pareto.	96
5.4	Resposta das RNAs para o ciclo de treinamento.	98
5.5	Distribuição dos torques das RNAs e o torque requerido no ciclo de treinamento.	99
5.6	Resposta das RNAs para a região de maiores velocidades do ciclo de treinamento.	100
5.7	Resposta das RNAs para o ciclo Campinas-São Paulo.	101
5.8	Distribuição dos torques das RNAs e o torque requerido no ciclo de treinamento.	102
5.9	Arquiteturas das RNAs obtidas no treinamento.	104
6.1	Diagrama da simulação hardware-in-the-loop da RNA.	106
6.2	Tempo de comunicação e processamento da RNA.	106
6.3	Resposta da RNA para a simulação Hardware-in-the-loop.	107
6.4	Resposta da RNA entre 3600 e 3400 segundos.	107
6.5	Simulação HIL da RNA com um tempo de atuação de 0,1 s.	108

Lista de Tabelas

2.1	Parâmetros do veículo (Genta e Morello, 2009).	45
2.2	Parâmetros de Pacejka do pneu (Genta e Morello, 2009).	46
2.3	Potência, inércia e massa de motores elétricos comerciais.	47
2.4	Métodos utilizados para determinar de ciclos de condução.	59
2.5	Estratégias de controles.	60
2.6	Redes neurais artificiais aplicadas ao gerenciamento de energia e potência de veículos com propulsão elétrica.	63
4.1	Funções de ativações.	76
4.2	Comparação dos modelos RNAs.	81
4.3	Resultados de modelos RNA e Fuzzy para troca de marcha.	87
4.4	Tempo de processamento da ponderação e soma dos sinais.	88
4.5	Tempo de processamento de cada função de ativação.	88
5.1	Resultados alcançados pelas configurações de RNA treinadas.	95
6.1	Desempenho da RNA na simulação Hardware-in-the-loop.	108

Lista de Abreviaturas e Siglas

Letras Latinas

$\mathbf{X_c}$	Vetor cromossomo do gerador de ciclo	
$\mathbf{X_R}$	Vetor cromossomo da rede neural de previsão de carga de bateria	
$\mathbf{X_S}$	Vetor cromossomo da rede neural artificial para a troca de marcha	
$\mathbf{X_G}$	Vetor cromossomo da rede neural artificial para o gerenciamento de potência do veículo elétrico	
A_B	Amplitude da zona exponencial da bateria	[V]
$a_{cic,max}$	Aceleração mínima permitida para o ciclo de condução	[m/s ²]
$a_{cic,min}$	Aceleração máxima permitida para o ciclo de condução	[m/s ²]
a_{cic}	Aceleração do ciclo de condução	[m/s ²]
A_f	Área frontal projetada do veículo	[m ²]
A_m	Amplitude de busca de um p�metro de projeto	
a_{req}	Aceleração requerida	[m/s ²]
a_x	Aceleração longitudinal do veículo	[m/s ²]
B	Fator de rigidez	
b	Dist�ncia do CG do v�culo ao eixo dianteiro	[m]
B_B	Capacidade exponencial da bateria	[Ah ⁻¹]
C	Fator de forma	
c	Dist�ncia do CG do v�culo ao eixo traseiro	[m]
C_d	Coeficiente de arrasto aerodin�mico	

C_{st}	Consumo equivalente de energia	[R\$/km]
D	Valor de pico	
D_A	Resistência aerodinâmica	[N]
d_{cg}	Distância percentual da posição do CG do veículo em relação ao seu entre eixo [%]	
D_R	Distância percorrida pelo veículo na simulação	[m]
DoD	profundidade de descarga da bateria	[%]
$dSoC$	Variação do estado de carga da bateria	[%/s]
E	Fator de curvatura	
E^{max}	Emissão máxima de um gás	[g/km]
E^{min}	Emissão mínima de um gás	[g/km]
E_0	Tensão constante do circuito equivalente da bateria	[V]
E_{CO}	Emissão de monóxido de carbono	[g/km]
E_{HC}	Emissão de hidrocarbonetos	[g/km]
E_{NOx}	Emissão de óxido de nitrogênio	[g/km]
$E_{V,max}$	Erro máximo da velocidade do veículo simulado e a velocidade do ciclo	[m/s]
$E_{V,RMS}$	Valor da raiz do erro médio quadrado da velocidade do veículo simulado e a velocidade do ciclo	[m/s]
f^{max}	Valor máximo do critério de treinamento	[m/s]
f^{min}	Valor mínimo do critério de treinamento	[m/s]
F_t	Fator de desempenho	
F_x	Força de tração nas rodas do veículo	[N]
F_y	Força lateral atuando no veículo	[N]
f_1	Primeiro critério de treinamento	

f_2	Segundo critério de treinamento	
f_3	Terceiro critério de treinamento	
f_r	Coeficiente de resistência de rolamento	
$F_{y,f}$	Força lateral atuando no eixo dianteiro	[N]
$F_{y,r}$	Força lateral atuando no eixo traseiro	[N]
$F_{z,1}$	Força vertical atuando na roda dianteira esquerda	[N]
$F_{z,2}$	Força vertical atuando na roda dianteira direita	[N]
$F_{z,3}$	Força vertical atuando na roda traseira esquerda	[N]
$F_{z,4}$	Força vertical atuando na roda traseira direita	[N]
$F_{z,f}$	Força vertical atuando no eixo dianteiro	[N]
$F_{z,r}$	Força vertical atuando no eixo traseiro	[N]
FC	Consumo de combustível do veículo	[L]
g	Aceleração gravitacional	[m/s ²]
H	Restrições do processo evolutivo genético	
h_{cg}	Altura do CG do veículo	[m]
i	Número do conjunto roda/pneu analisado	
I^*	Corrente dinâmica em baixa frequência	[A]
I_z	Momento de inércia de guinada do veículo	[kgm ²]
I_{bat}	Corrente requerida da bateria	[A]
I_C^a	Corrente elétrica média de carga durante o ciclo equivalente	[A]
I_D^a	Corrente elétrica média de descarga durante o ciclo equivalente	[A]
I_{max}	Corrente máxima de descarga	[A]
I_{ME}	Inércia do motor elétrico	[kgm ²]
I_R	Inércia do conjunto roda e pneu	[kgm ²]

k	Número de ciclos equivalentes	
k_s	Fator de escala para mutação	
$K_{\phi,f}$	Rigidez do eixo dianteiro	[N/m]
$K_{\phi,r}$	Rigidez do eixo traseiro	[N/m]
K_B	Constante de polarização	[V/Ah]
L	Entre eixo	[m]
M	Massa do veículo	[kg]
M_{bat}	Massa da bateria	[kg]
M_{ME}	Massa do sistema de propulsão elétrica (ME e inversor)	[kg]
M_{SE}	Massa total do sistema elétrico (Baterias, ME e inversor)	[kg]
M_z	Momento de alinhamento do pneu	[Nm]
MV	Vetor micro viagem do ciclo	
n	Número de indivíduos da população	
N_a	Número de parâmetros da função de ativação	
N_c	Número de parâmetros de uma camada da rede neural	
N_N	Número de neurônios da camada N	
N_n	Número de parâmetros de cada neurônios	
N_{rna}	Número de parâmetros da rede neural artificial	
O_c	Número máximo de ciclos completos para o fim de uma bateria	
O_e	Número máximo de ciclos para o fim da vida da bateria	
P	Vetor parada do ciclo	
P_E	Potência específica da bateria	[W/kg]
P_p	Fator de penalidade	
Q_{bat}	Capacidade da bateria	[Ah]

Q_{BOL}	Capacidade da bateria no início da vida útil	[Ah]
Q_{EOL}	Capacidade da bateria no fim da vida útil	[Ah]
Q_k	Capacidade da bateria após o k -ésimo ciclo equivalente	[Ah]
Q_{nom}	Capacidade nominal da bateria	[Ah]
R	Valor de correlação	
R_c	Raio da curva	[m]
R_g	Raio do pneu não deformado	[m]
R_{hx}	Resistência devido ao engate	[N]
R_p	Raio efetivo do do pneu	[m]
R_x	Resistência ao rolamento	[N]
S	Resposta da rede neural artificial da variação do estado de carga da bateria [%]	
s	Sinal de entrada da função de ativação	
S_E	Energia específica da bateria	[Wh/kg]
S_h	Incremento horizontal	
S_p	Probabilidade de seleção de um indivíduo da população	[%]
S_v	Incremento vertical	[N]
SoC	Estado de carga da bateria (State of Charge)	[%]
SoC_0	Estado de carga inicial da bateria	[%]
SoH	Estado de saúde da bateria (State of Health)	[%]
t	Instante de tempo de integração	[s]
T_{amb}	Temperatura ambiente	[K]
$t_{b,f}$	Bitola dianteira	[m]
$t_{b,r}$	Bitola traseira	[m]
t_b	Bitola	[m]

$t_{cic,max}$	Tempo máximo permitido para o ciclo de condução	[s]
t_{cic}	Tempo total do ciclo de condução	[s]
$T_{f,max}$	Torque máximo transmissível na área de contato entre o pneu e o solo para o eixo dianteiro	[Nm]
$T_{ME,f}$	Torque do motor elétrico dianteiro	[Nm]
$T_{ME,r}$	Torque do motor elétrico traseiro	[Nm]
T_{ME}	Torque máximo do motor elétrico	[Nm]
$t_{par,max}$	Tempo máximo de parada permitido para o ciclo de condução	[s]
$t_{par,mut}$	Tempo de parada após a mutação	[s]
t_{par}	Tempo de parada	[s]
T_P	Torque do motor elétrico em fase de potência constante	[Nm]
$T_{r,max}$	Torque máximo transmissível na área de contato entre o pneu e o solo para o eixo traseiro	[Nm]
t_{rec}	Tempo de recarga da bateria	[s]
T_{ref}	Temperatura ambiente de referência	[K]
T_{req}	Torque requerido pelos motores	[Nm]
t_{rna}	Tempo de processamento total da rede neural artificial	[s]
V_{bat}	Tensão da bateria	[V]
$V_{cic,max}$	Velocidade máxima permitida para o ciclo de condução	[m/s]
V_{cic}	Velocidade do ciclo de condução	[m/s]
$V_{MV,mut}$	Sinal de velocidade de uma micro viagem após a mutação	[m/s]
V_{MV}	Sinal de velocidade de uma micro viagem	[m/s]
V_{nom}	Tensão nominal da bateria	[V]
V_{sim}	Velocidade obtida pela simulação do veículo elétrico com a rede neural artificial	[m/s]

$V_{sx,p}$	Velocidade relativa de escorregamento	[m/s]
$V_{x,p}$	Velocidade longitudinal do pneu	[m/s]
V_x	Velocidade longitudinal do veículo	[m/s]
$V_{y,p}$	Velocidade lateral do pneu	[m/s]
V_y	Velocidade lateral do veículo	[m/s]
W	peso do veículo	[N]
w	Ponderação de um sinal de entrada de um neurônio da rede neural artificial	

Letras Gregas

α	Ângulos de escorregamento lateral do pneu	[rad]
α_f	Ângulos escorregamento lateral do pneu dianteiro	[rad]
α_p	Ângulos escorregamento lateral de um pneu	[rad]
α_r	Ângulos escorregamento lateral do pneu traseiro	[rad]
β	Ângulos escorregamento lateral do veículo	[rad]
β_n	Valor de viés de um neurônio	
$\Delta F_{z,f}$	Transferência de carga lateral no eixo dianteiro	[N]
$\Delta F_{z,r}$	Transferência de carga lateral no eixo traseiro	[N]
$\Delta F_{z,x}$	Transferência de carga longitudinal	[N]
Δt	Intervalo de tempo da simulação	[s]
δ	Ângulos de esterçamento médio das rodas	[rad]
δ_i	Ângulos de esterçamento ideal para a roda interna a curva	[rad]
δ_o	Ângulos de esterçamento ideal para a roda externa a curva	[rad]
$\dot{\gamma}$	Taxa de guinada do veículo	[rad/s]
ϵ	Índice de degradação da bateria	

η_{inv}	Eficiência do inversor	[%]
η_{ME}	Eficiência do motor elétrico	[%]
γ	Guinada do veículo	[rad]
γ_C	Fator de estresse da corrente no carregamento da bateria	
γ_D	Fator de estresse da corrente no descarregamento da bateria	
κ_x	Escurregamento longitudinal do pneu	
λ_1	Parâmetro 1 da função de ativação	
λ_2	Parâmetro 2 da função de ativação	
ω_{max}	Velocidade máxima do motor elétrico	[rad/s]
$\omega_{ME,f}$	Velocidade máxima do motor elétrico em fase de torque constante dos motores dianterios	[rad/s]
$\omega_{ME,r}$	Velocidade máxima do motor elétrico em fase de torque constante dos motores traseiros	[rad/s]
ω_{ME}	Velocidade máxima do motor elétrico em fase de torque constante	[rad/s]
Ω_p	Velocidade rotacional do conjunto roda e pneu	[rad/s]
ω_P	Velocidade do motor elétrico em fase de potência constante	[rad/s]
Φ	Função de distribuição cumulativa da distribuição normal	
ϕ	Ângulos de rolagem do chassi	[rad]
Ψ	Constante de Arrhenius	
ψ	Função de ativação	
ρ	Densidade do ar	[kg/m ³]
Θ	Ângulo de cambagem do pneu	[rad]
θ	Inclinação da via	[rad]
ξ	Fator de estresse devido à descarga da bateria	

Sobrescritos

max Máximo

min Mínimo

Subscritos

bat Bateria

BOL Condição de início de vida útil da bateria

C Número da camada da rede neural artificial

cg Centro de gravidade

cic Ciclo

EOL Condição de fim de vida útil da bateria

f Frontal

i Posição da roda

max Máximo

ME Motor elétrico

min Mínimo

mut Mutado

MV Micro viagem

N Número do neurônio de uma camada

nom Nominal

np Número de paradas do ciclo

p Pneu

par Parada

r Traseiro

<i>req</i>	Requerido
<i>sim</i>	Simulado
<i>x</i>	Longitudinal
<i>y</i>	Lateral
<i>z</i>	Vertical

Siglas

ABNT	<i>Associação Brasileira de Normas Técnicas</i>
ADVISOR	<i>Advanced Vehicle Simulator</i>
CO	<i>Monóxido de carbono</i>
FA	<i>Floresta Aleatória</i>
FLC	<i>Controle de Logica Fuzzy</i>
FTC	<i>Controle Tolerante a Falhas</i>
FTP-75	<i>Federal Test Procedure at urban drivng</i>
HC	<i>Hidrocarbonetos</i>
HWFET	<i>Highway Fuel Economy Test Cycle</i>
LabSIn	<i>Laboratório de Sistemas Integrados</i>
ME	<i>Motor Elétrico</i>
MPC	<i>Estratégia de controle preditivo</i>
MVS	<i>Máquina de Vetores Suporte</i>
NBR	<i>Norma Brasileira</i>
NO _x	<i>Óxido de nitrogênio</i>
PID	<i>Controle Proporcional Integral Derivativo</i>
RMC	<i>Rede neural de multicamada</i>

RMSE	<i>Valor da raiz do erro médio quadrado</i>
RNA	<i>Redes neurais artificiais</i>
RNC	<i>Rede neural de cinza</i>
RNMLCP	<i>Rede neural de memória de longo e curto prazo</i>
RNR	<i>Rede neural de retropropagação</i>
RNRB	<i>Rede neural de regularização bayesiana</i>
SFTP	<i>Supplemental Federal Test Procedure</i>
SMC	<i>Estratégia de controle por deslizamento</i>
US06	<i>United States n.º 06 drive cycle</i>
VE	<i>Veículo Elétrico</i>
VHE	<i>Veículo Híbrido Elétrico</i>
WTLC	<i>Worldwide Harmonized Light-Duty Driving Cycle</i>

Sumário

1	INTRODUÇÃO	26
1.1	Objetivo do Trabalho	28
1.2	Histórico	28
1.3	Contribuições do trabalho	29
1.4	Divisão do trabalho	30
2	REVISÃO BIBLIOGRÁFICA	32
2.1	Veículos elétricos	32
2.2	Dinâmica do veículo	34
2.2.1	Dinâmica longitudinal	34
2.2.2	Dinâmica lateral	37
2.2.3	Dinâmica vertical	40
2.2.4	Modelo de pneu	42
2.3	Torque máximo transmissível	44
2.4	Configurações do Veículo	45
2.5	Motores Elétricos	46
2.6	Baterias	47
2.7	Aprendizado de máquinas	51
2.7.1	Máquinas de vetor de suporte	51
2.7.2	Floresta aleatória	52
2.7.3	Redes neurais artificiais	53
2.8	Ciclos de condução	54
2.8.1	Métodos de determinação de ciclos de condução	58
2.9	Sistema de controles em tempo real	59
2.10	Redes neurais artificiais aplicadas em gerenciamento de energia ou potência . .	62
3	GERADOR DE CICLOS DE CONDUÇÃO	65
3.1	Método de desenvolvimento dos ciclos de condução	67
3.2	Algoritmo evolucionário para a geração dos ciclos de condução	67
3.3	Formulação do problema	69
3.4	Ciclos gerados	71
3.5	Ciclo de Treinamento	72
4	MODELO DE REDES NEURAIS ARTIFICIAIS	74
4.1	Modelo de neurônio	74
4.2	Arquitetura da rede neural artificial	77
4.3	Aplicação da rede - Treinamento da rede	78
4.4	Aplicação da RNA em controle de troca de marcha	81

4.5	Implementação da RNA em um microcontrolador	87
5	REDE NEURAL ARTIFICIAL APLICADA AO GERENCIAMENTO DE POTÊNCIA DE VEÍCULOS ELÉTRICOS	89
5.1	Formulação do Problema	90
5.2	Resultados	93
6	SIMULAÇÃO EM TEMPO REAL	105
6.1	Implementação da RNA na simulação HIL	105
6.2	Resultado da Simulação Hardware-in-the-loop	107
7	CONCLUSÃO	110
7.1	Trabalhos futuros	111
7.2	Trabalhos publicados	112
7.2.1	Trabalhos publicados em periódicos	112
7.2.2	Trabalhos publicados em capítulo de livro	114
7.2.3	Trabalhos aceitos e publicados em congressos	114
	Referências Bibliográficas	115

1 INTRODUÇÃO

Os debates em torno das questões ambientais têm ganhado cada vez mais espaço no âmbito da indústria automotiva, devido à preocupação com o aquecimento global e a poluição. Atualmente, na Europa já foram definidos novos padrões obrigatórios da emissão de dióxido de carbono em relação aos dados de emissão de 2021, sendo que a emissão média de toda a frota deverá ser reduzida em 15% até 2025 e em 37,5% até 2030 (ICCT, 2020). No Brasil, o Programa Nacional de Controle de Emissões Veiculares (Proconve) também tem apresentado novas metas e regulamentações ambientais à indústria automotiva com o intuito de limitar a emissão de poluentes, uma vez que os veículos contribuem de forma significativa para degradação da qualidade ambiental (Ministério do Meio Ambiente, 2018).

Os procedimentos para a avaliação das emissões, em veículos rodoviários automotores leves no Brasil, são definidos pela Associação Brasileira de Normas Técnicas (ABNT) e descritos na Norma Brasileira NBR 6601 (ABNT, 2012). A norma estabelece um método para a determinação da quantidade dos gases poluentes emitidos pelo veículo, como hidrocarbonetos totais, monóxido de carbono, óxido de nitrogênio e dióxido de carbono. Essas emissões são mensuradas aplicando um ciclo de condução específico, que simula um veículo em trânsito de vias urbanas (ABNT, 2012). Entretanto, esse ciclo e outros ciclos normatizados podem não representar a realidade local encontrada pelo usuário do veículo, como a intensidade do tráfego, as características do relevo e o próprio comportamento do motorista.

Para tanto, se torna necessário não só o desenvolvimento de novas tecnologias voltadas à mobilidade, visando o aumento da eficiência dos veículos, mas também avaliar essas tecnologias em condições que representem adequadamente a realidade. Logo, visando o desenvolvimento e inovação, além das inúmeras exigências, há uma crescente busca por veículos equipados com motores elétricos, visto que a emissão de poluentes pode ser reduzida de maneira substancial, além do custo operacional desse tipo de veículo ser mais baixo (Verma *et al.*, 2021). Além disso, no Brasil há um crescimento na produção de energia com base em fontes renováveis, alcançando em 2020 a taxa de 74,2% do total produzido, destacando-se a geração fotovoltaica que apresentou um crescimento de 61,1% quando comparada com a geração referente ao ano de 2019 (EPE, 2021).

Observa-se um crescimento na demanda de veículos eletrificados, sendo os veículos elétricos híbridos e puramente elétricos os que mais se destacam, possuindo um mercado já consolidado tanto na Europa quanto nos Estados Unidos da América. No Brasil, a indústria da eletromobilidade ainda é pouco explorada, mas com expectativa de crescimento com a apresentação do projeto de Lei 13.755/2018, que ficou popularmente conhecido como Rota 2030, que prevê o fomento de projetos de pesquisa e desenvolvimento voltados para a área automotiva, estimulando o desenvolvimento de novas tecnologias (Brasil, 2018).

Logo, o presente trabalho visa aproveitar essa demanda por veículos eletrificados no mundo, aliada com o estímulo promovido pelo governo brasileiro, para o desenvolvimento de novas tecnologias voltadas à mobilidade. Dessa maneira, foi desenvolvida uma estratégia de gerenciamento de potência aplicada aos veículos elétricos utilizando aprendizado de máquinas. Esse gerenciador de potência deve ser robusto, conseguindo apresentar um desempenho adequado não só para os ciclos de condução normatizados, mas também para ciclos reais.

Na Figura 1.1 é apresentando um desenho esquemático da proposta do trabalho. Inicialmente é necessário construir um ciclo de condução que seja capaz de representar tanto as condições de direção reais, encontradas por veículos ao trafegarem pelas vias de uma cidade, quanto as exigências presentes nos ciclos normatizados e regulamentados. Para isto, foi necessário desenvolver um gerador de ciclos, utilizando perfis de condução padrões e sinais de velocidade de veículos reais para criar um ciclo de condução de treinamento.

Esse ciclo de treinamento, em conjunto com as características geométricas (bitola, entre-eixo, raio do pneu, etc.) e inerciais (massa, posição do CG, momento de inércia, etc.) do veículo elétrico foram empregados no aprendizado da estratégia de gerenciamento de potência do veículo elétrico. Durante a aprendizagem busca-se encontrar simultaneamente a melhor estratégia e o melhor sistema de potência elétrico para o veículo.

Por fim, a estratégia de gerenciamento de potência foi analisada em uma simulação em tempo real. Dessa maneira, a simulação verifica o desempenho, em condições reais, da estratégia de gerenciamento de potência desenvolvida pelo algoritmo de aprendizagem de máquinas. A estratégia deve conseguir atuar rápido o suficiente para corrigir o comportamento do veículo elétrico, seguindo o ciclo de condução de treinamento ou outro perfil de velocidade desejado.




Figura 1.1: Fluxograma do trabalho proposto.

1.1 Objetivo do Trabalho

O objetivo principal deste trabalho é desenvolver uma estratégia de controle de potência para um veículo elétrico com tração nas quatro rodas, por meio de aprendizado de máquinas. Para garantir que o controle apresente um desempenho adequado, no seu desenvolvimento e configuração, serão utilizados ciclos de condução que representem o comportamento de veículos em condições reais. Outro ponto importante da estratégia de controle é a sua capacidade de atuar em tempo real.

Para tal, este trabalho foi dividido nos seguintes objetivos específicos:

- Desenvolver um algoritmo para a geração de ciclos de conduções.
- Desenvolver um modelo de rede neural artificial com arquitetura totalmente adaptável.
- Implementar o modelo de rede para realizar a estratégia de controle de potência de um veículo elétrico.
- Avaliar a estratégia de controle de potência em condições reais, por meio de uma simulação hardware-in-the-loop.

1.2 Histórico

O Laboratório de Sistemas Integrados (LabSIn) do Departamento de Sistemas Integrados da Faculdade de Engenharia Mecânica da UNICAMP desenvolve pesquisas nas áreas de projeto modular, metodologia de projeto, dinâmica veicular e acessibilidade. O Laboratório tem a tradição no desenvolvimento e estudo de modelos que reproduzem o comportamento dinâmico de veículos, além da análise e validação desses modelos por meio de diversos experimentos. Para apresentar a evolução das pesquisas desenvolvidas pelo LabSIn, foram listados os principais estudos em dinâmica veicular, relacionados com este trabalho e desenvolvidos nos últimos anos.

- Em Eckert (2017), desenvolveu-se uma bancada dinamométrica validar experimentalmente modelos de dinâmicos longitudinais de veículos automotores. Com os atuadores da bancada é possível fornecer torques as rodas do veículo, para emular as resistências ao movimento encontradas no seu movimento. Dessa maneira, pode-se reproduzir as diferentes condições de operação a partir dos ciclos de conduções e avaliar o desempenho do veículo.
- Em Santiciolli (2018), estudaram-se modelos que representam o comportamento de pneus de pequeno porte. A partir desses modelos, foi desenvolvida e construída uma bancada experimental para a obtenção dos parâmetros que modelam um determinado pneu. Dessa maneira, a partir dos resultados experimentais da bancada e de uma otimização baseada em Algoritmo Genético foi possível caracterizar o comportamento de um pneu de pequeno porte.

- Em Bertoti (2018), realizou-se um estudo do comportamento dinâmico da bancada dinamométrica de rolos duplos do Laboratório de Sistemas Integrados da UNICAMP. Durante o estudo, buscou-se descrever o comportamento da bancada por meio de um modelo dinâmico não-linear com quatro graus de liberdade. Com isso, o modelo pode ser implementado em malhas de controle retroalimentados, gerando valores de torques mais próximos da realidade.
- Em Yamashita (2018), apresentou-se um estudo de estratégias de controles aplicadas a correção da trajetória de veículos. Para isso, foi desenvolvido um controle baseado em lógica fuzzy e aplicado a um veículo híbrido. Os parâmetros do controle são otimizados visando reproduzir comportamentos semelhantes para veículos em condições de operações distintas.
- Em Silva (2020), desenvolveu-se uma estratégia de controle por lógica fuzzy para controlar a trajetória, guinada e velocidade de veículos híbridos e elétricos. Os parâmetros do controle foram determinados por meio de uma otimização por algoritmo genético. Posteriormente, o controle foi implementado em um microcontrolador e uma simulação hardware-in-the-loop foi realizada para ser validado.
- Em Lourenço (2020), desenvolveu-se o projeto de uma bancada dinamométrica e um protótipo de veículos/robôs em escala reduzida. Por meio de modelagem computacional, os seus principais componentes foram dimensionados. O funcionamento do conjunto (bancada e protótipo) foi estudado com o auxílio uma simulação dinâmica multifísica em ADAMS/Simulink.
- Em Miranda (2022), realizou-se um estudo da dinâmica planar de veículos elétricos híbridos plug-in e puramente elétricos. Para o gerenciamento de potência foi utilizada uma estratégia de controle por lógica fuzzy, otimizada por um algoritmo de busca multiobjetivo baseado em enxame de partículas (MOPSO - Multi-objective Particle Swarm Optimization).
- Em da Silva (2022), apresentou-se uma otimização dos trens de potência de veículos híbridos utilizando um método de algoritmo genético multiobjetivo. O foco foi minimizar o consumo de combustível, as emissões poluentes, o tamanho da bateria e maximizar o seu estado de saúde. Para o gerenciamento de potência da transmissão, elétrica e a combustão, foi utilizado um controle de lógica fuzzy.

1.3 Contribuições do trabalho

A principal contribuição deste trabalho refere-se ao desenvolvimento de uma rede neural artificial com arquitetura genérica. Um dos desafios das redes neurais é determinar a sua arquitetura ideal, visto que ela deve ser complexa o suficiente para solucionar o problema e, ao mesmo tempo, simples o suficiente para diminuir o tempo de processamento da resposta. Dessa maneira, a proposta desse trabalho, foi desenvolver um modelo de rede neural artificial de mul-

ticamadas, em que a sua arquitetura fosse totalmente genérica, podendo apresentar diversas configurações em sua estrutura.

No desenvolvimento da rede neural artificial com arquitetura genérica, o seu modelo necessitou ser suficientemente adaptável, podendo alterar de forma rápida e simples o seu número de camadas ocultas, o número de neurônios, os pesos das conexões dos neurônios, as funções de ativação de cada neurônio e os seus parâmetros. Desse modo, durante o seu processo de aprendizagem, são avaliadas diversas configurações de arquitetura, com o objetivo de encontrar a mais adequada para o problema proposto.

O treinamento da rede neural artificial, proposto nesse trabalho, é um feito pro meio de um método baseado em um algoritmo evolucionário genético multiobjetivo. Dessa maneira, inicialmente, são definidos objetivos a serem alcançados no treinamento. Posteriormente, redes aleatórias foram geradas, simuladas, avaliadas em relação aos objetivos e armazenadas em um banco de dados. Em seguida, novas redes são geradas a partir da aplicação de operadores genéticos (seleção, cruzamento e mutação) nas redes do banco de dados, de modo que as redes com melhores aptidões apresentam maiores chances de serem selecionadas. Então, as novas redes são avaliadas e arquivadas no banco de dados, repetindo o processo até que os objetivos fossem alcançados e ocorresse a estagnação do processo evolutivo.

1.4 Divisão do trabalho

O presente trabalho é dividido em 7 capítulos. No capítulo 1 foi apresentada uma introdução com as motivações e os objetivos do trabalho, além de uma contextualização.

No capítulo 2 são abordados alguns conceitos relacionados à dinâmica veicular, objetivando principalmente discutir a obtenção dos parâmetros necessários para o estudo e modelagem de um veículo. Também é apresentada uma síntese de aprendizagem de máquinas e as técnicas mais utilizadas. Posteriormente, os principais ciclos de conduções são descritos. Por fim, as principais estratégias de controle aplicadas em tempo real são apresentadas.

No capítulo 3 são apresentadas análises dos ciclos normatizados e ciclos reais, em que são analisadas as acelerações e velocidades que os ciclos são submetidos. Em seguida, um método para a geração de ciclos de condução, baseado em um algoritmo evolucionário, é proposto. Assim, o gerador de ciclos desenvolvido é aplicado para gerar dois ciclos de condução.

No capítulo 4 é detalhado o modelo de rede neural artificial desenvolvido, destacando o modelo de neurônio utilizado na rede, bem como a sua arquitetura e o método de treinamento da rede. Para avaliar o desempenho da rede neural desenvolvida, ela é utilizada para modelar o estado de carga de uma bateria em condições reais. A resposta da rede é comparada com a descarga real da bateria.

No capítulo 5 são descritos os processos de implementação e de treinamento da rede neural artificial genérica no gerenciamento de potência de veículos elétricos. Além disso, os resultados obtidos pela rede são apresentados, avaliando a sua capacidade em seguir o perfil de

velocidade do ciclo de treinamento.

No capítulo 6 são apresentados os resultados alcançados de uma simulação em tempo real da estratégia, obtida no treinamento e implementação da rede em um microcontrolador. Por meio de uma simulação em Hardware-in-the-loop, foi possível validar a ação do gerenciamento de potência desenvolvido.

Por fim, no capítulo 7 são apresentadas as conclusões que podem ser compreendidas a partir deste trabalho, além de sugestões e observações de trabalhos futuros para dar sequência em pesquisas de redes neurais aplicadas à estratégia de gerenciamento de potência.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentada uma revisão de ciclos de conduções, aprendizado de máquinas e controles de veículos em tempo real. Também são abordados conceitos teóricos e uma discussão sobre as forças longitudinais, laterais e verticais, além de uma busca geral de conceitos e parâmetros necessários para o desenvolvimento das simulações dos modelos dinâmicos.


2.1 Veículos elétricos

Os veículos elétricos (VEs), ou veículos puramente elétricos, são veículos que utilizam exclusivamente a energia elétrica para gerar a potência mecânica de tração que movimenta o veículo (Williamson, 2013). A energia elétrica é armazenada em baterias, utilizadas como fonte de alimentação para um ou mais motores elétricos (MEs) acionarem as rodas do veículo. A carga das baterias pode ser feita a partir de fontes não renováveis ou renováveis, normalmente, elas são conectadas à rede elétrica e recarregadas (Das *et al.*, 2021). Por outro lado, é possível utilizar um sistema fotovoltaico (Nicoli *et al.*, 2018) ou um sistema eólico (Raoufat *et al.*, 2018) para alimentar as baterias do VE.


As principais desvantagens do VEs estão associadas com as suas baterias, que apresentam um alto custo, um alto tempo de recarga e autonomia limitada (Ehsani *et al.*, 2018). Entretanto, entre todos os veículos de combustíveis alternativos, os VEs apresentam-se como uma opção viável para melhorar a qualidade do ar, reduzir as emissões de gases poluentes e o uso de óleo derivado de petróleo (Williamson, 2013).

O sistema de potência e transmissão elétrico pode ser dividido em três subsistemas: a propulsão por motor elétrico, fonte de energia e auxiliar (Ehsani *et al.*, 2018). O subsistema de propulsão elétrica é formado pelo conversor eletrônico de potência, pelo motor elétrico, pela transmissão mecânica e pelas rodas motrizes. O subsistema da fonte de energia consiste no conjunto de baterias, no sistema de reabastecimento e no sistema de gerenciamento de energia. Por fim, o sistema auxiliar compreende a fonte de alimentação auxiliar, direção elétrica e o sistema de climatização do veículo.


O subsistema de propulsão pode possuir diversas arquiteturas, que podem apresentar tração apenas em um eixo (traseiro ou dianteiro) do veículo ou tração nos dois eixos (tração nas quatro rodas). As configurações com tração nas quatro rodas apresentam melhor desempenho no controle dinâmico do veículo, quando comparadas às configurações com tração em apenas um eixo, uma vez que permite a ação do controle em mais elementos de forma simultânea (Silva, 2020 e Silva *et al.*, 2022a). Por outro lado, esse tipo de configuração apresenta maior complexidade, com um número maior de componentes, que os sistemas com tração em um eixo. Desse modo, a configuração com tração nas quatro rodas apresenta um desafio maior no controle dinâmico do VE, que deve conciliar a atuação em todos os MEs do veículo.




(a) Configuração 1



(b) Configuração 2



(c) Configuração 3



(d) Configuração 4

Figura 2.1: Tipos de configurações de veículos elétricos.

Neste trabalho, o foco é desenvolver um controle que proporcione o melhor comportamento dinâmico para o veículo, dessa maneira, as configurações mais relevantes de VEs com tração nas quatro rodas serão analisadas. Na Figura 2.1 são apresentadas as principais configurações do sistema de propulsão elétrica em VEs (Eckert *et al.*, 2017). Na primeira configuração, o VE possui quatro MEs acoplados diretamente em cada uma de suas rodas. Na segunda configuração, o VE apresenta dois MEs conectados a diferenciais mecânicos no eixo dianteiro e traseiro. Na terceira configuração, dois MEs são acoplados diretamente nas rodas do eixo traseiro e um ME é conectado a um diferencial mecânico posicionado no eixo dianteiro. Por fim, na quarta configuração, um ME é conectado a um diferencial mecânico no eixo traseiro, enquanto, no eixo dianteiro o VE possui dois MEs acoplados em cada uma das rodas.

Para identificar qual das configurações de VE com tração nas quatro rodas seria a mais adequada, Eckert *et al.* (2017) desenvolveu um estudo comparativo das quatro configurações. O estudo utiliza um processo de otimização, por meio de um algoritmo genético, que determina os MEs e as relações de transmissões de cada configurações, visando maximizar o desempenho do VE e minimizar a descarga da bateria. Na otimização os VEs foram simulados e avaliados por ciclos de condução padrões (NBR 6601, NBR 7024 e US06).

A configuração 1 do sistema de propulsão apresentou a solução com melhor desempenho em reproduzir os ciclos de condução, enquanto a configuração 4 apresentou a solução com maior autonomia (menor descarga de bateria). Por outro lado, a configuração 1 proporcionou a solução com o melhor comprometimento entre autonomia e desempenho. Dessa maneira, para este trabalho, o VE estudado possuirá a transmissão indicada pela configuração 1.

Uma vez definido a arquitetura do sistema de propulsão elétrica que será estudado no VE, inicia-se o desenvolvimento dos seus modelos dinâmicos. No tópico seguinte são abordados os conceitos de dinâmica veicular, indicando os esforços que o VE está submetido durante o seu movimento.

2.2 Dinâmica do veículo

A dinâmica veicular é o seguimento que estuda e analisa as interações entre o veículo, condutor e o ambiente, bem como todas as forças produzidas durante a condução do veículo. Para simplificar e facilitar a sua compreensão, a dinâmica veicular é separada em dinâmica longitudinal, lateral e vertical. Inicialmente, a dinâmica longitudinal do veículo será apresentada, seguida da dinâmica lateral e, por fim, a dinâmica vertical.

2.2.1 Dinâmica longitudinal

Um veículo, deslocando longitudinalmente, é submetido a diversas forças que atuam em sua direção de movimento. Essas forças que produzem o movimento do veículo são a força de tração do pneu F_x [N], a força de resistência ao rolamento R_x [N], a força de resistência devido

ao arrasto aerodinâmica D_A [N], a força devido ao engate de um reboque R_{hx} [N] e a força de resistência ao aclave ou a força devido ao declive da via $W \sin \theta$ [N] (Gillespie, 1992). Um desenho esquemático com as forças que atuam no veículo, durante o deslocamento longitudinal, é mostrado na Figura 2.2.




Figura 2.2: Forças atuando no veículo no plano longitudinal-vertical.

A força de tração do pneu F_x [N] é a força longitudinal gerada na área de contato entre o pneu e a via. Essa força surge devido à variação da velocidade linear do veículo e a velocidade linear no ponto de contato do pneu com o solo, proveniente da velocidade rotacional da roda. Dessa maneira, a variação de velocidades provoca um escorregamento longitudinal no pneu (Pacejka, 2012). No capítulo 2.2.4, esse fenômeno será explicado detalhadamente, apresentando o modelo utilizado para determinar a longitudinal.

A resistência ao rolamento do pneu R_x [N] é uma resistência ao movimento do veículo que ocorre devido à energia perdida na aderência e deformação do pneu ao entrar em contato com o solo. O pneu sofre deformações por toda a superfície de contato durante a rotação da roda, essas deformações provocam uma dissipação de energia devido ao amortecimento interno do material que constitui o pneu (Genta e Morello, 2009). Para baixas velocidades, a resistência ao rolamento é o principal obstáculo ao movimento do veículo e pode ser determinada pelo peso do veículo $W \cos \theta$ [N] perpendicular à direção do movimento multiplicado por um coeficiente de resistência de rolamento f_r , como é apresentado na Equação 2.1.

$$R_x = f_r W \cos \theta \quad (2.1)$$

O coeficiente de resistência de rolamento pode variar devido a diversos parâmetros, como a força normal, a pressão interna, a temperatura de trabalho, a velocidade do veículo V_x [m/s], a área de contato, as dimensões e o material do pneu. No entanto, o parâmetro que possui o maior impacto na determinação do coeficiente de resistência ao rolamento é a velocidade longitudinal do veículo (Gillespie, 1992). Dessa maneira, o coeficiente pode ser estimado pela Equação 2.2.

$$f_r = 0,010(1 + 0,0224V_x) \quad (2.2)$$

Outra força muito impactante na resistência ao movimento é a resistência aerodinâmica, que surge devido ao arrasto aerodinâmico e ao atrito viscoso do veículo com o ar (Genta e Morello, 2009). Para altas velocidades, o arrasto aerodinâmico apresenta a maior influência no desempenho do veículo, bem como determina a sua velocidade máxima (Gillespie, 1992). A resistência aerodinâmica pode ser determinada pela densidade do ar ρ [kg/m³], pelo coeficiente aerodinâmico C_d , pela área frontal projetada do veículo A_f [m²] e pela sua velocidade longitudinal V_x , como indicado na Equação 2.3.

$$D_A = \frac{1}{2}\rho C_d A_f V_x^2 \quad (2.3)$$

Por fim, a resistência devido ao aclone, ou força devido ao declive, é a componente do peso do veículo na direção longitudinal. Essa força ou resistência ocorre devido à inclinação da rampa θ [rad] pela qual o veículo desce ou sobe. Para um angulo de inclinação da rampa negativo, surge uma força favorável ao movimento do veículo, contribuindo positivamente para o movimento longitudinal. Por outro lado, para um angulo de inclinação da rampa positivo, surge uma força de resistência ao movimento, que deve ser superada para que o veículo seja capaz de subir a rampa.

Com todas as forças de resistências ao movimento devidamente definidas, pode-se determinar o desempenho do veículo em aceleração ou desaceleração a_x [m/s²]. Aplicando a 2ª Lei de Newton na direção longitudinal do veículo, é possível obter o somatório de forças, como apresentado na Equação 2.4, em que g a aceleração gravitacional [m/s²].

$$\frac{W}{g}a_x = F_x - R_x - D_A - R_{hx} - W \sin\theta \quad (2.4)$$

Em condições reais, o motorista altera a condição de aceleração ou desaceleração do veículo conforme a sua necessidade. Para isso, o torque aplicado nas rodas do veículo é ampliado ou reduzido, por meio dos comandos nos pedais de aceleração e frenagem. Os ciclos de conduções são uma alternativa para reproduzir a demanda de motoristas ao trafegarem em vias de uma cidade, indicando um perfil de velocidade a ser seguido pelo veículo. Dessa maneira, a aceleração requerida a_{req} [m/s²] para que o veículo altere a sua velocidade V_x [m/s], no instante de tempo t [s], e alcance a velocidade do ciclo V_{cic} [m/s] em um determinado intervalo de tempo Δt [s] pode ser determinada pela Equação 2.5. O intervalo de tempo (passo de itera-

ção) é definido na simulação, quanto menor o intervalo maior será a precisão nos cálculos, em contrapartida, maior será o tempo de processamento da simulação.

$$a_{req}(t) = \frac{V_{cic}(t + \Delta t) - V_x(t)}{\Delta t} \quad (2.5)$$

A partir da aceleração requerida pelo veículo, é possível estimar o torque que os motores elétricos devem empregar nas rodas para que o veículo alcance a velocidade desejada. Dessa maneira, o torque requerido T_{req} [Nm] pelos motores elétricos pode ser calculado em função da aceleração requerida, das forças de resistência ao movimento, das inércias dos motores elétricos I_{MEs} [kgm²] e da inércias do conjunto roda e pneu I_R [kgm²].

$$T_{req} = \left(\frac{W}{g} a_{req} + R_x + D_A + R_{hx} + W \sin \theta \right) R_p + \frac{(I_R + I_{EMs}) a_{req}}{R_p} \quad (2.6)$$

Uma vez compreendido os principais conceitos de dinâmica longitudinal, no capítulo seguinte são apresentados os modelos que caracterizam a dinâmica lateral do veículo, em condições sem e com escorregamento do pneu, evidenciando a influência da geometria do veículo, o torque e a força.

2.2.2 Dinâmica lateral

Para compreender o comportamento dinâmico de um veículo ao realizar uma curva e desenvolver um modelo matemático, inicialmente, o veículo é estudado para baixas velocidades. Para essa condição de condução, a aceleração lateral do veículo é pequena e pode ser considerada nula, consequentemente, as forças laterais e os deslizamentos desenvolvidos nos pneus são pequenos e também podem ser desprezados (Gillespie, 1992).

Na Figura 2.3, é apresentado um desenho esquemático do comportamento de um veículo ao realizar uma curva em baixa velocidade. As trajetórias das rodas do veículo (indicadas pelas linhas tracejadas em vermelho) devem estar tangentes ao centro da curva. Os pneus não apresentam nenhum escorregamento, dessa maneira, o centro da curva localiza-se na projeção do eixo traseiro do veículo. Essa característica geométrica apresentada pelas rodas do veículo é conhecida como geometria de Ackermann.

A Geometria de Ackermann determina os esterçamentos ideais para as rodas do veículo durante a curva, caso não respeitem essa geometria, as rodas entrarão em conflito. Dessa maneira, cada uma das rodas sofrerá algum escorregamento, influenciando no desgaste do pneu significativamente. Por outro lado, caso a geometria de Ackermann seja respeitada, o aumento do ângulo de esterçamento da roda tende a aumento o seu torque auto-alinhante, desse modo, o motorista possui uma sensação natural de realimentação (Genta e Morello, 2009). A partir de uma análise trigonométrica da geometria de Ackerman, é possível determinar os ângulos de esterçamento da roda dianteira interna a curva δ_i [rad] e da roda externa δ_o [rad]. Nas Equações 2.7 e 2.8 são indicados os ângulos de esterçamento ideais para as rodas dianteiras do veículo.




Figura 2.3: Comportamento de um veículo em curva para baixas velocidades.

$$\delta_o = \arctan \left(\frac{L}{R_c + t_{b,f}/2} \right) \quad (2.7)$$

$$\delta_i = \arctan \left(\frac{L}{R_c - t_{b,f}/2} \right) \quad (2.8)$$

Com base Equações 2.7 e 2.8 é possível perceber que quanto maior o entre eixo do veículo L maior serão os ângulos de esterçamento necessário para realizar uma curva com mesmo raio, esse fato explica a dificuldade que veículos com grande entre eixos possuem ao realizar curvas de pequenos raios. Também pode-se observar que quanto maior o tamanho da bitola dianteira do veículo $t_{b,f}$ maior é a diferença entre os ângulos de esterçamento das rodas (interna e externa).

Uma vez compreendido os conceitos relevantes de um veículo em curvas para baixas velocidades, é estudado o seu comportamento para altas velocidades. Nessa condição a aceleração lateral não é pequena e não pode ser desprezada. Desse modo, tanto as forças laterais F_y [N] quanto os ângulos de escorregamentos α [rad] produzidos nos pneus devem ser examinados. Na Figura 2.4, um desenho esquemático do comportamento de um veículo ao realizar uma curva em altas velocidades é apresentado.

No desenho esquemático apresentado na Figura 2.4, o entre eixo do veículo deve ser menor que o raio da curva (Gillespie, 1992). Dessa maneira, com base nas Equações 2.7 e 2.8, os ângulos de esterçamento (δ_i e δ_o) são pequenos. De forma análoga, a diferença entre o ângulo de esterçamento da roda interna e externa à curva é pequena, visto que a bitola do veículo é pequena comparada ao raio da curva. Com isso, é possível simplificar e expressar os estercimentos das rodas como apenas um ângulo δ [rad].




Figura 2.4: Comportamento de um veículo em curva para baixas velocidades.

Pela Figura 2.4, ainda é possível observar que as trajetórias dos pneus (linhas tracejadas em vermelho) não seguem as suas direções longitudinais (linhas tracejadas em preto). Esses desalinhamentos ocorrem devido ao escorregamento produzido nos pneus, chamado de ângulo de deriva do pneu ou escorregamento lateral do pneu α [rad]. O ângulo de deriva de um pneu α_p [rad] pode ser determinado em função da sua velocidade longitudinal $V_{x,p}$ [Nm] e da sua velocidade lateral ($V_{y,p}$), como apresentado na Equação 2.9.

$$\alpha_p = \frac{V_{y,p}}{V_{x,p}} \quad (2.9)$$

Os escorregamentos laterais nos pneus dianteiros α_f [rad] e traseiros α_r [rad] alteram a direção de deslocamento do veículo. Desse modo, o ângulo de esterçamento das rodas pode ser reescrito considerando os escorregamentos dos pneus, como indicado na Equação 2.10.

$$\delta = \frac{L}{R_c} + \alpha_f - \alpha_r \quad (2.10)$$

A direção do vetor velocidade do veículo não está necessariamente alinhado ao seu eixo longitudinal, devido aos escorregamentos dos pneus. Dessa maneira, o veículo não desloca na direção do seu eixo longitudinal. O ângulo determinado pela variação do eixo longitudinal do veículo e o seu vetor velocidade é chamado de ângulo de escorregamento lateral do veículo β [rad], conforme apresentado na Figura 2.5. O ângulo de escorregamento lateral pode ser calculado pela tangente da velocidade lateral do veículo (V_y) dividida pela sua velocidade longitudinal (V_x), como indicado na Equação 2.11 (Jazar, 2008).




Figura 2.5: Ângulo de escorregamento lateral do veículo.

$$\beta = \arctan \left(\frac{V_y + x\dot{\gamma}}{V_x + y\dot{\gamma}} \right) \quad (2.11)$$

Tendo compreendido os conceitos de dinâmica lateral, no tópico seguinte é abordada a dinâmica vertical e sua influência na transferência de carga que afeta diretamente a força vertical a qual a roda é submetida.

2.2.3 Dinâmica vertical

Na dinâmica vertical, para este trabalho, serão consideradas apenas as influências da transferência de carga na aceleração, desaceleração e no comportamento em curvas do veículo. Dessa maneira, o modelo desenvolvido não estuda o veículo passando por obstáculos verticais, como lombadas e depressões.

Durante a aceleração e desaceleração do veículo, há uma transferência da carga (força vertical) atuando sobre cada um dos pneus dianteiros e traseiros. Essa transferência de carga é provocada devido ao braço de alavanca gerado pela altura do CG do veículo. Dessa maneira, quanto maior a altura do CG h_{cg} [m] maior será a transferência de carga experimentada pelo veículo. Na Figura 2.6 é apresentada uma representação da transferência de carga do veículo longitudinalmente.

A transferência de carga longitudinal $\Delta F_{z,x}$ [N] ocorre devido à inclinação da estrada, a aceleração e a desaceleração de veículo (Genta e Morello, 2009). A transferência ocorre do eixo dianteiro para o eixo traseiro na aceleração, por outro lado, se dá do eixo traseiro para o dianteiro na desaceleração. Quanto maior o entre eixo do veículo L [m] menor será a transferência de carga gerada no veículo. Na Equação 2.12, o cálculo da transferência de carga longitudinal é apresentado.




Figura 2.6: Transferência de carga do veículo longitudinalmente.

$$\Delta F_{z,x} = \frac{Wh_{cg}a_x + Wh_{cg}\sin(\theta)}{2L} \quad (2.12)$$

Analogamente a transferência de carga longitudinal, ao realizar uma curva, há transferências de carga lateral no eixo dianteiro e traseiro, que ocorre das rodas internas para as rodas externas à curva (Genta e Morello, 2009). As transferências de carga do eixo dianteiro $\Delta F_{z,f}$ [N] e do traseiro $\Delta F_{z,r}$ [N] são determinadas pela força lateral, a geometria do veículo e a altura do CG h_{cg} [m], como indicado nas Equações 2.13 e 2.14.

$$\Delta F_{z,f} = (F_{y,f} + F_{y,r}) \frac{h_{cg}b}{2Lt_{b,f}} \quad (2.13)$$

$$\Delta F_{z,r} = (F_{y,f} + F_{y,r}) \frac{h_{cg}a}{2Lt_{b,r}} \quad (2.14)$$

Com as transferências de cargas devidamente determinadas, é possível calcular a carga em cada um dos pneus do veículo em função da distância percentual do CG d_{CG} , em relação ao eixo dianteiro b/L . Dessa maneira, as cargas do eixo dianteiro e traseiro são definidas pelas Equações 2.15 e 2.16, respectivamente.

$$F_{z,1,2} = \frac{W\cos(\theta)d_{cg} - \Delta F_{z,x} \pm \Delta F_{z,f}}{2} \quad (2.15)$$

$$F_{z,3,4} = \frac{W\cos(\theta)(1 - d_{cg}) + \Delta F_{z,x} \pm \Delta F_{z,r}}{2} \quad (2.16)$$

2.2.4 Modelo de pneu

Para compreender o comportamento dinâmico da interação do pneu com o solo, diversos modelos lineares e não-lineares foram desenvolvidos. Conforme a precisão exigida, o modelo pode levar em consideração vários parâmetros como a deformação do pneu, a sua pressão interna, a carga submetida, a sua velocidade angular, entre outros.

De modo geral, os modelos lineares são os mais utilizados, devido à simplicidade que eles oferecem para a modelagem do veículo. Entretanto, para obter um comportamento mais preciso e adequado do veículo, neste trabalho será implementado a fórmula mágica, que expressa o modelo semiempírico proposto por Pacejka (2012). Esse modelo, visa ajustar as curvas das forças e momentos atuantes no pneu, para diversas condições experimentais. As equações são conhecidas como fórmula mágica, utilizada para simular e caracterizar os esforços produzidas na área de contato do pneu com o solo, com base nos escorregamentos no pneu.

Na Figura 2.7 é apresentado detalhadamente o comportamento do dinâmico do pneu, gerado pelo deslocamento longitudinal do veículo. O ponto P representa o centro de rotação do pneu em rolagem livre, no momento em que nenhum torque de tração ou frenagem é aplicado na roda. A distância entre o centro do pneu e o ponto P define o raio efetivo do pneu R_p [m] (determinado experimentalmente), que difere do seu raio geométrico R_g [m] (não deformado).




Figura 2.7: Detalhamento do comportamento dinâmico do pneu descrito no modelo de Pacejka.

Com a aplicação de um torque de tração ou frenagem na roda, surge no ponto P uma velocidade relativa de escorregamento $V_{sx,p}$ [m/s] e um escorregamento longitudinal. A velocidade relativa é calculada pela diferença entre a velocidade longitudinal V_x [m/s] e a velocidade tangencial do pneu, determinada pela rotação do pneu Ω_p [rad/s] e o seu raio efetivo R_p [m], como indicado na Equação 2.17.

$$V_{sx,p} = V_x - \Omega_p R_p \quad (2.17)$$

O escorregamento longitudinal κ_x [%] é determinado pela relação entre a velocidade relativa de escorregamento e a velocidade longitudinal, como indicado na Equação 2.18.

$$\kappa_x = -\frac{V_x - \Omega_p R_p}{V_x} \quad (2.18)$$

A força de tração do pneu F_x [N] é a força longitudinal gerada na área de contato entre o pneu e a via. Essa força é produzida devido ao escorregamento longitudinal κ_x [%] apresentado pelo pneu, que surge devido à variação de velocidade longitudinal do veículo V_x [m/s] e a velocidade do pneu, determinada pela velocidade angular da roda ω [rad/s] e pelo raio do pneu R_p [m] (Pacejka, 2012).

A força longitudinal pode ser determinada em função dos parâmetros do pneu, formado pelo fator de rigidez B_x , o fator de forma C_x , o valor de pico D_x , o fator de curvatura E_x , o incremento horizontal S_{h_x} e o incremento vertical S_{v_x} (Pacejka, 2012). O cálculo da força longitudinal é apresentado na Equação 2.19, em que i representa cada pneu do veículo. Os parâmetros do pneu são obtidos conforme indicado na Equação 2.20, na qual b_0 a b_{10} são coeficientes empíricos, obtidos experimentalmente (Bakker *et al.*, 1989).

$$F_{x,i}(\kappa_{x,i}) = D_x \sin \left(C_x \arctan \left(B_x (1 - E_x) (\kappa_{x,i} + S_{h_x}) + E_x \arctan(B_x (\kappa_{x,i} + S_{h_x})) \right) \right) + S_{v,x} \quad (2.19)$$

$$\begin{aligned} C_x &= b_0 \\ D_x &= b_1 F_{z,i}^2 + b_2 F_{z,i} \\ E_x &= b_6 F_{z,i}^2 + b_7 F_{z,i} + b_8 \\ B_x &= \frac{(b_3 F_{z,i}^2 + b_4 F_{z,i}) e^{-b_5 F_{z,i}}}{C_x D_x} \\ S_{h,x} &= b_9 F_{z,i} + b_{10} \\ S_{v,x} &= 0 \end{aligned} \quad (2.20)$$

A fórmula mágica expressa a força lateral F_y como uma função dos parâmetros do pneu, conforme apresentado na Equação 2.21 (Bakker *et al.*, 1989), similar ao caso longitudinal apresentado pela Equação 2.19. Na Equação 2.22 são apresentados os cálculos dos parâmetros, em que b_0 a b_{13} são coeficientes empíricos e Θ [rad] representa o ângulo de cambagem do pneu.

$$F_{y,i}(\alpha_i) = D_y \text{sen} \left(C_y \arctan \left(B_y (1 - E_y) (\alpha_i + S_{h,y}) \right. \right. \\ \left. \left. + E_y \arctan(B_y (\alpha_i + S_{h,y})) \right) \right) + S_{v,y} \quad (2.21)$$

$$\begin{aligned} C_y &= b_0 \\ D_y &= b_1 F_{z,i}^2 + b_2 F_{z,i} \\ E_y &= b_6 F_{z,i} + b_7 \\ B_y &= \frac{b_3 \text{sen} \left(2 \arctan \left(\frac{F_{z,i}}{b_4} \right) \right) \left(1 - b_5 |\Theta| \right)}{C_y D_y} \\ S_{h,y} &= b_8 \Theta + b_9 F_{z,i} + b_{10} \\ S_{v,y} &= b_{11} \Theta F_{z,i} + b_{12} F_{z,i} + b_{13} \end{aligned} \quad (2.22)$$

Por fim, o momento de alinhamento do pneu M_z [Nm] pode ser determinado pela Equação 2.23 (Pacejka, 2012). Os parâmetros do pneu são calculados com os coeficientes empíricos b_0 a b_{13} e com a Equação 2.24.

$$M_{z,i}(\alpha_i) = D_z \text{sen} \left(C_z \arctan \left(B_z (1 - E_z) (\alpha_i + S_{h,z}) \right. \right. \\ \left. \left. + E_z \arctan(B_z (\alpha_i + S_{h,z})) \right) \right) + S_{v,z} \quad (2.23)$$

$$\begin{aligned} C_y &= b_0 \\ D_y &= b_1 F_{z,i}^2 + b_2 F_{z,i} \\ E_y &= \frac{b_6 F_{z,i}^2 + b_7 F_{z,i} + b_8}{(1 - b_{13} |\Theta|)} \\ B_y &= \frac{(1 - b_{12} |\Theta|) (b_3 F_{z,i}^2 + b_4 F_{z,i}) e^{-b_5 F_{z,i}}}{C_y D_y} \\ S_{h,y} &= b_9 \Theta \\ S_{v,y} &= (b_{10} F_{z,i}^2 + b_{11} F_{z,i}) \Theta \end{aligned} \quad (2.24)$$

2.3 Torque máximo transmissível

Um dos fatores limitantes de desempenho em aceleração do veículo é o torque máximo transmissível na área de contato do solo com o pneu. Essa limitação ocorre devido à capacidade de tração e frenagem do pneu em um determinado solo (Genta e Morello, 2009). Dessa maneira, o torque requerido pelas rodas deve ser restringido pelo torque máximo transmissível.

O torque máximo transmissível no contato do pneu com o solo é determina em função da aceleração gravitacional g [m/s²], do coeficiente de atrito no contato pneu com o solo μ , da massa do veículo M [kg], do seu entre eixo L [m], da posição longitudinal do seu centro de gravidade e da sua altura h_{cg} [m]. Assim, o cálculo do torque máximo transmissível para o eixo dianteiro $T_{f,max}$ [N] e para o eixo traseiro $T_{r,max}$ [N] é apresentado, respectivamente, na Equação 2.25 e 2.26.

$$T_{f,max} = \mu \left(\frac{Mgc}{2L} - \frac{Mh_{cg}a_x}{2L} \right) R_P \quad (2.25)$$

$$T_{r,max} = \mu \left(\frac{Mgc}{2L} + \frac{Mh_{bg}a_x}{2L} \right) R_P \quad (2.26)$$

2.4 Configurações do Veículo

Para este trabalho serão estudados veículos que apresentam motores elétricos em seu sistema de geração de potência. Os parâmetros geométricos e de inércia do veículo utilizado como referência para o modelo dinâmico são apresentados na Tabela 2.1 (Genta e Morello, 2009). Os parâmetros do pneu são mostrados na Tabela 2.2 (Genta e Morello, 2009).

Tabela 2.1: Parâmetros do veículo (Genta e Morello, 2009).

Parâmetros	Valores
Bitola dianteira $t_{b,f}$	1,49 m
Bitola traseira $t_{b,r}$	1,48 m
Raio do pneu R_p	0,29 m
Massa do veículo M	1150 kg
Entre-eixo L	2,66 m
Distância do CG ao eixo traseiro c	1,86 m
Distância do CG ao eixo dianteiro b	0,80 m
Distância percentual do CG em relação ao eixo traseiro d_{cg}	0,70
Altura do CG h_{cg}	1,48 m
Rigidez da suspensão dianteira $K_{\phi,f}$	10 kN/m
Rigidez da suspensão traseira $K_{\phi,r}$	10 kN/m
Momento de inércia de guinada do veículo I_z	1850 kgm ²
Momento de inércia do conjunto roda e pneu kgm ² I_R	0,50 kgm ²
Coeficiente de arrasto aerodinâmico C_d	0,46
Coeficiente de resistência ao rolamento f_r	0,01
Área frontal projetada do veículo A_f	1,8 m ²

Tabela 2.2: Parâmetros de Pacejka do pneu (Genta e Morello, 2009).

Parâmetros	Fórmula mágica		
	F_x	F_y	M_z
b_0	1,65	1,65	$6,80 \cdot 10^{-2}$
b_1	-7,61	-34,0	4,41
b_2	$1,12 \cdot 10^3$	$1,25 \cdot 10^3$	1,36
b_3	$-7,36 \cdot 10^{-3}$	$3,04 \cdot 10^3$	4,09
b_4	$1,44 \cdot 10^2$	12,8	-3,28
b_5	$-7,66 \cdot 10^{-2}$	$5,01 \cdot 10^{-3}$	0,25
b_6	$-3,86 \cdot 10^{-3}$	$-2,11 \cdot 10^{-2}$	0,00
b_7	$8,50 \cdot 10^{-2}$	0,77	$-7,92 \cdot 10^{-2}$
b_8	$7,57 \cdot 10^{-2}$	0,00	0,00
b_9	$2,36 \cdot 10^{-2}$	0,00	0,00
b_{10}	$2,36 \cdot 10^{-2}$	0,00	0,00
b_{11}	—	0,00	0,00
b_{12}	—	0,00	0,00
b_{13}	—	0,00	0,00

2.5 Motores Elétricos

Com o modelo dinâmico do veículo devidamente determinando, bem como os parâmetros do veículo que serão utilizados, é necessário entender o comportamento e o funcionamento dos motores elétricos. Os parâmetros de projeto que definem a curva de torque do motor elétrico nas rodas do veículo elétrico são definidos durante o treinamento da rede neural, com o objetivo de obter os sistemas de acionamento eletrificado mais adequados para o gerenciamento de potência. Este método foi implementado em trabalhos anteriores, nos quais uma curva genérica de torque foi ajustada pelo procedimento de otimização e definida conforme o torque máximo do motor elétrico T_{ME} [Nm] e velocidade ω_{ME} [rad/s] na fase de torque constante (Eckert *et al.*, 2022b; Miranda *et al.*, 2022). Neste sentido, o torque T_P [Nm] e a velocidade ω_P [rad/s] em fase de potência constante podem ser determinados pela Equação 2.27 e Equação 2.28, respectivamente. No ponto de torque nulo da curva de desempenho, a velocidade máxima do motor elétrico ω_{max} é definida por regressão linear.

$$T_P = 0,3T_{ME} \quad (2.27)$$

$$\omega_P = \frac{T_{ME}\omega_{ME}}{T_P} \quad (2.28)$$

Além disso, os dados de referência para o mapa de eficiência de motores elétricos foram baseados em procedimentos experimentais que foram realizados em um teste de bancada de volante instrumentado descrito em um estudo publicado (Yamashita *et al.*, 2018; Eckert *et al.*, 2022b). A eficiência do motor elétrico η_{ME} [%] para cada condição de operação (torque

e rotação) é apresentada no mapa de eficiências da Figura 2.8a. Para determinar a eficiência do inversor η_{inv} [%], com base no ponto de operação do ME, é realizado uma interpolação do mapa de eficiência apresentado na Figura 2.8b.




Figura 2.8: Mapas de eficiências do motor elétrico e do inversor.

A massa do sistema de propulsão elétrica (ME e inversor) M_{ME} [kg] e a sua inércia I_{ME} [kgm²] são determinadas com base em dados de especificações comerciais reais de motores usados em veículos híbridos, apresentados na Tabela 2.3. Portanto, a massa e a inércia são obtidas a partir da potência do ME, utilizando um método de interpolação polinomial.

Tabela 2.3: Potência, inércia e massa de motores elétricos comerciais.

Potência elétrica [kW]	Massa M_{ME} [kg]	Inércia I_{ME} [kgm ²]
5	11,0	0,10
7	13,4	0,13
12	21,4	0,20
20	39,0	0,24
30	61,0	0,30

2.6 Baterias

As baterias são os componentes do veículo responsáveis por armazenar a energia elétrica utilizadas pelos MEs. Para este trabalho, serão utilizadas baterias de íon-lítio, visto que se apresentam como uma solução mais viável para VEs, permitindo cargas e descargas mais rápidas que as baterias de chumbo-ácido e as de níquel-hidreto metálico (Williamson, 2013). A vida útil das baterias de íon-lítio pode ser uma desvantagem, entretanto, se gerenciadas em condições adequadas, é possível prolongar consideravelmente a sua de vida útil (Williamson, 2013).

Para analisar o comportamento da bateria de íon-lítio, é utilizado o modelo presente no bloco de baterias genéricas disponível no ambiente computacional Simulink™ (MathWorks, 2022). Com base nas propriedades da bateria, essa ferramenta consegue simular o comportamento de diversas baterias recarregáveis (MathWorks, 2022).

A corrente da bateria I_{bat} [A], requerida pelo trem de força do veículo, pode ser definida em função dos torques dos motores elétricos T_{EM} [Nm], das velocidades dos motores elétricos ω_{ME} [rad/s], eficiência do motor elétrico η_{ME} , eficiência do inversor η_{inv} e a tensão real da bateria V_{bat} [V], como apresentado pela Equação 2.29 (Silva *et al.*, 2021).

$$I_{bat} = \frac{2T_{ME,f}\omega_{ME,f}}{\eta_{ME,f}\eta_{inv,f}V_{bat}} + \frac{2T_{ME,r}\omega_{ME,r}}{\eta_{ME,r}\eta_{inv,r}V_{bat}} \quad (2.29)$$

A demanda de corrente dos motores elétricos não pode ultrapassar a corrente máxima de descarga permitida pela bateria. A corrente máxima de descarga I_{max} [A] é determinada pela potência específica da bateria P_E [W/kg] (300 W/kg para baterias de íons de lítio), massa da bateria M_{bat} [Kg] e tensão V_{bat} [V], conforme indicado na Equação 2.30 (Eckert *et al.*, 2022b).

$$I_{max} = \frac{P_E M_{bat}}{V_{bat}} \quad (2.30)$$

O estado de carga de uma bateria SoC [%] é parâmetro responsável por indicar a sua capacidade disponível. Para determinar o estado de carga em um determinado momento, o modelo da bateria utiliza a corrente da bateria I_{bat} [A], a sua capacidade Q_{bat} [Ah] e o seu estado de carga inicial SoC_0 [%], como indicado na Equação 2.31 (MathWorks, 2022).

$$SoC(t) = SoC_0 - \left(\frac{1}{Q_{bat}} \int_0^t I_{bat}(t) dt \right) 100 \quad (2.31)$$

A profundidade de descarga DoD [%] pode ser determinada em função do estado de carga da bateria, como apresentado na Equação 2.32.

$$DoD(t) = 100 - SoC(t) \quad (2.32)$$

Quando a bateria sofre descargas profundas, ou seja, o seu estado de carga se aproxima de zero, o número de ciclos de carga e descarga da bateria é severamente reduzido, diminuindo a sua vida útil (Fuhs, 2008). Dessa maneira, para evitar descargas excessivas e prolongar a vida útil da bateria, o valor mínimo para o estado de carga SoC deve ser de 40% na simulação (Correa *et al.*, 2015; da Silva, 2022).

A tensão dinâmica da bateria é determinada conforme o princípio do modelo de bateria de Shepherd para baterias de íon-lítio (Shepherd, 1965; MathWorks, 2022). Dessa maneira, a tensão da bateria V_{bat} [V] é calculada pela tensão constante do circuito equivalente da bateria E_0 [V], pela constante de polarização K_B [V/Ah], pela corrente elétrica da bateria I_{bat} [A], pela capacidade nominal da bateria Q_{nom} [Ah], pela corrente dinâmica em baixa frequência, I^* [A],

pela amplitude da zona exponencial A_B [V] e pela capacidade exponencial B_B [Ah⁻¹], como indicado na Equação 2.33 e 2.34 (da Silva, 2022).

$$V_{bat}^{(I^* < 0)} = E_0 - K_B \left(\frac{Q_{nom}}{I_{bat}t - 0,1Q_{nom}} \right) I^* - K_B \left(\frac{Q_{nom}}{Q_{nom} - I_{bat}t} \right) I_{bat}t + A_B e^{-B_B I_{bat}t} \quad (2.33)$$

$$V_{bat}^{(I^* > 0)} = E_0 - K_B \left(\frac{Q_{nom}}{Q_{nom} - I_{bat}t} \right) I^* - K_B \left(\frac{Q_{nom}}{Q_{nom} - I_{bat}t} \right) I_{bat}t + A_B e^{-B_B I_{bat}t} \quad (2.34)$$

A estimativa da vida útil de uma bateria, assim como avaliar a sua degradação, é um dos grandes desafios encontrado nos modelos de previsão do comportamento de baterias. Dessa maneira, para estimar o estado de saúde da bateria será utilizado o modelo de envelhecimento de baterias íon-lítio proposto por Motapon *et al.* (2020). O modelo tem uma característica genérica, podendo ser aplicado em diversas configurações de baterias íon-lítio. Entretanto, o modelo não é adequado para métodos de identificação de parâmetros, devido ao custo computacional empregado na sua solução.

Um ciclo completo da bateria pode ser definido pelo processo de descarga total da bateria ($SoC = 0\%$) seguido da sua recarga absoluta ($SoC = 100\%$). Para cada bateria existe um valor O_c que representa o número máximo de ciclos completos que ela pode ser submetida. Entretanto, em condições reais, a bateria nem sempre sofrerá descarga e carga completa, dessa maneira, a vida útil da bateria é avaliada com base em um número equivalente ciclos. Para cada ciclo de descarga e carga há um impacto na capacidade da bateria, provocando a sua degradação. Dessa maneira, para o k -ésimo ciclo equivalente, é possível determinar um índice de degradação da bateria ϵ (em função da profundidade de descarga DoD e número máximo de ciclos da bateria para o final de sua vida O_e). O cálculo do índice de degradação da bateria é apresentado na Equação 2.35

$$\epsilon(k) = \epsilon(k-1) + \frac{0,5}{O_e(k-1)} \left(2 - \frac{DoD(k-2) + DoD(k)}{DoD(k-1)} \right) \quad (2.35)$$

O número máximo de ciclos para o fim da vida da bateria O_e é determinado pela Equação 2.36. O número máximo de ciclos completos é indicado por O_e , o fator de estresse devido à descarga da bateria representado por ξ , a constante de Arrhenius denotada por Ψ , a temperatura ambiente de referência expressa por T_{ref} [K] e a temperatura ambiente indicada por T_{amb} [K], definida para este trabalho como constante e igual a 293,15 K. A corrente elétrica média durante o ciclo equivalente é expressa por I_C^a [A] para a carga da bateria e por I_C^a [A] para a descarga. Por fim, o fator de estresse devido à corrente é indicado por γ_C para carga e por γ_D para a descarga.

$$O_e(k) = O_c \left(\frac{DoD(k)}{100} \right)^\xi \left(I_D^a(k) \right)^{-\gamma_D} \left(I_C^a(k) \right)^{-\gamma_C} \exp \left(- \Psi \left(\frac{1}{T_{ref}} - \frac{1}{T_{amb}(k)} \right) \right) \quad (2.36)$$

Com o índice de degradação da bateria ϵ , a capacidade da bateria no início da vida útil Q_{BOL} [Ah] (BOL - *Beginning of Life*) e a capacidade da bateria no fim da vida útil Q_{EOL} [Ah] (EOL - *End of Life*) é possível determinar a sua capacidade Q_k para um k -ésimo ciclo equivalente. O cálculo da capacidade é indicado na Equação 2.37.

$$Q_k(k) = Q_{BOL} - \epsilon(k)(Q_{BOL} - Q_{EOL}) \quad (2.37)$$

O estado de saúde da bateria SoH [%] será o parâmetro utilizado para avaliar a degradação da bateria. Esse parâmetro é determinado pela razão entre a capacidade atual da bateria Q_k e a sua capacidade no início da vida útil Q_{BOL} , como apresentado na Equação 2.38. A bateria atinge o fim da vida útil quando a sua capacidade de descarga atinge 80% da capacidade da bateria no começo da vida útil ($SoH = 80\%$ ou $\epsilon = 0$), conforme é orientado pela norma ISO 12405-2 (ISO, 2012).

$$SoH(k) = \frac{Q_k(k)}{Q_{BOL}} \quad (2.38)$$

Durante as simulações realizadas no treinamento, as baterias do VE sofrem descargas ao realizar o ciclo de condução de treinamento. Dessa maneira, após cada simulação é realizado um processo de recarga da bateria. Então, o perfil de corrente elétrica produzido pela descarga e carga forma um ciclo de operação da bateria. Para avaliar a degradação da bateria uma simulação de ciclagem é realizada, a bateria é submetida ao ciclo de operação por 3000 horas (Eckert *et al.*, 2022b). Por fim, ao final da simulação o seu estado de saúde da bateria SoH é determinado e utilizado para orientar o processo de treinamento Silva *et al.*, 2021.

A massa da bateria M_{bat} [kg] é o fator mais importante para avaliar a relação entre peso/custo do sistema e a autonomia do veículo. Ela pode ser calculada em função da tensão nominal da bateria V_{nom} [V], capacidade nominal Q_{nom} [Ah] e energia específica S_E [Wh/kg], considerada aproximadamente 150 Wh/kg para baterias de íon-lítio, como apresentado na Equação 2.39.

$$M_{bat} = \frac{V_{nom} Q_{nom}}{S_E} \quad (2.39)$$

Por fim, a massa total do sistema elétrico do veículo M_{SE} [kg] pode ser determinada pela soma da massa da bateria M_{bat} e da massa dos MEs e inversores M_{ME} , como indicado na Equação 2.40.

$$M_{SE} = M_{bat} + M_{ME} \quad (2.40)$$

Uma vez compreendido os conceitos fundamentais dos componentes elétricos do veículo, no capítulo seguinte é apresentado um estudo dos principais métodos de aprendizado de máquinas, buscando entender as suas aplicações e limitações.

2.7 Aprendizado de máquinas

A aprendizagem de máquina pode ser definida como a programação de computadores para otimizar um critério de desempenho, utilizando dados de experiências anteriores ou exemplos (Alpaydin, 2014). Dessa maneira, a partir de um modelo definido, um algoritmo de aprendizado é executado, buscando otimizar os seus parâmetros. Essa otimização é feita com base em dados de treinamento ou experiências anteriores. O modelo pode ser preditivo para realizar previsões no futuro, ou descritivo para obter conhecimento dos dados, ou ambos (Alpaydin, 2014).

O aprendizado de máquina usa a teoria da estatística na construção de modelos matemáticos, dessa maneira, ela tem o objetivo de fazer inferências a partir de uma amostra de dados (Mohri *et al.*, 2018). Para isto, são necessários algoritmos eficientes na resolução do problema de otimização, processando e armazenando a grande quantidade de dados da aprendizagem. Posteriormente, o modelo e seus parâmetros definidos devem conseguir realizar inferências com exatidão (Alpaydin, 2014).

Existem basicamente três tipos de algoritmos de aprendizagem de máquinas: aprendizagem supervisionada, não supervisionada e por reforço (Russell e Norvig, 2021). No método supervisionado, o algoritmo recebe um conjunto de dados classificados e após o aprendizado determina a classificação de novas entradas. Por outro lado, no método não supervisionado, o algoritmo recebe um conjunto de dados sem classificação e encontra padrões neles. Por fim, o algoritmo de reforço interage com o ambiente e recebe recompensas por cada ação tomada.

Para alguns casos é possível desenvolver uma aprendizagem semi-supervisionada, que consiste em uma combinação do sistema supervisionado e não supervisionado (Russell e Norvig, 2021). Dessa maneira, o algoritmo recebe dados classificados e não classificados. Na aprendizagem, busca-se categorizar os dados em função dos seus padrões e das classificações inicialmente definidas (Mohri *et al.*, 2018).

2.7.1 Máquinas de vetor de suporte

O método de máquina de vetores de suportes (MVS), do inglês *Support Vector Machine*, é um método de aprendizagem supervisionada, que pode ser utilizado para mapear a relação complexa das entradas com a saída de sistemas não lineares. As MVSs classificam os dados com o auxílio de um ou mais hiperplanos, que definem a fronteira de separação máxima dos pontos de cada classe (Alpaydin, 2014).

Na Figura 2.9 é apresentado um exemplo de aplicação do método de MVS, em que deseja classificar os dados em dois grupos (triângulos verdes e círculos vermelhos). O hiperplano é representado pela linha contínua azul, que delimita os dois conjuntos de dados. Quanto maior a distância dos pontos ao hiperplano mais confiável será a classificação dos dados (Alpaydin, 2014). Essa distância é conhecida como margem máxima de separação (delimitada pelas linhas tracejadas). Dessa maneira, o objetivo da MVS é encontrar um hiperplano com a maior margem possível, aumentando a possibilidade de novos dados serem classificados corretamente (Russell e Norvig, 2021).




Figura 2.9: Exemplo de aplicação do método de máquina de vetor suporte.

O separador de margem máximo determinado pelo MVS, facilita a generalização de diversos problemas. Além disso, apesar de o hiperplano de separação ser linear, ele tem a capacidade de incorporar os dados em um espaço de dimensão superior, por meio de funções de kernel não lineares (Russell e Norvig, 2021). Os MVSs não são paramétricos, pois o hiperplano é determinado por pontos de referência, não por um conjunto de parâmetros. Entretanto, ele armazena apenas os pontos mais próximos do hiperplano, dessa maneira, os outros pontos podem ser descartados. Portanto, esse método possui a flexibilidade de representar funções complexas e a capacidade de generalização do problema (Mohri *et al.*, 2018).

2.7.2 Floresta aleatória

O método da floresta aleatória (FA), do inglês *Random Forest*, é um método de aprendizagem supervisionada, que pode ser utilizada na classificação e regressão de dados (Russell e Norvig, 2021). As FAs utilizam diversas árvores de decisão, treinadas cada uma por um subconjunto de dados, em que o objetivo principal é variar aleatoriamente as escolhas dos parâmetros (atributos). Cada ramificação da floresta recebe uma amostra aleatória de atributos e determina qual deles fornece o maior ganho de informação (Alpaydin, 2014). Esse processo permite que a FA seja mais robusta, garantindo a capacidade de generalização do problema.




Figura 2.10: Exemplo do método da floresta aleatória.

Uma representação visual da FA é apresentada na Figura 2.10, em que diversas árvores de decisão são utilizadas para chegar a um resultado. Cada árvore de decisão representa um classificador tendencioso, que possui conhecimento do sobre o problema geral baseado no sub-conjunto utilizado no processo de treinamento. Dessa maneira, para uma certa entrada, cada árvore indicará uma decisão. A partir destas decisões a FA determinará a resposta final, podendo ser o valor que mais se repete (no caso de classificação) ou a média dos valores (no caso da regressão). Ainda, existe a possibilidade de atribuir um peso para cada uma das árvores, determinando a importância de cada uma delas na decisão final da FA.

2.7.3 Redes neurais artificiais

O método de redes neurais artificiais (RNA), do inglês *Artificial Neural Network*, é um método de aprendizagem supervisionada inspirado em redes neurais biológicas. A RNA é formada por diversos elementos conhecidos como neurônios, conectados entre si e responsáveis por processar informações (Haykin, 2005). Cada neurônio possui um estado interno de atividade específico, que reage com as suas entradas.

A ideia deste método é treinar redes com caminhos de computação longos, permitindo que todas as variáveis de entrada interajam entre-si de maneira complexa (Russell e Norvig, 2021). Assim, essas redes podem ser aplicadas a diversos problemas não lineares e com alta complexidade.

A RNA cria redes entre as entradas e saídas com uma ou várias camadas conectadas, essas camadas fornecem características não lineares para o método (Alpaydin, 2014). As ligações entre os neurônios de cada camadas são realizadas por pesos, que podem ser em uma única

direção ou em ambas as direções. No caso em que há retroalimentação (ambas as direções), a saída dos neurônios de uma camada influenciam na resposta dos neurônios da camada anterior. Um exemplo das camadas de uma RNA é apresentada na Figura 2.11.




Figura 2.11: Exemplo do método de redes neurais.

Durante o processo de aprendizagem do método RNA, procura-se determinar os melhores valores dos pesos, que representam as ligações entre os neurônios das camadas (Russell e Norvig, 2021). Os valores de entrada do problema são propagados pelas camadas da RNA até a camada de saída. Os valores obtidos na saída são comparados com os valores desejados, determinando um erro de saída da rede. Esse erro alimenta a RNA com a intenção de ajustar os pesos para que na iteração seguinte o erro de saída diminua.

2.8 Ciclos de condução

Para avaliar a conformidade dos padrões de emissões de veículos são realizados testes padronizados, conhecidos como ciclos de testes de condução ou ciclo de direção (Barlow, 2009). Esses ciclos visam reproduzir o comportamento característico de veículos trafegando em vias reais. Um ciclo é definido por uma sequência de pontos no tempo, em que cada ponto pode definir uma velocidade de referência que o veículo analisado deve seguir, ou uma rotação e um torque a ser seguido pelo motor. O perfil de inclinação da via em alguns casos também pode ser fornecido, para uma análise mais detalhada (Giakoumis, 2017).

A principal vantagem dos ciclos de conduções é o fato de ser um método padronizado para medir as emissões de poluentes e o consumo de combustível (Barlow, 2009). Outra vantagem dos ciclos é a possibilidade de comparar diferentes veículos e motores.

Um dos ciclos mais relevantes para testar a conformidade das emissões de veículos motorizados é o ciclo FTP-75 (*Federal Test Procedure at urban driving*). Esse ciclo foi desenvolvido nos Estados Unidos na década de 70, para representar a direção típica no centro de Los Angeles em horário de pico. Para isso, foi utilizada simulação de Monte Carlo, em que foram avaliados o tempo ocioso, o número de paradas, e a velocidade média e máxima (Barlow, 2009).

No Brasil esse ciclo é utilizado para avaliar as emissões de veículos rodoviários automotores leves. Os procedimentos para realizar este teste são descritos na Norma Brasileira NBR 6601 (ABNT, 2012). O veículo é posicionado em um dinamômetro de chassi, o ciclo FTP-75 é reproduzido e durante o seu funcionamento são determinados os hidrocarbonetos totais, gases orgânicos não metano, monóxido de carbono, óxido de nitrogênio, dióxido de carbono e material não particulado emitidos (ABNT, 2012).

O sinal de velocidade pelo tempo do ciclo FTP-75 é apresentado na Figura 2.12. O ciclo pode ser dividido em três fases, a primeira fase a frio, a segunda estabilização e a terceira fase a quente. A primeira fase representa o comportamento do veículo a frio, simulando o seu funcionamento pela manhã após o seu desligamento durante toda a noite. A segunda fase representa a estabilização do motor, atingindo a sua condição aquecimento máximo. Depois da segunda fase, o motor é desligado por 10 min. Por fim, a terceira fase é igual à primeira, no entanto, iniciada com o motor quente, para simular o estacionamento de um carro e o seu retorno após um breve período. Dessa forma, as emissões coletadas durante o ciclo consideram a partida a frio e a quente do veículo, fornecendo uma representação mais precisa da condução do veículo (Giakoumis, 2017).




Figura 2.12: Ciclo de condução FTP-75.

O ciclo FTP-75 apresenta uma variação conhecida como ciclo FTP-72, que apresenta apenas a primeira e a segunda fase do ciclo original. O ciclo FTP-72 pode ser aplicado para testes com veículos elétricos e a baterias (Barlow, 2009). Para isso, com a bateria é carregada completamente, o veículo reproduz o ciclo sucessivamente até que a bateria seja totalmente descarregada. Assim, a bateria sem carga é recarregada e o consumo de energia do veículo é determinado em kWh (Giakoumis, 2017).

Embora o ciclo FTP-75 seja referência nos testes de emissões de veículos leves, esse ciclo apresenta algumas carências, como na representação de perfis de condução mais agressivos, com altas velocidades e altas acelerações (Barlow, 2009). Dessa maneira, para suprir essas carências foram desenvolvidos procedimentos suplementares ao FTP-75, conhecidos como *Supplemental Federal Test Procedure* (SFTP). O principal ciclo descrito pelo SFTP é o ciclo US06 (*United States n.º 06 drive cycle*), que visa reproduzir o comportamento de direção em acelerações mais severas, em altas velocidades e em uma faixa de velocidade de cruzeiro (Giakoumis, 2017).

Na Figura 2.13 é apresentado o perfil de velocidade do ciclo de condução SFTP US06. O ciclo pode ser separado em três etapas, a primeira possui duas micro viagens que representam o tráfego em regiões urbanas, a segunda emula a condução em regiões rodoviárias atingindo a velocidade máxima de 129,2 km/h e, por fim, a terceira corresponde a direção em regiões urbanas.

O ciclo US06 deve ser executado após a estabilização da temperatura do veículo (operação a quente), em que o motor e o catalisador alcançaram as temperaturas específicas de trabalho (Giakoumis, 2017). Em geral, o ciclo US06 pode ser reproduzido em seguida do FTP-75.




Figura 2.13: Ciclo de condução US06.

Outro ciclo de condução relevante é o ciclo HWFET, do inglês *Highway Fuel Economy Test Cycle*, (ciclo rodoviário NBR 7024) que foi desenvolvido para representar o perfil de condução em rodovias, sendo utilizado para determinar o consumo de combustível em vias não urbanas (Giakoumis, 2017). Esse ciclo é composto por quatro tipos de vias: local, coletora, arterial principal e secundária, como indicado na Figura 2.14. Esse ciclo deve ser realizado duas vezes, na primeira execução o motor é aquecido, enquanto na segunda ocorre a amostragem dos dados de operação do veículo. Outra possibilidade é executá-lo depois do ciclo FTP-75.




Figura 2.14: Ciclo de condução HWFET.

Por fim, um ciclo muito importante no estudo de veículos é o ciclo WTLC (*Worldwide Harmonized Light-Duty Driving Cycle*). Esse ciclo foi desenvolvido em conjunto por diversos países (Japão, Índia, Coreia do Sul e União Europeia) com o objetivo de harmonizar os procedimentos de teste relacionados às emissões para veículos leves (Giakoumis, 2017). Essa harmonização dos procedimentos não tem o propósito de definir requisitos e metas de emissão idênticos para todos os países, visto que cada país tem necessidades diferentes. Entretanto, tem a intenção de ser um modelo que aproxime as regulamentações, eliminando as diferenças desnecessárias (Barlow, 2009). Dessa maneira, não há a necessidade de projetar um veículo para cada país, o mesmo projeto, com pequenos ajustes se necessário, pode atender todas as regulamentações. A harmonização dos procedimentos tem impacto em escala global, reduzindo custo de desenvolvimento e produção dos veículos (Barlow, 2009).

O ciclo WTLC é dividido em quatro fases, como apresentado na Figura 2.15. Cada fase caracteriza os tipos de estradas e os limites velocidades diferentes no mundo (Giakoumis, 2017). As fases são definidas de acordo com a sua velocidade máxima: a primeira fase para velocidades baixas até 60 km/h, a segunda fase para velocidades médias entre 60 e 80 km/h, a terceira fase para velocidades altas entre 80 e 110 km/h, e por fim, a quarta com velocidades extra-altas com velocidades acima de 110 km/h.




Figura 2.15: Ciclo de condução WLTC.

2.8.1 Métodos de determinação de ciclos de condução

Os ciclos padrões apresentados são muito importantes, pois geram uma padronização dos testes e experimentos de todos os veículos. Isto permite não só estudar o comportamento e as emissões dos veículos, como avaliar e comparar o desempenho de novas tecnologias desenvolvidas, uma vez que há um procedimento padrão de experimento. Entretanto, os ciclos podem não conter todas as dificuldades encontradas por motoristas ao trafegar por vias urbanas e rodoviárias reais. Dessa maneira, surge a necessidade de garantir que o veículo ou a tecnologia em estudo seja avaliada em condições reais de operação. Uma alternativa para esse desafio é produzir um ciclo de condução que emule a operação real do veículo.

O processo de desenvolvimento de um ciclo de condução é muito complexo, para isto diversas metodologias podem ser utilizadas. Na Tabela 2.4 são apresentados os principais métodos utilizados na literatura. O método estocástico pode gerar um ciclo de condução a partir da combinação e escalonamento dos ciclos padrões. Já o método de inteligência artificial, que baseado em perfis de velocidades, um algoritmo de aprendizado de máquinas é treinado para prever o comportamento típico de veículos em vias reais. O método de Markov, por sua vez, gera um ciclo de condução por meio das cadeias de Markov. Por fim, o método evolucionário utiliza ciclos padrões e operadores genéticos para desenvolver um novo ciclo de condução, que emule o comportamento real do veículo.

Os trabalhos apresentados na Tabela 2.4, exibem diversos métodos empregados no desenvolvimento de ciclos de condução. Entretanto, a maioria dos métodos utiliza ciclos padrões para gerar os novos ciclos. Dessa maneira, não são considerados o comportamento de veículo em vias reais. Para este trabalho, ciclos de reais, obtidos por veículos ao trafegarem por vias urbanas e rodoviárias, serão utilizados para gerar um novo ciclo.

Tabela 2.4: Métodos utilizados para determinar de ciclos de condução.

Método	Referência	Detalhes
Estocástico	Feroldi e Carignano (2016)	Os ciclos de condução estocásticos são gerados a partir de ciclos padrões, em que seguimentos dos ciclos são escalonados e combinados aleatoriamente. Esses ciclos são desenvolvidos para análises de VEHs
Inteligência Artificial	Murphey <i>et al.</i> (2012)	Um algoritmo de aprendizado de máquinas é utilizado para prever os tipos de vias e os níveis de congestionamento do tráfego encontrado no mundo real. O ciclo desenvolvido é utilizado para desenvolver um controle de potência para VEHs
Método de Markov	Wang <i>et al.</i> (2019)	Um ciclo de condução é desenvolvido por cadeias de Markov para a aplicação em VEs. O método utiliza dados reais coletados por veículos de transporte de passageiros
Algoritmo Evolucionário	Perhinschi <i>et al.</i> (2011)	Um algoritmo evolucionário baseado em operadores genéticos desenvolve ciclos de condução a partir de ciclos padrões, aplicado a caminhões e ônibus.

2.9 Sistema de controles em tempo real

Com os principais ciclos de condução apresentados, os conceitos fundamentais de aprendizados de máquinas entendidos e o modelo dinâmico planar do veículo definido, é realizada uma pesquisa dos principais controles em tempo real. Essa pesquisa é sintetizada na Tabela 2.5, os trabalhos listados apresentam diversas estratégias de controle aplicadas em modelos dinâmicos veiculares que atuam instantaneamente para corrigir o comportamento do veículo.

Uma estratégia de gerenciamento de energia em veículos híbridos elétricos é proposta por Song *et al.* (2020) a partir de um controle tolerante a falhas (FTC), também conhecido como *fault-tolerant contro*. Para isso é desenvolvido um método de otimização multiobjetivo em tempo real, baseado no princípio mínimo de Pontryagin, para reduzir o consumo de combustível, a descarga e degradação da bateria. Um modelo simplificado de dinâmica longitudinal determina os torques requeridos que alimentam o controle de gerenciamento de energia. A eficácia do método proposto por Song *et al.* (2020) é avaliada na execução de alguns ciclos de condução. Como resultado, observou-se uma redução na degradação da bateria durante o funcionamento em marcha lenta do veículo, partida e parada do veículo.

Tabela 2.5: Estratégias de controles.

Estratégia	Referências	Detalhes
FTC	Zhang <i>et al.</i> (2019a)	FTC para VEs com ME in-wheel considerando o sistema de esterçamento.
PID	Wang <i>et al.</i> (2011)	Um controlador PID de torque diferencial para veículos elétricos com rodas independentes.
FLC	Yamashita (2018)	FLC aplicado na modelagem e controle de estabilidade de um veículo híbrido.
	Eckert <i>et al.</i> (2020)	FLC para dividir a potência entre os sistemas de potência, nas rodas dianteiras e traseiras, para melhor desempenho em VE com dois HESS.
	Wang <i>et al.</i> (2021)	FLC desenvolvido para melhorar a estabilidade e fornecer uma distribuição de torque ideal em um veículo elétrico com tração nas quatro rodas.
	Silva <i>et al.</i> (2022a)	FLC aplicado a diferenciais eletrônicos para corrigir a trajetória e a guinada de veículos modulares híbridos e elétricos
SMC	Hu <i>et al.</i> (2019)	O SMC analisa a influência de diferentes distribuições de torque das rodas na estabilidade e na economia de energia de um VE.
	Ding <i>et al.</i> (2020)	SMC robusto usado para regular a razão de escorregamento de um VE com tração nas quatro rodas.
	Zhang <i>et al.</i> (2019b)	Um SMC robusto para controle de estabilidade lateral de VEs.
MPC	Guo <i>et al.</i> (2020)	O MPC para um controle de momento de guinada em tempo real aplicado em VEs.
	Zhu <i>et al.</i> (2019)	O MPC aplicado em um controle de frenagem/aceleração para VEs com quatro MEs in-wheel.
	Jalali <i>et al.</i> (2017)	MPC de estabilidade lateral de veículos usando tração dianteira ativa e freios diferenciais.
MVS	Sheng e Xiao (2015)	Modelo de MVS associado com lógica fuzzy desenvolvido para estimar o estado de carga de baterias de fosfato de lítio ferro
	Klass <i>et al.</i> (2014)	Controle de gerenciamento de energia baseado em MVS aplicado a VEs.
FA	Harold <i>et al.</i> (2020)	Gerenciador de potência baseado em FA, aplicado em VEHs.
RNA	Murphey <i>et al.</i> (2013)	Gerenciador de energia treinado por um algoritmo RNA aplicado a VEH.
	Lio <i>et al.</i> (2020)	Desenvolvimento e comparação de quatro tipos de RNA utilizadas para modelar o comportamento da dinâmica longitudinal de um veículo

Guo *et al.* (2020) propôs uma estratégia de controle preditivo (MPC) não linear em tempo real, para o controle do momento de guinada de veículos elétricos. O controle é desenvolvido a partir de um modelo de veículo simplificado (modelo bicicleta) associado a um modelo de pneu baseado na Fórmula Mágica. Para verificar o desempenho do controle desenvolvido são realizadas simulações utilizando o CarSim™, que fornece o ângulo de esterçamento das rodas, a taxa de guinada do veículo, o seu ângulo de escorregamento lateral e a demanda total de torque de tração. Posteriormente, o controle preditivo determina o momento de guinada desejado que será aplicado no veículo elétrico.

Pozzi *et al.* (2020) desenvolveu um gerenciador de energia para células da bateria (íon-lítio), em que cada célula é modelada separadamente como um Modelo de Partícula Única. Um controle preditivo não linear é proposto para carregar a bateria de maneira ideal, considerando os limites de tensão e temperatura de cada célula individualmente. O controle é desenvolvido baseado em sensibilidade para simplificar e reduzir o custo computacional, dessa maneira, o modelo é obtido pela linearização da dinâmica ao longo de uma trajetória. A estratégia de gerenciamento de energia é testada em simulações hardware-in-the-loop, obtendo resultados satisfatórios e adequados para a implementação em tempo real.

Uma estratégia de gerenciamento de energia em tempo real para veículos elétricos *plug-in* é desenvolvido por Das *et al.* (2021), utilizando programação dinâmica. Para isso, é proposta uma otimização multi-objetivo em tempo real associada a programação dinâmica, dessa maneira, a carga ou descarga da bateria é definida em tempo real buscando reduzir do custo da eletricidade, minimizar a degradação da bateria e a reduzir a troca de energia com a rede. O desempenho do controle é avaliado experimentalmente, utilizando uma célula de baterias comerciais ligadas a um carregador bidirecional, responsável por emular a carga e descarga da bateria. Os resultados obtidos comprovam a capacidade do controle em atuar adequadamente em tempo real, atingindo os objetivos propostos.

Murphey *et al.* (2013) desenvolveu um gerenciador inteligente de energia para veículos elétricos híbridos (VEH). O gerenciador utilizada um algoritmo de aprendizado de máquinas baseado em redes neurais artificiais (RNA) para determinar a melhor distribuição de potência do motor a combustão e potência elétrica, além dos momentos em que o veículo deve gerar energia para carregar as suas baterias. O gerenciador tem como objetivo a minimização do consumo total de combustível ao realizar o ciclo de condução padrão FTP-75.

2.10 Redes neurais artificiais aplicadas em gerenciamento de energia ou potência

Para compreender os tipos de redes neurais aplicadas em veículos com propulsão elétrica atualmente, os principais trabalhos que empregam RNAs em problemas com gerenciamentos de energia ou potências são sintetizados na Tabela 2.6.

Chen *et al.* (2022) apresenta um estudo em estratégia de consumo equivalente mínimo aplicada em VEH plug-in, que utiliza duas redes neurais. A primeira rede desenvolvida é uma rede neural de regularização bayesiana (RNRB), elaborada para prever um fator equivalente ideal, responsável por ponderar o consumo de combustível do MCI e de energia elétrica do ME. Além disso, o fator equivalente deve garantir que a energia elétrica seja consumida gradualmente ao longo da viagem e o estado de carga da bateria no fim da simulação satisfaça as restrições predefinidas. A segunda rede é uma rede neural de retropropagação (RNR) é projetada para determinar a condição de operação do MCI, ligado ou desligado. O treinamento da rede é realizado com por meio de programação dinâmica com o objetivo de reduzir o consumo de combustível do MCI. Após o treinamento, nove ciclos de condução são simulados para avaliar a economia de combustível do método de gerenciamento proposto.

Han *et al.* (2022) desenvolve uma estratégia de controle de gerenciamento de energia preditiva para um veículo elétrico híbrido plug-in, considerando o controle térmico dos motores elétricos. Para isso, quatro redes neurais são projetadas e avaliadas para estimar a velocidade futura do veículo. As redes avaliadas são: RNR, RNRB, rede neural de memória de longo e curto prazo (RNMLCP) e rede neural de multicamadas (RMC). A rede RNRB apresentou a maior eficiência em estimar a velocidade futura do veículo, por outro lado, a rede RMC obteve o menor tempo de processamento. Essa velocidade estimada do veículo é usada como entrada para o controle preditivo, determinado com base no princípio de Pontryagin, incluindo a dinâmica térmica, que visa minimizar os custos operacionais e manter a temperatura de trabalho do motor elétrico em um valor adequado.

Min *et al.* (2022) realiza uma pesquisa em estratégia de gerenciamento de energia para veículos elétricos híbridos com célula a combustível. A estratégia é desenvolvida com o objetivo de maximizar a vida útil da célula a combustível. O veículo utiliza a célula de carga como fonte principal de energia e uma bateria de ion-lítio como fonte auxiliar. Dessa maneira, a estratégia de gerenciamento de energia deve equilibrar o uso da bateria e da célula a combustível, evitando o seu desligamento e mudanças rápidas de corrente, visto que elas podem reduzir a sua vida útil. Para isto, a rede neural foi treinada por um algoritmo genético, uma vez que esse algoritmo mostrou-se capaz de evitar a estratégia faça paradas desnecessárias e variações mais suaves na corrente. Por fim, simulações e experimentos comparativos foram realizados para verificar a validade da estratégia de gerenciamento proposta.

Tabela 2.6: Redes neurais artificiais aplicadas ao gerenciamento de energia e potência de veículos com propulsão elétrica.

Tipo da Rede	Referências	Detalhes
RNRB e RNR	Chen <i>et al.</i> , 2022	Duas redes neurais de multcamadas são desenvolvidas para alimentar uma estratégia de consumo equivalente mínimo de um VEH plug-in. A primeira é utilizada na predição de um fator de equivalência, que pondera o consumo de energia do MCI e do ME, enquanto a segunda determina o estado do ME, ligado ou desligado.
RMR	Pereira <i>et al.</i> , 2021	Uma rede neural é desenvolvida para modelar o comportamento de uma célula a combustível. A partir da tensão da célula a combustível, do estado de carga da bateria e de um estado de carga desejado, um controle preditivo não linear realiza o gerenciamento de energia de um VEH.
RNRB, RNR, RNMLCP e RMC	Han <i>et al.</i> , 2022	Quatro tipos de redes são avaliadas para a predição da velocidade de um VEH. A velocidade futura, determinada pela rede, e o estado de carga da bateria são utilizados para determinar o comportamento ideal do veículo por controle preditivo de modelo baseado no princípio mínimo de Pontryagin.
RMC	Min <i>et al.</i> , 2022	Rede neural treinada para o gerenciamento de energia de um VEH, que possui uma célula a combustível como fonte de energia principal e um conjunto de baterias como fonte de energia auxiliar.
RMC	He <i>et al.</i> , 2021	Uma rede neural multcamadas, aplicada em estratégia de gerenciamento de energia para VEH, baseada em sistema ciberfísico. A rede determina o comando de controle dos motores do VEH com base nas informações de tráfego e o no seu comportamento.
RNC	Liu <i>et al.</i> , 2022	Rede neural aplicada na predição da tendência de velocidade de um VEH plug-in, estimando a sua velocidade no próximo instante de tempo. Então, a velocidade futura é aplicada em um controle adaptativo fuzzy, que planeja a velocidade alvo do veículo.

Liu *et al.* (2022) apresenta um estudo de uma estratégia hierárquica de controle de gerenciamento de energia para um veículo elétrico híbrido plug-in autônomo. Para isto, na camada superior do controle, uma rede neural cinza (RNC) é utilizada para prever a tendência de velocidade futura do veículo, utilizada como entrada para um controle adaptativo difuso determinar a velocidade alvo do veículo. Na camada inferior, um algoritmo de otimização genético é aplicado para mapear um fator equivalente nas condições de operação do veículo, visando minimizar o seu consumo equivalente. Esse fator equivalente visa determinar a distribuição de potência do ME e do MCI. Um controlador de lógica fuzzy é empregado para realizar uma correção no fator equivalente mapeado pela otimização. Por fim, experimentos baseados em simulações hardware-in-the-loop são realizados para determinar o desempenho da estratégia proposta.

Pereira *et al.* (2021) desenvolve uma estratégia de gerenciamento de energia para um veículo híbrido com célula a combustível. A estratégia utiliza um modelo de controle preditivo não linear, que emprega uma RNR para modelar a célula a combustível, uma vez que as redes conseguem se adaptar com precisão a problemas não lineares. Após o desenvolvimento da estratégia de gerenciamento de energia, o controle preditivo não linear foi implementado em um microcontrolador e uma simulação hardware-in-the-loop foi realizada com uma célula a combustível real. Os resultados obtidos nos experimentos demonstram que a estratégia de gerenciamento desenvolvida consegue atender a demanda de energia do veículo, e operar na região de maior eficiência da célula a combustível.

Existem diversos estudos que aplicam redes neurais artificiais em gerenciamentos de energia e potência, entretanto, na maioria desses estudos, a rede neural é utilizada como uma ferramenta auxiliar, prevendo apenas a velocidade futura do veículo ou o comportamento de um componente da transmissão. Nesses estudos são utilizados diversos tipos de redes para solucionar os problemas propostos, em alguns casos diferentes redes e arquiteturas são avaliadas para determinar a configuração mais adequada para o problema. Dessa maneira é necessário realizar diversos treinamentos para encontrar a rede e a arquitetura ideal, consumindo bastante tempo e um grande custo computacional.

Este trabalho, propõe um modelo inovador de redes neurais artificiais que será aplicado ao gerenciamento de potência de veículos elétricos. O modelo é baseado em redes neurais de multicamadas, ele é desenvolvido para ser totalmente adaptável, podendo alterar a sua estrutura de maneira rápida e simples, o seu número de camadas, o número de neurônios de cada camada e a função de ativação de cada neurônio. Dessa maneira, a arquitetura e os parâmetros mais adequados para essa rede serão definidos durante o seu treinamento, ampliando o potencial da rede e reduzindo o custo computacional do treinamento.

3 GERADOR DE CICLOS DE CONDUÇÃO

Para entender cada um dos ciclos de condução padrões, são inicialmente analisadas as acelerações e velocidades que os ciclos submetem os veículos. Posteriormente, é realizado o mesmo estudo para ciclos reais, obtidos em bancos de dados que reúnem viagens reais de veículos ao trafegarem por vias urbanas e rodoviárias (Steinstraeter *et al.*, 2020).

Na Figura 3.1 é apresentado um histograma 3D da aceleração pela velocidade, encontradas do ciclo de condução FTP-75. Pelo histograma é possível notar que o ciclo apresenta acelerações máximas de aproximadamente $1,5 \text{ m/s}^2$, tanto na aceleração quanto na desaceleração (frenagem). Percebem-se duas concentrações no histograma, a primeira com 18% do ciclo na faixa de $-0,1 \text{ m/s}^2$ a $0,1 \text{ m/s}^2$ para a aceleração e de 0 a 5 km/h para a velocidade. A segunda concentração de 8% do ciclo, na faixa de $-0,1 \text{ m/s}^2$ a $0,1 \text{ m/s}^2$ para a aceleração e de 40 km/h a 45 km/h para a velocidade.




Figura 3.1: Histograma do ciclo de condução FTP-75.

O histograma 3D das acelerações e velocidades atingidas no ciclo de condução HWFET é apresentado na Figura 3.2. Pelo histograma percebe-se que o ciclo possui uma aceleração máxima de aproximadamente 4 m/s^2 e desaceleração mínima de $-3,5 \text{ m/s}^2$. Ainda, é possível notar duas concentrações no histograma, a primeira com 8% da amostra do ciclo na faixa de $-0,1 \text{ m/s}^2$ a $0,3 \text{ m/s}^2$ para a aceleração e de 0 a 8 km/h para a velocidade. A segunda concentração de 8% do ciclo, na faixa de $-0,1 \text{ m/s}^2$ a $0,3 \text{ m/s}^2$ para a aceleração e de 97 km/h a 105 km/h para a velocidade.

Para o ciclo de condução WLTC, o histograma da aceleração pela velocidade é apresentado na Figura 3.3. É possível notar que o ciclo possui uma aceleração máxima de aproximadamente $1,75 \text{ m/s}^2$ e desaceleração mínima de $-1,5 \text{ m/s}^2$. Ainda, se observa uma concentração de pontos com aproximadamente 12% da amostra do ciclo na faixa de $-0,1 \text{ m/s}^2$ a $0,1 \text{ m/s}^2$ para a aceleração e de 0 a 8 km/h para a velocidade.




Figura 3.2: Histograma do ciclo de condução HWFET.




Figura 3.3: Histograma do ciclo de condução WLTC.

A Figura 3.4 indica o histograma do comportamento da velocidade e da aceleração de ciclos reais. Pelo histograma nota-se que os ciclos apresentam acelerações máximas de aproximadamente 6 m/s^2 e mínimas de -12 m/s^2 . A velocidade máxima encontrada nesses ciclos reais foi de 150 km/h , acima das velocidades máximas dos ciclos padrões. No histograma, é possível perceber duas concentrações, a primeira com 15% do ciclo na faixa de $-0,5 \text{ m/s}^2$ a $0,5 \text{ m/s}^2$ para a aceleração e de 0 a 5 km/h para a velocidade. A segunda concentração de 24% do ciclo, na faixa de $-0,5 \text{ m/s}^2$ a $0,5 \text{ m/s}^2$ para a aceleração e de 90 km/h a 95 km/h para a velocidade.




Figura 3.4: Histograma dos ciclos reais.

3.1 Método de desenvolvimento dos ciclos de condução

Existem diversos métodos que podem ser utilizados para produzir um ciclo de condução, como apresentado no capítulo 2.8.1. De maneira geral, o método da cadeia de Markov tem sido amplamente empregado na determinação de ciclos, que avaliam a emissão de veículos a combustão. Entretanto, esse método precisa de uma elevada quantidade de parâmetros dos ciclos com diferentes veículos para refletir um ambiente de condução real (Zhang *et al.*, 2019c). Assim, o tempo de simulação desse método é muito alto, para conseguir produzir um ciclo com a representatividade necessária. Por outro lado, os métodos evolucionários podem alcançar o mesmo objetivo de maneira mais eficiente que a cadeia de Markov (Zhang *et al.*, 2019c).

Para este trabalho, a geração dos ciclos de conduções será feita a partir de um algoritmo evolucionário. Para garantir que o ciclo gerado seja capaz de reproduzir o comportamento de veículos trafegando em vias reais, o algoritmo é alimentado pelo banco de ciclos de conduções reais. Dessa forma, na geração do ciclo são utilizados tanto dados reais quanto padronizados.

3.2 Algoritmo evolucionário para a geração dos ciclos de condução

Inicialmente, os dados dos ciclos são divididos, organizados e suas propriedades determinadas. Na Figura 3.5 é apresentado um ciclo de condução real, que representa uma viagem realizada por um veículo. Essa viagem é dividida em partes, micro viagens (regiões destacadas em azul) e paradas (regiões destacadas em verde). As micro viagens representam os momentos em que o veículo está trafegando pelas vias, enquanto as paradas indicam os momentos em que o veículo fica esperando para retomar seu movimento. Após a divisão, as micro viagens

são armazenadas em um banco de dados, com as suas propriedades (velocidade máxima atingida, distância percorrida, tempo, acelerações máximas e mínimas). As paradas também são armazenadas com o tempo que o veículo não está em movimento.




Figura 3.5: Ciclo de condução real.

O banco de dados, formado pelas micro viagens e paradas, é utilizado para iniciar o algoritmo evolucionário, como apresentado no fluxograma da Figura 3.6. A princípio, os dados são filtrados com base em requisitos definidos para o ciclo desejado, dessa maneira, as micro viagens com propriedades indesejadas são descartadas. Posteriormente, o algoritmo monta diversos ciclos iniciais, com as micro viagens e paradas filtradas. O número de paradas que o ciclo deve conter é determinado previamente.

As características dos ciclos iniciais são avaliadas, em relação às características desejadas, por exemplo, a velocidade média do ciclo, o tempo máximo do ciclo e a distância total percorrida. Posteriormente, novos ciclos são gerados a partir dos ciclos iniciais por meio de operadores genéticos. As características desses novos ciclos são avaliadas e eles são armazenados com a população de ciclos já existentes. A população de ciclos é organizada e ordenada em função da avaliação realizada. O processo é repetido até obter um número pre-determinado de ciclos que atendem as características e requisitos definidos.

Os operadores genéticos são compostos por três etapas, a seleção, cruzamento e mutação. Na seleção dois ciclos são escolhidos com base na avaliação das suas características. Posteriormente, no cruzamento, um novo ciclo é formado a partir das micro viagens e paradas dos dois ciclos selecionados, em que a cada ciclo tem 50% de chance de transmitir seus genes. Por fim, as micro viagens e paradas do novo ciclo combinado tem 50% de chance de sofrer mutação, essa mutação pode ocorrer de duas formas. A primeira forma é a substituição da micro viagem ou parada por outra do banco de dados, enquanto a segunda é o escalonamento do sinal de forma aleatória.




Figura 3.6: Fluxograma do algoritmo evolucionário genético para a geração dos ciclos de condução.

O ciclo a ser gerado ainda pode estar sujeito a diversas restrições, para garantir que ele apresente as características desejadas. Por exemplo, a velocidade do ciclo de condução V_{cic} [m/s] pode ser limitada por velocidade máxima $V_{cic,max}$ [m/s], as acelerações do ciclo a_{cic} [m/s²] podem ser restringidas por uma aceleração máxima $a_{cic,max}$ [m/s²] e uma desaceleração mínima $a_{cic,min}$ [m/s²], o tempo total do ciclo t_{cic} [s] delimitado por um tempo máximo permitido $t_{cic,max}$ [s], e por fim, o tempo de parada também pode ser limitado por um tempo máximo de parada $t_{par,max}$ [s]. Na Equação 3.1 são apresentadas as restrições que o gerador está submetido.

$$H(\mathbf{X}_c) = \begin{cases} V_{cic} \leq V_{cic,max} \\ a_{cic,min} \leq a_{cic} \leq a_{cic,max} \\ t_{cic} \leq t_{cic,max} \\ t_{par} \leq t_{par,max} \end{cases} \quad (3.1)$$

3.3 Formulação do problema

Para iniciar o processo de geração de novos ciclos, inicialmente, as micro viagens (MV) e paradas (P) que formam cada ciclo são armazenadas em um cromossomo $\mathbf{X}_c$, como indicado na Equação 3.2. Dessa maneira, cada cromossomo representa um ciclo de condução gerado, em que o número de paradas do ciclo np é definido previamente.

$$\mathbf{X}_c = [P_1 \ MV_1 \ P_2 \ MV_2 \ \dots \ MV_{(np-1)} \ P_{np}] \quad (3.2)$$

Cada um dos ciclos (cromossomos) tem as suas características avaliadas, por exemplo, a velocidade média do ciclo e o seu tempo máximo do ciclo. Dessa maneira, na avaliação são determinados as diferenças das propriedades do ciclo analisado em relação aos valores desejados. Essas diferenças definem os critérios de avaliação das características do ciclo f_c .

Posteriormente, os cromossomos são classificados em relação ao seu desempenho em reproduzir as características desejadas. Para determinar o fator de desempenho de cada ciclo F_t é utilizado o método da soma dos pesos adaptativos (Gen *et al.*, 2008). Dessa maneira, a cada iteração do algoritmo evolucionário, todas as características dos ciclos são ponderadas pelos valores máximos dos critérios de avaliação f_c^{max} e pelos valores mínimos f_c^{min} . Na Equação 3.3 é apresentado o cálculo do fator de desempenho de cada ciclo, baseado no método da soma dos pesos adaptativos.

$$F_t(\mathbf{X}_c) = \sum_{c=1}^2 \frac{f_c^{max} - f_c(\mathbf{X}_c)}{f_c^{max} - f_c^{min}} \quad (3.3)$$

Depois da classificação dos ciclos de condução, os operadores genéticos são aplicados na população de ciclos. Inicialmente, são selecionados de forma aleatória dois ciclos dos n indivíduos da população. Para isto, é utilizado o método da roleta, em que a probabilidade de seleção de cada indivíduo $S_p(\mathbf{X}_c)$ [%] é proporcional ao seu fator de desempenho $F_t(\mathbf{X}_c)$. A probabilidade de seleção de um indivíduo da população é determinada pelo seu fator de desempenho dividido pelo somatório dos fatores de desempenho dos n indivíduos da população, como pode ser visto na Equação 3.4.

$$S_p(\mathbf{X}_c) = \frac{F_t(\mathbf{X}_c)}{\sum_{k=1}^n F_t(\mathbf{X}_c)} \quad (3.4)$$

Depois da seleção dos dois ciclos da população, segue-se para o processo de cruzamento. Dessa maneira, as micro viagens e paradas dos ciclos são combinadas aleatoriamente para gerar um novo ciclo de condução. A probabilidade cada micro viagem ou parada do novo ciclo ser do primeiro indivíduo selecionado é de 50% e do segundo indivíduo 50%.

Após o cruzamento, o novo ciclo gerado passa pelo processo de mutação, que visa introduzir mudanças nos elementos do novo ciclo. A probabilidade de cada parada ou micro viagem sofrer mutação é de 50%. Neste trabalho a mutação pode ocorrer de duas formas, por substituição ou por escalonamento. Na substituição, a micro viagem ou a parada é trocada por outra do banco de micro viagens e paradas (Perhinschi *et al.*, 2011). Já no escalonamento, a micro viagem ou a parada é redimensionada por um fator de escala k_s , que varia de 0,8 a 1,2 (Feroldi e Carignano, 2016). Dessa maneira, perfil de velocidade da micro viagem V_{MV} [m/s] é multiplicado pelo fator de escala gerando o novo perfil de velocidade $V_{MV,mut}$ [m/s], como indicado na Equação 3.5. Na parada, o fator de escala multiplica o seu tempo de parada t_{par} [s], como apresentado na Equação 3.6

$$V_{MV,mut} = k_s V_{MV} \quad (3.5)$$

$$t_{par,mut} = k_s t_{par} \quad (3.6)$$

Depois da aplicação dos operadores genéticos, as características dos novos ciclos de conduções são avaliadas e os seus fatores de desempenhos são calculados. Em seguida, esse os novos ciclos são acrescentados na população dos ciclos, que é novamente classificada. Para manter o tamanho da população estável, o algoritmo descarta os ciclos com os piores fatores de desempenho. Para a geração dos ciclos foi utilizada uma população de 100 ciclos.

Os ciclos de conduções que não são superados, por outros em nenhuma das características analisadas, são conhecidos como ciclos ou soluções não dominadas. O conjunto dos ciclos não dominados, ou seja, as soluções ótimas encontradas, definem a fronteira Pareto (Weise, 2009). Para determinar a estagnação do processo evolutivo, é utilizado o critério de convergência da repetibilidade da fronteira de Pareto, após 50 gerações sem novos ciclos não dominados (Eckert *et al.*, 2019b).

3.4 Ciclos gerados

Com o método evolucionário genético para a geração de ciclos de condução desenvolvido, o algoritmo foi implementado em uma interface gráfica para facilitar a sua utilização e a exportação dos ciclos gerados. As características desejadas e as restrições exigidas para o ciclo desejado, podem ser inseridas diretamente na interface. Na Figura 3.7 é apresentado a interface gráfica criada para o gerador de ciclos.




Figura 3.7: Interface gráfica do gerador de ciclos desenvolvido.

O gerador de ciclos desenvolvidos é utilizado para gerar novos ciclos de condução, que reproduzam os desafios encontrados em condições reais, dois exemplos de ciclos gerados são apresentados na Figura 3.8. Para este exemplo, nenhuma restrição foi utilizada para filtrar as micro viagens e paradas. O algoritmo tem como objetivo encontrar dois ciclos com velocidade média de 30 km/h e 6 paradas, o tempo máximo e a distância percorrida não foram restringidos.




Figura 3.8: Exemplos de ciclos gerados.

O primeiro ciclo apresenta um tempo de condução de 1200 segundos, com velocidade máxima de 90 km/h e tempo de parada máximo de 200 segundos. Por outro lado, o segundo ciclo possui um tempo de condução de aproximadamente 800 segundos, com velocidade máxima de 75 km/h e tempo de parada máximo de 50 segundos. Os dois ciclos obtidos apresentam as mesmas características desejadas, entretanto, as suas micro viagens e paradas são completamente diferentes. Dessa maneira, o algoritmo consegue gerar ciclos distintos com características similares, reproduzindo a variabilidade encontrada em ciclos reais.

3.5 Ciclo de Treinamento

Com o gerador de ciclos desenvolvido, é possível definir um ciclo de condução que será utilizado durante o treinamento da rede. Esse ciclo de treinamento deve ser capaz de reproduzir as dificuldades representadas nos ciclos de condução padrão e os desafios encontrados pelos veículos em condições reais. Para isso, o ciclo de treinamento será formado por uma combinação de outros ciclos.

Os primeiros ciclos selecionados para formar o conjunto de treinamento são os ciclos padrões NBR 6601, NBR 7024 e US06. Esses ciclos combinados já são utilizados em diversos trabalhos que buscam gerenciar a potência de veículos (Eckert *et al.*, 2022b e Silva *et al.*, 2021). O ciclo NBR 6601 (FTP-75) foi escolhido por ser um dos principais ciclo utilizados no Brasil para avaliar os veículos em vias urbanas, enquanto o ciclo NBR 7024 (HWFET) foi definido por ser um ciclo rodoviário. O ciclo US06 foi selecionado por reproduzir um ciclo rodoviário mais agressivo e, com isso, ele fornece ao treinamento sinais maiores de acelerações e velocidades. Após a definição dos ciclos de conduções padrões, o gerador de ciclos é utilizado para gerar ciclos que reproduzam condições reais em vias urbanas e rodoviárias.

Na Figura 3.9 é apresentado o perfil do ciclo de condução formado para o treinamento da rede neural. O sinal de velocidade do ciclo NBR 6601 é apresentado pela curva azul, o ciclo NBR 7024 pela curva vermelha, o ciclo US06 pela curva em preto, o ciclo urbano gerado pela curva em verde e o ciclo rodoviário gerado pela curva em roxo.




Figura 3.9: Ciclo definido para o treinamento da RNA.

4 MODELO DE REDES NEURAIS ARTIFICIAIS

Neste capítulo serão abordados conceitos referentes ao desenvolvimento e aplicação do modelo de redes neurais artificiais que será utilizado neste trabalho. O modelo desenvolvido é baseado em uma arquitetura de múltiplas camadas, podendo assumir qualquer configuração em sua estrutura. Dessa maneira, os parâmetros a serem determinados durante a fase de treinamento, assim como a estratégia de treinamento, serão detalhados.

4.1 Modelo de neurônio

O modelo RNA de múltiplas camadas, de modo geral, apresenta uma estrutura com diversas camadas de neurônios, em que os neurônios das camadas são conectados entre si para processar os dados. Dessa maneira, para desenvolver uma RNA é necessário, inicialmente, elaborar um modelo que represente os neurônios da rede. Na Figura 4.1 é apresentado o modelo convencional de neurônio, no qual o neurônio recebe os sinais da camada anterior, processa as informações e envia para a próxima camada um sinal de resposta.




Figura 4.1: Modelo de neurônio.

Os sinais de entrada do neurônio são ponderados por pesos w_n , dessa maneira, quanto maior for a relevância do sinal para a tomada de decisão do neurônio maior será o seu peso. Os sinais ponderados são somados com um valor de viés β_n , responsável por promover um deslocamento no sinal resultante. Posteriormente, esse sinal decorrente da soma é aplicado em uma função de ativação, que determina o valor da resposta do neurônio. Por fim, essa resposta é enviada para os neurônios da próxima camada.

Existem diversos tipos de funções de ativação, de maneira geral, todos os neurônios da rede possuem a mesma função de ativação e apenas os seus parâmetros são definidos durante o treinamento (Lv *et al.*, 2018). A escolha do tipo mais adequado de função de ativação pode ser feita com base nas necessidades e aplicações da RNA. Além disso, em diversos casos, a escolha é feita pela comparação dos desempenhos das funções de ativação (Özbay e Tezel, 2010; Kiliçarslan e Celik, 2022). Dessa maneira, são selecionadas algumas funções de ativação e para cada uma delas uma rede é desenvolvida e treinada. Entretanto, esse método despende muito tempo de processamento e recurso computacional, uma vez que é necessário treinar várias redes para o mesmo objetivo. Há outros trabalhos que utilizam uma combinação de diversas funções de ativação nos neurônios da rede (Apicella *et al.*, 2021).










Para a rede proposta neste trabalho, a função de ativação utilizada em cada um dos neurônios será definida durante o seu treinamento. Dessa maneira, o treinamento será responsável por determinar as funções mais adequadas para cada um dos neurônios da rede, que podem apresentar funções de ativação distintas. Desse modo, não é necessário realizar diversos treinamentos com diversas funções de ativação, reduzindo o tempo de processamento e o custo computacional. As principais funções de ativação, empregadas em aprendizado de máquinas, foram selecionadas para compor um banco de funções, que poderão ser utilizadas por cada neurônio da rede.

Na Tabela 4.1 são apresentadas as funções de ativações disponíveis no treinamento para o neurônio. Para cada função é apresentada a equação que a descreve, os seus parâmetros $\lambda_{1,2}$ (definidos no treinamento) e o seu gráfico. A primeira função é linear que retorna uma resposta proporcional ao sinal de entrada.

A segunda função apresentada é a Função Sigmoid, que é muito utilizada em regressões logísticas (Alpaydin, 2014). Quanto menor for o valor do sinal de entrada, mais ele tende para 0 e quanto maior ele for mais tende a 1. O parâmetro λ_1 é responsável por determinar a suavidade da mudança das duas tendências da função, quanto menor for o parâmetro mais suave será essa mudança. Uma das desvantagens dessa função é não apresentar simetria em torno do zero, gerando respostas sempre positivas. Para corrigir esse problema e centralizar a função no zero, a equação da Função Sigmoid é ajustada, gerando a Função Sigmoid Simétrica, que retorna valores de -1 a 1.

Para a Função Degrau, há a sua ativação (saída igual a 1) quando o sinal de entrada for positivo, caso contrário ela se mantém inativa (saída igual a 0). Essa função é adequada na classificação do sinal em duas classes ou uma resposta binária. Outra função de ativação é a Tangente Hiperbólica, assim como a Função Sigmoid Simétrica, ela é centralizada no zero e apresenta uma resposta simétrica, que varia de -1 a 1.

Tabela 4.1: Funções de ativações.

Função de ativação	Equação	Parâmetros	Gráfico
Linear	$\psi(s) = \lambda_1 s$	λ_1	
Função Sigmoid	$\psi(s) = \frac{1}{1+e^{-\lambda_1 s}}$	λ_1	
Função Sigmoid Simétrica	$\psi(s) = \frac{2}{1+e^{-\lambda_1 s}} - 1$	λ_1	
Função Degrau	$\psi(s) = 0, se s < 0$ $\psi(s) = 1, se s \geq 0$	—	
Tangente Hiperbólica	$\psi(s) = \tanh s$	—	
ReLU Paramétrica	$\psi(s) = 0, se s \leq 0$ $\psi(s) = \lambda s, se s > 0$	λ	
Leaky ReLU Paramétrica	$\psi(s) = \max(\lambda_1 s, \lambda_2 s)$	λ_1, λ_2	
SELU	$\psi(s) = \lambda_1 \lambda_2 (e^s - 1), se s < 0$ $\psi(s) = \lambda_1 s, se s \geq 0$	λ_1, λ_2	
GELU	$\psi(s) = s\Phi(s)$	—	

A Função ReLU Paramétrica (Unidade Linear Retificada) é ativada para todo sinal de entrada positivo, apresentando uma resposta linear, enquanto para valores negativos de entrada, ela permanece inativa. Outra variação dessa função é a Leaky ReLU Paramétrica, que apresenta uma característica linear λ_1 quando o sinal é negativo e outra λ_2 quando o sinal é positivo. Essa função retorna como resposta o maior valor entre às duas características lineares.

A Função SELU (Unidade Linear Exponencial Escalonada) apresenta um comportamento linear quando o sinal é positivo e um comportamento exponencial quando o sinal é negativo. Por fim, a função GELU (Unidade Linear de Erro Gaussiano) é determinada pela função de distribuição cumulativa da distribuição normal do sinal ($\Phi(s)$) multiplicado pelo próprio sinal (s).

O número de parâmetros de cada neurônio varia em função da quantidade de sinais de entrada N_{N-1} (determinada pelo número de neurônios da camada anterior) e do número de parâmetros da sua função de ativação N_a (indicado na Tabela 4.1). O número total de parâmetros a ser determinado no treinamento para cada neurônio (N_n) é apresentado na Equação 4.1.

$$N_n = N_{N-1} + N_a + 1 \quad (4.1)$$

4.2 Arquitetura da rede neural artificial

Com o modelo do neurônio devidamente definido é possível iniciar a construção da rede neural. Uma rede é formada por uma camada de entrada, que recebe os sinais de entrada da rede, uma camada de saída, que retorna a(s) resposta(s) da rede, e por uma ou mais camadas ocultas, que conectam a camada de entrada e a camada de saída. Cada camada é formada por um conjunto de neurônios, conectados aos neurônios da camada anterior e da posterior.

Para este trabalho, propõe-se o desenvolvimento de uma RNA de multicamadas com arquitetura genérica, dessa maneira, a rede pode apresentar diversas configurações, podendo possuir várias camadas e neurônios. O processo de treinamento da rede é responsável por determinar a estrutura da rede, definindo o número de camadas ocultas e o número de neurônios de cada camada. Para essa rede não há retroalimentação das camadas, ou seja, as ligações dos neurônios são feitas em apenas uma direção, da entrada para a saída. Na Figura 4.2 é apresentado um desenho esquemático da RNA de arquitetura genérica.

Nas camadas de entrada e saída, o número de neurônios é determinado pelos sinais de entrada e saída da rede. Além disso, as funções de ativação dos neurônios dessas camadas podem ser definidas conforme a necessidade do sinal de saída da rede ou o sinal de entrada disponível. Por exemplo, caso a saída desejada seja o estado de um determinado motor, ligado ou desligado, a função de ativação mais pertinente seria a Função Degrau. Por outro lado, a escolha da melhor função de ativação para um neurônio pode não ser trivial, por exemplo, no caso da saída desejada seja um sinal contínuo, uma vez que há diversas funções de ativação que podem ser viáveis. Dessa maneira, o treinamento poderá determinar as funções mais adequadas para os neurônios das camadas de entrada e saída.




Figura 4.2: Desenho esquemático da rede neural artificial com arquitetura genérica.

O treinamento da RNA genérica é responsável por definir a melhor arquitetura para rede, os pesos que ponderam os sinais de conexões dos neurônios e o tipo de função de ativação de cada um dos neurônios, bem como os seus parâmetros. Dessa maneira, o treinamento busca para a RNA genérica, implementada em um determinado problema, a estrutura de rede e os parâmetros mais adequados. No processo de treinamento da rede, são avaliadas diversas configurações de rede (arquitetura, peso e funções de ativação), visando encontrar as RNA que apresentem os melhores desempenhos na execução da tarefa estipulada. O método de treinamento utilizado é baseado em algoritmo genético e abordado na seção 4.3, 4.4 e 5.

O número de parâmetros que devem ser obtidos no treinamento para cada camada (N_c) pode ser determinado pelo número de parâmetros de cada neurônio vezes o número de neurônios (N_N), como apresentado na Equação 4.2.

$$N_c = N_N(N_{N-1} + N_a + 1) \quad (4.2)$$

4.3 Aplicação da rede - Treinamento da rede

Para entender a aplicação de aprendizado de máquinas em modelos reais, inicialmente, procura-se modelar o estado de carga de uma bateria SoC [%]. O algoritmo deverá ser capaz de prever o estado de carga de uma bateria em condições reais. Para isso, é utilizado um banco de dados (Steinstraeter *et al.*, 2020) que fornece as condições de operações encontradas em baterias

de veículos elétricos. Dessa maneira, a RNA genérica determinará a variação do estado de carga de uma bateria com base na sua tensão e corrente elétrica, como mostrado na Figura 4.3.




Figura 4.3: Exemplo do método de redes neurais.

Inicialmente, a rede será composta por uma camada oculta com dez neurônios, em que seus neurônios utilizam funções de ativações Sigmoid. Por outro lado, na camada de saída serão utilizados neurônios com funções de ativação linear. Para essa rede não há retroalimentação das camadas, ou seja, as ligações dos neurônios são feitas em apenas uma direção, da entrada para a saída.

Para este trabalho será utilizado um treinamento baseado em um algoritmo evolucionário genético. O principal objetivo do treinamento é garantir que o modelo RNA reproduza o comportamento de carga e descarga da bateria, ou seja, ele deve estimar com precisão a variação do estado de carga da bateria $dSoC$ [%/s]. Dessa maneira, durante o treinamento, o algoritmo evolucionário genético procura os valores dos parâmetros do modelo RNA, que melhor estimam a descarga da bateria.

Para avaliar o desempenho do modelo RNA, no treinamento o primeiro critério avaliado será a correlação da resposta do modelo (S) em comparação aos dados de treinamento ($dSoC$), como apresentado na Equação 4.3.

$$f_1 = \frac{\sum (dSoC_k - \overline{dSoC})(S_k - \bar{S})}{\sqrt{\sum (dSoC_k - \overline{dSoC})^2 \sum (S_k - \bar{S})^2}} \quad (4.3)$$

O segundo critério avaliado durante o treinamento será o valor da raiz do erro médio quadrado (RMSE), como indicado na Equação 4.4.

$$f_2 = \sqrt{\frac{1}{n} \sum (dSoC_k - S_k)^2} \quad (4.4)$$

Para avaliar a aptidão de cada uma das RNA, correlacionando os dois critérios de avaliação, foi utilizado o método da soma dos pesos adaptativos, proposto por Gen *et al.* (2008). Dessa maneira, o fator de desempenho F_t de cada uma das RNA é determinado pela soma dos dois critérios, ponderados pelos valores máximos e mínimos encontrados na população, como mostrado na Equação 4.5.

$$F_t(\mathbf{X}_R) = \frac{f_1^{max} - f_1(\mathbf{X}_R)}{f_1^{max} - f_1^{min}} + \frac{f_2^{max} - f_2(\mathbf{X}_R)}{f_2^{max} - f_2^{min}} \quad (4.5)$$

Os parâmetros para definir o modelo RNA são reunidos em um vetor denominado cromossomo ($\mathbf{X}_R$), como apresentado na Equação 4.6.

$$\mathbf{X}_R = [w_1 \ w_2 \ \dots \ w_{40} \ w_{b,1} \ \dots \ w_{b,10} \ \lambda_{1,1} \ \lambda_{1,2} \ \dots \ \lambda_{10,2}] \quad (4.6)$$

Os cromossomos são simulados, analisados, armazenados na população e classificados. Posteriormente, os operadores genéticos do treinamento é aplicado, dessa maneira, dois indivíduos são selecionados pelo método da roleta (apresentado no capítulo 3.3). Os indivíduos têm seus parâmetros combinados e mutados para gerar uma nova RNA. Então, o novo indivíduo é simulado, avaliado e adicionado a população. O processo se repete até a convergência do treinamento.

O critério de convergência utilizado no treinamento é proposto por Eckert *et al.* (2017), que indica a estagnação do processo evolutivo pela repetibilidade da fronteira de Pareto após 50 gerações consecutivas.

Após o treinamento, sinais de tensão e corrente reais foram aplicados no modelo RNA para prever o comportamento de carga e descarga de uma bateria. Para avaliar o desempenho do modelo RNA desenvolvido, a sua resposta foi comparada com estado de carga real apresentado pela bateria. O modelo RNA desenvolvido também é comparado com um modelo RNA gerado com o auxílio de um aplicativo de redes neurais do MatLabTM (*ntstool*). Essa ferramenta possibilitar configurar e treinar um modelo RNA a partir de uma série de dados temporais. Para uma comparação justa, os dois modelos apresentam a mesma estrutura, ou seja, possuem o mesmo número de camadas, neurônios e as mesmas funções de ativação.

Na Figura 4.4 são apresentadas as respostas do modelo RNA desenvolvido (curva tracejada em vermelho) e do modelo RNA gerado com o auxílio do MatLabTM (curva ponto tracejada em preto) em comparação ao comportamento de descarga da bateria (curva contínua em azul). Pelas curvas, é possível notar que os dois modelos RNA conseguem reproduzir o perfil real de descarga da bateria. O modelo desenvolvido apresenta um desempenho melhor em comparação

ao modelo gerado pelo MatLab™, visto que se mantém mais próximo da curva de descarga da bateria.




Figura 4.4: Resposta de modelos RNA da descarga da bateria.

Uma comparação dos modelos RNA com a descarga real da bateria é realizada por meio da correlação e a raiz do erro médio quadrado (RMSE) das curvas, como pode ser visto na Tabela 4.2. Pode se notar que o modelo RNA desenvolvido apresenta uma correlação maior e um valor RMSE menor que o modelo gerado pelo MatLab. Esse desempenho superior do modelo desenvolvido se deve a sua maior autonomia na definição do método de treinamento e seu critério de parada.

Tabela 4.2: Comparação dos modelos RNAs.

Modelo RNA	RMSE	Correlação
MatLab	0,4177	0,9987
Proposto	0,1708	0,9994

Verificada a capacidade da RNA proposta em reproduzir o comportamento de descarga de uma bateria, segue-se para avaliar o seu desempenho no controle de troca de marcha de um veículo. Dessa maneira, será possível examinar a aplicação da RNA em problemas de tomada de decisões envolvendo a dinâmica de veículos automotores.

4.4 Aplicação da RNA em controle de troca de marcha

Para avaliar o desempenho da RNA genérica aplicada em um problema de estratégia de troca de marcha em veículos, será utilizado como referência o estudo descrito por Eckert *et al.* (2019a). O estudo apresenta um controle de troca de marcha baseado em lógica

fuzzy, determinado por uma otimização multiobjetivo, visando maximizar o desempenho, minimizar o consumo de combustível e minimizar as emissões de gases poluentes do veículo Chevrolet Celta 1.0L. O controle de troca de marcha desenvolvido no estudo, quando comparado com a estratégia convencional, indicou uma menor emissão de gases poluentes, maior economia de combustível e maior desempenho.

A estratégia de troca de marcha define o comando que deve ser executado na caixa de engrenagens da transmissão, como avançar, reduzir ou manter a posição da marcha (Eckert *et al.*, 2019a). Esse comando é determinado com base nas condições de operação do veículo, como o torque requerido, a rotação e a temperatura do motor. O Torque requerido é calculado conforme a demanda do motorista ou com base no perfil de velocidade do ciclo de condução a ser reproduzido. A rotação do motor pode ser estabelecida pela velocidade linear do veículo, pela posição da marcha e pelas relações de engrenamento do sistema de transmissão. Na Figura 4.5 é apresentado um desenho esquemático da estratégia de troca de marcha.

Para iniciar a implementação da RNA genérica, o modelo de veículo (capítulo 2.2) foi adaptado, adotando os parâmetros físicos e inerciais do Chevrolet Celta apresentados no estudo de Eckert *et al.* (2019a). Para o eixo dianteiro foi implementado o sistema de transmissão do veículo, um motor de combustão interna acoplado a caixa de engrenagens por uma embreagem. Então, a caixa transmite a potência para um diferencial mecânico, que conduz a potência para as rodas do veículo.




Figura 4.5: Desenho esquemático do controle de troca de marcha.

Para simular o comportamento do motor de combustão interna será utilizada a ferramenta de simulação ADVISOR™ (Advanced Vehicle Simulator), que possibilita quantificar o consumo de combustível, o desempenho e as emissões de um motor (Markel *et al.*, 2002). Outro ponto importante da ferramenta é a possibilidade de simular o regime transiente da partida a frio de veículos, visto que ela consegue estimar a eficiência do catalisador do veículo, influenciada pela temperatura do motor (Markel *et al.*, 2002). Dessa maneira, o ADVISOR™ é empregado por diversos estudos em sistemas de propulsão veicular, por apresentar um pacote simples, flexível e robusto para determinar as mudanças esperadas devido à implementação de uma tecnologia (Gökce e Ozdemir, 2014, Zhou *et al.*, 2020 e Hu *et al.*, 2020).

O ADVISOR™ é calibrado para simular um motor de combustão interna 1.0L 4 cilindros (Chevrolet Celta), por meio dos mapas de consumo específico e emissões presentes em seu banco de dados. Dessa maneira, a partir de um ponto de operação do motor, determinado pelo seu torque efetivo e pela sua velocidade angular, o ADVISOR™ determina o seu consumo de combustível instantâneo e as emissões liberadas na saída do escapamento. Com o modelo dinâmico da transmissão e a posição da marcha da caixa de engrenagens é possível calcular o torque e rotação do motor, em função do torque requerido (demanda do motorista ou ciclo) e da velocidade do veículo (modelo dinâmico).

A transmissão por caixa de engrenagens, a ferramenta ADVISOR™ e a RNA genérica são implementadas no modelo dinâmico do veículo para simular e avaliar o comportamento do veículo de referência. Para a análise de emissões de gases poluentes atmosféricos, serão avaliadas as emissões de hidrocarbonetos (HC), monóxido de carbono (CO) e óxidos de nitrogênio (NO_x) geradas pelo motor de combustão interna durante a simulação do veículo ao reproduzir o ciclo NBR6601 (FTP-75).

Para este estudo, o treinamento da RNA genérica será realizado, também, por um algoritmo evolucionário genético. O treinamento, assim como no estudo usado como referência, terá como objetivo minimizar o consumo de combustível, minimizar as emissões de poluentes e maximizar o desempenho do veículo. Portanto, a arquitetura e os parâmetros da RNA são ajustados no treinamento, conforme os resultados obtidos pelas redes em relação aos objetivos definidos.

O primeiro objetivo é minimizar o consumo de combustível do veículo FC [L], determinado com o auxílio do ADVISOR™ durante a sua simulação. Esse objetivo é apresentado na Equação 4.7.

$$f_1 = \min (FC(\mathbf{X}_S)) \quad (4.7)$$

O segundo objetivo é minimizar as emissões dos gases poluentes, dessa maneira, com o auxílio do ADVISOR™, são quantificadas as emissões de HC (E_{HC}), CO (E_{CO}) e NO_x (E_{NO_x}) durante a simulação. Posteriormente, é realizada uma soma ponderada dos gases emitidos pelo veículo, em que a ponderação é feita em função da emissão máxima (E^{max}) e mínima (E^{min})

de cada gás encontrada na população. Dessa maneira, o segundo objetivo do treinamento é indicado na Equação 4.8.

$$f_2 = \min \left(\frac{E_{HC}(\mathbf{X}_S) - E_{HC}^{min}}{E_{HC}^{max} - E_{HC}^{min}} + \frac{E_{CO}(\mathbf{X}_S) - E_{CO}^{min}}{E_{CO}^{max} - E_{CO}^{min}} + \frac{E_{NOx}(\mathbf{X}_S) - E_{NOx}^{min}}{E_{NOx}^{max} - E_{NOx}^{min}} \right) \quad (4.8)$$

O terceiro objetivo do treinamento visa maximizar o desempenho do veículo ao realizar o ciclo de condução NBR6601. Para isto, é avaliada a correlação (R) entre o perfil de velocidade obtido pelo veículo com a RNA implementada e o ciclo. Assim, o último objetivo é mostrado na Equação 4.9.

$$f_3 = \max (R(\mathbf{X}_S)) \quad (4.9)$$

Por fim, para determinar a aptidão da RNA, correlacionando os três objetivos estabelecidos, é realizada a soma dos pesos adaptativos e iterativos (Gen *et al.*, 2008). Dessa maneira, cada critério é ponderado pelos valores máximos e mínimos encontrados na população a cada geração/iteração. A função objetivo é calculada com o auxílio da Equação 4.10

$$F_t(\mathbf{X}_S) = \frac{f_1^{max} - f_1(\mathbf{X}_S)}{f_1^{max} - f_1^{min}} + \frac{f_2^{max} - f_2(\mathbf{X}_S)}{f_2^{max} - f_2^{min}} + \frac{f_3^{max} - f_3(\mathbf{X}_S)}{f_3^{max} - f_3^{min}} \quad (4.10)$$

Os parâmetros que determinam a RNA genérica são reunidos em um vetor denominado cromossomo ($\mathbf{X}_S$), como apresentado na Equação 4.11. Posteriormente, os cromossomos são simulados, os resultados avaliados e armazenados na população.

$$\mathbf{X}_S = [w_{1,1} \ w_{2,1} \ \dots \ w_{N,C} \ \lambda_{1,1} \ \lambda_{1,2} \ \dots \ \lambda_{N,2}] \quad (4.11)$$

Inicialmente, são geradas aleatoriamente 100 RNAs, que formam a uma população inicial de redes. Posteriormente as RNAs são simuladas, os seus critérios de treinamentos avaliados e o seu fator de desempenho é determinado. Então, a população das redes é classificada e duas RNAs da população são selecionadas pelo método da roleta (descrito no capítulo 3.3). Essas duas RNAs são combinadas para formar uma nova RNA, em que há uma probabilidade de 50% de cada um dos indivíduos selecionados definir os parâmetros da nova rede. Após o cruzamento das redes, a nova RNA é mutada para introduzir novos valores na população. Por fim, a nova RNA é simulada e adicionada a população.

As RNAs que não são dominadas por outras redes em todos os critérios são denominadas redes não dominadas, constituindo a Fronteira de Pareto. Quando a população ultrapassa o limite de 100 RNAs, o algoritmo de treinamento exclui as redes com piores fatores de desempenho e dominadas, soluções que não são fronteira de Pareto.

A estagnação do processo evolutivo do treinamento é determinada com base repetibilidade da sua fronteira de Pareto. Dessa maneira, após 50 gerações sem alteração no conjunto de soluções não dominadas, o treinamento é encerrado (Eckert *et al.*, 2019a).

Após o treinamento da rede, o conjunto das soluções não dominadas por outras em todos os critérios de treinamento formam a fronteira de Pareto, exibidas na Figura 4.6. O losango em magenta representa a RNA com menor consumo de combustível ($\min f_1$), o losango em verde mostra a solução que apresentou o menor fator de emissão ($\min f_2$), e o losango azul indica a rede que teve o melhor desempenho do veículo ($\max f_3$). A estrela em vermelho corresponde a RNA que apresenta a melhor combinação nos três critérios simultaneamente, determinado pela função objetivo.




Figura 4.6: Fronteira de Pareto para o treinamento da estratégia RNA para a troca de machar.

A resposta com o menor consumo de combustível apresenta o maior fator de emissão de gases poluentes e um dos piores desempenhos entre as RNAs da fronteira de Pareto. Por outro lado, a rede com menor fator de emissão demonstra um dos maiores consumos de combustível e um desempenho intermediário. Já a RNA que obteve o melhor desempenho exibe o maior consumo de combustível e um fator de emissão intermediário. Por fim, a melhor solução obtida no treinamento apresenta um fator de emissão e um desempenho intermediários, contudo, no consumo de combustível ela se aproxima da melhor resposta.

A RNA que melhor atendeu aos critérios simultaneamente é analisada. A resposta do sinal de velocidade e a posição da marcha do veículo são apresentadas na Figura 4.7. A velocidade obtida pelo veículo com o RNA implementado é apresentada pela curva contínua em vermelho e a curva tracejada em preto indica o ciclo de condução NBR 6601 (Figura 4.7 *a*). É possível notar que o sinal de velocidade do veículo e o perfil do ciclo de condução se sobrepõem. Na Figura 4.7 *b* é apresentada a posição da marcha do veículo ao longo do ciclo de condução.




Figura 4.7: Resposta de modelos RNA na troca de marcha.

Por fim, os resultados obtidos pela RNA genérica são comparados com o controlador de lógica fuzzy (FLC - *Fuzzy Logic Control*) desenvolvido no estudo usado como referência (Eckert *et al.*, 2019a). Na Tabela 4.3 é apresentada a comparação do desempenho atingido pelas duas estratégias de troca de marchas (RNA e FLC) e o veículo padrão (estratégia indicada no manual do veículo). Pode-se notar que tanto o FLC quanto a RNA demonstraram uma evolução quando comparados a estratégia padrão, reduzindo o consumo de combustível e a emissão dos três gases poluentes. Por outro lado, quando a RNA é comparada com o FLC, observa-se uma diminuição no consumo de combustível (0,045 L) e na emissão de NO_x (0,020 g/km), entretanto, a rede atingiu um maior emissão de CO (0,075 g/km). Na emissão de HC as duas estratégias chegaram a valores semelhantes, com uma leve vantagem para a RNA, que emitiu 0,002 g/km a menos que o FLC.

Tabela 4.3: Resultados de modelos RNA e Fuzzy para troca de marcha.

Resultados	Melhor Compromisso		Celta Padrão
	FLC	RNA	
Consumo [L]	1,180	1,135	1,470
NO _x [g/km]	0,195	0,175	0,235
CO [g/km]	1,353	1,428	1,911
HC [g/km]	0,243	0,241	0,279

4.5 Implementação da RNA em um microcontrolador

Para avaliar o desempenho da RNA em condições reais, o tempo despendido no processamento de cada etapa da rede foi determinado. Para isto, cada etapa foi implementada em um microcontrolador Atmel 328p (plataforma Arduino) e o seu tempo de processamento calculado. A partir do tempo de processamento é possível verificar se a RNA consegue responder/atuar numa frequência igual ou maior que o projeto necessita. Dessa maneira, esse tempo de processamento máximo exigido pode se tornar uma restrição aplicada ao treinamento da rede.

Inicialmente é determinado o tempo consumido em cada etapa de processamento do neurônio. Como dito anteriormente (seção 4.1), são basicamente duas etapas, na primeira há uma soma dos sinais ponderados com um valor de viés e na segunda o sinal resultante é aplicado na função de ativação do neurônio.

Na primeira etapa há a multiplicação dos sinais de entrada por pesos e, em seguida, todos os sinais são somadas com um valor de viés. O número de sinais de entrada depende da quantidade de neurônios da camada anterior, dessa maneira, é necessário avaliar o tempo de processamento para diversas condições. As ponderações dos sinais e a soma deles com o valor de viés são implementadas no microcontrolador.

Na Tabela 4.4 é apresentado o tempo médio necessário para o microcontrolador processar essa primeira etapa em função do número de neurônios da camada anterior. É possível notar que o tempo médio de processamento varia entre 21 μs e 96 μs . Quanto maior a quantidade de neurônios da camada anterior, maior será o tempo de processamento do neurônio nessa etapa.

Em seguida é avaliado o tempo despendido na segunda etapa de processamento do neurônio. Dessa maneira, todas as funções de ativação foram implementadas no microcontrolador e o tempo médio de processamento foi determinado. Na Tabela 4.5 são apresentados os tempos médios de processamento de cada função de ativação. As funções ReLU e Leaky ReLU são as funções que necessitam de menos tempo para processar o sinal 13 μs e 17 μs , respectivamente. As duas funções comparam dois valores e retornam o maior deles. Em contrapartida, a função GELU é a que mais despende tempo para processar o sinal e retornar uma resposta (432 μs), isso se deve a função de distribuição cumulativa da distribuição normal ser bastante complexa, necessitando de mais tempo para sua solução.

Tabela 4.4: Tempo de processamento da ponderação e soma dos sinais.

Número de Neurônios da camada anterior	Tempo de processamento (μs)
1	21
2	29
3	37
4	45
5	53
6	62
7	70
8	79
9	88
10	96

Tabela 4.5: Tempo de processamento de cada função de ativação.

Função de ativação	Tempo de processamento (μs)
Linear	38
Função Sigmoid	141
Função Sigmoid Simétrica	147
Função Degrau	31
ReLU Paramétrica	13
Leaky ReLU Paramétrica	17
Tangente Hiperbólica	297
SELU	89
GELU	432

A partir os tempos de processamento das ponderações dos sinais de entrada e os tempos de processamento das funções de ativação é possível calcular o tempo de processamento de um determinado neurônio da rede. Dessa maneira, com base na arquitetura de uma certa RNA, pode-se calcular o tempo de processamento de cada um dos seus neurônios. Somando os tempos de processamento de todos os neurônios, tem-se o tempo de processamento total da RNA t_{rna} .

5 REDE NEURAL ARTIFICIAL APLICADA AO GERENCIAMENTO DE POTÊNCIA DE VEÍCULOS ELÉTRICOS

Para iniciar o estudo da estratégia de gerenciamento de potência, a RNA genérica desenvolvida é adaptada e implementada no modelo dinâmico do veículo elétrico. O sistema de propulsão determinado do veículo possui tração nas quatro rodas, em que um ME é acoplado em cada uma das rodas (capítulo 2.1). Dessa maneira, a estratégia de gerenciamento deve determinar a condição de operação de cada um dos motores do veículo, com base no comportamento do veículo e na demanda exigida pelo motorista. Na Figura 5.1 é apresentado um desenho esquemático do funcionamento da RNA genérica proposta para gerenciar a potência do veículo elétrico.




Figura 5.1: Estratégia de controle de potência proposta.

O gerenciador de potência utiliza as eficiências instantâneas dos sistemas de potência de cada eixo do veículo e o torque requerido pelo motorista para determinar o comando que deve ser empregado aos MEs. Essas variáveis são adotadas como entrada para a RNA genérica, visto que elas apresentaram excelentes resultados em diversos trabalhos, que estudaram gerenciamento de potência em veículos (da Silva *et al.*, 2021; Eckert *et al.*, 2022b e Eckert *et al.*, 2022a).

O torque requerido pelo motorista, para este trabalho, é determinado a partir da diferença entre a velocidade do veículo (modelo dinâmico) e o ciclo de condução (velocidade desejada). Para realizar o treinamento da RNA genérica é utilizado um ciclo de condução específico (capítulo 3.5), que visa reproduzir as exigências dos ciclos padrões e as dificuldades encontradas em condições reais. Por outro lado, as eficiências dos sistemas de potência são determinadas pela sua velocidade angular, pelo torque efetivo, pelo mapa de eficiência do ME e do inversor

(capítulo 2.5). A velocidade angular de cada ME é calculada com base na velocidade linear do veículo, enquanto, o torque efetivo é estabelecido pelo gerenciador de potência.

As eficiências e o torque requerido são processados pela RNA genérica, que retorna os torques que devem ser aplicados em cada ME do veículo. Posteriormente, o comando da RNA é avaliado, em que é verificado se o torque não ultrapassa os limites de tração do pneu, se a corrente necessária para o torque excede a corrente máxima da bateria e se há carga na bateria (*SoC*). Caso alguma condição seja desobedecida, o torque é saturado para que elas sejam respeitadas.

O intervalo de tempo utilizado para realizar a integração do modelo numérico nas simulações será de 0,050 ms, uma vez que a redução desse valor não produz um aumento considerável da acuracidade dos resultados. Esse valor do intervalo de integração, também é utilizado em outros trabalhos que simulam modelos dinâmicos de veículos (Silva *et al.*, 2022a; Silva *et al.*, 2022b e Eckert *et al.*, 2022b).

5.1 Formulação do Problema

Para este trabalho será utilizado um treinamento baseado em um algoritmo genético. O treinamento visa encontrar a RNA mais adequada, sua arquitetura e parâmetros, para gerenciar a distribuição de potência de um veículo elétrico, com motores elétricos *in-wheel*. Durante o treinamento também serão definidos o pacote de baterias e os motores elétricos mais adequados. O objetivo do treinamento é encontrar a configuração de RNA, motores e bateria que apresente a maior autonomia, menor consumo equivalente de energia, menor massa e maior vida útil da bateria. Dessa maneira, para atingir esses objetivos, três critérios de treinamento são definidos.

O primeiro critério de treinamento é a maximização da autonomia do veículo. Na simulação, o veículo repete o ciclo de treinamento até o estado de carga *SoC* da bateria atingir 40%. Então, a distância percorrida pelo veículo D_R [km] é determinada. Dessa maneira, a autonomia do veículo é definida pela Equação 5.1.

$$f_1 = \max(D_R(\mathbf{X}_G)) \quad (5.1)$$

O segundo critério avaliado visa minimizar a massa do sistema elétrico (baterias e motores elétricos) M_{SE} [kg] e minimizar o tempo de recarga da bateria t_{rec} [s]. Esse critério faz uma soma ponderativa entre as massas e o tempo de recarga. A ponderação é realizada pelos valores máximos e mínimos encontrados na população, como indicado na Equação 5.2. Dessa maneira, quanto mais próximo de 0 for o segundo critério f_2 , melhor será a resposta e quanto mais próximo de 2, pior será a resposta.

$$f_2 = \min \left(\frac{M_{SE}(\mathbf{X}_G) - M_{SE}^{min}}{M_{SE}^{max} - M_{SE}^{min}} + \frac{t_{rec}(\mathbf{X}_G) - t_{rec}^{min}}{t_{rec}^{max} - t_{rec}^{min}} \right) \quad (5.2)$$

Por fim, o terceiro critério tem em vista minimizar os custos da bateria. Dessa maneira, busca-se maximizar a vida útil da bateria, estado de saúde SoH , e minimizar o consumo equivalente de energia C_{st} [R\$/km] (custo de recarga da bateria pela distância percorrida). A Equação 5.3 apresenta a soma ponderativa dos dois parâmetros que determinam o terceiro critério de treinamento.

$$f_3 = \min \left(\frac{SoH^{max} - SoH(\mathbf{X}_G)}{SoH^{max} - SoH^{min}} + \frac{C_{st}(\mathbf{X}_G) - C_{st}^{min}}{C_{st}^{max} - C_{st}^{min}} \right) \quad (5.3)$$

Para avaliar a aptidão de cada uma das RNAs, foi utilizado o método dos pesos adaptativos iterativos, proposto por Gen *et al.* (2008), que pondera cada critério em relação aos valores máximos e mínimos encontrados na população. Os critérios ponderados são somados com um fator de bônus e um fator de penalidade (P_p). O fator de bônus visa aumentar o valor de aptidão das respostas com menores tempos de processamento da RNA (t_{rna}), dessa maneira, favorecendo RNAs mais rápidas que serão mais adequadas na aplicação em condições reais. Por fim, o fator de penalidade visa penalizar as soluções dominadas da população, assim, $P_p(\mathbf{X}_G)$ assume o valor de 0 para essas soluções e 1 para as soluções não dominadas. A Equação 5.4 apresenta o cálculo da função objetivo F_t para cada solução.

$$F_t(\mathbf{X}_G) = \sum_{c=1}^3 \frac{f_c^{max} - f_c(\mathbf{X}_G)}{f_c^{max} - f_c^{min}} + \frac{t_{rna}^{max} - t_{rna}(\mathbf{X}_G)}{t_{rna}^{max} - t_{rna}^{min}} + P_p(\mathbf{X}_G) \quad (5.4)$$

Os parâmetros para definir o modelo da RNA genérica, os parâmetros do ME e da bateria são reunidos em um vetor denominado cromossomo ($\mathbf{X}_G$), como apresentado na Equação 5.5.

$$\mathbf{X}_G = [w_{1,1} \ w_{2,1} \ \dots \ w_{N,C} \ \lambda_{1,1} \ \lambda_{1,2} \ \dots \ \lambda_{N,2} \ V_{bat} \ Q_{bat} \ T_{EM,f} \ T_{EM,t} \ \omega_{EM,f} \ \omega_{EM,t}] \quad (5.5)$$

Todas as soluções precisam atender alguns critérios, que garantem que as elas produzam respostas viáveis para gerenciamento de distribuição potência. Na Equação 5.6 são apresentados todas as restrições utilizadas durante o treinamento da rede.

$$H(\mathbf{X}_G) = \begin{cases} D_R(\mathbf{X}_G) \geq 101 \text{ km} \\ R(\mathbf{X}_G) \geq 0,999 \\ RMSE(\mathbf{X}_G) \leq 0,5 \text{ km/h} \\ \max(|V_{sim}(\mathbf{X}_G) - V_{cic}|) \leq 5 \text{ km/h} \\ t_{rna} \leq 50 \text{ ms} \\ 100 \text{ V} \leq V_{bat} \leq 400 \text{ V} \\ 50 \text{ Ah} \leq Q_{bat} \leq 150 \text{ Ah} \\ 50 \text{ Nm} \leq T_{EM,f}, T_{EM,r} \leq 300 \text{ Nm} \\ 250 \text{ rpm} \leq \omega_{EM,f}, \omega_{EM,r} \leq 3000 \text{ rpm} \end{cases} \quad (5.6)$$

As quatro primeiras restrições visam garantir que todas as soluções reproduzam o ciclo de treinamento adequadamente. A primeira restrição elimina todas as configurações (RNA, MEs e baterias) que não consigam completar o ciclo de treinamento. Dessa maneira, na simulação, o veículo deve percorrer uma distância D_R [km] maior que o ciclo (101 km).

A segunda restrição é a correlação R entre o perfil de velocidade apresentado pela solução da RNA (V_{sim}) e o ciclo de treinamento (V_{cic}). A correlação é utilizada para assegurar que a solução reproduz um comportamento semelhante ao ciclo. Na Equação 5.7 é apresentado o cálculo da segunda restrição de treinamento.

$$R = \sqrt{\frac{(\sum (V_{sim} - \bar{V}_{sim}) (V_{cic} - \bar{V}_{cic}))^2}{\sum (V_{sim} - \bar{V}_{sim})^2 \sum (V_{cic} - \bar{V}_{cic})^2}} \quad (5.7)$$

A terceira e a quarta restrições são aplicadas para garantir que a velocidade do veículo mantenha-se próximo da velocidade desejada, em todo o ciclo de treinamento. A terceira restrição avalia raiz do erro médio quadrado (RMSE) entre o sinal de velocidade apresentado solução da RNA (V_{sim}) e o ciclo de treinamento (V_{cic}), como indicado na Equação 5.8. Por outro lado, quarta restrição descarta as soluções que, em qualquer instante de tempo, apresentem uma variação da sua velocidade maior que 5 km/h em relação ao ciclo.

$$RMSE = \sqrt{\frac{1}{t} \sum_{i=1}^t (V_{sim,i} - V_{cic,i})^2} \quad (5.8)$$

A quinta restrição é definida para assegurar que o tempo de processamento da RNA seja menor que o tempo de integração numérica da simulação (50 ms). Dessa maneira, em uma simulação hardware-in-the-loop, a RNA conseguirá gerar um comando de atuação para cada passo de integração da simulação.

A sexta e sétima restrições definem o intervalo de busca da tensão V_{bat} e da capacidade Q_{bat} da bateria do veículo. Já a oitava e nona restrições determinam os limites de torque T_{EM} e rotação ω_{EM} dos motores elétricos. Esses valores limites são definidos por meio da especificação de baterias e MEs comerciais utilizados em veículos híbridos e elétricos (Eckert *et al.*, 2022b; Silva *et al.*, 2021).

Depois das soluções que não atendem as restrições serem eliminados, os cromossomos simulados são avaliados e armazenados num banco de dados, chamado de população. A população é classificada em função da sua aptidão (Equação 5.4) e aleatoriamente dois indivíduos da população são escolhidos por meio do método da roleta (Sastry *et al.*, 2005). Dessa maneira, a probabilidade de seleção S_P de um indivíduo é proporcional ao seu fator de desempenho, como indicado na Equação 5.9.

$$S_P(\mathbf{X}_G) = \frac{F_t(\mathbf{X}_G)}{\sum_{i=1}^t F_t(\mathbf{X}_G)} \quad (5.9)$$

Após a seleção dos dois indivíduos da população é realizado o cruzamento. Nessa etapa, os elementos dos cromossomos são combinados para formar um novo cromossomo. Cada elemento do novo indivíduo tem a probabilidade de 50% de ser do indivíduo 1 e de 50% de ser do indivíduo 2.

Em seguida, o novo indivíduo passa por um processo de mutação dos seus elementos. Essa mutação tem o objetivo de introduzir novos valores aos elementos do indivíduo e a probabilidade de cada elemento sofrer mutação é de 50%. A mutação máxima que o elemento pode sofrer é 10% da amplitude de busca de cada elemento A_m e determinada por um número gerado aleatoriamente σ_m , que varia entre -1 e 1. Então, essa mutação é somada ao valor do elemento original $\nu_{original}$, dando origem ao valor do elemento mutado ν_{mutado} , como indicado na Equação 5.10.

$$\nu_{mutado} = \nu_{original} + 0,1A_m\sigma_m \quad (5.10)$$

O critério de convergência utilizado no treinamento é determinado pela repetibilidade da fronteira de Pareto, que segundo Eckert *et al.* (2017) após 50 gerações de soluções não dominadas ocorre a estagnação do processo evolutivo da otimização.

5.2 Resultados

O treinamento baseado em algoritmo genético foi executado para encontrar a arquitetura mais adequada para a RNA, os motores elétricos e baterias para o melhor gerenciamento da divisão de potência do veículo elétrico. Após a convergência do algoritmo de treinamento da RNA, a fronteira de Pareto da população resultante define as soluções ideais que melhor representam o comprometimento entre os critérios de otimização, ela é apresentada na Figura 5.2. Os pontos em preto representam as soluções não dominadas, o losango rosa indica a solução com maior autonomia ($\min f_1$), o losango em verde representa a solução com menor massa do sistema elétrico e menor tempo de recarga ($\min f_2$) e o losango em ciano mostra a solução com maior estado de saúde da bateria e menor consumo equivalente ($\min f_3$). Por fim, a estrela vermelha representa a solução com o melhor compromisso entre os três critérios avaliados, ou seja, que apresenta o maior fator de desempenho ($\max F_t$).

Na Tabela 5.1 são apresentados as configurações e os resultados dos veículos e das RNAs obtidas no treinamento. Pode-se notar que a primeira RNA $\max(F_t)$ apresenta a arquitetura mais simples, contendo apenas 13 parâmetros. A segunda RNA $\max(f_1)$ apresenta a maior distância percorrida, a maior quantidade de baterias e os maiores motores elétricos. A terceira rede $\max(f_2)$ apresenta a menor distância percorrida, a menor expectativa de vida útil da bateria, a menor massa de bateria e os menores motores elétricos. Por fim, a quarta rede $\min(f_3)$ apresenta o menor consumo elétrico relativo, o menor custo equivalente de viagem e a rede mais complexa, contendo 279 parâmetros.




Figura 5.2: Fronteira de Pareto para o treinamento da estratégia RNA de gerenciamento de potência.

A rede neural com a maior autonomia do veículo ($\max(f_1)$) apresenta a maior expectativa de vida da bateria, a maior massa do sistema de propulsão elétrica, o maior custo de viagem e o maior custo equivalente. Como no treinamento essa configuração prioriza a autonomia do veículo, ela possui a maior bateria, aumentando a massa do sistema elétrico, e consequentemente, diminuindo o desgaste da bateria ao realizar o ciclo de treinamento, provocando o aumento da sua expectativa de vida útil.

Tabela 5.1: Resultados alcançados pelas configurações de RNA treinadas.

Configuração da RNA	Resultados			
	$\max(F_t)$	$\max(f_1)$	$\min(f_2)$	$\min(f_3)$
Distância percorrida D_R [km]	157,8	247,3	102,4	155,9
Correlação da velocidade e ciclo R	0,999	0,999	0,999	0,999
Erro médio da velocidade $RMSE$ [km/h]	0,031	0,065	0,040	0,398
Erro máximo da velocidade [km/h]	2,467	2,448	2,045	1,981
Tempo de recarga da bateria T_{rec} [h]	2,357	2,353	2,342	2,419
Massa do sistema elétrico M_{SE} [kg]	295,4	463,4	216,9	266,5
Potência elétrica consumida [kWh]	24,84	43,01	16,21	24,31
Consumo elétrico relativo [kWh/km]	0,157	0,174	0,158	0,156
Custo da viagem [R\$]	19,70	34,11	12,86	19,28
Custo equivalente C_{st} [R\$/km]	0,125	0,138	0,126	0,124
Estado de saúde da bateria SoH	0,956	0,967	0,935	0,964
Expectativa de vida útil da bateria ($SoH = 0,8$) [10^3 km]	205,0	368,2	158,3	229,5
Número de parâmetros da RNA N_{rna}	13	147	64	279
Tempo de processamento t_{rna} [ms]	1	4	2	9
Variáveis de projeto				
Massa da bateria M_{bat} [kg]	195,1	389,3	151,8	222,7
Tensão elétrica da bateria V_{bat} [V]	355,4	397,6	276,6	399,7
Capacidade da bateria Q_{bat} [Ah]	82,32	146,8	82,30	83,59
Torque dos MEs dianteiros $T_{EM.f}$ [Nm]	270,6	297,5	272,7	293,6
Rotação dos MEs dianteiros $\omega_{EM.f}$ [rpm]	340,9	340,1	356,3	340,5
Massa dos MEs dianteiros [kg]	35,32	38,29	36,95	37,89
Torque dos MEs traseiros $T_{EM.r}$ [Nm]	258,2	292,1	258,3	291,2
Rotação dos MEs traseiros $\omega_{EM.f}$ [rpm]	329,1	321,1	316,4	329,7
Massa dos MEs traseiros [kg]	32,88	35,83	31,77	36,51

A solução com menor massa do sistema elétrico e menor tempo de recarga ($\min(f_2)$) apresenta a menor distância percorrida, o menor custo da viagem e a menor expectativa de vida da bateria. Essa rede favorece configurações com baterias menores (menor massa), o suficiente para, pelo menos, completar o ciclo de treinamento. Dessa maneira, há um maior desgaste da bateria ao realizar o ciclo, diminuindo a sua expectativa de vida.

A RNA que visa a maior expectativa de vida e o menor custo equivalente da viagem ($\min(f_3)$), possui o maior tempo de recarga da bateria, enquanto a sua distância percorrida, a sua massa e expectativa de vida são valores intermediários. O terceiro critério de treinamento não apresenta uma correlação alta com os demais critérios, o que evidencia que para uma mesma massa de baterias é possível aumentar a sua expectativa de vida e diminuir os custos equivalentes da viagem, com o uso do gerenciador de potência adequado. A mesma situação pode ser observada na autonomia do veículo. Para distâncias percorridas similares é possível diminuir o custo equivalente da viagem e aumentar a expectativa de vida da bateria.

Na Figura 5.3 é apresentado o tempo de processamento da RNA (t_{rna}), de cada solução da Fronteira de Pareto, em comparação com o seu fator de desempenho e os critérios de otimização. Pela Figura 5.3 *a* é possível notar que as soluções que apresentam os maiores fatores de desempenho são as soluções com menores tempos de processamento da RNA, isso se deve a bonificação concedida para as RNAs mais rápidas (Equação 5.4). Por outro lado, a Figura 5.3 *b*, *c* e *d* não apresentam uma correlação entre o tempo de atuação e os critérios de otimização.




Figura 5.3: Tempo de processamento das RNAs da Fronteira de Pareto.






Pela Figura 5.3 *b* é possível notar que existem soluções que conseguem percorrer distâncias similares com diferenças nos tempos de processamento da RNA consideráveis. Essa diferença ocorre devido ao tipo de arquitetura da RNA, ou seja, pelo tamanho da rede (quantidade de camadas e neurônios) e pelas funções de ativação definidas para cada neurônio. Dessa maneira, durante o treinamento é possível encontrar duas ou mais soluções que apresentem respostas semelhantes com arquiteturas distintas. Para beneficiar as soluções que apresentam uma arquitetura mais dinâmica, é necessário adicionar o bônus em relação ao processamento. Assim, durante o treinamento as soluções mais eficientes têm mais chances de gerar novos indivíduos.

Na Figura 5.4 são apresentadas as respostas dos sinais de velocidade dos veículos elétricos com as RNAs obtidas no treinamento, em comparação ao sinal de velocidade do ciclo de condução utilizado para o treinamento (curva contínua em preto). O sinal de velocidade da RNA que apresenta o maior fator de desempenho ($\max F_t$) é indicado pela curva tracejada em vermelho na Figura 5.4*a*. A resposta da RNA com maior autonomia ($\min f_1$) é apresentada na Figura 5.4*b* e representada pela curva tracejada em magenta. Na Figura 5.4*c* é exibido, em verde, o desempenho da rede com menor massa do sistema elétrico e menor tempo de recarga ($\min f_2$). Por fim, a velocidade obtida pela RNA com maior estado de saúde da bateria e menor consumo equivalente ($\min f_3$) é indicada pela curva tracejada em ciano na Figura 5.4*d*.

Os sinais de velocidades de todas as 4 configurações de RNAs se aproximam do ciclo de condução de treinamento coeficiente de correlação. Dessa maneira, todas as redes apresentam desempenhos adequados na reprodução do ciclo. As curvas tracejadas em azul indicam o estado de carga da bateria (*SoC*) de cada um dos veículos. De maneira geral, é possível notar dois momentos de intensa descarga da bateria, que correspondem com os perfis rodoviários do ciclo de treinamento. O primeiro ocorre entre 2000 s e 3100 s, quando o veículo reproduz o ciclo de NBR 7024 e o ciclo US06, enquanto o segundo momento ocorre entre 4200 s e 6000 s, instantes em que o veículo emula o ciclo rodoviário desenvolvido pelo gerador de ciclos.






O veículo com menor massa do sistema elétrico (Figura 5.4*c*) termina o ciclo com o menor estado de carga (40%), enquanto o veículo com maior autonomia (Figura 5.4*b*) termina o ciclo com o maior estado de carga (75%). Isso ocorre devido às prioridades de cada critério, o primeiro critério visa aumentar a autonomia, dessa maneira, possui a maior massa de baterias (Tabela 5.1). Por outro lado, o segundo critério visa minimizar a massa do sistema elétrico, dessa maneira, o veículo apresenta uma quantidade de baterias suficiente para conseguir terminar o ciclo de treinamento. Por fim, as outras duas soluções $\min f_3$ e $\max F_t$ terminam o ciclo de treinamento com estados de carga intermediários, respectivamente, de 55% e 60%.

Na Figura 5.5 são apresentadas as distribuições dos torques determinadas pelas RNAs, indicadas pela porcentagem do torque requerido exercida pelos MEs dianteiros, e os torques requeridos nos MEs. Dessa maneira, as curvas tracejadas em azul indicam o torque requerido pelos MEs para executar o ciclo, enquanto as curvas contínuas exibem a proporção do torque requerido aplicado pelos MEs dianteiros. A RNA com maior fator de desempenho (Figura 5.5 *a*) apresenta uma variação na distribuição de torques entre 50% e 78%, a RNA com maior

(a) Maior fator de desempenho ($\max F_t$)(b) Maior distância percorrida ($\max f_1$)(c) Menor massa do sistema elétrico e menor tempo de recarga bateria ($\min f_2$)(d) Maior útil da bateria e menor consumo equivalente ($\min f_3$)

(e) Legenda

Figura 5.4: Resposta das RNAs para o ciclo de treinamento.

(a) Maior fator de desempenho ($\max F_t$)(b) Maior distância percorrida ($\max f_1$)(c) Menor massa do sistema elétrico e menor tempo de recarga bateria ($\min f_2$)(d) Maior útil da bateria e menor consumo equivalente ($\min f_3$)

(e) Legenda

Figura 5.5: Distribuição dos torques das RNAs e o torque requerido no ciclo de treinamento.

autonomia (Figura 5.5 *b*) exibe a variação entre 10% e 76%, a RNA com menor massa (Figura 5.5 *c*) varia entre 20% e 95% e, por fim, a RNA com maior vida útil da bateria (Figura 5.5 *d*) varia entre 50% e 100%.

Como dito anteriormente, as 4 soluções conseguem reproduzir o ciclo de condução adequadamente. Entretanto, para as altas velocidades há uma diferença no desempenho das soluções em acompanhar o ciclo de treinamento. Na Figura 5.6 são apresentadas as respostas das RNAs para os instantes de maior velocidade do ciclo treinamento. É possível perceber que a RNA priorizam a autonomia ($\max f_1$) apresenta dificuldade em seguir o perfil nos trechos mais elevados ou com mudanças bruscas, uma vez que ela apresentam uma massa de baterias elevadas, aumentando a inércia do veículo e diminuindo a sua capacidade de atingir altas acelerações. Para a RNA que visa a diminuição da massa do sistema elétrico e do tempo de recarga ($\min f_2$), essa dificuldade ocorre devido aos motores elétricos determinados no treinamento, que apresentem menores massas e, conseqüentemente, menores torques máximos (T_{ME}).









Figura 5.6: Resposta das RNAs para a região de maiores velocidades do ciclo de treinamento.






Para avaliar o comportamento das RNAs obtidas no treinamento em ciclos diferentes, elas foram simuladas em um ciclo real entre Campinas e São Paulo. Na Figura 5.7 são apresentadas as respostas dos sinais de velocidade dos veículos elétricos, com as RNAs obtidas no treinamento, em comparação ao sinal de velocidade do ciclo de condução utilizado para o treinamento (curva contínua em preto). O sinal de velocidade da RNA que apresenta o maior fator de desempenho ($\max F_t$) é indicado pela curva tracejada em vermelho na Figura 5.7a. A resposta da RNA com maior autonomia ($\min f_1$) é apresentada na Figura 5.7b e representada pela curva tracejada em magenta. Na Figura 5.7c é exibido, em verde, o desempenho da rede com menor massa do sistema elétrico e menor tempo de recarga ($\min f_2$). Por fim, a velocidade obtida pela RNA com maior estado de saúde da bateria e menor consumo equivalente ($\min f_3$) é indicada pela curva tracejada em ciano na Figura 5.7d.

Pela Figura 5.7 é possível notar que de maneira geral todas as quatro configurações de RNA conseguem reproduzir o ciclo Campinas-São Paulo adequadamente. A primeira RNA apresentada ($\max F_t$) possui um valor RMSE, entre o sinal de velocidade obtida pela rede e o ciclo Campinas-São Paulo, de 0,07 km/h e uma variação máxima entre as velocidades de 4,26 km/h. É possível notar que entre 0 e 2400 s, percurso rodoviário do ciclo, há um consumo maior

(a) Maior fator de desempenho ($\max F_t$)(b) Maior distância percorrida ($\max f_1$)(c) Menor massa e tempo de recarga da bateria ($\min f_2$)(d) Maior vida útil da bateria e menor custo equivalente ($\max f_3$)

(e) Legenda

Figura 5.7: Resposta das RNAs para o ciclo Campinas-São Paulo.

(a) Maior fator de desempenho ($\max F_t$)(b) Maior distância percorrida ($\max f_1$)(c) Menor massa do sistema elétrico e menor tempo de recarga bateria ($\min f_2$)(d) Maior vida útil da bateria e menor consumo equivalente ($\min f_3$)


(e) Legenda

Figura 5.8: Distribuição dos torques das RNAs e o torque requerido no ciclo de treinamento.


de energia, enquanto, na região urbana, o consumo é menor. A segunda rede ($\min f_1$) apresentou um valor RMSE de 0,08 km/h e uma divergência entre as velocidades do veículo e do ciclo de 4,43 km/h. Pode-se perceber que ao final do ciclo essa rede manteve 80% do seu estado de carga (SoC). Para a terceira RNA apresentada, obteve-se um valor RMSE de 0,07 km/h e a maior diferença das velocidades encontrada foi de 4,22 km/h. Ao final do ciclo, a terceira RNA é a configuração que terminou o ciclo Campinas-São Paulo com o menor estado de carga da bateria, consumindo metade da energia armazenada. Por fim, a quarta e última rede apresentada, exibiu um valor RMSE de 0,07 km/h e uma variação máxima da sua velocidade em relação ao perfil do ciclo de 4,18 km/h.

Na Figura 5.8 são apresentados os torques requeridos nos MEs de cada configuração de veículo, gerada no treinamento, e as porcentagens das distribuições de torques nos eixos do veículo, determinadas pela estratégia de gerenciamento de potência RNA. Pode-se notar que a RNA com maior fator de desempenho (5.8a) apresenta uma variação mais suave no seu sinal de distribuição de torque que as demais RNAs. A RNA com maior autonomia (5.8b), que apresentam picos de distribuição de torque próximo dos 40% e acima dos 90%, indicando uma mudança brusca de comportamento dos MEs e a utilização, praticamente, de apenas um dos eixos do veículo.


Na Figura 5.9 são apresentados desenhos esquemáticos das arquiteturas das RNAs obtidas no treinamento das redes. A RNA com maior desempenho (Figura 5.9 a) apresenta a arquitetura mais simples com 2 camadas, na primeira camada há 2 neurônios, com funções de ativação sigmoid simétrica, e na segunda há 1 neurônio com função de ativação hiperbólica. A RNA com a maior distância percorrida (Figura 5.9 b) apresenta uma arquitetura com alta complexidade contendo 5 camadas e 23 neurônios. Já a rede com menor massa e menor tempo de recarga (Figura 5.9 c) exibiu uma arquitetura com complexidade intermediária, formada por 3 camadas e 11 neurônios. Por fim, RNA que buscou a maior vida útil da bateria e menor custo equivalente (Figura 5.9 d) apresentou a arquitetura de maior complexidade, com 6 camadas e 34 neurônios.




(a) RNA maior fator de desempenho




(b) RNA maior distância percorrida



(c) RNA menor massa e tempo de recarga da bateria



(d) RNA maior vida útil da bateria e menor custo equivalente



(e) Legenda das funções de ativação

Figura 5.9: Arquiteturas das RNAs obtidas no treinamento.

6 SIMULAÇÃO EM TEMPO REAL

Após o treinamento da RNA genérica em MatLab™, foram realizados testes para verificar a sua eficiência na determinação da distribuição de potência em condições reais. A rede com melhor fator de desempenho, obtida no treinamento, foi implementada em um microcontrolador ATmega 328p, em plataforma Arduino. Nos últimos anos, as placas Arduino tornaram-se populares como uma solução para ferramentas de prototipagem rápida para circuitos eletrônicos (Silva *et al.*, 2022a).

Essas plataformas vêm apresentando grande eficiência como sistemas de aquisição, atuação e controle em várias áreas da ciência. É possível citar como exemplo um controle preditivo adaptativo desenvolvido para o resfriamento de um central de servidores. O desempenho do controle foi avaliado por um microcontrolador ATmega 328p, que realizava a aquisição do sinal de temperatura da central, processava o controle e atuava com nas unidades de refrigeração (Martínez-García *et al.*, 2021). Esse microcontrolador também é utilizado no controle de uma plataforma robótica com oito garras, utilizada para melhorar a mobilidade em terrenos irregulares e acidentados (Wu *et al.*, 2021). Outro exemplo de aplicação é no controle de quadricóptero, em que a plataforma Arduino é utilizada para realizar a comunicação dos comandos de atuação do controle (Kuchwa-Dube e Pedro, 2022)

6.1 Implementação da RNA na simulação HIL

Para realizar a simulação pelo método hardware-in-the-loop (HIL), inicialmente, um algoritmo RNA específico foi desenvolvido e implementado na plataforma Arduino. A arquitetura da RNA implementada reproduz a arquitetura com maior fator de desempenho, obtido no treinamento. Posteriormente, foi desenvolvida a comunicação entre o microcontrolador e o MatLab™ (computador). A Figura 6.1 apresenta um diagrama da simulação do método HIL implementado.

A placa Arduino e o MatLab™ (computador) enviam e recebem dados por comunicação serial, eles convertem o valor das variáveis em quatro bits e enviam um para o outro. O algoritmo desenvolvido em MatLab™ estima o comportamento do veículo e transmite os valores de torque requerido e as eficiências dos motores para o microcontrolador. O microcontrolador (Arduino) recebe as entradas, processa o algoritmo da RNA e retorna a distribuição de torque que deve ser empregada no veículo. Em seguida, o computador insere no modelo os torques informados pelo Arduino e prevê o comportamento do veículo no próximo instante, fechando o ciclo de simulação. Este processo é repetido até o final da simulação.

Devido à pouca memória do Arduino, para realizar o processamento da RNA foi necessário usar variáveis inteiras. Uma variável inteira é armazenada em 8 bits, desta forma é possível fazer cálculos com quatro casas de precisão. A utilização desse tipo de variável implica num erro no cálculo do torque devido à precisão do Arduino da ordem de 0,019 Nm e 0,398%.




Figura 6.1: Diagrama da simulação hardware-in-the-loop da RNA.

Por fim, avaliou-se o tempo para o processamento de um comando de atuação, do momento em que o MatLabTM envia o comportamento atual do veículo (torque requerido e eficiências dos motores elétricos) até o instante que o mesmo recebe o comando para o gerenciamento de potência. Na Figura 6.2 é apresentado um gráfico com o tempo de comunicação e processamento da RNA para diversos comportamentos do veículo. Nota-se que o tempo de atuação do microcontrolador varia entre 0,012 s até 0,018 s, enquanto o tempo médio de atuação é de 0,015 s. Nota-se um pico de quase 0,030 s no tempo de atuação da aquisição numero 54. Embora esse tempo seja maior que as demais aquisições, o passo de atuação utilizado na simulação é de 0,050 s, dessa maneira, o microcontrolador conseguiria responder rápido o suficiente para gerenciar a divisão de potência do VE.




Figura 6.2: Tempo de comunicação e processamento da RNA.

6.2 Resultado da Simulação Hardware-in-the-loop

Com a implementação da RNA no microcontrolador e com a comunicação com o MatLab™ desenvolvida, inicia-se a simulação HIL para o ciclo de treinamento. O microcontrolador atinge uma frequência de atuação de aproximadamente 20 Hz (0,05 segundos entre cada intervalo de atuação). A resposta obtida pela RNA implementada no processo HIL é apresentada na Figura 6.3. A curva em verde tracejada representa a resposta obtida pelo microcontrolador na simulação HIL e a curva contínua em preto representa o ciclo de condução utilizado no treinamento da RNA.




Figura 6.3: Resposta da RNA para a simulação Hardware-in-the-loop.

A Figura 6.4 apresenta a resposta obtida pela RNA do microcontrolador nos instantes entre 3600 s e 3640 s em comparação ao ciclo e a resposta obtida pela RNA do MatLab™. Nota-se uma pequena divergência na resposta do microcontrolador e do MatLab™ durante os momentos de aceleração do veículo, em que o microcontrolador apresenta uma maior dificuldade em acompanhar o ciclo. Na simulação HIL com o RNA no microcontrolador, o valor RMSE da velocidade em comparação ao ciclo de treinamento foi de 0,188 km/h e o erro máximo foi de 3,986 km/h. Por outro lado, na simulação da RNA em MatLab™, o valor RMSE da velocidade foi de 0,176 km/h e o erro máximo foi de 3,986 km/h. Os desempenhos alcançados pelo microcontrolador e pelo MatLab são similares, dessa maneira, o microcontrolador consegue reproduzir eficientemente o sinal de velocidade do ciclo.





Figura 6.4: Resposta da RNA entre 3600 e 3640 segundos.

Para verificar o tempo de atuação mínimo que o microcontrolador deve possuir para conseguir reproduzir o ciclo de treinamento de maneira eficaz, foram realizadas simulações com diferentes tempos de atuação da RNA. Para isso, foi implementado no microcontrolador um atraso no envio do comando de atuação para o MatLab™ (modelo do veículo). Na Tabela 6.1 são apresentados os valores dos tempos de atuação testados e os seus desempenhos. Para cada tempo de atuação é apresentado o valor RMSE da velocidade do veículo simulado em relação ao ciclo ($E_{V,RMS}$) e o erro máximo entre as duas velocidades ($E_{V,max}$).


Tabela 6.1: Desempenho da RNA na simulação Hardware-in-the-loop.

Tempo de Atuação da RNA (s)	$E_{V,RMS}$ (Km/h)	$E_{V,max}$ (km/h)
0,200	2,380	6,127
0,100	0,276	3,986
0,050	0,169	3,771
0,025	0,166	3,764
0,020	0,165	3,755

Pela Tabela 6.1 é possível notar que a partir de 0,100 s de tempo de atuação a RNA não consegue reproduzir com qualidade o sinal de velocidade do ciclo de treinamento. Na Figura 6.5 é apresentada a resposta de velocidade da RNA para esse tempo de atuação ao reproduzir o ciclo de treinamento.



(a) Resposta da RNA para o ciclo de treinamento



(b) Resposta da RNA entre 5050 e 5100 segundos

Figura 6.5: Simulação HIL da RNA com um tempo de atuação de 0,1 s.

Na Figura 6.5a, é possível observar que, de maneira geral, a RNA aparenta conseguir reproduzir adequadamente o ciclo de condução. Entretanto, na Figura 6.5b, nota-se que para alguns trechos do ciclo, a RNA não consegue atuar rápido o suficiente para gerenciar as potências nos MEs, gerando uma divergência considerável entre a resposta do VE e o ciclo de treinamento. Dessa maneira, apesar da RNA (com tempo de atuação de 0,100 s) não corrigir perfeitamente a velocidade do veículo em todo o ciclo, ela ainda consegue reproduzir o seu perfil de velocidade global de forma adequada.

O tempo mínimo de atuação da RNA implementada no microcontrolador Atmel328p, para que ela consiga gerenciar corretamente a distribuição de potência do VE, deve ser no máximo de 0,100 s. Dessa forma, mesmo que o microcontrolador perca algum ponto de atuação devido a algum problema na comunicação ou no processamento dos dados, ele ainda conseguirá gerenciar a distribuição de potência do VE.

Para verificar a qualidade dos resultados obtidos na simulação HIL é realizada uma comparação dos tempos de resposta com outros trabalhos da literatura. Aziziaghdam e Alankuş (2022) desenvolveram um controle longitudinal para veículos pesados autônomos. O controle define a condição de trabalho do motor a combustão com base no comando do pedal de aceleração, a aceleração do veículo e um radar. Esse controle apresentou uma taxa de atuação que varia entre 0,050 s e 0,100 s, determinada pelos componentes do sistema de controle, o pedal de aceleração e o radar possuem uma taxa de aquisição de 0,050 s e o acelerômetro utilizado no veículo apresenta uma taxa de amostragem de 0,020 s.

Dickey e Lu (2003) também desenvolveu um controle longitudinal para veículos que visa controlar o torque do motor a combustão, os freios a ar e o freio retarder. Os comandos de atuação definidos pelo controle e as condições de operação do veículo são enviados por uma rede de comunicação serial. Nos testes experimentais do controle, o tempo de atraso do comando de atuação da frenagem até a efetiva frenagem do veículo foi de 0,450 s e o atraso do comando de torque do motor até a mudança da velocidade do veículo foi de 0,400 s.

Desse modo, em comparação com os resultados da literatura, a implementação da RNA desenvolvida em HIL se mostra promissora para aplicações em condições reais, uma vez que o seu tempo de processamento é consideravelmente menor. O microcontrolador escolhido para a implementação é bastante simples e possui limitações no seu processamento e no armazenamento dos dados, dessa maneira, caso seja necessário aumentar precisão e diminuir o tempo de resposta da RNA, é possível utilizar microcontroladores mais potentes.

7 CONCLUSÃO

Esta tese tem como principal contribuição o desenvolvimento de um modelo de rede neural artificial multicamadas, em que a sua arquitetura fosse totalmente genérica, podendo apresentar diversas configurações em sua estrutura. O número de camadas ocultas, o número de neurônios, os pesos das conexões dos neurônios, as funções de ativação de cada neurônio e os seus parâmetros são definidos durante a aprendizagem da rede neural. Desse modo, o treinamento da rede neural artificial foi feito pro meio de um método baseado em um algoritmo evolucionário genético multiobjetivo.

Para entender a aplicação da rede neural genérica proposta em modelos reais e em controle de veículos, a rede foi implementada em dois problemas. No primeiro a rede foi utilizada para prever o estado de carga de uma bateria, enquanto, no segundo, foi aplicada para determinar a estratégia de troca de marchas de um veículo. Na previsão do estado de carga da bateria, a rede apresentou resultados satisfatórios, conseguindo reproduzir o sinal de descarga da bateria adequadamente. A rede genérica foi comparada com um modelo gerado pelo aplicativo de redes neurais do MatLab™ (ntstool), obtendo resultados superiores. A curva de descarga da rede apresentou um valor RMSE de 0,1708, enquanto, a curva obtida pelo aplicativo foi de 0,4177. No problema da estratégia de troca de marcha, a RNA visou aumentar o desempenho do veículo, diminuir o consumo de combustível e as emissões de gases poluentes ao executar o ciclo de condução NBR 6601. Após o treinamento da rede, os resultados obtidos foram comparados com a estratégia padrão do veículo, recomendada em seu manual, e com um controlador de lógica fuzzy. O veículo com a estratégia da rede alcançou um comportamento consideravelmente melhor que o veículo padrão, reduzindo as emissões de gases poluentes e diminuindo o consumo de combustível em 0,3350 L. Na comparação com da rede com o controle fuzzy, os resultados foram semelhantes, mas com uma pequena vantagem para a estratégia RNA, que atingiu uma economia maior de combustível (0,0450 L).

Para assegurar que a estratégia desenvolvida conseguisse responder de maneira adequada aos desafios encontrados por veículos trafegando em vias reais, foi necessário elaborar um gerador de ciclos de conduções. O gerador de ciclos foi utilizado para determinar um perfil de velocidade que emulasse as condições reais encontradas em vias urbanas e outro em vias rodoviárias, a partir de critérios definidos previamente. Esses dois ciclos foram combinados com os ciclos padrões NBR 6601, NBR 7024 e US06, formando um ciclo de treinamento. Dessa maneira, o ciclo de treinamento reproduziu os desafios encontrados por veículos em condições reais e as dificuldades apresentadas nos ciclos de condução padrão. Posteriormente, esse ciclo foi utilizado para treinar a estratégia de gerenciamento de potência do veículo.

Posteriormente, a rede foi implementada com o modelo dinâmico do veículo elétrico, para gerenciar a distribuição de potência dos motores elétricos. O treinamento evolucionário genético multiobjetivo encontrou diversas soluções não dominadas (fronteira de Pareto) para o problema proposto., desse conjunto de soluções quatro redes neurais se destacaram. A primeira rede apresentou a maior autonomia, podendo percorrer 247,3 km antes de descarregar completamente a sua bateria, entretanto, também apresentou a maior massa para o sistema de propulsão elétrico, atingindo 389,3 kg. A segunda rede obteve o menor tempo de recarga da bateria, 2,342 h para a sua recarga, e a menor massa do sistema elétrico, 151,8 kg, por outro lado, foi a solução que percorreu a menor distância, apenas 102,4 km. A terceira rede obteve o menor custo equivalente da viagem, apresentando um valor de R\$ 0,124 por km percorrido. Por último, a solução com maior comprometimento entre os objetivos do treinamento, maior fator de desempenho, apresentou uma autonomia de 157,8 km, massa do sistema elétrico de 295,4 kg, uma expectativa de vida útil da bateria de 205.000 km, um valor RMSE de 0,172 km/h para a variação máxima de 3,986 km/h.

Por fim, a rede neural artificial que obteve o maior fator de desempenho no treinamento foi implementada em um microcontrolador Atmel 328p e uma simulação hardware-in-the-loop foi desenvolvida, para avaliar a rede neural atuando em uma condição de operação real. O tempo de processamento gasto pelo microcontrolador para determinar a atuação dos motores elétricos variou entre 0,012 s e 0,018 s, com tempo médio de 0,015 s. Essa taxa de atuação se mostrou adequada para o gerenciamento da potência do veículo, uma vez que o tempo de simulação do modelo dinâmico é de 0,050 s. Dessa maneira, o microcontrolador foi capaz de determinar o comando a ser aplicado nos motores antecipadamente ao passo de iteração do modelo dinâmico do veículo.

Os resultados obtidos na simulação hardware-in-the-loop mostraram que o microcontrolador conseguiu gerenciar a distribuição de potência do veículo elétrico adequadamente, atingindo resultados semelhantes aos obtidos no treinamento. O valor RMSE da velocidade do veículo em comparação com o ciclo de treinamento, obtido pela simulação com o microcontrolador, foi de 0,188 km/h e a variação máxima das velocidades foi de 3,986 km/h. Enquanto os valores encontrados no treinamento foram de 0,176 km/h para o valor RMSE e 3,986 km/h para a variação máxima.

7.1 Trabalhos futuros

Apesar deste trabalho ter chegado a resultados promissores em relação ao gerenciamento de potência de veículos puramente elétricos, ainda podem ser buscadas novas propostas de gerenciamento de energia para veículos híbridos elétricos e principalmente melhor caracterização experimental.

A rede neural proposta nesse trabalho já se mostrou adequada para aplicação em micro-controladores simples, dessa maneira, como trabalho futuro, é possível implementar a estratégia em um protótipo de veículo em pequena escala desenvolvido pelo LabSIn. O modelo dinâmico do veículo pode ser ajustado para se adequarem ao protótipo em escala reduzida, assim como a rede neural pode ser treinamento novamente para ele. Em seguida, o desempenho da estratégia pode ser avaliado pelo veículo executando ciclos de conduções predefinidos. Para isso, poderá ser utilizado um dinamômetro em escala reduzida, desenvolvido pelo LabSIn e em construção. Com o dinamômetro será possível determinar os torques e velocidades angulares de cada uma das rodas, além de comparar com os valores obtidos nas simulações. Também será possível avaliar o perfil de descarga da bateria do veículo em escala.

A rede neural genérica ainda pode ser utilizada para determinar a estratégia de gerenciamento de potência de outros veículos de combustíveis alternativos. Os veículos híbridos elétricos (*plug-in* ou não) e veículos híbridos elétricos hidráulicos são exemplos em que a rede genérica surge como uma solução promissora, com base na experiência de outros trabalhos publicados em gerenciamento de potência.

Outra aplicação da rede neural genérica, já apresentada nesse trabalho, é a sua utilização na previsão do comportamento de baterias. Dessa maneira, a rede pode ser ajustada para prever não só o estado de carga da bateria como o seu estado de saúde. Alguns recursos de simulação de baterias, como a ferramenta do MatLab™, apresentam um tempo de processamento elevado para determinar a degradação da bateria. Dessa forma, a utilização da rede para prever o comportamento do estado de saúde da bateria é vantajosa devido ao seu baixo tempo de processamento.

7.2 Trabalhos publicados

Nesta seção são listados os trabalhos publicados e submetidos, com autoria ou coautoria do autor desta tese, durante o período do doutorado.

7.2.1 Trabalhos publicados em periódicos

SILVA, F.L.; SILVA, L.C.A.; ECKERT, J.J. e LOURENÇO, M.A.M. Robust fuzzy stability control optimization by multi-objective for modular vehicle. **Mechanism and Machine Theory**, v.167, 104554, 2022.

SILVA, F.L.; SILVA, L.C.A.; ECKERT, J.J.; YAMASHITA, R.Y. e LOURENÇO, M.A.M. Parameter influence analysis in an optimized fuzzy stability control for a four-wheel independent-drive electric vehicle. **Control Engineering Practice**. 2022.

SILVA, S.F.; ECKERT, J.J.; SILVA, F.L.; SILVA, L.C. e DEDINI, F.G. Multi-objective optimization design and control of plug-in hybrid electric vehicle powertrain for minimization of energy consumption, exhaust emissions and battery degradation. **Energy Conversion and Management**, v. 234, 113909, 2021.

SILVA, L.C.D.A.; ECKERT, J.J.; LOURENÇO, M.A.D.M.; SILVA, F.L.; CORRÊA, F.C. e DEDINI, F.G. Electric vehicle battery-ultracapacitor hybrid energy storage system and drivetrain optimization for a real-world urban driving scenario. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**. v. 43, 2021.

MIRANDA, M.H.; SILVA, F.L.; LOURENÇO, M.A.; ECKERT, J.J. e SILVA, L.C. Vehicle drivetrain and fuzzy controller optimization using a planar dynamics simulation based on a real-world driving cycle. **Energy**, v. 257, p. 124769, 2022.

ECKERT, J.J.; BARBOSA, T.P.; SILVA S.F.; SILVA, F.L.; SILVA, L.C.A. e DEDINI F.G. Electric hydraulic hybrid vehicle powertrain design and optimization-based power distribution control to extend driving range and battery life cycle. **Energy Conversion and Management**. 2022.

LOURENÇO, M.A.M.; ECKERT, J.J.; SILVA, F.L.; MIRANDA, M.H.R. e SILVA, L.C.A. Uncertainty analysis of vehicle fuel consumption in twin-roller chassis dynamometer experiments and simulation models. **Mechanism and machine Theory**, v. 180, 105126, 2023.

LOURENÇO, M.A.M.; ECKERT, J.J.; SILVA, F.L.; SANTICIOLLI, F.M. e SILVA, L.C.A. Vehicle and twin-roller chassis dynamometer model considering slip tire interactions. **Mechanics Based Design of Structures and Machines**, 2022.

ECKERT, J.J.; BARBOSA, T.P.; SILVA, F.L.; ROSO, V.R.; SILVA, L.C.A. e SILVA, L.A.R. Optimum fuzzy logic controller applied to a hybrid hydraulic vehicle to minimize fuel consumption and emissions. **Expert Systems with Applications**, v. 207, p. 117903, 2022.

SILVA, S.F.; ECKERT, J.J.; CORRÊA, F.C.; SILVA, F.L.; SILVA, L.C.A. e DEDINI, F.G. Dual HESS electric vehicle powertrain design and fuzzy control based on multi-objective optimization to increase driving range and battery life cycle. **Applied Energy**, v. 324, p. 119723, 2022.

ECKERT, J.J.; SILVA, F.L.; SILVA, S.F.; BUENO, A. V.; OLIVEIRA, M.L.M. e SILVA, L.C.A. Optimal design and power management control of hybrid biofuel-electric powertrain. **Applied Energy**, v. 325, p. 119903, 2022.

7.2.2 Trabalhos publicados em capítulo de livro

LOURENÇO M.A.M.; SILVA F.L.; SILVA L.C.A.; ECKERT J.J.; CORRÊA F.C. A Small-Scale Dynamometer Roller Analysis by Laval Rotor Approach. In: Balthazar J.M. (eds) **Vibration Engineering and Technology of Machinery**. Mechanisms and Machine Science, vol 95. Springer, Cham. 2021.

SILVA F.L.; SILVA S.F.; SANTICIOLLI F. M.; ECKERT J.J.; SILVA L.C.A. e DEDINI F.G. Multi-objective Optimization of the Steering System and Fuzzy Logic Control Applied to a Car-Like Robot. In: Pucheta M., Cardona A., Preidikman S., Hecker R. (eds) **Multibody Mechatronic Systems. MuSMe 2021**. Mechanisms and Machine Science, vol 94. Springer, Cham. 2021.

7.2.3 Trabalhos aceitos e publicados em congressos

LOURENÇO, M.A.M.; SILVA, F.L.; MIRANDA, M.H.R.; ECKERT, J.J.; SILVA, L.C.A. Simulação em Escala Reduzida de Protótipo de Veículo Elétrico em dinamômetro de Chassi em ADAMS®/Simulink® **XV Congreso Iberoamericano de Ingeniería Mecánica**. En: Universidad Politécnica de Madrid. 2022.

MIRANDA, M.H.R.; SILVA, L.C.A.; ECKERT, J.J.; LOURENÇO, M.A.M.; SILVA, F.L. e DEDINI, F.G. Desenvolvimento de um modelo de dinâmica planar para veículos. **Blucher Engineering Proceedings**, v. 8, n. 1, 463 – 474, 2021.

SILVA, S.F.; ECKERT, J.J.; SILVA, F.L.; SILVA, L.C.A. e DEDINI, F.G. Modelagem e simulação de um sistema start/stop para redução de consumo de combustível e emissões de gases poluentes. **Blucher Engineering Proceedings**, v. 8, n. 1, 486–498, 2021.

ROCHA, C.H.F.; ECKERT, J.J.; SILVA, L.C.A.; DEDINI, F.G.; SILVA, F.L. e LOURENÇO, M.A.M. Análise cinemática para uma caixa de engrenagens planetárias aplicadas em veículos híbridos e elétricos. **Blucher Engineering Proceedings**, v. 8, n. 1, 475–485, 2021.

MATTOS, J.A.B.; SILVA, L.C.A.; ECKERT, J.J.; DEDINI, F.G.; SILVA, S.F. e SILVA, F.L. Application of CFD into an automotive torque converter. **Congresso SAE Brasil 2021**, 2021.

Referências Bibliográficas

ABNT. Determinação de hidrocarbonetos, monóxido de carbono, óxido de nitrogênio, dióxido de carbono e materiais particulados no gás de exaustão. **NBR 6601**, 2012.

ALPAYDIN, E. **Introduction to Machine Learning**. The MIT Press, 2014. ISBN 978-0262028189.

APICELLA, A.; DONNARUMMA, F.; ISGRÒ, F. e PREVETE, R. A survey on modern trainable activation functions. **Neural Networks**, v. 138, 14–32, 2021.

AZIZIAGHDAM, E.T. e ALANKUŞ, O.B. Longitudinal control of autonomous vehicles consisting power-train with non-linear characteristics. **IEEE Transactions on Intelligent Vehicles**, v. 7, n. 1, 133–142, 2022.

BAKKER, E.; PACEJKA, H.B. e LIDNER, L. A new tire model with an application in vehicle dynamics studies. In **Autotechnologies Conference and Exposition**. SAE International, apr 1989.

BARLOW, T. **A Reference Book of Driving Cycles for Use in the Measurement of Road Vehicle Emissions: Version 3**. Published project report. IHS, 2009.

BERTOTI, Elvis. **Caracterização Dinâmica de uma Bancada Dinamométrica Veicular de Rolos Duplos**. 2018. Dissertação (Mestrado). Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas, SP.

BRASIL. Programa rota 2030 - mobilidade e logística. **Decreto-lei nº 13.755, de 10 de dezembro de 2018**NBR 7024, 2018.

CHEN, Z.; LIU, Y.; ZHANG, Y.; LEI, Z.; CHEN, Z. e LI, G. A neural network-based ecms for optimized energy management of plug-in hybrid electric vehicles. **Energy**, v. 243, 122727, 2022.

CORREA, F.C.; ECKERT, J.J.; SILVA, L.C.; COSTA, E.S.; SANTICIOLLI, F.M. e DEDINI, F.G. Gear shifting strategy to improve the parallel hybrid vehicle fuel consumption. In **2015**

IEEE Vehicle Power and Propulsion Conference (VPPC), pp. 1–6. IEEE, 2015.

DA SILVA, Samuel Filgueira. **Otimização multiobjetivo do controle fuzzy e projeto de arquiteturas de trem de potência de veículos hibridizados plug-in**. 2022. Dissertação (Mestrado). Faculdade de Engenharia Mecânica - FEM, Universidade Estadual de Campinas - UNICAMP.

DA SILVA, S.F.; ECKERT, J.J.; SILVA, F.L.; SILVA, L.C. e DEDINI, F.G. Multi-objective optimization design and control of plug-in hybrid electric vehicle powertrain for minimization of energy consumption, exhaust emissions and battery degradation. **Energy Conversion and Management**, v. 234, 113909, 2021.

DAS, R.; WANG, Y.; BUSAWON, K.; PUTRUS, G. e NEAIMEH, M. Real-time multi-objective optimisation for electric vehicle charging management. **Journal of Cleaner Production**, v. 292, 126066, 2021.

DICKEY, S. e LU, X.Y. Control actuation of fully automated heavy-duty vehicles using sae j1939. In **IEEE IV2003 Intelligent Vehicles Symposium. Proceedings (Cat. No.03TH8683)**, pp. 400–405. 2003.

DING, X.; WANG, Z. e ZHANG, L. Hybrid control-based acceleration slip regulation for four-wheel-independently-actuated electric vehicles. **IEEE Transactions on Transportation Electrification**, pp. 1–1, 2020.

ECKERT, Jony Javorski. **Desenvolvimento de bancada dinamométrica para validação da influência da estratégia de troca de marchas na dinâmica veicular longitudinal**. 2017. Tese (Doutorado). Faculdade de Engenharia Mecânica - FEM, Universidade Estadual de Campinas - UNICAMP.

ECKERT, J.J.; BARBOSA, T.P.; DA SILVA, S.F.; SILVA, F.L.; SILVA, L.C. e DEDINI, F.G. Electric hydraulic hybrid vehicle powertrain design and optimization-based power distribution control to extend driving range and battery life cycle. **Energy Conversion and Management**, v. 252, 115094, 2022a.

ECKERT, J.J.; D. A. SILVA, L.C.; DEDINI, F.G. e CORRÊA, F.C. Electric vehicle powertrain and fuzzy control multi-objective optimization, considering dual hybrid energy storage systems.

IEEE Transactions on Vehicular Technology, v. 69, n. 4, 3773–3782, 2020.

ECKERT, J.J.; SANTICIOLLI, F.M.; YAMASHITA, R.Y.; CORRÊA, F.C.; SILVA, L.C. e DEDINI, F.G. Fuzzy gear shifting control optimisation to improve vehicle performance, fuel consumption and engine emissions. **IET Control Theory & Applications**, v. 13, n. 16, 2658–2669, 2019a.

ECKERT, J.J.; SILVA, F.L.; DA SILVA, S.F.; BUENO, A.V.; DE OLIVEIRA, M.L.M. e SILVA, L.C. Optimal design and power management control of hybrid biofuel–electric powertrain. **Applied Energy**, v. 325, 119903, 2022b.

ECKERT, J.J.; SILVA, L.C.; COSTA, E.S.; SANTICIOLLI, F.M.; DEDINI, F.G. e CORRÊA, F.C. Electric vehicle drivetrain optimisation. **IET Electrical Systems in Transportation**, v. 7, n. 1, 32–40, 2017.

ECKERT, J.J.; SILVA, L.C.D.A.E.; COSTA, E.D.S.; SANTICIOLLI, F.M.; CORRÊA, F.C. e DEDINI, F.G. Optimization of electric propulsion system for a hybridized vehicle. **Mechanics Based Design of Structures and Machines**, v. 47, n. 2, 175–200, 2019b.

EHSANI, M.; GAO, Y.; LONGO, S. e EBRAHIMI, K. **Modern Electric, Hybrid Electric, and Fuel Cell Vehicles**. CRC Press, third edition ed., 2018. ISBN 978-0-4295-0488-4.

EPE. Fact sheet: Anuário estatístico de energia elétrica 2021. **Materials Today: Proceedings**, 2021.

FEROLDI, D. e CARIGNANO, M. Sizing for fuel cell/supercapacitor hybrid vehicles based on stochastic driving cycles. **Applied Energy**, v. 183, 645–658, 2016.

FUHS, A. **Hybrid vehicles: and the future of personal transportation**. CRC Press, 2008. ISBN 978-1-42-007534-2.

GEN, M.; CHENG, R. e LIN, L. **Network models and optimization: Multiobjective genetic algorithm approach**. Springer Science & Business Media, 2008.

GENTA, G. e MORELLO, L. **The automotive chassis**, v. 1. Springer, 2009.

GIAKOUMIS, E.G. **Driving and Engine Cycles**, v. 1. Springer International Publishing, 2017.

GILLESPIE, T.D. **Fundamentals of vehicle dynamics**. Society of Automotive Engineers - SAE, 1992.

GUO, N.; LENZO, B.; ZHANG, X.; ZOU, Y.; ZHAI, R. e ZHANG, T. A real-time nonlinear model predictive controller for yaw motion optimization of distributed drive electric vehicles. **IEEE Transactions on Vehicular Technology**, v. 69, n. 5, 4935–4946, 2020.

GÖKCE, K. e OZDEMIR, A. An instantaneous optimization strategy based on efficiency maps for internal combustion engine/battery hybrid vehicles. **Energy Conversion and Management**, v. 81, 255–269, 2014.

HAN, J.; SHU, H.; TANG, X.; LIN, X.; LIU, C. e HU, X. Predictive energy management for plug-in hybrid electric vehicles considering electric motor thermal dynamics. **Energy Conversion and Management**, v. 251, 115022, 2022.

HAROLD, C.K.D.; PRAKASH, S. e HOFMAN, T. Powertrain control for hybrid-electric vehicles using supervised machine learning. **Vehicles**, v. 2, n. 2, 267–286, 2020.

HAYKIN, S. **Redes neurais: Principios e prática**. Bookman, second edition ed., 2005.

HE, H.; WANG, Y.; LI, J.; DOU, J.; LIAN, R. e LI, Y. An improved energy management strategy for hybrid electric vehicles integrating multistates of vehicle-traffic information. **IEEE Transactions on Transportation Electrification**, v. 7, n. 3, 1161–1172, 2021.

HU, J.; TAO, J.; XIAO, F.; NIU, X. e FU, C. An optimal torque distribution control strategy for four-wheel independent drive electric vehicles considering energy economy. **IEEE Access**, v. 7, 141826–141837, 2019.

HU, X.; ZHANG, X.; TANG, X. e LIN, X. Model predictive control of hybrid electric vehicles for fuel economy, emission reductions, and inter-vehicle safety in car-following scenarios. **Energy**, v. 196, 117101, 2020.

ICCT. European vehicle market statistics. **International Council on Clean Transportation Europe**, 2020.

ISO. Electrically propelled road vehicles - test specification for lithium-ion traction battery packs and systems - part 2: High-energy applications. **ISO Standard No.12405-2:2012**, pp. 1–60, 2012.

JALALI, M.; KHOSRAVANI, S.; KHAJEPOUR, A.; CHEN, S.K. e LITKOUHI, B. Model predictive control of vehicle stability using coordinated active steering and differential brakes. **Mechatronics**, v. 48, 30–41, 2017.

JAZAR, R.N. **Vehicle Dynamics**. Springer, 2008.

KILIÇARSLAN, S. e CELIK, M. Katsigeli: a nonlinear and kernel-based activation function for deep neural networks. **Neural Computing and Applications**, v. 34, n. 16, 13909–13923, 2022.

KLASS, V.; BEHM, M. e LINDBERGH, G. A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation. **Journal of Power Sources**, v. 270, 262–272, 2014.

KUCHWA-DUBE, C. e PEDRO, J.O. Chattering performance criteria for multi-objective optimisation gain tuning of sliding mode controllers. **Control Engineering Practice**, v. 127, 105284, 2022.

LIO, M.D.; BORTOLUZZI, D. e PAPINI, G.P.R. Modelling longitudinal vehicle dynamics with neural networks. **Vehicle System Dynamics**, v. 58, n. 11, 1675–1693, 2020.

LIU, Y.; HUANG, B.; YANG, Y.; LEI, Z.; ZHANG, Y. e CHEN, Z. Hierarchical speed planning and energy management for autonomous plug-in hybrid electric vehicle in vehicle-following environment. **Energy**, v. 260, 125212, 2022.

LOURENÇO, Maria Augusta de Menezes. **Desenvolvimento de dinamômetro de chassi para testes de veículos/robôs em pequena escala**. 2020. Dissertação (Mestrado). Faculdade de Engenharia Mecânica - FEM, Universidade Estadual de Campinas - UNICAMP.

LV, C.; XING, Y.; ZHANG, J.; NA, X.; LI, Y.; LIU, T.; CAO, D. e WANG, F.Y. Levenberg-marquardt backpropagation training of multilayer neural networks for state estimation of a safety-critical cyber-physical system. **IEEE Transactions on Industrial Informatics**, v. 14,

n. 8, 3436–3446, 2018.

MARKEL, T.; BROOKER, A.; HENDRICKS, T.; JOHNSON, V.; KELLY, K.; KRAMER, B.; OKEEFE, M.; SPRIK, S. e WIPKE, K. Advisor: a systems analysis tool for advanced vehicle modeling. **Journal of Power Sources**, v. 110, n. 2, 255–266, 2002.

MARTÍNEZ-GARCÍA, F.; BADAWEY, G.; KHERADMANDI, M. e DOWN, D.G. Adaptive predictive control of a data center cooling unit. **Control Engineering Practice**, v. 107, 104674, 2021.

MATHWORKS. Generic battery model. <https://www.mathworks.com/help/physmod/sps/powersys/ref/battery.html>, 2022. [Online; acessado em 25-Agosto-2022].

MIN, D.; SONG, Z.; CHEN, H.; WANG, T. e ZHANG, T. Genetic algorithm optimized neural network based fuel cell hybrid electric vehicle energy management strategy under start-stop condition. **Applied Energy**, v. 306, 118036, 2022.

MINISTÉRIO DO MEIO AMBIENTE, . Estabelece as fases proconve 17 e proconve 18 de exigências do programa de controle da poluição do ar por veículos automotores - proconve para veículos automotores leves novos de uso rodoviário. **Resolução n. 492, de 20 de dezembro de 2018. Publicado no Diário Oficial da União**, 2018.

MIRANDA, M.H.; SILVA, F.L.; LOURENÇO, M.A.; ECKERT, J.J. e SILVA, L.C. Electric vehicle powertrain and fuzzy controller optimization using a planar dynamics simulation based on a real-world driving cycle. **Energy**, v. 238, 121979, 2022.

MIRANDA, Matheus Henrique Rodrigues. **Otimização do sistema de propulsão e do gerenciamento de potência por lógica fuzzy em veículos elétricos e híbridos considerando a dinâmica planar e um ciclo de condução real**. 2022. Dissertação (Mestrado). Faculdade de Engenharia Mecânica - FEM, Universidade Estadual de Campinas - UNICAMP.

MOHRI, M.; ROSTAMIZADEH, A. e TALWALKAR, A. **Foundations of Machine Learning**. Adaptive Computation and Machine Learning. The MIT Press, 2 ed., 2018. ISBN 0262039400; 978-0262039406.

MOTAPON, S.N.; LACHANCE, E.; DESSAINT, L.A. e AL-HADDAD, K. A generic cycle life model for lithium-ion batteries based on fatigue theory and equivalent cycle counting. **IEEE Open Journal of the Industrial Electronics Society**, v. 1, 207–217, 2020.

MURPHEY, Y.L.; PARK, J.; CHEN, Z.; KUANG, M.L.; MASRUR, M.A. e PHILLIPS, A.M. Intelligent hybrid vehicle power control—part i: Machine learning of optimal vehicle power. **IEEE Transactions on Vehicular Technology**, v. 61, n. 8, 3519–3530, 2012.

MURPHEY, Y.L.; PARK, J.; KILIARIS, L.; KUANG, M.L.; MASRUR, M.A.; PHILLIPS, A.M. e WANG, Q. Intelligent hybrid vehicle power control—part ii: Online intelligent energy management. **IEEE Transactions on Vehicular Technology**, v. 62, n. 1, 69–79, 2013.

NICOLI, M.; DAS, R.; WANG, Y.; PUTRUS, G.; TURRI, R. e KOTTER, R. A smart grid modelling tool for evaluating optimal control of electric vehicles. In **2018 53rd International Universities Power Engineering Conference (UPEC)**, pp. 1–6. 2018.

PACEJKA, H.B. **Tire and Vehicle Dynamics (Third Edition)**. Butterworth-Heinemann, third edition ed., 2012. ISBN 978-0-08-097016-5.

PEREIRA, D.F.; LOPES, F.D.C. e WATANABE, E.H. Nonlinear model predictive control for the energy management of fuel cell hybrid electric vehicles in real time. **IEEE Transactions on Industrial Electronics**, v. 68, n. 4, 3213–3223, 2021.

PERHINSCHI, M.G.; MARLOWE, C.; TAMAYO, S.; TU, J. e WAYNE, W.S. Evolutionary algorithm for vehicle driving cycle generation. **Journal of the Air & Waste Management Association**, v. 61, n. 9, 923–931, 2011.

POZZI, A.; TORCHIO, M.; BRAATZ, R.D. e RAIMONDO, D.M. Optimal charging of an electric vehicle battery pack: A real-time sensitivity-based model predictive control approach. **Journal of Power Sources**, v. 461, 228133, 2020.

RAOOFAT, M.; SAAD, M.; LEFEBVRE, S.; ASBER, D.; MEHRJEDRI, H. e LENOIR, L. Wind power smoothing using demand response of electric vehicles. **International Journal of Electrical Power Energy Systems**, v. 99, 164–174, 2018.

RUSSELL, S.J. e NORVIG, P. **Artificial Intelligence: A Modern Approach, Global Edition**.

Pearson, 4 ed., 2021. ISBN 9780134610993,1292401133,9781292401133,9781292401171.

SANTICIOLLI, Fabio Mazzariol. **Parametrização de modelos de pneus aplicada a pneus de pequeno porte**. 2018. Tese (Doutorado). Faculdade de Engenharia Mecânica - FEM, Universidade Estadual de Campinas - UNICAMP.

SASTRY, K.; GOLDBERG, D. e KENDALL, G. **Genetic Algorithms**, pp. 97–125. Springer US, Boston, MA, 2005. ISBN 978-0-387-28356-2.

SHENG, H. e XIAO, J. Electric vehicle state of charge estimation: Nonlinear correlation and fuzzy support vector machine. **Journal of Power Sources**, v. 281, 131–137, 2015.

SHEPHERD, C.M. Design of primary and secondary cells: Ii . an equation describing battery discharge. **Journal of The Electrochemical Society**, v. 112, n. 12, 657, 1965.

SILVA, Fabrício Leonardo. **Modelagem e análise de sistemas de controle em diferenciais eletrônicos para veículos híbridos e elétricos**. 2020. Dissertação (Mestrado). Faculdade de Engenharia Mecânica - FEM, Universidade Estadual de Campinas - UNICAMP.

SILVA, F.L.; SILVA, L.C.; ECKERT, J.J. e LOURENÇO, M.A. Robust fuzzy stability control optimization by multi-objective for modular vehicle. **Mechanism and Machine Theory**, v. 167, 104554, 2022a.

SILVA, F.L.; SILVA, L.C.; ECKERT, J.J.; YAMASHITA, R.Y. e LOURENÇO, M.A. Parameter influence analysis in an optimized fuzzy stability control for a four-wheel independent-drive electric vehicle. **Control Engineering Practice**, v. 120, 105000, 2022b.

SILVA, S.F.; ECKERT, J.J.; SILVA, F.L.; DE ALKMIN E, L.C. e DEDINI, F.G. Multi-objective optimization design and control of plug-in hybrid electric vehicle powertrain for minimization of energy consumption, exhaust emissions and battery degradation. **Energy Conversion and Management**, 2021.

SONG, K.; WANG, X.; LI, F.; SORRENTINO, M. e ZHENG, B. Pontryagin's minimum principle-based real-time energy management strategy for fuel cell hybrid electric vehicle considering both fuel economy and power source durability. **Energy**, v. 205, 118064, 2020.

STEINSTRAETER, M.; BUBERGER, J. e TRIFONOV, D. Battery and heating data in real driving cycles. 2020.

VERMA, S.; DWIVEDI, G. e VERMA, P. Life cycle assessment of electric vehicles in comparison to combustion engine vehicles: A review. **Empresa de Pesquisa Energética**, 2021.

WANG, J.; GAO, S.; WANG, K.; WANG, Y. e WANG, Q. Wheel torque distribution optimization of four-wheel independent-drive electric vehicle for energy efficient driving. **Control Engineering Practice**, v. 110, 104779, 2021.

WANG, J.N.; WANG, Q.N.; JIN, L.Q. e SONG, C.X. Independent wheel torque control of 4wd electric vehicle for differential drive assisted steering. **Mechatronics**, v. 21, n. 1, 63–76, 2011.

WANG, Z.; ZHANG, J.; LIU, P.; QU, C. e LI, X. Driving cycle construction for electric vehicles based on markov chain and monte carlo method: A case study in beijing. **Energy Procedia**, v. 158, 2494–2499, 2019. Innovative Solutions for Energy Transitions.

WEISE, T. **Global Optimization Algorithm: Theory and Application**. 01 2009.

WILLIAMSON, S.S. **Energy Management Strategies for Electric and Plug-in Hybrid Electric Vehicles**. Springer New York, NY, first edition ed., 2013. ISBN 978-1-4614-7710-5.

WU, J.; YANG, H.; LI, R.; RUAN, Q.; YAN, S. e AN YAO, Y. Design and analysis of a novel octopod platform with a reconfigurable trunk. **Mechanism and Machine Theory**, v. 156, 104134, 2021.

YAMASHITA, Rodrigo Yassuda. **Modelagem e Controle de Estabilidade Aplicada a Veículo de Tração Integral**. 2018. Dissertação (Mestrado). Faculdade de Engenharia Mecânica - FEM, Universidade Estadual de Campinas - UNICAMP.

YAMASHITA, R.Y.; SILVA, F.L.; SANTICIOLLI, F.M.; ECKERT, J.J.; DEDINI, F.G. e SILVA, L.C. Comparison between two models of bldc motor, simulation and data acquisition. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, v. 40, n. 2, 1–11, 2018.

ZHANG, H.; ZHAO, W. e WANG, J. Fault-tolerant control for electric vehicles with inde-

pendently driven in-wheel-motors considering individual driver steering characteristics. **IEEE Transactions on Vehicular Technology**, v. 68, n. 5, 4527–4536, 2019a.

ZHANG, L.; WANG, Y. e WANG, Z. Robust lateral motion control for in-wheel-motor-drive electric vehicles with network induced delays. **IEEE Transactions on Vehicular Technology**, v. 68, n. 11, 10585–10593, 2019b.

ZHANG, M.; SHI, S.; LIN, N. e YUE, B. High-efficiency driving cycle generation using a markov chain evolution algorithm. **IEEE Transactions on Vehicular Technology**, v. 68, n. 2, 1288–1301, 2019c.

ZHOU, Y.; RAVEY, A. e PÉRA, M.C. Multi-objective energy management for fuel cell electric vehicles using online-learning enhanced markov speed predictor. **Energy Conversion and Management**, v. 213, 112821, 2020.

ZHU, J.; WANG, Z.; ZHANG, L. e DORRELL, D.G. Braking/steering coordination control for in-wheel motor drive electric vehicles based on nonlinear model predictive control. **Mechanism and Machine Theory**, v. 142, 103586, 2019.

ÖZBAY, Y. e TEZEL, G. A new method for classification of ecg arrhythmias using neural network with adaptive activation function. **Digital Signal Processing**, v. 20, n. 4, 1040–1049, 2010.