



RAFAEL ÁVILA DOS SANTOS

**DESENVOLVIMENTO DE *SOFT-SENSORS* UTILIZANDO
MGGP E APRENDIZADO DE MÁQUINAS PARA ESTIMAÇÃO
DE FORÇAS DE VEÍCULOS COM PNEU INTELIGENTE**

LAVRAS – MG

2026

RAFAEL ÁVILA DOS SANTOS

**DESENVOLVIMENTO DE *SOFT-SENSORS* UTILIZANDO MGGP E
APRENDIZADO DE MÁQUINAS PARA ESTIMAÇÃO DE FORÇAS DE VEÍCULOS
COM PNEU INTELIGENTE**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Sistema Inteligentes, para a obtenção do título de Mestre.

Prof. Dr. Bruno Henrique Groenner Barbosa
Orientador

Prof. Dr. André Murilo de Almeida Pinto
Co-orientador
Prof. Dr. Danton Diego Ferreira
Co-orientador

**LAVRAS – MG
2026**

**Ficha catalográfica elaborada pela Coordenadoria de Processos Técnicos da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Santos, Rafael Ávila dos

Desenvolvimento de *Soft-Sensors* Utilizando MGGP e
Aprendizado de Máquinas Para Estimação de Forças de Veícu-
los com Pneu Inteligente / Rafael Ávila dos Santos. – Lavras :
UFLA, 2026.

174p. : il.

Dissertação (Mestrado)–Universidade Federal de Lavras,
2026.

Orientador: Prof. Dr. Bruno Henrique Groenner Barbosa.

Coorientador: Prof. Dr. André Murilo de Almeida Pinto.

Coorientadora: Prof. Dr. Danton Diego Ferreira.

Bibliografia.

1. pneus inteligentes. 2. aprendizagem de máquina. 3. soft
sensors. I. Barbosa, Bruno Henrique Groenner.

RAFAEL ÁVILA DOS SANTOS

**DESENVOLVIMENTO DE *SOFT-SENSORS* UTILIZANDO MGGP E
APRENDIZADO DE MÁQUINAS PARA ESTIMAÇÃO DE FORÇAS DE VEÍCULOS
COM PNEU INTELIGENTE**

**DEVELOPMENT OF SOFT SENSORS USING MGGP AND MACHINE LEARNING
FOR ESTIMATING FORCES IN VEHICLES WITH INTELLIGENT TYRE**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Sistema Inteligentes, para a obtenção do título de Mestre.

APROVADA em 10 de fevereiro de 2026.

Prof. Dr. Bruno Henrique Groenner Barbosa	UFLA
Prof. Dr. Danton Diego Ferreira	UFLA
Prof. Dr. Daniel Augusto Pereira	UFLA
Prof. Dr. Giovani Bernardes Vitor	UNIFEI

Prof. Dr. Bruno Henrique Groenner Barbosa
Orientador

Prof. Dr. André Murilo de Almeida Pinto
Co-orientador

Prof. Dr. Danton Diego Ferreira
Co-orientador

**LAVRAS – MG
2026**

AGRADECIMENTOS

Em primeiro, agradeço ao nosso pai maior, Deus, por cada instante da minha existência. Agradeço por todas as bênçãos que sempre me direciona. Pelas oportunidades que coloca em minha vida, sejam elas oportunidades de crescimento pessoal, intelectual, profissional ou acadêmico. Agradeço pela força e persistência que me dá para conseguir lutar por todos os meus objetivos, em prol do bem de todos que estão a minha volta.

Agradeço aos meus pais, que sempre foram e sempre serão dois exemplos para mim, de pessoa, e de casal. Exemplos para mim de como manter o sorriso no rosto e a boa vivência, mesmo em dias difíceis onde era mais comum de se esperar por desavenças e descrenças. Agradeço por todo o suporte que sempre me deram, por sacrifícios que fizeram por mim, e que me trouxeram até aqui seguindo minha carreira acadêmica, como pesquisador, e como propagador do conhecimento.

Agradeço à Maria Clara, por todo o amor e carinho. Agradeço pelo suporte e incentivo que me direciona. Agradeço por permitir e existir o nosso crescimento mútuo, fazendo jus a palavra de nosso pai maior, que juntos somos um só.

Agradeço fortemente ao meu orientador e coorientadores, Bruno Groenner, Danton Diego e André Murilo, por serem inspirações como professores, pesquisadores, e pessoa. Agradeço pelo apoio e pelas reuniões enriquecedoras sobre dinâmica veicular.

Agradeço à FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais) e a UFLA (Universidade Federal de Lavras) pelos recursos financeiros destinados à execução do projeto.

Agradeço por aqueles que já se foram, mas que em sua vivência também foram essenciais para que tudo isso fosse possível, e por isso devem ser lembrados.

"Não tenho nenhum talento especial. Apenas sou apaixonadamente curioso."

(Albert Einstein)

RESUMO

Com o avanço tecnológico, os veículos evoluíram de sistemas puramente mecânicos para plataformas inteligentes dotadas de sensoriamento embarcado. Embora essa instrumentação aumente a inteligência e a segurança veicular, ela também eleva custos, limitando a disseminação de tecnologias avançadas. Nesse contexto, *Soft Sensors* tornam-se uma alternativa ao inferirem grandezas de interesse a partir de variáveis correlacionadas medidas por sensores de baixo custo, como é o caso dos Pneus Inteligentes. Neste trabalho, desenvolvem-se *Soft Sensors* baseados em modelos NARX (*Nonlinear AutoRegressive with eXogenous inputs*)/FIR (*Finite Impulse Response*) identificados pelo algoritmo evolucionário MGGP (*Multigene Genetic Programming*) para estimar as forças F_x , F_y e F_z nas rodas de um veículo de passageiros, utilizando exclusivamente dados de aceleração provenientes de pneus inteligentes. O problema foi formulado como MIMO, pois as entradas correspondem às acelerações nos três eixos ao longo do ângulo de rotação do pneu e as saídas são as três forças. As características de entrada foram extraídas na região do *contact patch*, organizadas por ângulo de rotação com resolução de $2,5^\circ$, avaliando-se três intervalos ($\pm 10^\circ$, $\pm 20^\circ$ e $\pm 35^\circ$), diferentes configurações de atrasos e duas estratégias de treinamento, com os modelos específicos por pneu e os modelos treinados com os quatro pneus simultaneamente (generalização). A validação contemplou manobras com diferentes forças predominantes (reta, *Slalom*, *Double Lane Change*, curvas constantes, curvas com frenagem e direção aleatória), além de um comparativo com modelos de aprendizado de máquina (LSTM, GRU e MLP) por meio das métricas MAPE e R^2 . Os resultados indicaram que o intervalo $\pm 10^\circ$ tende a produzir modelos menos precisos e com maior variância, enquanto $\pm 20^\circ$ e $\pm 35^\circ$ apresentaram desempenho pareado, sugerindo que $\pm 20^\circ$ já é suficiente para a predição das forças. Observou-se ainda que modelos com apenas um atraso podem reduzir a variância e superar configurações com múltiplos atrasos. No melhor caso, considerando as forças críticas associadas a cada condição de operação, os modelos NARX/FIR identificados via MGGP atingiram $\text{MAPE} \leq 12\%$ e $R^2 \geq 0,80$ nessas forças predominantes, mantendo desempenho superior ao comparativo com LSTM, GRU e MLP nas condições avaliadas. Quanto à generalização, modelos treinados com dados dos quatro pneus simultaneamente apresentaram desempenho competitivo frente aos específicos, reforçando a relevância prática da abordagem MIMO/generalista. A análise estrutural evidenciou acoplamentos relevantes entre as forças, com recorrência de termos autorregressivos entre F_y e F_z . Por fim, os modelos NARX/FIR via MGGP superaram LSTM, GRU e MLP nas condições avaliadas, mantendo baixa complexidade

ao utilizar apenas 63 parâmetros. Assim, os resultados confirmam o potencial de pneus inteligentes e do MGGP para a estimação de grandezas dinâmicas, com implicações para sistemas veiculares mais acessíveis, redundantes e seguros.

Palavras-chave: veículos autônomos; sistemas inteligentes; dinâmica veicular; pneu inteligente; mggp.

ABSTRACT

With technological advancement, vehicles have evolved from purely mechanical systems to intelligent platforms equipped with embedded sensing. Although this instrumentation increases vehicle intelligence and safety, it also raises costs, limiting the dissemination of advanced technologies. In this context, *Soft Sensors* become an alternative by inferring quantities of interest from correlated variables measured by low-cost sensors, as is the case with Intelligent Tires. In this work, we develop *Soft Sensors* based on NARX (*Nonlinear AutoRegressive with eXogenous inputs*)/FIR (*Finite Impulse Response*) models identified by the evolutionary algorithm MGGP (*Multigene Genetic Programming*) to estimate the forces F_x , F_y and F_z on the wheels of a passenger vehicle, using exclusively acceleration data from intelligent tires. The problem was formulated as MIMO, since the inputs correspond to the accelerations in the three axes along the tire rotation angle and the outputs are the three forces. The input features were extracted in the *contact patch* region, organized by rotation angle with a resolution of 2.5° , evaluating three intervals ($\pm 10^\circ$, $\pm 20^\circ$ and $\pm 35^\circ$), different delay configurations and two training strategies, with tire-specific models and models trained with all four tires simultaneously (generalization). The validation included maneuvers with different predominant forces (straight line, *Slalom*, *Double Lane Change*, constant cornering, cornering with braking and random steering), in addition to a comparison with machine learning models (LSTM, GRU and MLP) using the MAPE and R^2 metrics. The results indicated that the $\pm 10^\circ$ interval tends to produce less accurate models with higher variance, while $\pm 20^\circ$ and $\pm 35^\circ$ showed paired performance, suggesting that $\pm 20^\circ$ is already sufficient for force prediction. It was also observed that models with only one delay can reduce variance and outperform configurations with multiple delays. In the best case, considering the critical forces associated with each operating condition, the NARX/FIR models identified via MGGP achieved $\text{MAPE} \leq 12\%$ and $R^2 \geq 0.80$ for these predominant forces, maintaining superior performance compared to LSTM, GRU and MLP under the evaluated conditions. Regarding generalization, models trained with data from all four tires simultaneously showed competitive performance compared to specific ones, reinforcing the practical relevance of the MIMO/generalist approach. Structural analysis revealed relevant couplings between forces, with recurrence of autoregressive terms between F_y and F_z . Finally, the NARX/FIR models via MGGP outperformed LSTM, GRU and MLP under the evaluated conditions, maintaining low complexity by using only 63 parameters. Thus, the results confirm

the potential of intelligent tires and MGGP for estimating dynamic quantities, with implications for more accessible, redundant and safe vehicle systems.

Keywords: *autonomous vehicles; intelligent systems; vehicle dynamics; intelligent tire; mggp.*

INDICADORES DE IMPACTO

O desenvolvimento do presente trabalho gera impactos significativos em diversas áreas, abrangendo os âmbitos tecnológico, econômico, social e ambiental, alinhando-se diretamente a objetivos de desenvolvimento sustentável estabelecidos pela Organização das Nações Unidas (ONU). No domínio tecnológico, o desenvolvimento de *soft-sensors* pode conduzir à otimização da estimativa de estados de elevada importância em veículos inteligentes, tais como as velocidades laterais e longitudinais, o ângulo de deriva, entre outros, contribuindo para o fortalecimento da inovação e da infraestrutura tecnológica no setor automotivo, em consonância com o Objetivo de Desenvolvimento Sustentável 9 (Indústria, Inovação e Infraestrutura). A utilização de pneus inteligentes possibilita a captura de grandezas físicas por meio de sensores de baixo custo, como os acelerômetros, permitindo a modelagem de *soft-sensors* com um sensoreamento mais econômico. Nesse contexto, os *soft-sensors* também apresentam a capacidade de atuar como sistemas redundantes, contribuindo para o aumento da segurança veicular em circunstâncias de falha do sensor físico. A melhoria das previsões sobre estados críticos pode resultar na diminuição de acidentes, colaborando para o aumento da segurança rodoviária e para a preservação da vida humana, em alinhamento com o Objetivo de Desenvolvimento Sustentável 3 (Saúde e Bem-Estar). Ademais, a redução da dependência de sensores de alto custo pode resultar na diminuição do custo dos veículos inteligentes e em uma maior acessibilidade a essas tecnologias por parte da população de baixa renda, contribuindo para a redução das desigualdades no acesso à inovação tecnológica, em conformidade com o Objetivo de Desenvolvimento Sustentável 10 (Redução das Desigualdades). Por fim, a utilização de *soft-sensors* para a estimação mais precisa de estados dinâmicos permite aprimorar o controle veicular, contribuindo para a redução das emissões de dióxido de carbono e para o aumento do desempenho energético do veículo, em consonância com o Objetivo de Desenvolvimento Sustentável 13 (Ação Contra a Mudança Global do Clima).

IMPACT INDICATORS

The development of this work generates significant impacts across multiple areas, encompassing the technological, economic, social, and environmental domains, and is directly aligned with the Sustainable Development Goals established by the United Nations (UN). In the technological domain, the development of soft sensors can lead to the optimization of the estimation of highly relevant states in intelligent vehicles, such as lateral and longitudinal velocities, the sideslip angle, among others, thereby contributing to the strengthening of innovation and technological infrastructure in the automotive sector, in accordance with Sustainable Development Goal 9 (Industry, Innovation and Infrastructure). The use of intelligent tires enables the acquisition of physical quantities through low-cost sensors, such as accelerometers, allowing the modeling of soft sensors with more economical sensing architectures. In this context, soft sensors also have the capability to operate as redundant systems, contributing to increased vehicle safety in situations where physical sensors fail. Improved prediction of critical states may result in a reduction in accidents, thereby enhancing road safety and preserving human life, in alignment with Sustainable Development Goal 3 (Good Health and Well-Being). Furthermore, reducing reliance on high-cost sensors may lead to a decrease in the overall cost of intelligent vehicles and increased accessibility of these technologies for low-income populations, contributing to the reduction of inequalities in access to technological innovation, in accordance with Sustainable Development Goal 10 (Reduced Inequalities). Finally, the use of soft sensors for more accurate estimation of dynamic states enables improved vehicle control, contributing to the reduction of carbon dioxide emissions and to enhanced vehicle energy efficiency, in line with Sustainable Development Goal 13 (Climate Action).

LISTA DE FIGURAS

Figura 2.1 – Níveis de Autonomia Veicular	33
Figura 2.2 – Efeito do Sistema ABS em um Veículo	34
Figura 2.3 – Efeito do Sistema ESP em um Veículo	35
Figura 2.4 – Efeito do Sistema AEB em um Veículo	35
Figura 2.5 – Atuação do Sistema LKA em um Veículo	36
Figura 2.6 – Adaptive Cruise Control	36
Figura 2.7 – Traction Control System	37
Figura 2.8 – Parking Collision-Avoidance Assist	38
Figura 2.9 – Modelo Bicicleta	40
Figura 2.10 – Característica Dinâmica das Forças Longitudinal e Lateral	43
Figura 2.11 – Influência da Velocidade na Força Lateral	44
Figura 2.12 – Forças Longitudinais e Laterais Combinadas	45
Figura 2.13 – Pneumatic Trail	46
Figura 2.14 – Relação da Força Lateral, Momento de Alinhamento e <i>Pneumatic Trail</i>	47
Figura 2.15 – Rotação dos Eixos	48
Figura 2.16 – Pneu Inteligente	48
Figura 2.17 – Arquitetura MLP	50
Figura 2.18 – Arquitetura LSTM	52
Figura 2.19 – Arquitetura GRU	53
Figura 2.20 – Passos Para Modelagem de Sistemas	56
Figura 2.21 – Subdivisões da Computação Evolucionária	65
Figura 2.22 – Fluxograma dos Algoritmos Evolucionários	66
Figura 2.23 – Representações de Cruzamento e Mutação de um Indivíduo MGGP	70
Figura 2.24 – Representações dos Indivíduos MGGP MISO/SISO e MIMO	70
Figura 3.1 – Acelerômetro 3133A4 <i>Dytran</i>	76
Figura 3.2 – Sistema de Aquisição DEWE2-A4	77
Figura 3.3 – Transdutor de Força da Roda Modelo 12.8-50	77
Figura 3.4 – Amplificador MX1615BR	78
Figura 3.5 – Veículo Utilizado para Aquisição dos Dados	78

Figura 3.6 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação Direção em Linha Reta	79
Figura 3.7 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação <i>Double Lane Change</i>	79
Figura 3.8 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação <i>Slalom</i>	80
Figura 3.9 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação Curvas Constantes	80
Figura 3.10 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação Curvas Constantes com Frenagens	81
Figura 3.11 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação Direção Aleatória	81
Figura 3.12 – Dados de Treinamento	83
Figura 3.13 – (a) Pré-processamento, (b) Metodologia Principal (c) Metodologia Complementar	85
Figura 3.14 – Representação do <i>contact patch</i>	87
Figura 3.15 – Efeito da Filtragem dos Sinais de Aceleração: (a) Sem Filtragem, (b) Frequência de corte 400Hz	89
Figura 3.16 – Acelerações Z (V) por ângulo do Pneu Dianteiro Esquerdo	90
Figura 3.17 – Efeito dos Filtros em um Sinal de Aceleração em X: (a) Rotação Sem Filtragem <i>Butterworth</i> , (b) Rotação Com Filtragem <i>Butterworth</i> , (c) 0.0° Sem Filtragem Média Móvel, (d) 0.0° Com Filtragem Média Móvel	91
Figura 3.18 – Arquitetura MGGP	93
Figura 4.1 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Curvas Constantes com Frenagem do Pneu Traseiro Esquerdo	100
Figura 4.2 – Comparativo Por Velocidade da Métrica MAPE na Condição de Operação <i>Double Lane Change</i> e Por Pneu - Modelos NARX/FIR via MGGP Treinados com Diferentes Intervalos de Extração de Características	101
Figura 4.3 – Comparativo Por Velocidade da Métrica R ² na Condição de Operação <i>Double Lane Change</i> e Por Pneu - Modelos NARX/FIR via MGGP Treinados com Diferentes Intervalos de Extração de Características	102

Figura 4.4 – Comparativo Por Velocidade da Métrica MAPE na Condição de Operação <i>Slalom</i> e Por Pneu - Modelos NARX/FIR via MGGP Treinados com Diferentes Intervalos de Extração de Características	102
Figura 4.5 – Comparativo Por Velocidade da Métrica R^2 na Condição de Operação <i>Slalom</i> e Por Pneu - Modelos NARX/FIR via MGGP Treinados com Diferentes Intervalos de Extração de Características	103
Figura 4.6 – Comparativo Temporal entre Predições e Valores Reais do Modelo NARX/-FIR no <i>Double Lane Change</i> do Pneu Dianteiro Direito em suas Variações de Velocidade	104
Figura 4.7 – Comparativo Temporal entre Predições e Valores Reais do Modelo NARX/-FIR no <i>Double Lane Change</i> do Pneu Traseiro Direito em suas Variações de Velocidade	104
Figura 4.8 – Comparativo Temporal entre Predições e Valores Reais do Modelo NARX/-FIR no <i>Slalom</i> do Pneu Dianteiro Direito em suas Variações de Velocidade	105
Figura 4.9 – Comparativo Temporal entre Predições e Valores Reais do Modelo NARX/-FIR no <i>Slalom</i> do Pneu Traseiro Direito em suas Variações de Velocidade	105
Figura 4.10 – Comparativo da Métrica MAPE - Modelos NARX/FIR via MGGP Treinados Com Diferentes Intervalos de Características	107
Figura 4.11 – Comparativo da Métrica R^2 - Modelos NARX/FIR via MGGP Treinados Com Diferentes Intervalos de Características	108
Figura 4.12 – Comparativo da Métrica R^2 - Modelos NARX/FIR c/ Multi Atrasos, c/ um Atraso, e Modelos Para Todos os Pneus	110
Figura 4.13 – Comparativo da Métrica R^2 - Modelos NARX/FIR c/ Multi Atrasos, c/ um Atraso, e Modelos Para Todos os Pneus	111
Figura 4.14 – Comparativo da métrica MAPE - Modelos via MGGP, LSTM, GRU e MLP Treinados com Multi Atrasos	113
Figura 4.15 – Comparativo da métrica R^2 - Modelos via MGGP, LSTM, GRU e MLP Treinados com Multi Atrasos	114
Figura 4.16 – Comparativo da métrica MAPE - Modelos via MGGP, LSTM, GRU e MLP Treinados com Um Atraso	115
Figura 4.17 – Comparativo da métrica R^2 - Modelos via MGGP, LSTM, GRU e MLP Treinados com Um Atraso	116

Figura 4.18 – Uso das Características no Intervalo $\pm 20^\circ$ de Rotação do Pneu Dianteiro	
Esquerdo	117
Figura 4.19 – Uso das Características no Intervalo $\pm 35^\circ$ de Rotação do Pneu Dianteiro	
Esquerdo	117
Figura 1 – Variação do ângulo de esterçamento no movimento <i>Double Lane Change</i> em	
30 kph	123
Figura 2 – Variação do ângulo de esterçamento no movimento <i>Double Lane Change</i> em	
60 kph	124
Figura 3 – Relação entre Força Longitudinal e Acelerações no eixo X do Pneu Inteligente	
no Movimento <i>Double Lane Change</i> em 30 kph	124
Figura 4 – Relação entre Força Lateral e Acelerações no eixo Y do Pneu Inteligente no	
Movimento <i>Double Lane Change</i> em 30 kph	125
Figura 5 – Relação entre Força Vertical e Acelerações no eixo Z do Pneu Inteligente no	
Movimento <i>Double Lane Change</i> em 30 kph	125
Figura 6 – Relação entre Força Longitudinal e Acelerações no eixo X do Pneu Inteligente	
no Movimento <i>Double Lane Change</i> em 60 kph	126
Figura 7 – Relação entre Força Lateral e Acelerações no eixo Y do Pneu Inteligente no	
Movimento <i>Double Lane Change</i> em 60 kph	126
Figura 8 – Relação entre Força Vertical e Acelerações no eixo Z do Pneu Inteligente no	
Movimento <i>Double Lane Change</i> em 60 kph	127
Figura 9 – Variação do ângulo de esterçamento no movimento <i>Slalom</i> em 30 kph	127
Figura 10 – Variação do ângulo de esterçamento no movimento <i>Slalom</i> em 60 kph	128
Figura 11 – Relação entre Força Longitudinal e Acelerações no eixo X do Pneu Inteli-	
gente no Movimento <i>Slalom</i> em 30 kph	128
Figura 12 – Relação entre Força Lateral e Acelerações no eixo Y do Pneu Inteligente no	
Movimento <i>Slalom</i> em 30 kph	129
Figura 13 – Relação entre Força Vertical e Acelerações no eixo Z do Pneu Inteligente no	
Movimento <i>Slalom</i> em 30 kph	129
Figura 14 – Relação entre Força Longitudinal e Acelerações no eixo X do Pneu Inteli-	
gente no Movimento <i>Slalom</i> em 60 kph	130

Figura 15 – Relação entre Força Lateral e Acelerações no eixo Y do Pneu Inteligente no Movimento <i>Slalom</i> em 60 kph	130
Figura 16 – Relação entre Força Vertical e Acelerações no eixo Z do Pneu Inteligente no Movimento <i>Slalom</i> em 60 kph	131
Figura 17 – Variação das Características da Condição de Operação Direção em Linha Reta	133
Figura 18 – Variação das Características da Condição de Operação <i>Slalom</i>	134
Figura 19 – Variação das Características da Condição de Operação <i>Double Lane Change</i>	135
Figura 20 – Variação das Características da Condição de Operação Curvas Constantes . .	136
Figura 21 – Variação das Características da Condição de Operação Curvas Constantes com Frenagem	137
Figura 22 – Variação das Características da Condição de Operação Direção Aleatória . .	138
Figura 23 – Relação histerética de F_y e β dos quatro pneus na condição de operação <i>Double Lane Change</i>	140
Figura 24 – Relação histerética de F_y e β dos quatro pneus na condição de operação <i>Slalom</i> .	141
Figura 25 – Uso das Características no Intervalo $\pm 20^\circ$ de Rotação do Pneu Dianteiro Direito	144
Figura 26 – Uso das Características no Intervalo $\pm 35^\circ$ de Rotação do Pneu Dianteiro Direito	144
Figura 27 – Uso das Características no Intervalo $\pm 20^\circ$ de Rotação do Pneu Traseiro Esquerdo	145
Figura 28 – Uso das Características no Intervalo $\pm 35^\circ$ de Rotação do Pneu Traseiro Esquerdo	145
Figura 29 – Uso das Características no Intervalo $\pm 20^\circ$ de Rotação do Pneu Traseiro Direito	146
Figura 30 – Uso das Características no Intervalo $\pm 35^\circ$ de Rotação do Pneu Traseiro Direito	146
Figura 31 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Curvas Constantes com Frenagens do Pneu Dianteiro Esquerdo	147
Figura 32 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Curvas Constantes do Pneu Dianteiro Esquerdo	148
Figura 33 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Direção em Linha Reta do Pneu Dianteiro Esquerdo	148
Figura 34 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Direção Aleatória do Pneu Dianteiro Esquerdo	149

Figura 35 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Curvas Constantes do Pneu Traseiro Esquerdo	149
Figura 36 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Direção em Linha Reta do Pneu Traseiro Esquerdo	150
Figura 37 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Direção Aleatória do Pneu Traseiro Esquerdo	150
Figura 38 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação <i>Double Lane Change</i>	151
Figura 39 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação <i>Double Lane Change</i>	152
Figura 40 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação <i>Double Lane Change</i>	152
Figura 41 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação <i>Double Lane Change</i>	153
Figura 42 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação <i>Double Lane Change</i>	153
Figura 43 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação <i>Double Lane Change</i>	154
Figura 44 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção em Linha Reta	154
Figura 45 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção em Linha Reta	155
Figura 46 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção em Linha Reta	155
Figura 47 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção em Linha Reta	156
Figura 48 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção em Linha Reta	156
Figura 49 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção em Linha Reta	157
Figura 50 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação <i>Slalom</i>	157

Figura 51 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação <i>Slalom</i>	158
Figura 52 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação <i>Slalom</i>	158
Figura 53 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação <i>Slalom</i>	159
Figura 54 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação <i>Slalom</i>	159
Figura 55 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação <i>Slalom</i>	160
Figura 56 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens	160
Figura 57 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens	161
Figura 58 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens	161
Figura 59 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens	162
Figura 60 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens	162
Figura 61 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens	163
Figura 62 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes	163
Figura 63 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes	164
Figura 64 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes	164
Figura 65 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes	165
Figura 66 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes	165

Figura 67 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes	166
Figura 68 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção Aleatória	166
Figura 69 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção Aleatória	167
Figura 70 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção Aleatória	167
Figura 71 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção Aleatória	168
Figura 72 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção Aleatória	168
Figura 73 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção Aleatória	169

LISTA DE TABELAS

Tabela 3.1 – Descrição dos Conjuntos de Dados e Forças Críticas	84
Tabela 3.2 – Espaço de Busca para a Configuração dos Hiperparâmetros com Optuna. . .	92
Tabela 3.3 – Arquitetura dos modelos LSTM, MLP e GRU.	92
Tabela 4.1 – Quantidade de Modelos NARX/FIR por Tipo de Atraso	95
Tabela 4.2 – Contagem de Uso de Termos Autorregressivos nos modelos NARX por Tipo de Atraso	96
Tabela 4.3 – Melhores Hiperparâmetros por Modelos treinados com Multi Atrasos	112
Tabela 4.4 – Melhores Hiperparâmetros por Modelo e Pneu (Um Atraso)	112
Tabela 4.5 – Comparação dos Modelos: Tempo de Treinamento, N° de Parâmetros e FLOPs	119
Tabela 1 – Valores dos Parâmetros θ para os Modelos NARX/FIR Multi Atrasos do pneu Dianteiro Direito	142
Tabela 2 – Valores dos Parâmetros θ para os Modelos NARX/FIR um Atraso do pneu Dianteiro Direito	143

LISTA DE SIGLAS

R^2	Coeficiente de Determinação
ABS	<i>Anti-lock Braking System</i>
ACC	<i>Adaptive Cruise Control</i>
ADAS	<i>Advanced Driver-Assistance Systems</i>
AE	Algoritmos Evolucionários
AE	<i>Absolute Error</i>
AEB	<i>Autonomous Emergency Braking</i>
ARX	<i>AutoRegressive with eXogenous inputs</i>
Beidou	sistema de navegação chinês
CCD	<i>Charge-Coupled Device</i>
CE	Computação Evolucionária
CMOS	<i>Complementary Metal Oxide Semiconductor</i>
ESP	<i>Electronic Stability Program</i>
FIR	<i>Finite Impulse Response</i>
FLOPs	<i>FLoating-point OPerations</i>
FR	<i>Free Run</i>
Galileo	sistema de navegação europeu
GLONASS	sistema de navegação russo
GNSS	<i>Global Navigation Satellite System</i>
GPR	<i>Gaussian Process Regression</i>
GPS	<i>Global Positioning System</i>
GRU	<i>Gated Recurrent Unit</i>
IMU	<i>Inertial Measurement Unit</i>
kph	quilômetros por hora
LiDAR	<i>Light Detection and Ranging</i>
LKA	<i>Lane Keeping Assist</i>
LSTM	<i>Long Short-Term Memory</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MGGP	<i>Multigene Genetic Programming</i>

MIMO	<i>Multiple Input Multiple Output</i>
MISO	<i>Multiple Input Single Output</i>
MLP	<i>Multi-Layer Perceptron</i>
MQ	Mínimos Quadrados
MQP	Mínimos Quadrados Ponderados
MS	<i>Multiple Shooting</i>
MSE	<i>Mean Square Error</i>
NARMAX	<i>Nonlinear AutoRegressive Moving Average with eXogenous inputs</i>
NARX	<i>Nonlinear AutoRegressive with eXogenous inputs</i>
NN	<i>Neural Network</i>
NRMSE	<i>Normalized Root Mean Square Error</i>
OSA	<i>One Step Ahead</i>
PCA	<i>Parking Collision-Avoidance Assist</i>
PG	Programação Genética
PVDF	<i>Polyvinylidene Fluoride</i>
RADAR	<i>Radio Detection and Ranging</i>
RF	<i>Random Forest</i>
RMSE	<i>Root Mean Square Error</i>
RNN	<i>Recurrent Neural Network</i>
SAE	<i>Society of Automotive Engineers</i>
SISO	<i>Single Input Single Output</i>
SVM	<i>Support Vector Machine</i>
TCS	<i>Traction Control System</i>
V2I	<i>Vehicle-to-Infrastructure</i>
V2V	<i>Vehicle-to-Vehicle</i>

LISTA DE SÍMBOLOS

F_x	Força longitudinal na roda do veículo
F_y	Força lateral na roda do veículo
F_z	Força vertical na roda do veículo
δ	Ângulo de esterçamento
F_{xr}	Força longitudinal do pneu traseiro
F_{xf}	Força longitudinal do pneu dianteiro
F_{yr}	Força lateral do pneu traseiro
F_{yf}	Força lateral do pneu dianteiro
α_r	Ângulo de deriva do pneu traseiro
α_f	Ângulo de deriva do pneu dianteiro
β	Ângulo de deslizamento lateral do veículo
v_y	Velocidade lateral do veículo
v_x	Velocidade longitudinal do veículo
v	Velocidade do veículo
ψ	Ângulo de Guinada
l_r	Distância do eixo traseiro ao centro de gravidade
l_f	Distância do eixo dianteiro ao centro de gravidade
v_z	Velocidade vertical do veículo
a_x	Aceleração longitudinal
a_y	Aceleração lateral
$\dot{\psi}$	Taxa de Guinada
α	Ângulo de deslizamento lateral do pneu (ângulo de deriva)
k	Deslizamento longitudinal
B	Fator de rigidez (Pacejka)
C	Fator de forma (Pacejka)
D	Valor de pico (Pacejka)
E	Fator de curvatura (Pacejka)
S_H	Deslocamento horizontal (Pacejka)
S_v	Deslocamento vertical (Pacejka)
μ	Coeficiente de atrito pneu-estrada

C_{σ}	Rigidez longitudinal do pneu
C_{α}	Rigidez lateral do pneu
σ_x	Razão de deslizamento longitudinal
M_z	Momento de alinhamento
τ_y	Tensão lateral
$a_{x\alpha}$	<i>Pneumatic Trail</i>
X	Vetor/matriz de regressores (variáveis independentes)
ξ	Vetor de resíduos
θ	Vetor de parâmetros do modelo
J_{MQ}	Função custo dos Mínimos Quadrados
ξ_i	Resíduo da i-ésima observação

SUMÁRIO

1	INTRODUÇÃO	26
1.1	Objetivos	29
1.1.1	Objetivo Geral	29
1.1.2	Objetivos Específicos	29
1.2	Contribuições Do Trabalho	30
1.3	Organização	30
2	REFERENCIAL TEÓRICO	31
2.1	Veículos Inteligentes e Autonomia Veicular	31
2.1.1	Sistemas Avançados de Assistência ao Motorista - ADAS	34
2.1.2	Sensoriamento para Inteligência Veicular	37
2.1.3	Dinâmica Veicular	39
2.1.4	Pneus Inteligentes	44
2.1.4.1	Pneus Inteligentes na Indústria	46
2.2	Aprendizado de Máquinas	49
2.2.1	<i>Multi-Layer Perceptron</i>	<i>50</i>
2.2.2	<i>Long Short-Term Memory</i>	<i>51</i>
2.2.3	<i>Gated Recurrent Unit</i>	<i>51</i>
2.2.4	Identificação de Sistemas	52
2.3	Abordagens para Modelagem em Sistemas Dinâmicos	54
2.3.1	Seleção de Modelos	56
2.3.1.1	<i>AutoRegressive with eXogenous inputs</i>	<i>57</i>
2.3.1.2	<i>Finite Impulse Response</i>	<i>58</i>
2.3.1.3	<i>Nonlinear AutoRegressive with eXogenous inputs</i>	<i>58</i>
2.3.1.4	<i>Nonlinear AutoRegressive Moving Average with eXogenous inputs</i>	<i>59</i>
2.3.2	Estimação de Parâmetros	60
2.3.2.1	Mínimos Quadrados	60
2.3.2.2	Mínimos Quadrados Ponderados	61
2.3.3	Validação de Modelos	61
2.3.4	Métricas de Avaliação	63
2.4	Computação Evolucionária	64
2.4.1	Fundamentos de Otimização	66

2.4.2	Programação Genética	68
2.4.3	<i>Multigene Genetic Programming</i>	68
2.4.3.1	<i>Multigene Genetic Programming</i> MIMO	71
2.5	Trabalhos Relacionados	71
3	MATERIAIS E MÉTODOS	75
3.1	Banco de Dados	75
3.2	Descrição Geral da Metodologia	83
3.2.1	Pré-Processamento dos Sinais	86
3.2.1.1	Janelamento do Sinal	86
3.2.1.2	Filtragem do Sinal	88
3.2.2	Metodologia Principal de Modelagem	88
3.2.3	Metodologia Complementar	89
3.2.4	Normalização dos Dados	90
3.3	Arquitetura dos Algoritmos de Aprendizado de Máquinas	91
3.4	Arquitetura do <i>Multigene Genetic Programming</i>	92
4	RESULTADOS E DISCUSSÕES	94
4.1	Modelos NARX/FIR Polinomiais gerados pelo Algoritmo MGGP	94
4.2	Impacto da Velocidade na Qualidade dos Modelos NARX/FIR para o Caso DLC e Slalom	100
4.3	Efeito do Uso de Diferentes Intervalos na Extração das Características	103
4.4	Comparativo entre Diferentes Abordagens dos Modelos NARX/FIR	108
4.5	Comparativo entre Modelos NARX/FIR e Modelos de Machine Learning	109
4.6	Análise do Uso das Acelerações por Ângulo de Rotação do Pneu	113
4.7	Custo Computacional <i>Versus</i> Complexidade	118
5	CONCLUSÃO E TRABALHOS FUTUROS	120
	APÊNDICES	122
	ANEXOS	142
	REFERÊNCIAS	151

1 INTRODUÇÃO

À medida que a humanidade avança, o desenvolvimento tecnológico também cresce e se expande, possibilitando a integração de tecnologias onde antes não se via, como os veículos. Enquanto as primeiras versões de automóveis eram predominantemente mecânicos, é visto cada vez mais a aplicação de eletrônica embarcada com a adição de sensores nos automóveis. Esse movimento não é apenas uma tendência de mercado, ele representa uma mudança na própria forma como o veículo percebe o ambiente e responde a ele, tornando o sensoramento uma base para aumentar a segurança, o desempenho e a capacidade de decisão em situações críticas.

O sensoramento veicular permite a adição de inteligência, posteriormente trazendo níveis de autonomia ao mesmo. A norma SAE (*Society of Automotive Engineers*) J3016 estabelece seis categorias para a definição de veículos autônomos (Williams, 2021). Segundo a presente norma, os três primeiros níveis de autonomia veicular se enquadram como ADAS (*Advanced Driver-Assistance Systems*) (Greenwood; Lenneman; Baldwin, 2022). Do quarto ao último nível, o veículo adquire a capacidade de operar de forma autônoma, tornando-se inteiramente independente de intervenção humana no último nível. Em todos os casos, são presentes os níveis de tecnologia apropriados para o auxílio ao motorista ou autonomia veicular, incluindo o sensoramento do veículo. Por um lado, aumentar o grau de instrumentação do veículo para a captação de grandezas físicas reflete no aumento da inteligência veicular. Porém, isso também implica no aumento do custo do veículo. Existem sensores demasiadamente caros que, ao utilizá-los, se torna inviável o acesso desses veículos para pessoas que não possuem alto poder aquisitivo. Uma alternativa para contornar a dependência desses sensores de alto custo é o desenvolvimento de Sensor Virtual (*Soft Sensors*) a partir da modelagem de sistemas.

A modelagem de sistemas constitui uma atividade realizada em diversas áreas, dada a sua pertinência no desenvolvimento de aplicações que abrangem desde simuladores até projetos de controle para sistemas reais por meio de dados ou amostras (Schweiger *et al.*, 2020). A modelagem de sistemas pode ser obtida por meio de suas entradas e saídas, designada “Modelagem Caixa Preta”, ou “Identificação de Sistemas” (Aguirre, 2015). A obtenção do modelo permite a análise do comportamento do sistema em situações adversas sem comprometer o sistema físico real, além da realização de estudos aprofundados sobre o mesmo. De maneira geral, é possível obter a modelagem de um sistema a partir cinco passos: a aquisição de dados por meio de tes-

tes dinâmicos, a seleção da representação do modelo, a escolha da estrutura, a estimação dos parâmetros e a subsequente validação dos mesmos (Aguirre, 2015).

Dentro dos estudos sobre modelagem de sistemas, existem os *Soft Sensors*. Estes sensores virtuais partem da premissa que é possível inferir grandezas físicas indiretamente. Nesse contexto, a utilização de um sensor de alto custo pode ser substituída por sensores de menor custo para outras variáveis que possuem correlação com a variável desejada, sendo possível assim utilizá-las para a modelagem. Com isso, os *Soft Sensors* trazem diversos benefícios e utilidades. Eles podem ser utilizados para a redução de custos, dado a não necessidade de sensores caros, conforme dito anteriormente. No caso ainda da presença do sensor que infere diretamente a grandeza desejada, os *Soft Sensors* podem funcionar como um sistema redundante e detecção de falhas do sensor principal, tendo em vista que o sensor virtual continuará a fornecer informações para o sistema até mesmo quando o sensor principal não funciona.

Entre todas as fontes de informação disponíveis em um veículo, a região de contato pneu-solo é particularmente estratégica, pois concentra sinais diretamente associados ao atrito, às forças transmitidas ao veículo e, conseqüentemente, à sua estabilidade e segurança dinâmica. É nesse ponto que os Pneus Inteligentes passam a ter um papel particularmente atrativo.

O sensoriamento do veículo, conforme percorrido anteriormente, atualmente acontece até mesmo nos pneus, denominando-os assim como Pneus Inteligentes. Os Pneus Inteligentes representam uma vertente do sensoriamento que permite a obtenção de leituras de grandezas físicas relevantes a partir de sensores de baixo custo como o acelerômetro, o sensor PVDF (*Polyvinylidene Fluoride*), entre outros. A depender do tipo do sensor acoplado internamente aos pneus, é possível obter leituras de acelerações, rotações, deformações do pneu, entre outras grandezas. Dado a disponibilidade das informações pneu-solo advindas dos Pneus Inteligentes, possibilita-se e se faz útil a concepção dos *Soft Sensors*, principalmente quando se deseja explorar a dinâmica do contato pneu-solo sem depender de instrumentação custosa. Pneus inteligentes já estão inseridos no mercado como produtos dispostos ao uso por diversas empresas, como as renomadas Pirelli, Continental, entre outras, o que reforça o potencial prático e a relevância do tema para aplicações reais.

Na engenharia de maneira geral, há um elevado número de sistemas que apresentam características não lineares atribuídas em sua dinâmica, podendo ou não utilizar as próprias saídas atrasadas como entradas (termos autorregressivos) para as novas previsões. Nestes casos onde utiliza as próprias saídas atrasadas juntamente com as variáveis externas, os modelos

NARX (*Nonlinear AutoRegressive with eXogenous inputs*) podem constituir uma opção interessante para a modelagem destes sistemas e concepção dos *Soft Sensors* (Castro, 2021). Caso não seja utilizado termos autorregressivos, pode-se obter assim a modelagem de *Soft Sensors* a partir dos modelos FIR (*Finite Impulse Response*) baseado apenas nas variáveis externas. Com o intuito de identificar modelos sob a perspectiva de menor custo e complexidade computacional, os modelos NARX polinomiais, construídos a partir do algoritmo MGGP (*Multigene Genetic Programming*), são merecedores de destaque (Derner *et al.*, 2020). O MGGP é um algoritmo que evolui as capacidades da PG (Programação Genética) para construir equações denominadas como programas, sendo bastante utilizado em problemas de regressão simbólica (Gandomi; Alavi, 2012). Ambos os algoritmos citados são classificados como AE (Algoritmos Evolucionários), os quais são fundamentados nos conceitos da evolução das espécies, assim como descritos por Charles Darwin, visando identificar o indivíduo mais apto para resolver um problema específico, dado que um indivíduo codifica uma solução candidata ao problema. Os modelos de aprendizagem de máquina, como as redes LSTM (*Long Short-Term Memory*), GRU (*Gated Recurrent Unit*) e MLP (*Multi-Layer Perceptron*), evidenciam também aptidão para a modelagem de sistemas devido as suas capacidades de capturar dinâmicas dos dados. A solução apresentada nestes casos, contudo, não apresenta o mesmo nível de interpretabilidade do modelo polinomial NARX.

Em veículos inteligentes, sistemas com respostas rápidas são priorizados, tendo em vista que uma atuação tardia em circunstâncias específicas pode resultar em riscos materiais, como acidentes, e, no pior dos casos, colocar em risco a vida humana. As forças longitudinais (F_x), laterais (F_y) e verticais (F_z) das rodas do veículo, constituem grandezas de interesse que podem ser alvo de controle e atuação dos sistemas inteligentes, para evitar a ocorrência de tais situações de risco e acidentes. Nesse sentido, a aplicação de modelos estimativos como os *Soft Sensors* pode revelar-se de grande utilidade quando se deseja redundância da leitura de determinada grandeza física (feita diretamente pelo sensor físico, e indiretamente pelo sensor virtual), ou até mesmo a ausência do sensor de alto custo para a inferência direta de tais grandezas.

1.1 Objetivos

1.1.1 Objetivo Geral

O objetivo principal deste trabalho é desenvolver *Soft Sensors* capazes de inferir as forças longitudinal (F_x), lateral (F_y) e vertical (F_z) dos pneus de um veículo de passageiros, a partir de leituras do acelerômetro dos Pneus Inteligentes. O desenvolvimento desses *Soft Sensors* será realizado utilizando o algoritmo evolucionário MGGP (*Multigene Genetic Programming*), visando modelos NARX/FIR interpretáveis.

Com isso, o estudo em questão investiga o desempenho dos sensores virtuais em inferir sobre as forças atuantes em cada um dos pneus do veículo e em diferentes condições de operação onde as forças predominantes que atuam no pneu variam, utilizando apenas as medições das acelerações no Pneu Inteligente.

1.1.2 Objetivos Específicos

- Analisar o efeito da variação do intervalo utilizado para extrair as características, a partir do *contact patch* variando entre $\pm 10^\circ$, $\pm 20^\circ$ e $\pm 35^\circ$, no desempenho dos modelos gerados pelo MGGP.
- Analisar o efeito do número de atrasos permitido para as variáveis de entrada do modelo gerado pelo MGGP no desempenho da predição das forças.
- Comparar os modelos gerados pelo MGGP específicos por pneu e o modelo gerado pelo MGGP para atuar em qualquer um dos quatro pneus.
- Comparar os modelos gerados pelo MGGP com outras técnicas para desenvolvimento de *Soft Sensors* baseadas em aprendizado de máquinas, como as redes LSTM, GRU e MLP.
- Analisar o nível de importância das acelerações por ângulo de rotação do pneu com base na utilização pelos modelos.

1.2 Contribuições Do Trabalho

A contribuição deste trabalho vem em vista de demonstrar a capacidade da modelagem indireta das dinâmicas das forças das rodas, construindo assim os *Soft Sensors*, e utilizando exclusivamente as acelerações do Pneu Inteligente. O trabalho demonstra, portanto, o potencial existente nos Pneus Inteligentes para obter-se as características ligada às forças por meio de um sensor de baixo custo, como o acelerômetro.

A contribuição se estende ao modelar não apenas uma das forças, mas contemplando as forças lateral, longitudinal e vertical simultaneamente na modelagem. Trabalhos anteriores ou se limitam a estudar apenas uma das forças, como também abordam a modelagem em poucas condições de operação veicular. Ao abranger o estudo em seis condições de operações do veículo que variam entre si sobre as forças críticas existentes, o trabalho também recebe destaque.

1.3 Organização

A presente dissertação encontra-se estruturada em cinco seções, organizados da seguinte forma: a seção 2 aborda o Referencial Teórico, apresentando a fundamentação teórica necessária e abrangente para o trabalho. Na seção 3, são apresentados os Materiais e Métodos utilizados, abordando-se, por conseguinte, o banco de dados, os algoritmos e o pré-processamento a realizar. A seção 4 visa demonstrar os resultados obtidos aplicando-se a metodologia descrita anteriormente. Na seção 5 são apresentadas as conclusões e trabalhos futuros.

2 REFERENCIAL TEÓRICO

Nesta seção, são apresentados conceitos fundamentais pertinentes à pesquisa. Inicialmente, abordam-se veículos inteligentes, com foco em sistemas ADAS (*Advanced Driver-Assistance Systems*), em técnicas de sensoriamento para níveis de automação superiores e em dinâmica veicular. No âmbito dos veículos inteligentes, discute-se também o conceito e as aplicações de pneus inteligentes, incluindo versões já em produção oferecidas por grandes fabricantes. Em seguida, são revisados modelos de aprendizado de máquina comumente empregados na identificação de sistemas e no desenvolvimento de *Soft Sensors*. Posteriormente, são discutidas abordagens para a modelagem de sistemas dinâmicos, destacando-se a utilidade de algoritmos de computação evolucionária nesse contexto, em especial o algoritmo MGGP. Por fim, apresentam-se as métricas de avaliação tipicamente utilizadas na modelagem de sistemas, bem como uma revisão de trabalhos relacionados à temática.

2.1 Veículos Inteligentes e Autonomia Veicular

No domínio dos veículos, a autonomia é compreendida como a capacidade de realizar ações que não dependem da intervenção do condutor (Faisal *et al.*, 2019). Estas ações incluem a percepção, realizada por meio do sensoriamento, a tomada de decisão, processada pelos sistemas inteligentes, e a atuação direta com base em critérios técnicos, que podem ter em vista a segurança, a eficiência, a conformidade legal ou a ética. A complexidade destes sistemas varia significativamente em função da aplicação. Em casos mais elementares, como os robôs aspiradores, a autonomia está limitada à navegação em ambientes controlados, evitando obstáculos estáticos por meio de sensores básicos. Em aplicações complexas, como os carros autônomos, é necessário que o veículo processe uma elevada quantidade de dados em tempo real, incluindo o estado de semáforos e placas de trânsito, pedestres, outros veículos e eventos imprevisíveis, de modo a garantir um controle seguro da direção, velocidade e frenagem, mantendo a condução do veículo dentro das conformidades. Dessa forma, a base para a autonomia veicular é o sensoriamento, consequentemente, veículos inteligentes. A autonomia plena está presente apenas nos níveis mais elevados de classificação de veículos autônomos, conforme estabelecido pela norma SAE (*Society of Automotive Engineers*) J3016 (Williams, 2021). Em níveis inferiores, as autonomies encontram-se enquadradas no âmbito dos ADAS (*Advanced Driver-Assistance*

Systems) (Greenwood; Lenneman; Baldwin, 2022). Dessa forma, é entendido que todo veículo autônomo é um veículo inteligente, porém, nem todo veículo inteligente é classificado como um veículo autônomo.

A norma SAE J3016 estabelece seis níveis de autonomia que um veículo pode atingir, conforme ilustrado na Figura 2.1. Em conformidade com o nível 0 de autonomia, o veículo não exibe qualquer capacidade de se controlar sem a intervenção humana. No entanto, apresenta a aptidão para notificar o condutor por meio de sinais sonoros ou visuais. No primeiro nível, o veículo adquire a capacidade de executar funções de controle, embora se restrinja a uma única variável por vez. Exemplos podem ser a direção do veículo ou o sistema de frenagem, visando a correção e prevenção de situações indesejadas. No segundo nível de autonomia veicular, o veículo adquire a capacidade de controlar mais de um atuador de forma simultânea. Desta forma, os veículos que se enquadrem em algum dos três níveis iniciais exigirão naturalmente a presença e a ação do condutor. No grau de autonomia 3, o veículo adquire a capacidade de condução autônoma própria, embora, em circunstâncias desfavoráveis, continue a depender da intervenção do condutor. Em suma, neste patamar de autonomia, o veículo encontra-se limitado à condução autônoma apenas em circunstâncias convencionais de funcionamento. O nível 4 representa um nível de autonomia do veículo que é considerado autônomo pleno, ou seja, deixa de ser necessária a intervenção humana para a sua condução. As limitações do veículo em questão estão associadas às suas aplicações, que se restringem a viagens em áreas urbanas a baixa velocidade. Estas viagens apresentam um risco consideravelmente reduzido. No grau de autonomia veicular nível 5, o veículo está apto a conduzir-se de forma autônoma em quaisquer circunstâncias e situações de tráfego. É esperado que para o avanço do nível de autonomia seja exigida também uma infraestrutura maior para seu desenvolvimento, e mais sistemas inteligentes presentes nos veículos. Para que seja possível atingir um elevado grau de autonomia, os veículos passam a dispor de tecnologias como os sensores LiDAR, os radares, as câmeras e os ultrassons, que atuam diretamente na captação de grandezas físicas relevantes para o controle dos veículos (Yeong *et al.*, 2021; Vargas *et al.*, 2021).

A complexidade do problema justifica a necessidade de estudos aprofundados, incluindo a compreensão das grandezas físicas relevantes e a identificação dos sensores necessários para a sua integração no veículo, de modo a garantir a obtenção de leituras da variável de interesse ocasionando na inteligência veicular. Dada a necessidade de intervenções rápidas no veículo, é necessário um processamento computacional eficiente. Desta forma, um sistema inteligente

com componentes mais robustos reflete-se numa capacidade computacional superior. No entanto, esta maior robustez implica um custo mais elevado. Num segundo momento, será necessário procurar uma solução que implique um menor dispêndio computacional. Para tal, a utilização de modelos que processem as informações adquiridas de forma mais fácil constituirá uma alternativa viável.

Os veículos inteligentes ainda podem se deparar com um dilema. Quanto maior for a inteligência empregada no veículo, maior a necessidade de instrumentação e sensoriamento. Consequentemente, a medida que se aumenta a inteligência no veículo, também aumenta seu custo. Uma alternativa para isso é a inferência indireta de grandezas físicas, obtendo leitura de outras grandezas com sensores de menor custo. Visando isso, os *Soft Sensors* novamente aparecem como uma solução.

SAE J3016™ LEVELS OF DRIVING AUTOMATION™
Learn more here: [sae.org/standards/content/j3016_202104](https://www.sae.org/standards/content/j3016_202104)

Copyright © 2021 SAE International. The summary table may be freely copied and distributed AS-IS provided that SAE International is acknowledged as the source of the content.

	SAE LEVEL 0™	SAE LEVEL 1™	SAE LEVEL 2™	SAE LEVEL 3™	SAE LEVEL 4™	SAE LEVEL 5™
What does the human in the driver's seat have to do?	You are driving whenever these driver support features are engaged – even if your feet are off the pedals and you are not steering			You are not driving when these automated driving features are engaged – even if you are seated in “the driver’s seat”		
	You must constantly supervise these support features; you must steer, brake or accelerate as needed to maintain safety			When the feature requests, you must drive	These automated driving features will not require you to take over driving	
	These are driver support features			These are automated driving features		
What do these features do?	These features are limited to providing warnings and momentary assistance	These features provide steering OR brake/acceleration support to the driver	These features provide steering AND brake/acceleration support to the driver	These features can drive the vehicle under limited conditions and will not operate unless all required conditions are met		This feature can drive the vehicle under all conditions
Example Features	• automatic emergency braking • blind spot warning • lane departure warning	• lane centering OR adaptive cruise control	• lane centering AND adaptive cruise control at the same time	• traffic jam chauffeur	• local driverless taxi • pedals/steering wheel may or may not be installed	• same as level 4, but feature can drive everywhere in all conditions

Figura 2.1 – Níveis de Autonomia Veicular
(SAE International, 2021)

2.1.1 Sistemas Avançados de Assistência ao Motorista - ADAS

O termo ADAS (*Advanced Driver-Assistance Systems*) refere-se a sistemas inteligentes embarcados em veículos, cujo propósito é aumentar a segurança e proporcionar melhores condições de condução, entre outros benefícios (Tigadi *et al.*, 2016). Atualmente, é possível identificar diversas tecnologias que se inserem no domínio dos ADAS. Entre estas, destacam-se o ABS (*Anti-lock Braking System*), ESP (*Electronic Stability Program*), AEB (*Autonomous Emergency Braking*), LKA (*Lane Keeping Assist*), entre muitas outras.

O ABS (*Anti-lock Braking System*) é um dos sistemas embarcados mais conhecidos que auxilia na condução dos veículos. Este sistema é responsável por atuar em momentos em que há uma frenagem brusca do veículo realizada pelo piloto. Quando os sensores responsáveis detectam essa situação, o ABS intervém nos freios, evitando que as rodas travem e, consequentemente, que o veículo derrape na pista. A Figura 2.2 demonstra o efeito do ABS em um veículo.




Figura 2.2 – Efeito do Sistema ABS em um Veículo
Fonte: Do Autor (2026).

No que diz respeito ao controle de estabilidade do veículo, tem-se como exemplo o sistema ESP (*Electronic Stability Program*). Em circunstâncias de emergência, nas quais se torna necessário executar movimentos bruscos com o veículo, como, por exemplo, evitar a colisão com um objeto inesperado na pista, as forças atuantes no automóvel podem ocasionar a derrapagem ou, no pior dos cenários, o capotamento. Deste modo, o ESP atua ao reconhecer a derrapagem do veículo, acionando os freios de forma independente para controlar a situação e

evitar a continuidade da derrapagem. A *Rear-Wheel Steering* representa uma solução adicional para a estabilidade dos veículos. A Figura 2.3 ilustra a atuação de um veículo com o sistema ESP.




Figura 2.3 – Efeito do Sistema ESP em um Veículo
Fonte: Do Autor (2026).

Existem ainda sistemas embarcados que se encontram instalados em automóveis e que efetuam atualizações de forma mais ativa, como o AEB (*Autonomous Emergency Braking*) e o LKA (*Lane Keeping Assist*). O AEB, conforme o seu nome indica, atua na frenagem do veículo de forma automática, sem necessidade de intervenção por parte do condutor. O sistema de segurança é ativado quando os sensores detectam a possibilidade iminente de colisão entre o veículo e um objeto à sua frente, evitando-a. A Figura 2.4 mostra o funcionamento desse sistema.




Figura 2.4 – Efeito do Sistema AEB em um Veículo
Fonte: Do Autor (2026).

Assim como o AEB, o LKA opera de forma independente do condutor. A função do sistema é a de prevenir que o condutor desvie da faixa na autoestrada, corrigindo automaticamente a direção do veículo e garantindo uma condução segura. Todos esses exemplos citados

anteriormente demonstram o quão benéfico é a presença de sensores, assim como demonstram a sua utilidade em sistemas inteligentes nos veículos, capturando variáveis de interesse. A Figura 2.5 demonstra a atuação do LKA em um veículo.




Figura 2.5 – Atuação do Sistema LKA em um Veículo
Fonte: Do Autor (2026).

Outro sistema conhecido no contexto veicular é o ACC (*Adaptive Cruise Control*), conforme é mostrado na Figura 2.6. Esse sistema permite um controle inteligente de velocidade, mantendo uma distância constante do veículo da frente. Para isso, o sistema ACC coordena tanto a frenagem quanto a aceleração do veículo. Caso não haja um veículo a frente, ele apenas mantém uma velocidade constante no veículo. Para a detecção do veículo à frente o sistema ACC pode fazer uso de sensores como o LiDAR (Xiao; Gao, 2010).




Figura 2.6 – Adaptive Cruise Control
Fonte: Do Autor (2026).

Quando o veículo está iniciando sua locomoção sobre condições de inclinação, ou até mesmo em pistas de baixo atrito, pode ocorrer a sua derrapagem longitudinal. Para evitar essa eventualidade, existe então o TCS (*Traction Control System*), conforme apresentado na Figura 2.7. Dessa forma, o TCS atua em situações críticas, evitando a derrapagem das rodas do veículo ao realizar o controle de tração durante a aceleração, garantindo assim a sua estabilidade. Em

condições onde o veículo já está em deslocamento e se depara com uma condição adversa na pista, como uma poça de água, o TCS pode atuar evitando a derrapagem do veículo, devido à mudança da pista.




Figura 2.7 – Traction Control System

Fonte: Do Autor (2026).

Buscando evitar colisões traseiras, existe o sistema PCA (*Parking Collision-Avoidance Assist*) como pode ser visto na Figura 2.8. Neste caso, quando os sensores detectam risco de colisão iminente, ele emite sinais de alerta ao motorista. Esses sinais podem ser sonoros, visuais ou vibrando o volante do motorista. Se mesmo após o alerta o risco aumentar, o PCA pode acionar os freios do veículo, evitando a colisão.

2.1.2 Sensoriamento para Inteligência Veicular

Embora os sistemas ADAS possuam os respectivos sensores necessários para o seu funcionamento, para a autonomia veicular dos níveis 4 a 6, é necessário ainda mais exigência em termos de sensores e suas respectivas integrações nos veículos. Esta exigência deve-se ao fato de os sensores serem essenciais para que o veículo possa ter a autonomia plena, conforme visto anteriormente.

O sensor LiDAR (*Light Detection and Ranging*) é um sensor comumente utilizado na automação veicular para integração com visão computacional e detecção de objetos (Kim *et al.*, 2021). Este sensor funciona emitindo feixes de luz e captando-os novamente quando estes




Figura 2.8 – Parking Collision-Avoidance Assist
Fonte: Do Autor (2026).

voltam. A diferença de tempo entre a emissão e a recepção do feixe de luz permite a medição da distância dos objetos.

Outro equipamento importante e comumente presente nos veículos atuais são os sistemas de localização, conhecidos como GNSS (*Global Navigation Satellite System*). O GPS (*Global Positioning System*), o GLONASS (sistema de navegação russo), o Galileo (sistema de navegação europeu) e o Beidou (sistema de navegação chinês) são exemplos de sistemas GNSS utilizados em diferentes países (Pereira, 2023). Por meio da triangulação de satélites e dos respectivos sinais enviados e recebidos, é possível determinar as coordenadas do objeto desejado, o que permite a sua localização.

Ainda se tratando da navegação, é possível encontrar nos veículos dispositivos designados por IMU (*Inertial Measurement Unit*). Este dispositivo permite a inferência de grandezas como a força gravitacional, a rotação angular ou a velocidade do veículo ao qual está acoplado. Para isso, o dispositivo em questão pode ser composto por acelerômetro, giroscópio ou magnetômetro trabalhando em conjunto (Ahmad *et al.*, 2013).

Outro sensor muito utilizado atualmente nos veículos são as câmeras. Através dos sensores internos CMOS (*Complementary Metal Oxide Semiconductor*) ou CCD (*Charge-Coupled Device*), as câmeras são capazes de captar a luz do ambiente, sendo utilizadas para a detecção de objetos estáticos e móveis (Varghese; Boone *et al.*, 2015). Suas aplicações são diversas como identificação de placas de sinalização, ou até mesmo em ADAS voltados ao alerta de saída de faixa.

Os sensores RADAR (*Radio Detection and Ranging*) também se encontram presentes em veículos inteligentes (Ignatious; Khan *et al.*, 2022). Por meio das ondas geradas, os radares atuam com um campo de visão que são eficientes até mesmo na variação das condições do ambiente. Chuva, neblina, neve e até mesmo poeira podem ter impactos significativos no funcionamento do RADAR.

Enquanto os sensores RADAR operam em frequências de até 79 GHz para aplicações em veículos, existem também os ultrassônicos, que por sua vez, trabalham em frequências inferiores não ultrapassando 70 kHz nesse contexto (Yeong *et al.*, 2021). Os ultrassons têm a capacidade de detectar objetos sólidos, líquidos, granulares ou em pó. Embora os sensores de ultrassom tendem a ser mais baratos, eles são mais suscetíveis a interferências se comparado aos sensores RADAR.

Embora sejam os mais conhecidos, o sensoreamento veicular não se limita aos citados anteriormente. Há diversos outros sensores que podem ser integrados para leituras específicas da dinâmica veicular.

2.1.3 Dinâmica Veicular

Devido à natureza complexa da dinâmica veicular e as correlações entre as grandezas físicas existentes, em diferentes cenários de estudo é observada a existência de diferentes modelos e metodologias de análise. Uma dessas diferenças se dá considerando-se um modelo veicular de quatro ou de duas rodas. Se tratando de veículos de passageiros, sabe-se que originalmente o veículo é composto de quatro rodas para sua locomoção habitual. No entanto, é possível proceder a uma análise simplificada do veículo, por meio da substituição das duas rodas dianteiras por uma única roda virtual, bem como das duas rodas traseiras por uma única roda virtual. Quando isso é feito, trata-se do modelo chamado Modelo Bicicleta (Viehweger *et al.*, 2021). Este modelo é ilustrado pela Figura 2.9. Para além, essa simplificação é aplicável quando há ângulos de esterçamento (δ) pequenos (Hirschfeld; Malvezzi, 2022).

Na Figura 2.9, F_{xr} e F_{xf} são as forças longitudinais do pneu traseiro e dianteiro, respectivamente. Analogamente, F_{yr} e F_{yf} são as forças laterais do pneu traseiro e do pneu dianteiro. α_r é o ângulo de deriva do pneu traseiro, enquanto α_f é o correspondente para o pneu dianteiro. δ representa o ângulo de esterçamento, β é o ângulo de deslizamento lateral do veículo, v_y e v_x são as componentes laterais e longitudinais da velocidade v do veículo. ψ indica o ângulo de




Figura 2.9 – Modelo Bicicleta
Fonte: Do Autor (2026).

guinada, enquanto l_r e l_f são as distâncias dos eixos traseiro e dianteiro, a partir do centro de gravidade.

No que diz respeito às grandezas físicas atuantes nos veículos, uma das mais intuitivas de se considerar é, provavelmente, a velocidade. Procedendo à visualização do veículo sob o plano cartesiano, é possível decompor as velocidades atuantes nas componentes v_x , v_y e v_z . v_x representa a velocidade longitudinal do veículo. A velocidade v_y , por sua vez, é aquela que atua transversalmente, ou seja, sob a lateral do veículo. Em circunstâncias convencionais de operação, v_z é insignificante, uma vez que a escala de v_y e v_x é substancialmente superior a v_z . Para além, as taxas de v_x e v_y podem ser definidas com base nas acelerações a_x e a_y (longitudinal e lateral) e na taxa de guinada ($\dot{\psi}$) (que se deriva do ângulo de guinada, representado pelo símbolo ψ) do veículo:

$$\dot{v}_x = a_x + \dot{\psi}v_y, \quad (2.1)$$

$$\dot{v}_y = a_y - \dot{\psi}v_x. \quad (2.2)$$

Em circunstâncias em que um veículo se encontra em movimento, nos instantes em que ele está a realizar uma curva, uma ultrapassagem ou outras situações que impliquem um

deslocamento lateral, existirá um ângulo entre o movimento do veículo e a direção longitudinal dos pneus. Este ângulo é denominado de ângulo de deriva (α). Existe o ângulo equivalente para o veículo todo, chamado então de ângulo de deslizamento lateral (β). Em caso de um ângulo de deslizamento elevado, o veículo pode derrapar, o que é indesejável nas condições normais de deslocamento de um veículo de passageiro ou transporte. Com base no conhecimento das velocidades atuantes no veículo, é viável estabelecer a relação entre v_x e v_y , a qual se equipara ao ângulo de deslizamento:

$$\beta = \arctan\left(\frac{v_y}{v_x}\right). \quad (2.3)$$

É possível também denotar as forças atuantes nos pneus do veículo. A definição da equação representativa destas forças requer, em primeira instância, o estudo e a modelagem do pneu do veículo. Existem diferentes abordagens para modelar pneus veiculares, sendo a Fórmula Mágica de Pacejka uma das mais conhecidas e utilizadas atualmente (Pacejka, 2005). Essa abordagem baseia-se em um modelo empírico, onde as forças laterais (F_y) e longitudinais (F_x) são geradas, ela apresenta as seguintes equações:

$$y = D \sin \left\{ C \tan^{-1} \left[Bx - E \left(Bx - \tan^{-1}(Bx) \right) \right] \right\}, \quad (2.4)$$

$$Y(X) = y(x) + S_v, \quad (2.5)$$

$$x = X + S_H, \quad (2.6)$$

em que y representa a variável de saída, a qual pode assumir F_x ou F_y , X é a variável de entrada, podendo ser $\tan(\alpha)$ quando se deseja obter a força lateral F_y ou o deslizamento longitudinal k para o caso da força longitudinal F_x . Além disso, B é o fator de rigidez, C é o fator de forma, D é o valor de pico, E o fator de curvatura, S_H o deslocamento horizontal e S_v o deslocamento vertical.

Outra alternativa de modelagem é o Modelo Dugoff (Rajamani, 2011). A principal vantagem apresentada por esse modelo é a descrição combinada das forças lateral e vertical, levando em consideração os diferentes coeficientes de rigidez nestas direções. Esta modelagem apresenta as seguintes equações para as forças F_x e F_y atuantes no pneu:

$$F_x = C_\sigma \frac{\sigma_x}{1 + \sigma_x} f(\lambda), \quad (2.7)$$

$$F_y = C_\alpha \frac{\tan \alpha}{1 + \sigma_x} f(\lambda), \quad (2.8)$$

$$\lambda = \frac{\mu F_z (1 + \sigma_x)}{2 \sqrt{(C_\sigma \sigma_x)^2 + (C_\alpha \tan \alpha)^2}}, \quad (2.9)$$

$$f(\lambda) = \begin{cases} \lambda(2 - \lambda) & \text{se } \lambda < 1 \\ 1 & \text{se } \lambda \geq 1 \end{cases}. \quad (2.10)$$

onde F_z é a força vertical no pneu, μ é o coeficiente de atrito pneu-solo, C_σ é a rigidez longitudinal do pneu, C_α é a rigidez do pneu nas curvas, σ_x é a razão de deslizamento longitudinal e α o ângulo de deriva.

Além desses modelos, existem outras abordagens como o Modelo Brush, bem como modelos mais simplificados, como o Modelo Linear (Xu *et al.*, 2021). Para pequenos valores de ângulo de deriva e deslizamento longitudinal, tais modelos assumem que as forças lateral e longitudinal são aproximadamente proporcionais, respectivamente, ao ângulo de deriva (α) e ao deslizamento longitudinal (k), ponderados pelas rigidez lateral (C_α) e longitudinal (C_σ) (Rajamani, 2011; Jazar, 2025; Clover; Bernard, 1998). As equações abaixo definem matematicamente as forças modeladas linearmente (Jazar, 2025):

$$F_x = C_\sigma \times k \times F_z, \quad (2.11)$$

$$F_y = -C_\alpha \times \alpha, \quad (2.12)$$

em que C_σ é o coeficiente de rigidez longitudinal, C_α é o coeficiente de rigidez lateral, F_z é a força vertical, α é o ângulo de deriva, k é o deslizamento longitudinal.

As forças F_x e F_y especialmente se dão pela interação pneu-solo. Dado o movimento do veículo e o esterçamento da roda, isso impacta diretamente nessas forças. Em análise isolada, a força F_y é impactada diretamente pela variação do ângulo de deriva α , enquanto a força F_x pelo deslizamento longitudinal k . A Figura 2.10 mostra como modelos identificam a variação de F_y em detrimento de α , assim como F_x dado o valor de k . O gráfico é análogo para as duas forças

mencionadas anteriormente, mudando apenas o eixo de análise, tendo em vista que uma atua longitudinalmente e a outra lateralmente. É interessante perceber que para ângulos pequenos, existe uma crescente linear. Todavia, existe um ponto em que a força satura, chegando no seu máximo, e caindo posteriormente devido à derrapagem do pneu. A velocidade influencia diretamente essas forças, como pode ser visto no exemplo gráfico para a força lateral em 2.11. Quanto maior for a velocidade, mais propenso a derrapagem lateral o veículo está, logo, menor o ponto máximo da força. Para além, em uma análise mais real, é esperado a atuação combinada das forças lateral e longitudinal. Essa relação pode ser vista na Figura 2.12. A força F_z impacta nas outras duas forças, porém, ela não terá um comportamento análogo. A força F_z na verdade, se dá pela reação normal do solo ao peso estático do veículo, juntamente com as transferências de carga dinâmicas durante aceleração, frenagem e curva.




Figura 2.10 – Característica Dinâmica das Forças Longitudinal e Lateral

A medida que a roda do veículo é esterçada, além do aumento da força lateral (F_y) surge também o Momento de Alinhamento (M_z). O Momento de Alinhamento atua em torno do eixo vertical (Z) e é responsável por tentar girar a roda, fazendo-a permanecer na mesma direção da velocidade do pneu, anulando assim o ângulo de deriva α . Nesta situação, devido à distribuição de tensão (τ_y), a força F_y não atuará exatamente no centro geométrico da área de contato do pneu. Essa distância é chamada de *Pneumatic Trail* (a_{x_α}) e é ilustrada na Figura 2.13 onde é possível observar essa deformação. A Figura 2.14 demonstra como M_z e a_{x_α} se comportam em relação a F_y .

Considerando os três eixos ortogonais que definem as direções para referência da dinâmica veicular, é possível extrair informações sobre a rotação efetuada em cada um dos eixos,




Figura 2.11 – Influência da Velocidade na Força Lateral
(Rill; Castro, 2020)

denominados Guinada, Inclinação e Rolagem, conforme ilustrado na Figura 2.15. Rolagem representa a rotação em torno do eixo X, enquanto Guinada corresponde à rotação em torno do eixo Z e Inclinação representa a rotação em torno do eixo Y. No caso de se verificarem tais rotações, também é possível extrair informações das respectivas velocidades, acelerações e ângulos. Estas representam também grandezas físicas mensuráveis por sensores acoplados no chassi do veículo.

As grandezas físicas anteriormente mencionadas constituem apenas uma amostra das várias variáveis que podem ser obtidas. Outros exemplos passíveis de obtenção incluem o momento, a posição das rodas em relação ao respectivo eixo.

2.1.4 Pneus Inteligentes

A implementação de tecnologia e inteligência nos veículos é um tema de interesse crescente, que representa uma mudança sem precedentes na história. Os sistemas inteligentes têm uma presença cada vez mais notória, com o propósito de proporcionar uma vasta gama de benefícios. Estes benefícios abrangem desde o aumento da segurança e do conforto dos passageiros até a objetivos de caráter técnico, como o incremento da eficiência dos veículos (Barbosa *et al.*, 2021). No âmbito do estudo em questão, uma das vertentes de análise é dedicada aos deno-




Figura 2.12 – Forças Longitudinais e Laterais Combinadas
(Jazar, 2025)

minados “Pneus Inteligentes”. Esta tecnologia é utilizada com o objetivo de obter leituras dos sensores que sejam suficientes para representar a dinâmica veicular. As implementações em questão podem revelar-se úteis em qualquer nível de desenvolvimento de veículos autônomos, abrangendo desde o auxílio ao condutor até à plena autonomia do veículo.

As forças atuantes nas rodas do veículo constituem uma grandeza física de elevada importância para o estudo da dinâmica veicular. A leitura destas forças permite obter diversas informações, por exemplo, o tipo de rodovia ao qual o pneu está submetido. Para tal, é necessário acoplar ao pneu sensores feitos para capturar informação sobre as forças, como os acelerômetros. Neste sentido, a denominação “Pneu Inteligente” é atribuída ao dispositivo que incorpora sensores nos pneus convencionais, permitindo a extração de informações sobre as grandezas físicas que atuam diretamente nos pneus (Xu; Askari; Khajepour, 2022). Posteriormente, esta informação pode ser utilizada para diversos fins de aumento da inteligência computacional embarcada no veículo.

Além das forças atuantes no pneu, a tensão, a deformação, a aceleração, a pressão ou a temperatura constituem exemplos de estados que podem ser objeto de medição. Em virtude das diversas propriedades inerentes aos estados, é plausível a existência de diferentes tipologias de sensores nos pneus inteligentes. A título ilustrativo, pode-se mencionar alguns exemplos




Figura 2.13 – Pneumatic Trail
(Jazar, 2025)

de dispositivos que podem ser acoplados internamente em pneus inteligentes, nomeadamente acelerômetros, sensores ópticos, sensores de tensão, PVDF e sensores Hall. A Figura 2.16 ilustra como sensores podem ser acoplados na superfície interna dos pneus, obtendo assim o pneu inteligente. O dispositivo possibilita a estimativa de diversos fenômenos físicos, incluindo o potencial de atrito, as forças exercidas pelo pneu, bem como as características e a dinâmica da área de contato deste. Com base nessas estimativas, é viável agregar tecnologia para o controle dinâmico, segurança ou desempenho do veículo (Xiong; Yang, 2018).

2.1.4.1 Pneus Inteligentes na Indústria

Na indústria, já é possível encontrar algumas empresas que possuem seus pneus inteligentes em produção. A Pirelli possui em seu catálogo de produtos o pneu denominado *Cyber Tyre*. Conforme as informações da própria fabricante, esse pneu é voltado para a linha premium, especificamente para o veículo Pagani Utopia Roadster (Pirelli, 2025). Nele, o *Cyber Tyre* é capaz de inferir sobre a pressão, temperatura, e desgaste da banda de rodagem do pneu, transmitindo essas informações para a unidade de controle do veículo. Além disso, o *Cyber Tyre* também é capaz de estabelecer comunicações V2V (*Vehicle-to-Vehicle*) e V2I (*Vehicle-to-Infrastructure*) (Pirelli, 2024).




Figura 2.14 – Relação da Força Lateral, Momento de Alinhamento e *Pneumatic Trail*

Outra empresa que também destinou esforços para o desenvolvimento de pneus inteligentes foi a Continental. Neste contexto, dois de seus produtos que ela apresenta são os chamados *ContiSense* e *ContiAdapt*. Assim como o *Cyber Tyre*, o *ContiSense* permite obter informações sobre o desgaste e temperatura da banda de rodagem do pneu, além de permitir a detecção de possíveis furos. Já o *ContiAdapt* possui microcompressores que permitem que a área de contato do pneu seja adaptável, possibilitando configurar até quatro condições de pista diferentes. Com isso, o *ContiAdapt* permite uma dirigibilidade mais adequada em cenários como piso molhado, irregular, escorregadio ou em condições normais (Continental, 2025).




Figura 2.15 – Rotação dos Eixos
(Jazar, 2025) Adaptada

A Michelin também desenvolveu sua solução, chamada *Michelin Track Connect*. Essa solução trazia quatro sensores que poderiam ser acoplados internamente nos modelos de pneus *MICHELIN Pilot Sport Cup 2 Connect* ou *MICHELIN Pilot Sport Cup*. Posteriormente, as informações dos pneus eram transmitidas para um smartphone com o respectivo aplicativo necessário (Michelin, 2025a). Embora a Michelin tenha descontinuado esse produto em 2023, ela ainda atua com gêmeos digitais em Pneus Inteligentes, entre outros produtos (Michelin, 2025b).



Figura 2.16 – Pneu Inteligente
(Continental, 2025)

2.2 Aprendizado de Máquinas

Nas últimas décadas, o avanço tecnológico computacional tem possibilitado também a expansão de estudos e aplicações de Aprendizado de Máquina como nunca houve antes. Aprendizagem de Máquinas é entendida como a ciência de programar computadores, no intuito da criação de algoritmos capazes de realizar a extração de informações contidas em conjuntos de dados (Géron, 2022). Consequentemente, esta pode ser aplicada para os mais diversos fins. No âmbito da programação tradicional, o utilizador é o elemento que define as diretrizes de funcionamento que o computador deve seguir para alcançar os resultados pretendidos. Atualmente, no domínio do Aprendizado de Máquinas, é a máquina que assume a responsabilidade de determinar as regras, com base nas entradas e/ou saídas desejadas (Moroney, 2020). Os algoritmos que apresentam uma dependência de ambos os valores de entrada e as respectivas saídas, de modo a estabelecer as regras, contemplam os Algoritmos Supervisionados (Géron, 2022). Em contrapartida, caso apenas se necessite de informações de entrada e o modelo responsável poderá compreender as possíveis saídas, classifica-se como Algoritmo Não Supervisionado (Géron, 2022). Além disso, há tarefas que se revelam praticamente impossíveis ou altamente complexas de se criarem regras claras e objetivas com a programação tradicional, o que, por sua vez, é uma tarefa totalmente possível com o Aprendizado de Máquinas.

A detecção de objetos, o processamento de linguagem natural, a geração de dados, a classificação, a regressão e a modelagem de sistemas constituem exemplos de tarefas que podem ser executadas com recurso ao Aprendizado de Máquinas (Bishop; Nasrabadi, 2006). As suas aplicações mais relevantes são observadas em diversas áreas, tais como a medicina, a engenharia e a informática, entre outras (Jordan; Mitchell, 2015). É importante salientar que, de modo geral e independentemente da finalidade, a aplicação de um algoritmo de Aprendizagem de Máquina conduz soluções que apresentam reduzido nível de interpretabilidade, uma vez que a relação entre entradas e saídas não é explicitamente descrita. Em suma, considerando as entradas que a solução recebe, não é evidente como estas são relacionadas e manipuladas para se alcançar o resultado.

No domínio da identificação de sistemas, a Aprendizagem de Máquinas emerge como uma ferramenta de grande potencial, sendo que o LSTM e o MLP constituem algoritmos representativos amplamente empregados (Norgaard *et al.*, 2000). Tais abordagens enquadram-se na categoria de modelos do tipo Caixa Preta, uma vez que não incorporam conhecimento fí-

sico prévio do sistema, como acontece nos tipos Caixa Branca e parcialmente nos modelos do tipo Caixa Cinza. Entretanto, a classificação como caixa-preta não implica, necessariamente, baixa interpretabilidade. Dependendo da forma funcional adotada, é possível obter modelos baseados em dados que, embora classificados como caixa-preta, apresentam estrutura explícita e interpretável, como ocorre nos modelos polinomiais utilizados neste trabalho.

2.2.1 *Multi-Layer Perceptron*

O desenvolvimento do campo do computacional permitiu o reinício das investigações sobre aprendizagem de máquinas, tendo a descoberta do MLP igualmente resultado na retomada do estudo sobre a funcionalidade do Perceptron, agora de forma conjunta (Schmidhuber, 2015). O MLP recorre à técnica de aprendizagem profunda, mais concretamente à *back-propagation*, na qual o erro é propagado de forma proporcional entre os pesos dos Perceptrons da rede que constitui o MLP (Bishop; Nasrabadi, 2006). Esta técnica permite a correção conjunta dos pesos, com o objetivo de minimizar o erro das predições do modelo. O MLP clássico possui três camadas: a de entrada, a camada escondida e a camada de saída, conforme ilustrado pela Figura 2.17. A característica de *feedforward* é uma propriedade intrínseca à estrutura do MLP (Bengio *et al.*, 2017). Por se tratar de uma rede de *feedforward*, cada camada está ligada à sua sucessora, mas não existe uma ligação inversa, ou seja, não existe um caminho de regresso. Em contrapartida, a obtenção de retorno de informações é uma característica presente nas Redes Neurais Recorrentes (RNNs) tradicionais, bem como das redes avançadas LSTM e GRU (Nosouhian; Khoshouei, 2021).




Figura 2.17 – Arquitetura MLP

2.2.2 Long Short-Term Memory

LSTM (*Long Short-Term Memory*) representa um avanço nos estudos centrados nas RNN (*Recurrent Neural Network*) no domínio da Aprendizagem de Máquinas (Oruh; Viriri; Adegun, 2022). No geral, as RNNs apresentam células de memória como parte integrante da sua arquitetura. Estas células são responsáveis pelo aspecto funcional que caracteriza essas redes, tendo em vista que a predição atual leva em consideração premissas passadas. No caso das células de memória, estas premissas correspondem, na verdade, aos pesos utilizados na predição anterior. No caso da predição em séries temporais, a predição de um valor futuro da série temporal é efetuada com base em estados anteriores da mesma série, conhecida pela rede. A referida competência, inerente à LSTM, revela-se de elevada utilidade em contextos de aplicações onde existe uma dinâmica intrínseca associada aos dados, como na estimação da velocidade lateral, na estimação de forças, entre outras (Kong *et al.*, 2021).

Conforme ilustrado pela Figura 2.18, a arquitetura da LSTM é composta por três portas principais, sendo elas a porta de entrada, de saída e de esquecimento. Além disso, é presente em sua arquitetura dois estados da célula. A porta de entrada é responsável por determinar a quantidade de informação da nova entrada que será atualizada no estado da célula. A porta de saída, por sua vez, é responsável por ditar quais partes do estado da célula será lida e passada para frente. A terceira porta, porta de esquecimento, decide o quanto de informação do estado da célula anterior deverá ser descartada. Os estados da célula mencionados anteriormente é a parte crucial para o funcionamento da rede, pois ela é quem se responsabiliza pela memória de curto e longo prazo da rede, transportando as informações relevantes e fazendo as devidas previsões dos próximos passos de tempo. Todos esses processos internos à arquitetura da LSTM envolvem operações de soma, multiplicação, e aplicação de funções como sigmoide (σ) e tangente hiperbólica ($\tanh$).

2.2.3 Gated Recurrent Unit

Assim como as LSTMs, as GRU (*Gated Recurrent Unit*) são melhorias nas Redes Neurais Recorrentes (Dey; Salem, 2017). Sua arquitetura é mais simples se comparada a LSTM, entretanto, ela também é capaz de capturar dinâmicas existentes nos dados devido a sua capacidade de memória de longo prazo. Na GRU, as portas de esquecimento e de entrada são unidas,




Figura 2.18 – Arquitetura LSTM

formando uma única porta de atualização. Além disso, ao invés de possuir dois estados como a LSTM, a GRU passa a possuir apenas um estado da célula conforme visto na Figura 2.19. O GRU também difere da LSTM apresentando apenas a Porta de Esquecimento e a Porta de Atualização. Enquanto a LSTM possui dois estados da célula, separando então as responsabilidades de memória curta e longa, a GRU, por possuir apenas uma, atribui essas duas responsabilidades ao mesmo estado da célula. A porta de esquecimento na GRU é análoga ao LSTM, sendo assim responsável por controlar o quanto de informação deve ser esquecido do estado anterior. A função designada para a porta de atualização presente na GRU é decidir quanta informação do estado anterior deve ser preservada em relação às novas informações candidatas vistas. Operações de soma, multiplicação e aplicações de funções como sigmoide (σ) e tangente hiperbólica ($\tanh$) também são vistas na arquitetura da GRU.

Dentre as várias aplicabilidades existentes dos algoritmos de aprendizado de máquinas, a identificação de sistemas é uma delas, a qual será abordada na próxima seção.

2.2.4 Identificação de Sistemas

A identificação de sistemas dinâmicos pode constituir uma tarefa complexa, devido às características inerentes aos processos, que frequentemente apresentam uma elevada complexidade e diversos comportamentos não lineares (Aguirre, 2015). Outras limitações podem existir, tais como a ausência de informações sobre o sistema a ser modelado, o acesso restrito ou a




Figura 2.19 – Arquitetura GRU

difficuldade na medição de variáveis relevantes (Le-Yi; Wen-Xiao, 2013). Dessa forma, a identificação e a modelagem de sistemas assumem um papel preponderante e apresentam diversas utilidades. A implementação de melhorias ou a adaptação de outros sistemas a sistemas reais é inviável sem a realização de simulações prévias. A impossibilidade pode estar associada a riscos de vida, a grandes perdas financeiras em caso de insucesso, entre muitos outros aspectos. Desta forma, uma identificação consistente que represente de fato o sistema real possibilita diversas análises sem os riscos anteriormente mencionados. Com o modelo do sistema disponível para simulação, é possível compreender o seu comportamento, analisando-o em cenários hipotéticos e identificando seus padrões de comportamento. Esta abordagem permite a aplicação de técnicas de controle e a avaliação da sua eficácia na prevenção de situações indesejáveis (Keesman, 2011).

Em circunstâncias particulares, é viável conceber um sistema tão próximo do sistema real que resulta na criação dos denominados *Soft Sensors* (Curreri; Patane; Xibilia, 2021; Fujiwara; Kano; Hasebe, 2012). Os *Soft Sensors* apresentam a capacidade de substituir sensores físicos reais em uma instalação, dado a inferência indireta da grandeza física desejada (Souza; Araújo; Mendes, 2016). Em tal circunstância, ao invés de ocorrer a transmissão de um sinal elétrico por meio do sensor, o qual simboliza a medição de uma grandeza física, este é efetuado de forma virtual, por um algoritmo.

A criação de *Soft Sensors* pode ser dada objetivando diversos aspectos positivos. Existem grandezas físicas que exigem um custo elevado de instrumentação para ser possível medi-

las diretamente. Com a presença dos *Soft Sensors* e sua capacidade de inferência indireta, é possível ainda obter a medida desejada com uma aproximação considerável a leitura real, porém, com um custo reduzido. Quando há a possibilidade da leitura direta, o *Soft Sensors* ainda pode atuar como um sistema de redundância. Ainda visando o cenário onde é possível a leitura direta da variável, o *Soft Sensors* se aplica também como um detector de falhas do sensor físico. Em resumo, estes sensores virtuais podem ser úteis reduzindo custos, servindo como sistemas redundantes, como detectores de falhas, entre outras aplicações.

Para além, os sistemas podem ser classificados segundo a quantidade de entradas e saídas apresentadas. No âmbito da identificação e modelagem de sistemas, a quantidade de entradas e saídas de um modelo implica uma denominação (Ogata, 2010). A menor unidade concebida como um sistema é aquela que manipula apenas uma entrada, resultando numa única saída. Estes casos são entendidos como sistemas SISO (*Single Input Single Output*). No caso de se dispor de um sistema que apresente múltiplas entradas, que sejam manipuladas internamente para produzir uma saída, procede-se à sua classificação como MISO (*Multiple Input Single Output*). A terceira classificação é atribuída quando se verifica a existência de múltiplas entradas num sistema, que por sua vez, resultam em diversas saídas do mesmo. A classificação deste dispositivo é, portanto, do tipo MIMO (*Multiple Input Multiple Output*). As abordagens para a modelagem de tais sistemas também variam, podendo ser realizadas com informações já conhecidas sobre sua dinâmica, ou apenas com os dados de entrada e saída.

O nível de interpretabilidade de um modelo é uma consequência direta do método de modelagem adotado. Nesse contexto, existem três grupos de abordagens que diferem entre si quanto ao nível de interpretabilidade, conhecidos como Caixa Branca, Caixa Cinza e Caixa Preta (Aguirre, 2015; Khan; Khan, 2012), conforme apresentado na próxima seção.

2.3 Abordagens para Modelagem em Sistemas Dinâmicos

De acordo com Aguirre (2015), a modelagem de sistemas pode ser segmentada em três categorias: a modelagem Caixa Branca, a Caixa Cinza e a Caixa Preta. Embora todos os modelos apresentem a capacidade de se aproximarem do sistema real, verificam-se entre eles diferenças no que diz respeito ao nível de interpretabilidade que o modelo exibirá. A interpretabilidade, neste contexto, é entendida como o grau de detalhe que o modelo apresenta na demonstração

do processo por meio do qual a saída é obtida, tendo em consideração as relações e operações estabelecidas entre os valores de entrada do sistema.

A designação “Modelagem Caixa Branca” é atribuída às metodologias que descrevem o sistema por meio de relações matemáticas do processo (Close; Frederick; Newell, 2001). Em outras palavras, a referida modelagem é determinada pelas características físicas do processo. Aplicação de Força (conforme a 2ª Lei de Newton), transferência de calor (Lei de Fourier), e a Lei de Ohm são exemplos de propriedades físicas que possuem suas equações definidas e que descrevem seus devidos comportamentos.

Os sistemas modelados por meio da técnica de identificação Caixa Cinza são estruturados em equações de princípios físicos, juntamente com testes empíricos realizados (Khan; Khan, 2012). Estes testes estão sujeitos a variáveis exógenas ao sistema que é uma característica inerente ao processo. Estas variáveis estarão igualmente contidas nos modelos. Estas variáveis exógenas são compreendidas como fatores externos que não são passíveis de serem controlados pelo próprio sistema.

No caso de a modelagem decorrer a partir exclusivamente dos dados de entrada e da respectiva resposta na saída do sistema, a referida modelação é designada por "modelagem caixa preta". No âmbito da Modelagem Caixa Preta, o processo de identificação de sistemas pode ser segmentado em 5 etapas, conforme ilustrado na Figura 2.20 (Aguirre, 2015; Ljung *et al.*, 2020). Atualmente, a modelagem e representação digital de sistemas é predominante, tendo em vista o uso posterior do modelo para simulações, controle, entre outros usos. Por conseguinte, a primeira etapa consiste em adquirir dados suficientes para representar o sistema real. Esta etapa é realizada por meio da execução de testes dinâmicos que representem o funcionamento esperado do sistema real em condições operacionais específicas. Na segunda etapa, procede-se à seleção da representação matemática para a modelagem do sistema. A modelagem em questão pode ser ilustrada pelas representações polinomiais, ou até mesmo por modelos de Aprendizado de Máquinas. Após a seleção do modelo, procede-se à definição da estrutura deste. Para tal, é necessário estabelecer um critério de seleção. Este critério visará selecionar o modelo que melhor se aproxima ao real, tendo assim o menor erro em suas predições. Na quarta etapa, procede-se à estimativa dos parâmetros do modelo e, subsequentemente, à sua validação. Em circunstâncias em que a representação do modelo apresente uma relação linear entre si, a estimativa dos parâmetros pode igualmente ser efetuada recorrendo a métodos lineares, tais como o método dos mínimos quadrados e as suas variantes correspondentes. A validação pode

ser efetuada recorrendo a métricas de avaliação, tais como o RMSE (*Root Mean Square Error*), MAPE (*Mean Absolute Percentage Error*), entre outras. Essas etapas de seleção de modelos, estimação de parâmetros, validação de modelos e as métricas de avaliação são descritas com mais detalhes nas próximas seções.




Figura 2.20 – Passos Para Modelagem de Sistemas

2.3.1 Seleção de Modelos

Os sistemas podem apresentar comportamentos lineares ou não lineares. Com o objetivo de obter modelagens baseadas em polinômios que correlacionam as entradas e saídas do sistema, é necessário dispor de métodos de equacionamento que se demonstrem mais adequados ao problema em questão. Nesse sentido, os modelos polinomiais são ferramentas versáteis e amplamente utilizadas, pois conseguem aproximar uma variedade de relações funcionais, incluindo comportamentos não lineares, por meio da ajustagem de coeficientes que minimizam o erro entre os dados observados e a resposta do modelo. Além disso, proporcionam um equilíbrio entre a complexidade e a interpretabilidade. A realização da tarefa pode ser efetuada recorrendo a algumas abordagens, tais como a ARX (*AutoRegressive with eXogenous inputs*), FIR (*Finite Impulse Response*), NARX e NARMAX (*Nonlinear AutoRegressive Moving Average with eXogenous inputs*).

Vale ressaltar que, embora modelos polinomiais possam ser obtidos a partir dos métodos descritos anteriormente, essas estruturas não se restringem exclusivamente a esse tipo de aplicação. Ao empregar algoritmos de aprendizado de máquina, como redes MLP, LSTM e GRU, é possível fornecer ao modelo entradas atrasadas no tempo durante o processo de treinamento. Nesse sentido, a utilização de entradas defasadas, associadas aos respectivos pesos e operações internas características da arquitetura da rede, resulta em uma estrutura dinâmica análoga à de um modelo do tipo FIR, uma vez que a saída passa a depender exclusivamente de valores passados das entradas. De forma análoga, quando o conjunto de dados utilizado no treinamento inclui também saídas atrasadas, caracteriza-se uma estrutura do tipo NARX. Nesses casos, obtêm-se modelos FIR e NARX cuja forma funcional não é polinomial, sendo tais modelos geralmente classificados como modelos de natureza caixa-preta, com menor interpretabilidade em relação aos modelos polinomiais explícitos.

2.3.1.1 *AutoRegressive with eXogenous inputs*

Os modelos ARX (*AutoRegressive with eXogenous inputs*) são aplicados em sistemas que exibem apenas comportamento linear. A sua expressão matemática é descrita por:

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{1}{A(q)}v(k), \quad (2.13)$$

em que $y(k)$ e $u(k)$ representam, respectivamente, a saída e a entrada do modelo no instante k . $v(k)$ representa um ruído branco, que está intrínseco ao modelo. O operador de atraso do sistema discreto é representado por q^{-1} , de modo que a representação $q^{-2}y(k)$ significa dois atrasos da saída, ou seja, $y(k-2)$. O polinômio autorregressivo $A(q)$ e as entradas exógenas $B(q)$ são descritas pelas equações:

$$A(q) = 1 + a_1q^{-1} + \dots + a_{ny}q^{-ny}, \quad (2.14)$$

$$B(q) = b_0 + b_1q^{-1} + \dots + b_{nu}q^{-nu}, \quad (2.15)$$

sendo a_1 e a_{ny} os coeficientes na primeira e na n -ésima posição, os quais atuam ponderando a saída, consequentemente, definindo sua influência no valor atual dela mesma. Analogamente, b_0 e b_{nu} são os termos que ponderam a primeira e a n -ésima entrada e como elas influenciam a saída. ny representa o número de atrasos considerados na saída, enquanto nu é o número de atrasos na entrada. Para além, a expressão “entradas exógenas” refere-se a termos externos ao sistema. Essas variáveis exercem influência sobre o sistema, contudo, o sistema não manifesta qualquer efeito sobre elas.

2.3.1.2 *Finite Impulse Response*

A modelagem FIR é uma estrutura não recursiva, ou seja, depende apenas das entradas $u(k)$, além da presença do ruído branco $v(k)$. A Equação 2.16 demonstra sua expressão matemática linear.

$$y(k) = B(q)u(k) + v(k) \quad (2.16)$$

No caso não linear, modelos FIR podem ser definidos matematicamente por:

$$y(k) = f^{(\cdot)}[u(k - \tau_d), \dots, u(k - n_u)], \quad (2.17)$$

em que $f^{(\cdot)}$ é uma função não linear genérica, τ_d representa o tempo morto do sistema e n_u é o máximo atraso para a entrada u .

2.3.1.3 *Nonlinear AutoRegressive with eXogenous inputs*

No caso de se tratar da modelagem de um sistema com comportamento não linear, uma opção é a utilização da estrutura *Nonlinear AutoRegressive with eXogenous inputs* (NARX). Por meio das entradas e saídas atrasadas no tempo, a estrutura NARX constrói o modelo do sistema, implementando uma função não linear $f^{(\cdot)}$. A implementação desta função pode ser realizada por meio de duas abordagens principais: a utilização de polinômios ou com modelos mais complexos como as Redes Neurais Artificiais (RNAs). No âmbito da abordagem polinomial,

o símbolo f_l pode representar uma categoria de expansões polinomiais, incluindo séries de Volterra e polinômios ortogonais, entre outros exemplos. Esta abordagem resulta numa estrutura polinomial que demonstra as devidas correlações, que por sua vez, resulta na saída modelada do sistema. O benefício duplo desta abordagem advém da interpretabilidade do sistema modelado, decorrente da equação resultante, bem como do reduzido custo computacional associado à sua execução. Computacionalmente, o polinômio pode ser resolvido por meio de uma simples multiplicação de matrizes. O modelo NARX pode ser representado matematicamente por:

$$y(k) = f^{(\cdot)}[y(k-1), \dots, y(k-n_y), u(k-\tau_d), \dots, u(k-n_u)], \quad (2.18)$$

sendo que τ_d representa o tempo morto do sistema (caso o sistema não tenha tempo morto $\tau_d = 1$), n_y é o maior atraso para y e n_u é o maior atraso para u . $f^{(\cdot)}$ representa uma função não linear genérica, de maneira que a mesma pode ser substituída por polinômios, RNAs, entre outros.

2.3.1.4 *Nonlinear AutoRegressive Moving Average with eXogenous inputs*

O modelo NARMAX (*Nonlinear AutoRegressive Moving Average with eXogenous inputs*) representa uma extensão do modelo NARX, ao ponto em que incorpora entradas que representam o ruído ou perturbações não medidas presentes no sistema. Em termos matemáticos, o modelo NARMAX é representado por:

$$y(k) = f^{(\cdot)}[y(k-1), \dots, y(k-n_y), u(k-\tau_d), \dots, u(k-n_u), e(k-1), \dots, e(k-n_e)] + e(k), \quad (2.19)$$

onde os termos $e(k-1)$ até $e(k-n_e)$ correspondem aos erros passados do sistema, enquanto $e(k)$ representa o erro de modelagem que capta os efeitos que a função não linear $f^{(\cdot)}$ não representa de forma adequada.

Os coeficientes que multiplicam os termos com atraso podem ser estimados por meio de métodos como o Método dos Mínimos Quadrados Ordinários e suas variantes, conforme será discutido na seção a seguir.

2.3.2 Estimação de Parâmetros

Comumente são encontrados duas grandezas físicas ou atributos de processos que se relacionam entre si. Quando existe uma proporcionalidade linear nessa relação, é possível aplicar métodos que nos permitem obter a equação que descreve essa relação, conforme ilustrado pela equação 2.20:

$$y = X\hat{\theta} + \xi, \quad (2.20)$$

onde X é a matriz de valores observáveis das variáveis independentes (também chamado de regressores), y representa a variável dependente, ξ indica o vetor de resíduos, e por último, θ é o vetor de parâmetros do modelo que ponderam as variáveis independentes, e é ele o qual deve ser determinado. Sendo assim, a identificação de relações lineares a partir de dados pode ser efetuada por meio de diversos métodos, tais como os métodos dos Mínimos Quadrados Ordinários e suas variantes.

2.3.2.1 Mínimos Quadrados

O estimador denominado MQ (Mínimos Quadrados) (Cai; Chen; Yang, 2024) visa minimizar o erro, representado pela função custo:

$$J_{MQ} = \sum_{i=1}^n (y_i - x_i^T \theta_i)^2 = \sum_{i=1}^n \xi_i^2, \quad (2.21)$$

em que J_{MQ} é a função custo do método dos Mínimos Quadrados, y_i representa a i -ésima observação da variável dependente, x_i é o vetor de valores observados das variáveis independentes, θ é o vetor de parâmetros a ser estimado, $\hat{y}_i = x_i^T \theta$ é o valor estimado da saída e ξ_i corresponde ao resíduo associado à i -ésima observação, dentre as n observações disponíveis. Em síntese, o objetivo do método é determinar o vetor de parâmetros que minimiza a soma dos erros quadráticos. A equação de MQ pode ser formalizada por meio da operação de matrizes, conforme ilustrado pela equação 2.22:

$$\hat{\theta}_{MQ} = (X^T X)^{-1} X^T y, \quad (2.22)$$

onde X representa a matriz do modelo com os dados das variáveis independentes. O valor de y corresponde à resposta do sistema, ou seja, as saídas atingidas dado o conjunto das amostras. A relação entre as variáveis independentes e a variável dependente é modelada pelos coeficientes $\hat{\theta}_{MQ}$, que representam os pesos atribuídos a cada regressor.

2.3.2.2 Mínimos Quadrados Ponderados

Existem contextos nos quais já se dispõe de um conhecimento prévio das relações entre as amostras. Isso permite determinar se algumas amostras apresentam uma maior importância relativamente a outras. Com isso, pode ser desejável atribuir pesos para diferentes valores de erro. Desse modo, no método dos MQP (Mínimos Quadrados Ponderados) a Equação 2.21 é adaptada para:

$$J_{MQP} = \sum_{i=1}^n w_i (y_i - x_i^T \theta_i)^2 = \sum_{i=1}^n w_i \xi_i^2, \quad (2.23)$$

sendo w_i o peso do i -ésimo resíduo ξ_i , para cada uma das n observações.

Desta forma, é possível proceder à ponderação da importância das amostras, recorrendo ao método MQP (He; Rojas; Hjalmarsson, 2024), o qual estima os parâmetros por meio da Equação 2.24:

$$\hat{\theta}_{MQP} = (X^T W X)^{-1} X^T W y, \quad (2.24)$$

onde se encontra a presença da matriz $W \in R^{n \times n}$, a qual é uma matriz diagonal com os respectivos pesos de cada uma das n amostras. $\hat{\theta}_{MQP}$, são os termos que realizam a ponderação dos regressores na estimação via MQP.

2.3.3 Validação de Modelos

A medida que se obtém a modelagem de sistemas, é preciso avaliar o quanto o modelo consegue se aproximar do sistema real em cenários distintos do usado na construção do modelo. Em outras palavras, necessita-se validar o nível de generalização do nosso modelo. Para isso é possível avaliar o modelo em pelo menos três cenários de simulação diferentes, sendo eles denominados de OSA (*One Step Ahead*), MS (*Multiple Shooting*) e FR (*Free Run*).

No primeiro tipo de simulação, corresponde a técnica OSA, ao avaliar o modelo nessa condição, a predição será apenas da próxima amostra do comportamento dinâmico modelado. Para a realização desta predição, todos os dados utilizados são dados reais. Deste modo, é esperado que o erro seja baixo, uma vez que cada predição depende exclusivamente dos dados reais, sem a influência do acúmulo de erro resultante da utilização dos próprios dados preditos para próximas predições, conforme observado nos métodos MS (*Multiple Shooting*) e FR (*Free Run*). Outro ponto a se considerar é que, como visto na seção anterior, os algoritmos de estimação de parâmetros objetivam minimizar o quadrado dos resíduos. Sendo assim, até mesmo modelos ruins podem obter um erro um passo a frente pequenos, e por isso, a simulação um passo à frente não é um bom indicador de robustez do modelo.

A técnica MS é aplicada procedendo à predição de N passos à frente do modelo. Em função dos atrasos existentes nos regressores constituintes do modelo, é plausível que, em determinado momento das N predições subsequentes, este passe a empregar valores que foram preditos nos passos anteriores (Ribeiro; Aguirre, 2017). Em caso de ocorrência do exposto, verificará um acréscimo do erro de previsão, o qual o algoritmo de modelagem buscará minimizar.

A terceira técnica referida, denominada FR, é implementada por meio da simulação de toda a janela temporal que se encontra no banco de dados e em que se avalia o modelo. Desta forma, após a obtenção das condições iniciais para a primeira predição do modelo, este simulará as restantes predições, recorrendo aos dados anteriormente preditos a depender dos atrasos presentes nos regressores que constituem o modelo. Embora esta técnica seja a mais suscetível a erros, é a mais adequada no caso de *Soft Sensors*, uma vez que o objetivo é construir um sensor virtual que não dependa de dados reais da saída. Estes dados, em alguns casos, podem não estar disponíveis ou depender de sensores altamente custosos para a sua implementação, inviabilizando a sua utilização.

Com o intuito de obter a modelagem robusta de um sistema, as técnicas de MS e FR são superiores à OSA, precisamente devido às suas características de predição (Aguirre, 2015). No caso de ocorrência de um acúmulo de erros durante o processo de formação, utilizando estas técnicas, o algoritmo buscará pelo modelo que apresente o melhor desempenho, mesmo que para as predições futuras sejam utilizados dados preditos anteriormente. A robustez do modelo implica um custo de aplicação mais elevado para estas duas técnicas, que apresentam um custo computacional mais elevado em comparação com o OSA. O método de FR, que simula todos os

dados após as condições iniciais, é o que depende de mais recurso computacional, mas também o que retorna o melhor modelo para aplicações que não dependem dos dados reais passados.

2.3.4 Métricas de Avaliação

Em todos os tipos de validação do modelo durante o processo de identificação, conforme apresentados na seção anterior, o objetivo é que o comportamento do modelo se aproxime o mais possível do real, minimizando o erro de predição. Desta forma, o objetivo é que os estados futuros preditos se aproximem dos estados reais. Com isso, é comum utilizar métricas que quantificam as predições dos modelos. Uma métrica amplamente difundida que permite avaliar a discrepância entre os valores preditos e os valores reais é o MSE (*Mean Square Error*). O cálculo realizado pelo MSE é apresentado por:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.25)$$

onde n é o número de amostras avaliadas, y_i é o valor real do sistema e $\hat{y}_i$ é o valor predito pelo modelo do sistema.

A métrica de avaliação MSE, que eleva a diferença ao quadrado, penaliza os erros de magnitude elevada. A readequação dos valores, por meio do ajuste da escala, juntamente com a normalização para que a magnitude dos valores não impacte no valor da métrica, pode ser efetuada mediante a extração da raiz e normalização do MSE, resultando na métrica NRMSE (*Normalized Root Mean Square Error*). A Equação 2.26 demonstra matematicamente a definição do NRMSE:

$$\text{NRMSE} = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{y_{\max} - y_{\min}} \quad (2.26)$$

onde n é o número de amostras avaliadas, y_i é o valor real do sistema e $\hat{y}_i$ é o valor predito pelo modelo do sistema, $y_{\max}$ é o maior valor real e $y_{\min}$ é o menor valor real.

Comumente também é visto a métrica R^2 (Coeficiente de Determinação), conforme descrito matematicamente pela Equação 2.27:

$$R^2 = \left[1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \right], \quad (2.27)$$

onde N é o número de amostras avaliadas, y_i é o valor real do sistema, $\hat{y}_i$ é o valor predito pelo modelo para a i -ésima amostra e $\bar{y}$ é o valor médio real. Esta métrica traz a perspectiva do quão bem o modelo está se ajustando aos dados. Dessa forma, análoga à métrica de Pearson, um modelo que acompanha bem a magnitude e direção dos valores reais tendem a se aproximar de 1.

Por fim, outra possibilidade de utilização é a métrica MAPE (*Mean Absolute Percentage Error*), a qual indica a precisão do modelo em suas previsões, medindo a magnitude média do erro do modelo. Dessa forma, quanto menor o valor do MAPE, melhor nosso modelo é. O MAPE pode ser calculado por:

$$MAPE = \frac{100 \sum_{i=1}^N |y_i - \hat{y}_i|}{N |y_{max} - y_{min}|}, \quad (2.28)$$

onde N é o número de amostras avaliadas, y_i é o valor real do sistema, $\hat{y}_i$ é o valor predito pelo modelo para a i -ésima amostra, y_{max} é o maior valor real observado no conjunto e y_{min} é o menor valor real observado no conjunto.

2.4 Computação Evolucionária

Ao longo da história da humanidade, foi possível observar, em diversas áreas do conhecimento, o desenvolvimento tecnológico baseado em fenômenos naturais ou biológicos. A carácter exemplar, a aeronáutica moderna é responsável pelo desenvolvimento de aeronaves cuja aerodinâmica foi cuidadosamente otimizada, tendo como inspiração os padrões naturais de aves e insetos (Harvey *et al.*, 2023). Este campo de estudo também deu origem à pesquisa em redes neurais artificiais, que se dedica à criação de estruturas artificiais inspiradas nas conexões neurais. Outro domínio que desenvolve algoritmos para a resolução de problemas complexos com base na natureza é designado por CE (Computação Evolucionária).

Nesse âmbito, muitas abordagens têm como base o trabalho de Charles Darwin (1809-1882). Ele foi um biólogo britânico que, entre diversas pesquisas realizadas, se dedicou ao estudo do fenômeno da seleção natural no mundo animal. Em suma, esta teoria postula que a evolução das espécies decorre da sobrevivência do indivíduo mais apto, por meio de adaptações que ocorrem por meio do cruzamento que ocasiona a troca de genes e da mutação repentina,

numa nova geração de seres. Este conhecimento constitui a base para o desenvolvimento dos Algoritmos Evolucionários (Wirsansky, 2020).




Figura 2.21 – Subdivisões da Computação Evolucionária
(Lanham, 2023) Adaptada

Conforme demonstrado na Figura 2.21, a área da CE apresenta diversas subdivisões como Simulação Genética, PG (Programação Genética), Algoritmos Genéticos, entre outros (Li *et al.*, 2021; Lanham, 2023). Os Algoritmos Evolucionários constituem um ramo que se baseia na evolução natural das espécies, conforme descrito na biologia (Yan *et al.*, 2024). Neste sentido, os algoritmos são sustentados principalmente por conceitos como genes, cromossomos, cruzamento e mutação. Cada algoritmo apresentará as suas especificidades, contudo, todos terão o mesmo propósito: identificar uma solução ótima para o problema apresentado, com base nos dados de entrada. Para tal, primeiro é gerada uma população de indivíduos aleatória, a qual é necessário proceder à respectiva avaliação. O indivíduo é caracterizado pelos seus cromossomos, que determinam as suas características e, por conseguinte, o seu nível de aptidão em determinado contexto. O cromossomo, por sua vez, é composto pelos genes, que constituem a unidade fundamental da hereditariedade. O cruzamento corresponde à troca de genes entre indivíduos pais, resultando na geração de um novo cromossomo que será hereditário na nova geração. Este continua sujeito a mutação, que consiste numa troca repentina de um gene do seu cromossomo, o que pode resultar em ganho ou perda de aptidão. Essa sequência de etapas que acontece durante gerações, ou até que o critério de parada seja satisfeito, é demonstrada graficamente pela Figura 2.22.




Figura 2.22 – Fluxograma dos Algoritmos Evolucionários

A seleção dos indivíduos que irão compor a próxima geração requer a aplicação de métodos que considerem a aptidão (comumente denominada de *fitness*) de cada um, tendo em conta o cenário a ser otimizado. Entre os métodos frequentemente empregados, destacam-se os métodos de Torneio e Roleta (Lanham, 2023). No método de seleção por Torneio, uma quantidade N (2 ou 3, habitualmente) de indivíduos da população são selecionados. Após a seleção dos indivíduos, o vencedor será aquele que apresentar a maior aptidão. A aplicação do método da Roleta implica a ponderação direta da probabilidade de seleção do indivíduo pela sua aptidão. Por conseguinte, os indivíduos com um maior nível de aptidão física apresentam uma probabilidade superior de serem selecionados para a função de progenitores das gerações subsequentes.

2.4.1 Fundamentos de Otimização

Um problema de otimização geral pode ser formalizado matematicamente por:

$$\begin{aligned}
&\text{minimizar} && f_0(x) \\
&\text{sujeito a} && f_i(x) \leq 0, \quad i = 1, \dots, m \\
&&& h_j(x) = 0, \quad j = 1, \dots, p,
\end{aligned} \tag{2.29}$$

onde $x \in \mathbb{R}^n$ é a variável de otimização. $f_0 : \mathbb{R}^n \rightarrow \mathbb{R}$, por sua vez, define a função objetivo, também chamada de função custo. Já as inequações $f_i : \mathbb{R}^n \rightarrow \mathbb{R}$, $i = 1, \dots, m$ e as equações $h_j : \mathbb{R}^n \rightarrow \mathbb{R}$, $j = 1, \dots, p$ definem as restrições da função custo a ser otimizada.

O conhecimento clássico sobre a utilização de algoritmos evolucionários centra-se na otimização das denominadas funções custo. De modo geral, as funções custo são expressões que determinam a relação entre grandezas diretamente relacionadas com o problema em questão. A otimização desta função implica a procura de um valor ótimo que se aproxime do mínimo ou do máximo global. Esta aproximação depende da natureza do problema em questão. No caso de o objetivo principal consistir na otimização dos lucros de uma carteira de investimentos, a prioridade máxima será alcançar esse resultado. No caso de a questão ser a proliferação de bactérias num ambiente, é provável que se deseje que esta seja a mais baixa possível. Adicionalmente, os Algoritmos Evolucionários podem ser utilizados para encontrar os mínimos e os máximos, bem como para selecionar ou reduzir a quantidade de características utilizadas como entrada de modelos de Aprendizado de Máquinas. Esta metodologia é aplicada quando se pretende identificar as características mais relevantes de um problema, ou até mesmo minimizar o custo computacional ao operar com um número reduzido de dados. Independentemente de se tratar da identificação de valores ótimos ou da otimização da quantidade de características de um problema, é necessário representar o cenário em questão, de modo a permitir a realização da otimização. No âmbito da seleção de características, é comum a representação dos indivíduos da população como uma sequência binária, na qual o valor 1 representa a presença da respectiva característica no modelo e o valor 0 a respectiva ausência.

Para realizar a otimização, o problema também estará sujeito a restrições. Estas restrições, conforme o próprio nome indica, podem ser interpretadas como diretrizes de funcionamento que se deseja ou que estão presentes na nossa função custo, com vista à sua otimização. As restrições podem ser exemplificadas pelo tipo de variável com que é trabalhado (se esta for binária ou real, por exemplo), pelas relações internas entre variáveis específicas ou pelo intervalo de valores aceitáveis.

2.4.2 Programação Genética

A PG (Programação Genética) apresenta uma abordagem diferente no âmbito dos algoritmos que englobam os Algoritmos Evolucionários. Neste caso, o objetivo da PG é definir uma expressão matemática que descreva os dados (Shaosen *et al.*, 2024). A PG trabalha com uma estrutura de árvore que combina os dados e os operadores matemáticos definidos na sua entrada. Dessa forma, à medida que as iterações decorrem, a PG vai ajustando essa árvore, podendo adicionar ou remover tanto operadores como dados, de modo a ajustar-se à modelagem desejada.

Ao contrário do mencionado anteriormente, na PG não se define se a variável está restrita a um tipo (real, inteira, binária, etc.), já que o propósito da PG não é encontrar valores mínimos ou máximos de uma equação, mas sim lidar com um problema de otimização voltado a encontrar a equação que melhor descreve a dinâmica do conjunto de dados. Sendo assim, a restrição agora incide sobre os tipos de operação que podem ser realizados ao montar essas equações. Na PG, pode-se definir as operações como realizações da matemática, como a adição, a subtração, a multiplicação, funções cossenos, entre outras.

2.4.3 Multigene Genetic Programming

O MGGP (*Multigene Genetic Programming*) é um algoritmo evolutivo que descende da PG (ARI; Alagöz, 2021). Neste algoritmo, cada indivíduo é representado por um cromossomo no qual cada gene corresponde a uma PG. Em outras palavras, no âmbito do algoritmo MGGP, o indivíduo é compreendido como a soma ponderada das suas respectivas, PG o qual é expresso matematicamente por:

$$g(\varphi, \Theta) = \sum_{i=1}^m \theta_i g_i(\varphi), \quad (2.30)$$

onde $g_i(\cdot)$ representa a função base contida no gene i (dentre os m genes que compõem o indivíduo) que depende do vetor das variáveis de entrada, representado por φ . θ_i é o ponderador da respectiva função base. Θ neste caso representa o vetor dos coeficientes θ . Devido à combinação linear, os valores de θ_i são comumente calculados via Mínimos Quadrados.

Durante a execução do algoritmo MGGP, o cruzamento também acontece, porém, de duas formas distintas, denominadas Cruzamento de Baixo Nível e Cruzamento de Alto Nível. Conforme ilustrado na Figura 2.23, no Cruzamento de Baixo Nível, a troca ocorre em um gene específico de cada um dos indivíduos pai, correspondendo a uma parte da PG que compõe o gene. Em contrapartida, o Cruzamento de Alto Nível envolve a troca de partes dos cromossomos pais, ou seja, um conjunto de genes. Dessa forma, é escolhido um ponto de corte aleatório no cromossomo de cada um dos pais, e então realiza-se essa troca. A mutação está igualmente presente no interior do algoritmo (denominado aqui por Mutação de Alto Nível), manifestando-se pela substituição completa de um gene (ao contrário de parte da PG que representa o gene, conforme descrito no Cruzamento de Baixo Nível) selecionado aleatoriamente por outro gerado no momento da mutação. Desta forma, a nova PG é atribuída a esse gene. Quando ocorre a Mutação de Baixo nível, apenas uma parte de um gene específico de um indivíduo é substituído por outra parte gerada aleatoriamente. A Figura 2.24 ilustra graficamente, a representação de um indivíduo MGGP por meio da configuração de árvores menores, acompanhadas pelos respectivos operadores matemáticos e valores. Na Figura 2.23 é possível observar o processo de Cruzamento de Alto Nível entre os genes pais, que resultaram nos genes filhos, por meio da troca de uma parte do arranjo da árvore (gene) entre eles. Em última análise, a Figura 2.23 também ilustra graficamente o processo de mutação, no qual uma parte do gene do indivíduo MGGP é substituída por uma estrutura completamente nova, gerada aleatoriamente.

Como o MGGP encontra modelos matemáticos que expressam a dinâmica dos alvos desejados com base nas relações das entradas estabelecidas para o algoritmo, bem como nas possíveis operações matemáticas e atrasos no tempo, é possível definir para ele qual a estrutura matemática se pretende obter, ou que se mostra mais adequada à aplicação em questão. Para isso, o conhecimento prévio característico do problema pode ser útil para essa escolha. No âmbito da modelagem de sistemas, este conhecimento diz respeito às características lineares ou não lineares dos mesmos. Desta forma, é viável estabelecer estruturas como os exemplos ARX, FIR, NARX ou NARMAX para que o MGGP estruture a respectiva modelagem. O MGGP pode atuar tanto na modelagem de sistemas SISO como também na de sistemas MIMO, como será discorrido na próxima seção.




Figura 2.23 – Representações de Cruzamento e Mutação de um Indivíduo MGPP




Figura 2.24 – Representações dos Indivíduos MGPP MISO/SISO e MIMO

2.4.3.1 *Multigene Genetic Programming* MIMO

No caso de se pretender modelar sistemas MIMO com o MGGP, o algoritmo pode ser adaptado e fracionado em componentes. Em um sistema SISO ou MISO, um indivíduo MGGP é constituído por um único conjunto de árvores que representam precisamente as relações necessárias para prever a saída desejada. No caso de múltiplas saídas, um indivíduo MGGP é composto por listas de árvores, onde cada lista prediz uma das saídas desejadas conforme visto na Figura 2.24. Deste modo, o método dos mínimos quadrados para a estimação dos parâmetros deve ser realizado separadamente para cada lista que expressa cada saída, respectivamente. As operações de cruzamento e mutação ocorrerão conforme ilustrado na Figura 2.23, já que os indivíduos MGGP MIMO podem ser vistos como uma lista de indivíduos MISO e tratados separadamente.

Durante o treinamento ou a validação, o algoritmo MGGP pode avaliar a aptidão da modelagem do sistema, calculando o erro nas suas predições em contraponto com os valores reais de formas distintas. As abordagens de simulação OSA (*One Step Ahead*), MS (*Multiple Shooting*) e FR (*Free Run*) podem ser utilizadas para esse propósito (Castro, 2021).

2.5 Trabalhos Relacionados

Xu *et al.* (2023) propõem um sensor virtual para estimar propriedades de curva em pneus inteligentes, tais como a força lateral, o momento de alinhamento e o trilho pneumático. Para tal, foi utilizado um acelerômetro triaxial acoplado internamente no pneu, obtendo-se assim as leituras das forças nos três eixos X, Y e Z. As tecnologias utilizadas para a construção do sensor virtual foram uma GPR (*Gaussian Process Regression*), que foi treinada e avaliada pelo NRMSE (*Normalized Root Mean Square Error*). Este foi posteriormente comparado com três algoritmos de Aprendizagem de Máquinas: NN (*Neural Network*), RF (*Random Forest*) e SVM (*Support Vector Machine*). O GPR demonstrou ser a opção mais adequada para este caso.

Outro estudo recente sobre pneus inteligentes foi realizado por Quan *et al.* (2023). Neste trabalho, o pneu inteligente é composto por outro sensor, nomeadamente um sensor de PVDF (*Polyvinylidene Fluoride*). Em contraste com o método utilizado pelo acelerômetro, que consiste na obtenção das forças, o PVDF obtém a variação da tensão, consequentemente causada pela deformação do pneu. Ademais, o estudo visou estimar o coeficiente de atrito entre o pneu

e a estrada. A utilização de três métricas de avaliação, AE (*Absolute Error*), MAE (*Mean Absolute Error*) e MAPE permitiu concluir que a aplicação de Algoritmos Genéticos é promissora para a estimativa em questão.

Xu *et al.* (2021) utilizou algoritmos de aprendizado de máquina para a predição do ângulo de deriva lateral (β), através de leituras de acelerômetros em pneus inteligentes. O banco de dados utilizado variou o ângulo de deriva em até 10°. Dentro desta variação, ele comparou 3 algoritmos, sendo Redes Neurais, Redes Neurais Recorrentes e RF. Além disso, o estudo comparou diferentes técnicas de pré-processamento, primeiro analisando os dados no domínio da frequência e os outros dois sendo filtros passa-baixa com frequências de corte em 400 Hz e 2000 Hz. O estudo mostrou superioridade das Redes Neurais e menores erros utilizando os dados no domínio da frequência.

Em Santos *et al.* (2025b), foi investigada a aplicação do MGGP para a modelagem MIMO não linear das vibrações de uma aeronave F16 no solo. Utilizando dados reais de aceleração nos três eixos ortogonais, o estudo comparou o desempenho do MGGP com algoritmos de aprendizado de máquina consolidados, como as redes neurais LSTM e MLP. A métrica de avaliação utilizada foi o RMSE. Os resultados demonstraram que, embora o MLP tenha obtido os menores valores de RMSE para duas das três saídas modeladas, o MGGP apresentou desempenho competitivo, sendo superior para uma das saídas. O principal diferencial do MGGP foi sua capacidade de gerar um modelo interpretável na forma de um polinômio NARX, o que é vantajoso para análise da dinâmica do sistema e implementações que demandam transparência.

Um estudo focado na aplicação de pneus inteligentes para a classificação de superfícies de rodovias foi conduzido por Santos *et al.* (2025a). Este trabalho comparou o desempenho de cinco modelos de aprendizado de máquina (*Random Forest*, *Extra Trees*, *K-Nearest Neighbors*, *Gradient Boosting* e *MLP*) utilizando dados de dois sensores distintos, um acelerômetro triaxial e um sensor de Filme Piezoelétrico (PVDF). O objetivo era classificar oito tipos diferentes de superfície de rodovia. A avaliação, baseada em métricas como acurácia, precisão, *recall* e *F1-score*, revelou que todos os modelos apresentaram desempenho satisfatório. Contudo, os dados do sensor PVDF proporcionaram resultados superiores, com os modelos *Extra Trees* e *Gradient Boosting* atingindo acurácia de teste próxima a 97%. A análise estatística via boxplots confirmou a superioridade dos modelos baseados em ensemble (*Random Forest*, *Extra Trees* e *Gradient Boosting*) quando treinados com dados do PVDF.

Em Barbosa *et al.* (2021), foi proposta a estimação da força lateral de pneus inteligentes por meio de Regressão por Processos Gaussianos (GPR). O estudo utilizou um acelerômetro triaxial montado no interior do pneu para capturar acelerações nos eixos longitudinal, lateral e vertical durante diferentes manobras, incluindo altos ângulos de deriva, variações de carga vertical e velocidade. Os autores analisaram a correlação entre os sinais de aceleração e a força lateral, demonstrando que o sistema de pneu inteligente fornece informações confiáveis mesmo em condições severas de operação. O modelo baseado em GPR apresentou desempenho superior em relação a outros algoritmos de aprendizado de máquina, além de fornecer estimativas de incerteza, aspecto relevante para aplicações em controle veicular avançado. O trabalho evidencia o potencial do GPR na modelagem de forças laterais em pneus inteligentes, especialmente em cenários onde métodos tradicionais apresentam limitações.

No trabalho de Xu *et al.* (2021), foi investigada a estimação do ângulo de deriva do pneu utilizando tecnologia de pneu inteligente baseada em acelerômetros MEMS triaxiais instalados na banda interna do pneu. Os dados experimentais foram obtidos em um sistema de testes *MTS Flat-Trac*, considerando diferentes condições de carga vertical, velocidade e ângulo de deriva, com variações de até 10°. O estudo comparou três técnicas de aprendizado de máquina, com destaque para redes neurais, avaliando dados nos domínios do tempo e da frequência. Os resultados indicaram desempenho significativamente superior no domínio da frequência, revelando que amplitudes espectrais em torno de 1000 Hz apresentam forte correlação com o ângulo de deriva, permitindo estimativas mais precisas com implicações diretas para sistemas de controle de estabilidade veicular.

Em Xu *et al.* (2025), é abordado o problema da estimação simultânea do ângulo de deriva e da razão de escorregamento sob condições combinadas de escorregamento, caracterizadas por forte não linearidade e acoplamento entre os estados do pneu. O sistema de pneu inteligente proposto utiliza três sensores PVDF distribuídos lateralmente no interior do pneu, permitindo a captura de diferentes padrões de deformação na região de contato com o solo. A partir desses sinais, foram extraídas 13 características fisicamente interpretáveis para o treinamento de modelos baseados em GPR, comparados com redes neurais artificiais e máquinas de vetor de suporte. Os resultados, avaliados por meio do NRMSE, indicaram desempenho superior do GPR, com erros inferiores a 2,1% mesmo em manobras extremas, destacando a contribuição do estudo para o avanço de sensores inteligentes aplicados à dinâmica veicular.

O trabalho apresentado em Castro e Barbosa (2020) investiga o uso do MGGP para a seleção de estruturas de modelos NARMAX polinomiais em problemas de identificação de sistemas não lineares. O estudo propõe a integração do MGGP com métodos tradicionais de *Orthogonal Least Squares* (OLS) e o critério de *Error Reduction Ratio* (ERR), com o objetivo de ampliar o espaço de busca de estruturas sem incorrer na maldição da dimensionalidade. A metodologia foi aplicada a um sistema real de bombeamento hidráulico, demonstrando que o MGGP é capaz de identificar modelos mais precisos, com melhor desempenho tanto em predição um passo à frente quanto em simulação livre, quando comparado a abordagens tradicionais. O trabalho mostra a capacidade do MGGP de gerar modelos interpretáveis, com alto grau de não linearidade e dependências temporais longas, mantendo viabilidade computacional.

Em Cunha, Ferreira e Barbosa (2023), foi desenvolvido um sensor virtual (soft sensor) baseado em modelos NARX polinomiais, identificados por meio de MGGP, aplicado ao monitoramento de poços surgentes de petróleo. Utilizando uma base de dados real e pública (3W-dataset), o estudo buscou modelar o comportamento dinâmico da temperatura de operação do poço, visando à detecção de anomalias e falhas. O trabalho explorou diferentes configurações de atrasos e horizontes de predição, evidenciando a capacidade do MGGP em capturar dependências temporais longas com um número reduzido de termos. Os resultados demonstraram que o soft sensor proposto é capaz de representar adequadamente a dinâmica do processo, contribuindo para sistemas de monitoramento e diagnóstico em ambientes industriais hostis, com destaque para a interpretabilidade do modelo obtido.

Por fim, em Mota, Castro e Barbosa (2021), é apresentada a identificação de um sistema de bombeamento hidráulico por meio de uma abordagem multiobjetivo baseada em MGGP, considerando simultaneamente o erro estático, o erro dinâmico e a complexidade do modelo. Foram identificados modelos NARX e NARMAX polinomiais capazes de representar adequadamente o comportamento do sistema em regimes estático e dinâmico. A análise do conjunto de soluções de Pareto permitiu selecionar modelos com bom compromisso entre desempenho e simplicidade estrutural. Os resultados obtidos mostraram-se competitivos em relação a trabalhos anteriores sobre a mesma base de dados, reforçando o potencial do MGGP multiobjetivo como ferramenta eficaz para seleção de estruturas em identificação de sistemas não lineares.

3 MATERIAIS E MÉTODOS

Nesta seção, será detalhado o banco de dados utilizado, assim como a separação do que foi utilizada para treinamento e validação. Também será vista toda a metodologia realizada, contemplando o pré-processamento dos sinais, a construção dos modelos, e as técnicas utilizadas para validar os modelos e analisar seus desempenhos.

3.1 Banco de Dados

O banco de dados utilizado neste trabalho foi adquirido em parceria com a Universidade de Jilin, na China, sendo composto por leituras de sensores em seis condições de operação do veículo, as quais ainda são contempladas por dois grupos de dados distinguidos pelas siglas *iTire* e MTS. *iTire* refere-se às leituras provenientes dos acelerômetros que compõem os quatro Pneus Inteligentes no veículo (Dianteiro Esquerdo, Dianteiro Direito, Traseiro Esquerdo e Traseiro Direito). A referência do pneu utilizado é Pirelli2654R21, e nele foi acoplado internamente o acelerômetro 3133A4 da fabricante *Dytran Instruments* conforme pode ser visto na Figura 3.1. Para cada pneu inteligente, o acelerômetro retorna as acelerações dos eixos X, Y e Z utilizando a unidade de medida tensão (V). Os dados são amostrados dos Pneus Inteligentes pelo sistema de aquisição DEWE2-A4 (DEWETRON) a uma taxa de 10 kHz, conforme pode ser visto na Figura 3.2. O conjunto de dados denominado MTS apresenta também leituras das quatro rodas do veículo. Neste caso, o sensoriamento agora não se encontra dentro do pneu, como as leituras do *iTire*, mas sim na roda do veículo. As leituras do MTS para os quatro pneus compreendem as forças longitudinal (F_x), lateral (F_y) e vertical (F_z) (em Kilo-Newton) os quais são alvos de modelagem. Estas forças foram medidas utilizando o transdutor de força da roda modelo 12.8-50, provido pela MSC (*Michigan Scientific Corporation*), a qual passa pelo amplificador MX1615BR (HBM) para condicionamento do sinal, e segue também para o sistema de aquisição DEWE2-A4. A Figura 3.3 demonstra este transdutor acoplado a roda do veículo, e a Figura 3.4 mostra o amplificador MX1615BR. Além das forças, a posição angular (em graus) da rotação do pneu também está presente. Em termos de amostragem, o conjunto MTS se encontra a uma taxa reduzida, sendo amostrado a 100 Hz. O banco de dados contém a leitura de outras grandezas físicas das rodas, assim como do sensoreamento do chassi do veículo, porém, não foram utilizadas neste trabalho. O veículo utilizado é de tração dianteira,

ilustrado na Figura 3.5. Essa informação é relevante, pois a tração impactará diretamente nas leituras as forças das rodas onde a tração acontece. Além disso, as seis condições de operação foram realizadas em um ambiente de pista plana, sem inclinação. As Figuras 3.6, 3.7, 3.8, 3.9, 3.10 e 3.11 ilustram as forças F_x , F_y e F_z dos pneus traseiro esquerdo e dianteiro esquerdo dadas as seis condições de operação do veículo.




Figura 3.1 – Acelerômetro 3133A4 *Dytran*

A primeira condição de operação mantém o veículo em linha reta, em momentos de velocidade constante, seguindo com momentos de aceleração e frenagem constantes. Nos momentos de frenagem e aceleração do veículo nesta condição de operação, a força crítica que terá maior impacto será a força longitudinal F_x . As leituras de força vertical F_z dos pneus também devem sofrer alterações devido à transferência de carga pela aceleração e frenagem. Como não há deslocamento lateral significativo, a força lateral F_y é a menos impactada.

A segunda condição de pilotagem presente no banco de dados é chamada de *Slalom*. Nesta condição, é realizada manobras de desvio lateral entre cones por três vezes. Essa manobra foi repetida três vezes com o veículo nas velocidades de 30, 45 e 60 quilômetros por hora (kph). Em comparação com a primeira condição de operação citada anteriormente, nesta condição a força crítica se inverte. Como o movimento lateral é predominante, F_y passa a ser a força



Figura 3.2 – Sistema de Aquisição DEWE2-A4



Figura 3.3 – Transdutor de Força da Roda Modelo 12.8-50




Figura 3.4 – Amplificador MX1615BR



Figura 3.5 – Veículo Utilizado para Aquisição dos Dados




Figura 3.6 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação Direção em Linha Reta




Figura 3.7 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação *Double Lane Change*




Figura 3.8 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação *Slalom*




Figura 3.9 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação Curvas Constantes




Figura 3.10 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação Curvas Constantes com Frenagens




Figura 3.11 – Variação das Forças nos Pneus Dianteiro ($_F$) e Traseiro ($_R$) na Condição de operação Direção Aleatória

crítica, seguida por F_z devido à transferência de carga, mas agora, pelo movimento lateral e não longitudinal. Dentre as três forças, F_x deve ser menos impactada nessa condição de operação.

Já na terceira condição de operação, é feita a simulação de uma mudança de faixa brusca, conhecida como *Double Lane Change*. Esse movimento também foi repetido três vezes para cada uma das velocidades de 30, 45 e 60 kph. Como o movimento mais brusco é feito lateralmente, assim como o *Slalom*, a força crítica será F_y seguida por F_z e a menos impactada pelo movimento será F_x .

A quarta condição de operação mantém o veículo em curvas constantes a uma velocidade de 60 kph. Neste caso, a curva foi realizada tanto para a direita, mudando posteriormente para a esquerda, simulando assim a curva constante para ambos os lados do veículo. Como é uma curva constante, espera-se que F_y seja impactado em magnitude, mas permaneça constante em determinado valor, sem variações bruscas se comparado com o *Slalom* e *Double Lane Change*. O mesmo ocorrerá com F_z . Por outro lado, F_x só será impactada significativamente quando houver a troca do sentido da curva da direita para a esquerda. Nos demais momentos, ela deve permanecer próximo de zero, dado que a velocidade do movimento é constante.

A quinta condição de operação baseia-se na quarta, realizando as curvas com o veículo para a direita e para a esquerda. Porém, agora é realizada a frenagem nos momentos das curvas. Como a frenagem impacta na velocidade do veículo, agora haverá variações significativas também da força F_x . Logo, todas as forças F_x , F_y e F_z são relevantes nessa condição de operação, onde F_y e F_z são resultados do movimento em si, e F_x se dá devido à frenagem.

A última condição de operação foi denominada por direção aleatória. Ela contempla os estilos de direção suave e agressivo. Devido à natureza da condição de operação, todas as três forças F_x , F_y e F_z são relevantes e impactadas pelo movimento. A Tabela 3.1 resume os detalhes desses seis conjuntos. Além da variação das forças, para o melhor entendimento de cada condição de operação, o Apêndice B traz mais detalhes e gráficos sobre a variação de outras grandezas físicas como acelerações do chassi do veículo, velocidades lateral e longitudinal, ângulo de esterçamento.

A escolha dos dados para treinamento se deu visando a condição de operação que apresentasse maior variação e excitação das forças, capturando assim as suas dinâmicas mais críticas. Sendo assim, para o treinamento utilizou-se a condição de operação aleatória, em conjunto com dois movimentos *Slalom* realizados a 45 kph, conforme ilustrado na Figura 3.12. Essa extensão dos dados de operação aleatória ocorreu visando abranger mais movimentos abruptos

das forças F_y e F_z . Todas as outras cinco condições de operação foram utilizadas para validar os modelos nas previsões das forças, visando principalmente as forças críticas de cada condição de operação.




Figura 3.12 – Dados de Treinamento

3.2 Descrição Geral da Metodologia

A Figura 3.13 ilustra a metodologia adotada neste trabalho para a modelagem das três forças F_x , F_y e F_z a partir dos sinais provenientes do pneu inteligente, considerando os quatro algoritmos avaliados. A figura apresenta tanto a metodologia principal, quanto uma metodologia complementar com viés comparativo entre diferentes abordagens de modelagem, além de explicitar o pré-processamento necessário para a extração das características utilizadas como entradas dos algoritmos.

Os blocos de pré-processamento indicados nas Figuras 3.13-B e 3.13-C são detalhados na Figura 3.13-A. As características extraídas correspondem às acelerações nos três eixos do acelerômetro do pneu inteligente, organizadas em função do ângulo de rotação da roda. O intervalo de rotação do pneu considerado para a extração dessas características foi definido contemplando a região da área de contato do pneu com o solo (comumente denominada na literatura por *contact patch*).

Foram avaliados três intervalos distintos de rotação, sendo $\pm 10^\circ$, $\pm 20^\circ$ e $\pm 35^\circ$, todos com resolução angular de $2,5^\circ$. O intervalo de $\pm 35^\circ$ e a resolução adotada seguem a metodologia apresentada em Barbosa *et al.* (2021) que define esses valores. Já os intervalos de $\pm 10^\circ$ e $\pm 20^\circ$ foram escolhidos de forma arbitrária, visando reduzir a região analisada, mantendo ainda

Tabela 3.1 – Descrição dos Conjuntos de Dados e Forças Críticas

Conjunto	Condições de Operação e Forças Críticas
1	Direção em Linha Reta: Velocidade constante e momentos de aceleração/frenagem constantes. <i>Forças críticas:</i> F_x (longitudinal) com variações em F_z por transferência de carga. F_y pouco impactada.
2	Slalom: Manobra de desvio lateral entre cones (3 repetições a 30, 45, 60 kph). <i>Forças críticas:</i> F_y (lateral) predominante, seguida por F_z por transferência de carga lateral. F_x pouco impactada.
3	Double Lane Change: Mudança de faixa brusca (3 repetições a 30, 45, 60 kph). <i>Forças críticas:</i> Similar ao <i>Slalom</i>, F_y é crítica, seguida por F_z. F_x pouco impactada.
4	Curvas Constantes: Curvas sucessivas para direita e esquerda a 60 kph (3 repetições). <i>Forças críticas:</i> F_y e F_z com magnitudes constantes durante cada curva. F_x próxima de zero (velocidade constante).
5	Curvas com Frenagem: Mesmo perfil do Conjunto 4, mas com frenagem durante as curvas. <i>Forças críticas:</i> F_y e F_z (curva) + F_x (frenagem). Todas as três forças são relevantes.
6	Direção Aleatória: Estilos de direção suave e agressivo combinados. <i>Forças críticas:</i> F_x, F_y e F_z são todas impactadas devido à natureza variada do movimento.

a cobertura da região de contato do pneu com o solo. A variação dos intervalos e o treinamento independente dos modelos com essas características tiveram como objetivo avaliar o efeito da região adjacente ao *contact patch* na qualidade dos modelos obtidos. O janelamento do sinal será discutido de forma mais detalhada na Seção 3.2.1.1.

Todo o código referente à metodologia foi desenvolvido utilizando a linguagem de programação *Python*, em sua versão 3.10.11. Dois computadores distintos foram utilizados ao longo do trabalho, sendo um dedicado ao pré-processamento dos dados e outro ao treinamento dos algoritmos e à obtenção dos modelos das forças. O computador utilizado para o pré-processamento possui um processador Ryzen 7-5700U, 16 GB de memória RAM e sis-

tema operacional Windows 10. Já o computador utilizado para o treinamento dispõe de um processador Intel i9-14900, 128 GB de memória RAM e sistema operacional Windows 11.




Figura 3.13 – (a) Pré-processamento, (b) Metodologia Principal (c) Metodologia Complementar

3.2.1 Pré-Processamento dos Sinais

Esta seção descreve as etapas de pré-processamento aplicadas aos sinais de aceleração do pneu inteligente e às forças medidas nas rodas, conforme ilustrado na Figura 3.13-A. Essas etapas são comuns às metodologias principal e complementar e visam garantir a adequada sincronização dos sinais, a remoção de ruídos e a extração das características utilizadas na modelagem.

Os sinais de aceleração nos eixos A_x , A_y e A_z são amostrados a uma frequência de 10 kHz, enquanto as forças F_x , F_y e F_z são amostradas a 100 Hz, conforme já discutido na seção referente ao banco de dados. Para possibilitar o janelamento adequado dos sinais no domínio do ângulo de rotação do pneu, foi realizada a interpolação linear das forças. Dessa forma, o impacto da interpolação restringe-se ao aumento da quantidade de amostras das forças, sem alterar de forma significativa a dinâmica dos sinais.

Após a interpolação, tanto as acelerações quanto as forças passam pelo processo de janelamento considerando os intervalos angulares previamente definidos. No caso das forças, esse procedimento resulta na obtenção dos valores médios de F_x , F_y e F_z em cada janela angular correspondente.

3.2.1.1 Janelamento do Sinal

Como visto na seção referente ao banco de dados, as acelerações provenientes do pneu inteligente possuem uma taxa de amostragem aproximadamente 100 vezes maior do que os dados provenientes dos sensores das rodas, aos quais se deseja modelar as forças longitudinais, laterais e verticais. As acelerações são altamente suscetíveis a variações rápidas, de modo que a aplicação direta de *undersampling*, reamostrando os sinais para a mesma taxa das forças, poderia acarretar perda significativa de informação.

Para contornar esse problema, foi realizada a extração das acelerações do pneu inteligente por cada ângulo de rotação do pneu, estabelecendo-se intervalos angulares que contemplam a região do *contact patch*, que por sua vez, determina a área de contato do pneu com o solo. Dessa forma, como a característica é extraída em função do ângulo de rotação, o caráter temporal e a taxa de amostragem deixam de impactar diretamente a quantidade de amostras, uma vez que a quantidade de dados por ângulo permanece constante.

Para fins comparativos, foram considerados três intervalos de janelamento, sendo $\pm 10^\circ$, $\pm 20^\circ$ e $\pm 35^\circ$ a partir do ponto de máximo contato do pneu com o solo, considerado como referência angular nula. Para todos os intervalos, adotou-se uma resolução angular de $2,5^\circ$ para a captura das acelerações. A Figura 3.14 ilustra como o ponto de máximo contato (C) pode ser identificado a partir do ponto médio entre o mínimo (B) e o máximo (D) da aceleração no eixo X. Esse comportamento está associado aos instantes de entrada e saída do pneu do contato com o solo ao longo da rotação. Dessa forma, como os momentos de mínimo e máximo da aceleração sempre estarão presentes na aceleração do eixo X do acelerômetro do pneu, a partir da repetição entre esses momentos consecutivos, é possível janelar a rotação do pneu, e posteriormente, proporcionalmente com a quantidade de pontos, reduzir o intervalo de extração de características de 360° para o intervalo desejado. Após essa etapa do pré-processamento, o interesse passa a ser nos dados suficientes para representar a rotação do pneu, de forma independente da taxa de amostragem temporal e sem perda de informação relevante.




Figura 3.14 – Representação do *contact patch*

3.2.1.2 Filtragem do Sinal

No momento em que os sensores estão captando informações, os sinais de aceleração estão suscetíveis a ruídos, que se manifestam como distorções não condizentes com a dinâmica real do sistema. Dessa forma, é comum a aplicação de filtros para a remoção desses ruídos. Neste trabalho, adotou-se um filtro *Butterworth* passa-baixas de quinta ordem, com frequência de corte de 400 Hz, seguindo o critério apresentado em Barbosa *et al.* (2021).

A Figura 3.15 ilustra o efeito da aplicação do filtro nos sinais de aceleração dos três eixos de um acelerômetro acoplado à roda dianteira do veículo. Observa-se que a filtragem promove uma redução significativa dos ruídos, sem comprometer as características principais do sinal.

Entretanto, ao analisar as acelerações em função do ângulo de rotação do pneu, ainda se observa a presença de ruído, conforme ilustrado na Figura 3.16. Como nesse caso trata-se de um ruído de caráter espacial, e não mais temporal, foi aplicado um filtro de média móvel com janela deslizante de tamanho cinco. Esse filtro atua sobre as acelerações por ângulo de rotação, considerando as várias rotações que compõem o banco de dados. Dessa forma, entende-se que a filtragem passa a ocorrer no domínio espacial, e não mais no domínio temporal. A Figura 3.17 apresenta graficamente o efeito combinado dos filtros temporal e espacial. Os gráficos das acelerações nos eixos X , Y e Z para os pneus dianteiro esquerdo e traseiro esquerdo, em seis condições de operação, são apresentados no Anexo D.

3.2.2 Metodologia Principal de Modelagem

Após o pré-processamento, a metodologia consiste no treinamento de quatro algoritmos para a construção de modelos capazes de prever as forças longitudinais F_x , laterais F_y e verticais F_z . O algoritmo de foco principal deste estudo é o MGGP (*Multigene Genetic Programming*), enquanto os algoritmos LSTM (*Long Short-Term Memory*), GRU (*Gated Recurrent Unit*) e MLP (*Multi-Layer Perceptron*) são utilizados para fins comparativos.

Todos os algoritmos utilizam como entradas os dados de aceleração do pneu inteligente previamente processados. Para os algoritmos de aprendizado de máquina, os dados de entrada são normalizados, enquanto para o MGGP os dados permanecem não normalizados, uma vez que o objetivo é obter modelos interpretáveis diretamente a partir das equações geradas. As




Figura 3.15 – Efeito da Filtragem dos Sinais de Aceleração: (a) Sem Filtragem, (b) Frequência de corte 400Hz

métricas de avaliação consideram o treinamento de dez modelos para cada algoritmo e para cada pneu do veículo, com exceção do MGGP, que também é avaliado a partir do treinamento utilizando simultaneamente os dados dos quatro pneus. Todas essas etapas são detalhadas nas seções subsequentes.

3.2.3 Metodologia Complementar

A metodologia complementar surge visando realizar comparações entre diferentes abordagens de treinamento, avaliando o impacto da utilização de entradas com apenas um atraso ou com múltiplos atrasos, bem como a influência do treinamento do algoritmo MGGP utilizando dados de um único pneu ou dos quatro pneus simultaneamente. Além disso, essa metodologia permite analisar o efeito da variação do intervalo angular de janelamento na qualidade dos modelos obtidos, conforme ilustrado na Figura 3.13-C.




Figura 3.16 – Acelerações Z (V) por ângulo do Pneu Dianteiro Esquerdo

3.2.4 Normalização dos Dados

Para os algoritmos de aprendizado de máquinas, a normalização dos dados é uma etapa do pré-processamento importante, pois ajuda diretamente na eficiência dos algoritmos em modelar as saídas desejadas. Sendo assim, para os algoritmos LSTM, GRU e MLP os dados de entrada foram padronizados pela técnica Z-Score, a qual é vista matematicamente pela equação:

$$Z = \frac{x - x_{mean}}{x_{std}} \quad (3.1)$$

onde z é a característica normalizada, x é a característica a ser normalizada, x_{mean} é a média da característica e x_{std} é o desvio padrão da característica. As forças laterais e longitudinais e verticais às quais os modelos devem prever, permaneceram inalteradas.




Figura 3.17 – Efeito dos Filtros em um Sinal de Aceleração em X: (a) Rotação Sem Filtragem *Butterworth*, (b) Rotação Com Filtragem *Butterworth*, (c) 0.0° Sem Filtragem Média Móvel, (d) 0.0° Com Filtragem Média Móvel

3.3 Arquitetura dos Algoritmos de Aprendizado de Máquinas

A Tabela 3.3 apresenta a arquitetura de cada um dos três algoritmos de aprendizado de máquina treinados. Todos os algoritmos utilizaram o otimizador Adam e a métrica de avaliação MSE. Os parâmetros das arquiteturas, tais como taxa de aprendizado (*learning rate*), número de Neurônios Ocultos (*Hidden Units*), taxa de *dropout* e o *batch size* foram otimizados utilizando a técnica Optuna (Akiba *et al.*, 2019). Para essa busca, utilizaram-se os intervalos dos parâmetros demonstrados na Tabela 3.2.

Tabela 3.2 – Espaço de Busca para a Configuração dos Hiperparâmetros com Optuna.

Hiperparâmetros	Distirbuição / Tipo	Valores / Intervalo
Batch Size	Lista Discreta	32, 64, 128, 256, 524
Hidden Units	Distribuição Uniforme Inteira	16 to 96
Dropout Rate	Distribuição Uniforme Contínua	0,01 to 0,1
Learning Rate	Distribuição Uniforme Contínua	$1e^{-5}$ to $1e^{-2}$

Todos os três modelos foram treinados com 250 épocas, e fizeram uso das técnicas *ModelCheckpoint* e *EarlyStopping*. O *ModelCheckpoint* garante que seja salvo apenas o modelo que apresente o melhor resultado no conjunto de teste, dado a divisão dos dados entre treino e teste. Já o *EarlyStopping* é usado para que, caso não haja melhoria na métrica de avaliação no conjunto de teste durante um número definido de épocas de treinamento, o treinamento seja interrompido. Para este trabalho, a interrupção acontece após 20 épocas sem melhoria.

Tabela 3.3 – Arquitetura dos modelos LSTM, MLP e GRU.

Camada	Modelo LSTM	Modelo MLP	Modelo GRU
1	Input()	Input()	Input()
2	LayerNormalization()	LayerNormalization()	LayerNormalization()
3	LSTM(hidden_units)	Flatten()	GRU(hidden_units)
4	LayerNormalization()	Dense(hidden_units*2, activation='relu')	LayerNormalization()
5	Dropout(dropout_rate)	LayerNormalization()	Dropout(dropout_rate)
6	LSTM(hidden_units)	Dropout(dropout_rate)	GRU(hidden_units)
7	LayerNormalization()	Dense(hidden_units*2, activation='relu')	LayerNormalization()
8	-	LayerNormalization()	-
9	Dense(3)	Dense(3)	Dense(3)

3.4 Arquitetura do *Multigene Genetic Programming*

Como visto anteriormente, o problema em questão trata-se da modelagem MIMO, dado que as entradas são as acelerações dos pneus inteligentes por ângulo de rotação do pneu, e são três forças que se deseja modelar. Com isso, internamente a arquitetura do MGGP divide em três partes MISO conforme ilustrado pela Figura 3.18, objetivando as três equações NARX/FIR que mais se adequam, minimizando o erro entre o valor real e o predito pelas equações. A no-

menclatura NARX/FIR se dá devido à disponibilidade dos termos autorregressivos que, durante o processo evolutivo dos indivíduos, podem ou não ser utilizados. Em caso de uso, torna-se um modelo NARX. Caso contrário, se tem um modelo que depende apenas das relações não-lineares das entradas atrasadas, logo, um modelo FIR não-linear. O modelo NARX/FIR receberá os dados processados das acelerações, ou seja, as acelerações nos respectivos ângulos do pneu inteligente, dado o intervalo de extração. Com essas informações, o MGGP irá predizer as forças laterais (F_y), longitudinais (F_x) e verticais (F_z) do veículo.




Figura 3.18 – Arquitetura MGGP

Para o treinamento utilizando o algoritmo MGGP, é necessário definir inicialmente alguns parâmetros, tais como:

- Operadores de Atrasos a Serem Utilizados;
- N° de Gerações;
- Tamanho da População;
- N° de Termos;
- Tamanho Máximo do Termo;
- Método de Avaliação;
- Tipo de Avaliação (OSA, MS ou FR);
- N° de Passos à frente (Para Avaliação do tipo MS);
- Probabilidade de Cruzamento;
- Probabilidade de Mutação.

4 RESULTADOS E DISCUSSÕES

Nessa seção, serão apresentados os resultados obtidos aplicando-se a metodologia descrita anteriormente. Primeiramente, são apresentados os modelos polinomiais obtidos pelo algoritmo MGGP e como eles se configuram entre NARX e FIR. Na sequência, é visto o impacto da velocidade do veículo na qualidade de predição dos modelos para as condições de operação *Double Lane Change* e *Slalom*. Após isso, é mostrado o efeito da variação do intervalo na extração das acelerações por ângulo de rotação do pneu. Também é visto o comparativo entre as diferentes abordagens para a obtenção dos modelos NARX/FIR polinomiais via MGGP. A seção que segue, apresenta o comparativo dos modelos NARX/FIR com os modelos obtidos a partir dos algoritmos de aprendizado de máquina. Visando a interpretabilidade, a penúltima seção dos resultados mostra a análise do uso das acelerações por ângulo de rotação do pneu, e por fim, a última seção discorre sobre o custo computacional e a complexidade dos modelos obtidos.

4.1 Modelos NARX/FIR Polinomiais gerados pelo Algoritmo MGGP

A configuração dos parâmetros iniciais do algoritmo MGGP para o treinamento dos modelos NARX/FIR foram:

- Operadores de Atrasos a Serem Utilizados: q1, q2, q3, q4, q5;
- N° de Gerações: 250;
- Tamanho da População: 250;
- N° de Termos: 20;
- Tamanho Máximo do Termo: 15;
- Método de Avaliação: RMSE;
- Tipo de Avaliação (OSA, MS ou FR): MS;
- N° de Passos à frente (Para Avaliação do tipo MS): 100;
- Probabilidade de Cruzamento: 0,9;
- Probabilidade de Mutação: 0,2.

Após o treinamento dos modelos com o algoritmo MGGP por 250 épocas para cada um dos pneus, obtiveram-se as modelagens polinomiais NARX/FIR. Abaixo é demonstrado exemplos de equações para as três forças modeladas para os pneus Dianteiro Esquerdo, primeiro para o caso multi atrasos, e no segundo momento as equações para o caso onde se treinou

utilizando apenas um atraso (q1), ambos os casos utilizando o intervalo $\pm 20^\circ$ para a extração das características de aceleração por ângulo de rotação do pneu. Os valores dos parâmetros θ se encontram nas Tabelas no Anexo A. Mesmo ao utilizar o espaço de busca onde é possível aplicar mais de um atraso nas características, observa-se que, na sua maioria, os regressores são as acelerações com apenas um atraso. Para o exemplo com um atraso e para o caso multi atrasos apresentados, observa-se que os modelos para a força F_x , F_y e F_z apresentam-se como modelos NARX. Todavia, para cada pneu o MGPP foi executado 10 vezes, obtendo assim 10 modelos distintos por pneu. Durante estes treinamentos, também foi possível obter-se modelos que se configuram como FIR. A Tabela 4.1 apresenta o levantamento quantitativo de modelos NARX/FIR por força, nos cenários distintos do uso de atraso. Nesta Tabela o destaque volta-se para a força F_x que apresentou um equilíbrio entre as quantidades de modelos NARX e modelos FIR sem os termos autorregressivos. Por outro lado, F_y e F_z predominam-se como modelos NARX.

Tabela 4.1 – Quantidade de Modelos NARX/FIR por Tipo de Atraso

Tipo de Atraso	Força	FIR	NARX
Multi Atrasos	F_x	18	22
	F_y	2	38
	F_z	9	31
Um Atraso	F_x	17	23
	F_y	2	38
	F_z	5	35

A Tabela 4.2 demonstra quantitativamente, dentre os modelos NARX, a frequência de utilização dos termos autorregressivos nas modelagens que empregam tanto um único atraso quanto múltiplos atrasos. Observa-se que, nos modelos que utilizam apenas um atraso, o termo autorregressivo associado à força lateral F_y apresenta maior destaque, sendo o mais recorrente para a modelagem das três forças de saída. Para os modelos de F_y , nota-se ainda uma participação expressiva do termo autorregressivo F_z , indicando um acoplamento dinâmico relevante entre as forças lateral e normal. Já na modelagem de F_z , o termo autorregressivo F_y é o mais utilizado, reforçando essa interdependência. Observa-se ainda que a força lateral F_y é amplamente utilizada como termo autorregressivo na modelagem da força longitudinal F_x . Fisicamente, essa

relação pode ser associada ao fenômeno de compartilhamento do atrito no contato pneu–solo, no qual variações na força lateral impactam diretamente a capacidade do pneu em gerar força longitudinal, mesmo em instantes subsequentes.

Ao analisar os modelos com múltiplos atrasos, observa-se uma maior diversificação na utilização dos termos autorregressivos entre as forças F_x , F_y e F_z . Nesse caso, embora o termo F_y continue apresentando elevada frequência, especialmente na modelagem de F_z , há um balanceamento mais evidente entre os diferentes termos autorregressivos.

Tabela 4.2 – Contagem de Uso de Termos Autorregressivos nos modelos NARX por Tipo de Atraso

Tipo de Atraso	Output	F_x	F_y	F_z
Multi Atrasos	F_x	13	10	7
	F_y	23	11	27
	F_z	13	25	14
Um Atraso	F_x	4	13	9
	F_y	9	20	26
	F_z	5	29	17

Abaixo é apresentado as equações NARX/FIR utilizando o algoritmo MGGP com múltiplos atrasos, operando com até o quinto regressor q_5 :

$$\begin{aligned}
F_x[k] = & \theta_1 + \theta_2 \cdot Z_{10.0^\circ}[k-1] + \theta_3 \cdot X_{20.0^\circ}[k-6] \cdot X_{-5.0^\circ}[k-6] \\
& + \theta_4 \cdot X_{5.0^\circ}[k-1] + \theta_5 \cdot Y_{2.5^\circ}[k-1] \\
& + \theta_6 \cdot Z_{7.5^\circ}[k-45] \cdot X_{-17.5^\circ}[k-1] + \theta_7 \cdot X_{-12.5^\circ}[k-1] \\
& + \theta_8 \cdot Y_{-12.5^\circ}[k-1] + \theta_9 \cdot F_y[k-41] \\
& + \theta_{10} \cdot Z_{-2.5^\circ}[k-6] \cdot Z_{2.5^\circ}[k-6]^2 + \theta_{11} \cdot Z_{17.5^\circ}[k-1] \\
& + \theta_{12} \cdot Z_{-15.0^\circ}[k-1] + \theta_{13} \cdot Z_{15.0^\circ}[k-2] \\
& + \theta_{14} \cdot Z_{10.0^\circ}[k-14] \cdot Z_{10.0^\circ}[k-9] \cdot Z_{10.0^\circ}[k-8] + \theta_{15} \cdot Z_{20.0^\circ}[k-6] \\
& + \theta_{16} \cdot Y_{-7.5^\circ}[k-1] + \theta_{17} \cdot F_x[k-44] \\
& + \theta_{18} \cdot Z_{-15.0^\circ}[k-14] + \theta_{19} \cdot X_{2.5^\circ}[k-4] \cdot Y_{-12.5^\circ}[k-7] \cdot X_{2.5^\circ}[k-5] \cdot X_{-2.5^\circ}[k-6] \\
& + \theta_{20} \cdot Z_{-20.0^\circ}[k-1] + \theta_{21} \cdot Z_{-7.5^\circ}[k-1]
\end{aligned} \tag{4.1}$$

$$\begin{aligned}
F_y[k] = & \theta_1 + \theta_2 \cdot X_{-10.0^\circ}[k-1] + \theta_3 \cdot X_{-15.0^\circ}[k-1] \\
& + \theta_4 \cdot X_{5.0^\circ}[k-1] + \theta_5 \cdot X_{-17.5^\circ}[k-40] \cdot Y_{12.5^\circ}[k-24] \cdot X_{-17.5^\circ}[k-26] \\
& \cdot X_{-17.5^\circ}[k-33] \cdot Y_{12.5^\circ}[k-32] \\
& + \theta_6 \cdot Y_{7.5^\circ}[k-1] + \theta_7 \cdot Z_{5.0^\circ}[k-1] \cdot Y_{-12.5^\circ}[k-1] \\
& + \theta_8 \cdot Y_{17.5^\circ}[k-6] + \theta_9 \cdot Y_{-10.0^\circ}[k-1] \\
& + \theta_{10} \cdot Y_{-7.5^\circ}[k-12] \cdot Z_{20.0^\circ}[k-27] \cdot X_{20.0^\circ}[k-12] \cdot Z_{20.0^\circ}[k-30] \\
& \cdot Y_{-7.5^\circ}[k-24] \cdot X_{20.0^\circ}[k-17] \\
& + \theta_{11} \cdot X_{17.5^\circ}[k-27] \cdot X_{17.5^\circ}[k-36] \cdot Z_{-12.5^\circ}[k-37] + \theta_{12} \cdot Y_{17.5^\circ}[k-1] \\
& + \theta_{13} \cdot Z_{0.0^\circ}[k-1] + \theta_{14} \cdot X_{2.5^\circ}[k-12] \cdot X_{2.5^\circ}[k-14] \cdot Z_{10.0^\circ}[k-11] \\
& \cdot Z_{-15.0^\circ}[k-10] \cdot X_{2.5^\circ}[k-10] \\
& + \theta_{15} \cdot Z_{-5.0^\circ}[k-1] + \theta_{16} \cdot Y_{7.5^\circ}[k-9] \\
& + \theta_{17} \cdot Y_{-15.0^\circ}[k-1] + \theta_{18} \cdot X_{-15.0^\circ}[k-1] \cdot Z_{-20.0^\circ}[k-1] \\
& + \theta_{19} \cdot F_z[k-4] + \theta_{20} \cdot Y_{-12.5^\circ}[k-1] \\
& + \theta_{21} \cdot Z_{-7.5^\circ}[k-1] \cdot Y_{15.0^\circ}[k-1]
\end{aligned} \tag{4.2}$$

$$\begin{aligned}
F_z[k] = & \theta_1 \\
& + \theta_2 \cdot Y_{0.0^\circ}[k-19] \cdot Y_{7.5^\circ}[k-13] \cdot Y_{-17.5^\circ}[k-12] \cdot X_{-10.0^\circ}[k-16] + \theta_3 \cdot X_{-5.0^\circ}[k-3]^3 \\
& + \theta_4 \cdot X_{0.0^\circ}[k-5] + \theta_5 \cdot Z_{-20.0^\circ}[k-1] \\
& + \theta_6 \cdot X_{5.0^\circ}[k-1] + \theta_7 \cdot Z_{12.5^\circ}[k-1] \\
& + \theta_8 \cdot Z_{2.5^\circ}[k-1] + \theta_9 \cdot X_{-10.0^\circ}[k-1]^2 \\
& + \theta_{10} \cdot Y_{-2.5^\circ}[k-1] + \theta_{11} \cdot Z_{0.0^\circ}[k-5] \\
& + \theta_{12} \cdot X_{-10.0^\circ}[k-6] + \theta_{13} \cdot Z_{-5.0^\circ}[k-1] \\
& + \theta_{14} \cdot Y_{2.5^\circ}[k-1] + \theta_{15} \cdot F_x[k-27] \cdot F_x[k-25] \\
& + \theta_{16} \cdot X_{15.0^\circ}[k-1]^2 + \theta_{17} \cdot F_y[k-1] \\
& + \theta_{18} \cdot X_{0.0^\circ}[k-18] + \theta_{19} \cdot X_{-17.5^\circ}[k-11] \\
& + \theta_{20} \cdot Z_{-17.5^\circ}[k-1] + \theta_{21} \cdot Z_{5.0^\circ}[k-1]
\end{aligned} \tag{4.3}$$

Na sequência, é apresentado as equações NARX/FIR utilizando o algoritmo MGGP com apenas um atraso:

$$\begin{aligned}
F_x[k] = & \theta_1 \\
& + \theta_2 \cdot Z_{10.0^\circ}[k-1] \cdot Z_{2.5^\circ}[k-1]^3 + \theta_3 \cdot Z_{-17.5^\circ}[k-1] \\
& + \theta_4 \cdot Z_{-12.5^\circ}[k-1] + \theta_5 \cdot X_{5.0^\circ}[k-1] \\
& + \theta_6 \cdot Y_{12.5^\circ}[k-1] + \theta_7 \cdot Z_{0.0^\circ}[k-1]^2 \\
& + \theta_8 \cdot X_{7.5^\circ}[k-1] + \theta_9 \cdot X_{-17.5^\circ}[k-1] \\
& + \theta_{10} \cdot X_{-15.0^\circ}[k-1] + \theta_{11} \cdot X_{10.0^\circ}[k-1] \cdot X_{2.5^\circ}[k-1] \cdot F_x[k-1]^2 \cdot X_{10.0^\circ}[k-1] \\
& + \theta_{12} \cdot Z_{17.5^\circ}[k-1] + \theta_{13} \cdot X_{-20.0^\circ}[k-1] \\
& + \theta_{14} \cdot Z_{-20.0^\circ}[k-1] + \theta_{15} \cdot Y_{-2.5^\circ}[k-1] \\
& + \theta_{16} \cdot Y_{-7.5^\circ}[k-1] + \theta_{17} \cdot Z_{-7.5^\circ}[k-1] \\
& + \theta_{18} \cdot Z_{0.0^\circ}[k-1] + \theta_{19} \cdot X_{-12.5^\circ}[k-1] \\
& + \theta_{20} \cdot Z_{20.0^\circ}[k-1] + \theta_{21} \cdot Z_{10.0^\circ}[k-1]
\end{aligned} \tag{4.4}$$

$$\begin{aligned}
F_y[k] = & \theta_1 \\
& + \theta_2 \cdot X_{0.0^\circ}[k-1] + \theta_3 \cdot F_z[k-1] \\
& + \theta_4 \cdot Z_{7.5^\circ}[k-1] + \theta_5 \cdot Y_{-15.0^\circ}[k-1] \\
& + \theta_6 \cdot Y_{17.5^\circ}[k-1] + \theta_7 \cdot Y_{-7.5^\circ}[k-1] \\
& + \theta_8 \cdot Z_{-2.5^\circ}[k-1] \cdot F_x[k-1] + \theta_9 \cdot X_{2.5^\circ}[k-1] \\
& + \theta_{10} \cdot Y_{-12.5^\circ}[k-1] \cdot Z_{2.5^\circ}[k-1] + \theta_{11} \cdot X_{-12.5^\circ}[k-1] \\
& + \theta_{12} \cdot Y_{-12.5^\circ}[k-1] + \theta_{13} \cdot Y_{-10.0^\circ}[k-1] \\
& + \theta_{14} \cdot X_{-15.0^\circ}[k-1] + \theta_{15} \cdot Z_{7.5^\circ}[k-1] \cdot X_{-20.0^\circ}[k-1] \\
& + \theta_{16} \cdot X_{-15.0^\circ}[k-1] \cdot Z_{-17.5^\circ}[k-1] + \theta_{17} \cdot Z_{-7.5^\circ}[k-1] \\
& + \theta_{18} \cdot Y_{12.5^\circ}[k-1] + \theta_{19} \cdot Y_{-5.0^\circ}[k-1] \cdot Z_{-2.5^\circ}[k-1] \cdot Y_{-15.0^\circ}[k-1]^2 \cdot X_{10.0^\circ}[k-1] \\
& + \theta_{20} \cdot X_{-17.5^\circ}[k-1] + \theta_{21} \cdot X_{-2.5^\circ}[k-1]
\end{aligned} \tag{4.5}$$

$$\begin{aligned}
F_z[k] = & \theta_1 \\
& + \theta_2 \cdot Y_{-12.5^\circ}[k-1] + \theta_3 \cdot X_{-15.0^\circ}[k-1] \\
& + \theta_4 \cdot Z_{-12.5^\circ}[k-1] + \theta_5 \cdot X_{-17.5^\circ}[k-1] \\
& + \theta_6 \cdot X_{2.5^\circ}[k-1] + \theta_7 \cdot Y_{-7.5^\circ}[k-1] \\
& + \theta_8 \cdot Y_{-2.5^\circ}[k-1] + \theta_9 \cdot F_z[k-1] \cdot Z_{20.0^\circ}[k-1] \cdot F_z[k-1] \cdot Z_{0.0^\circ}[k-1] \\
& + \theta_{10} \cdot Z_{-17.5^\circ}[k-1] \cdot Y_{-5.0^\circ}[k-1] + \theta_{11} \cdot X_{5.0^\circ}[k-1] \\
& + \theta_{12} \cdot Z_{17.5^\circ}[k-1] + \theta_{13} \cdot X_{-10.0^\circ}[k-1] \\
& + \theta_{14} \cdot Z_{-2.5^\circ}[k-1] \cdot X_{-17.5^\circ}[k-1] + \theta_{15} \cdot X_{-20.0^\circ}[k-1] \\
& + \theta_{16} \cdot Z_{-20.0^\circ}[k-1] \cdot X_{-20.0^\circ}[k-1] + \theta_{17} \cdot X_{-2.5^\circ}[k-1] \\
& + \theta_{18} \cdot X_{-5.0^\circ}[k-1]^2 + \theta_{19} \cdot X_{7.5^\circ}[k-1] \\
& + \theta_{20} \cdot Y_{-5.0^\circ}[k-1] + \theta_{21} \cdot X_{20.0^\circ}[k-1]
\end{aligned} \tag{4.6}$$

Analisando as equações, é perceptível que utilizar apenas um atraso teve um ganho significativo em relação a equações simplificadas, aumentando o nível de interpretabilidade,

principalmente quando é comparado os dois modelos gerados para a força F_y . A Figura 4.1 ilustra a predição temporal das três forças por um modelo NARX/FIR polinomial na condição de operação em curvas constantes para ambos os lados com situações de frenagem do pneu traseiro esquerdo. É possível observar que a predição do modelo, embora ruidosa, segue a dinâmica das forças, principalmente F_y e F_z . É perceptível que para a força F_x o modelo teve mais dificuldade e apresenta erros mais representativos entre o predito e o real. O comparativo temporal entre o valor real e as preditas das forças nas demais condições de operação do veículo para o pneu traseiro esquerdo podem ser vistas no Anexo C.




Figura 4.1 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Curvas Constantes com Frenagem do Pneu Traseiro Esquerdo

4.2 Impacto da Velocidade na Qualidade dos Modelos NARX/FIR para o Caso DLC e Slalom

As Figuras 4.2, 4.3, 4.4, 4.5 mostram o comparativo entre os modelos treinados utilizando informações dos três intervalos distintos de rotação do pneu ($\pm 10^\circ$, $\pm 20^\circ$, $\pm 35^\circ$) e resolução de $2,5^\circ$ em todos os casos, para a predição dos movimentos realizados nas condições de operação *Double Lane Change* (DLC) e *Slalom*. O gráfico apresenta o informativo para os

quatro pneus do veículo sob a variação da velocidade em 30, 45 e 60 kph, e para a métrica MAPE limitou-se aos valores em até 50. Em consequência, os gráficos que não apresentam boxplots para a força F_x estão, na verdade, acima de 50 nesta métrica. Para quaisquer um dos intervalos utilizados para a extração de aceleração por ângulo de rotação do pneu, é perceptível pelas métricas de avaliação que, à medida que a velocidade aumenta, os modelos melhoram seus desempenhos na predição das forças predominantes nesta condição de operação, sendo as forças F_y e F_z . O mesmo não é possível afirmar da força F_x , que, por sua vez, apresenta valores de MAPE e R^2 muito inferiores, e sem melhorias proporcionais ao aumento da velocidade do veículo. Todavia, a qualidade do modelo melhorar suas predições de F_y e F_z com o aumento da velocidade sobrepõe ao gargalo da predição de F_x , tendo em vista que nesta condição de operação, o risco de incidentes está justamente nas componentes das grandezas físicas atuantes lateralmente do veículo, assim como na transferência de carga, onde, no extremo, causa o capotamento. Visando a atuação de controle do veículo, a qual objetiva evitar situações indesejadas nesta condição de operação, os modelos demonstram boa capacidade em inferir sobre F_y e F_z .




Figura 4.2 – Comparativo Por Velocidade da Métrica MAPE na Condição de Operação *Double Lane Change* e Por Pneu - Modelos NARX/FIR via MGGP Treinados com Diferentes Intervalos de Extração de Características

É possível visualizar no domínio temporal o efeito de melhoria nas forças predominantes F_y e F_z do movimento, que justifica os valores das métricas de avaliação, conforme ilustrado em




Figura 4.3 – Comparativo Por Velocidade da Métrica R^2 na Condição de Operação *Double Lane Change* e Por Pneu - Modelos NARX/FIR via MGPP Treinados com Diferentes Intervalos de Extração de Características




Figura 4.4 – Comparativo Por Velocidade da Métrica MAPE na Condição de Operação *Slalom* e Por Pneu - Modelos NARX/FIR via MGPP Treinados com Diferentes Intervalos de Extração de Características



Figura 4.5 – Comparativo Por Velocidade da Métrica R^2 na Condição de Operação *Slalom* e Por Pneu - Modelos NARX/FIR via MGGP Treinados com Diferentes Intervalos de Extração de Características

4.6, 4.7, 4.8 e 4.9, onde a curva azul representa as forças captadas pelos sensores, e a curva vermelha representa os valores preditos pelos modelos polinomiais construídos utilizando o MGGP. Nas imagens, pode-se observar que as curvas das forças predominantes se aproximam com o aumento da velocidade. Em termos de magnitude, pode-se observar que F_x é menor do que as forças anteriormente citadas. Como não há uma normalização dos dados durante o treinamento, e o MGGP avalia os modelos candidatos pela métrica RMSE, o erro de predição de F_x terá um peso menor se comparado com os erros de F_y e F_z . Dessa forma, possuir um peso menor no erro total, e ter menos característica dado que não é a força predominante do movimento, resulta em modelos que não são capazes de prever F_x adequadamente utilizando apenas as características advindas dos Pneus Inteligentes.

4.3 Efeito do Uso de Diferentes Intervalos na Extração das Características

Nesta seção, será apresentado um estudo sobre o impacto na qualidade de predição dos modelos, dada a variação do intervalo utilizado para extrair as acelerações por ângulo de rotação do pneu. Com isso, o intuito de investigação é entender se um intervalo maior impacta em




Figura 4.6 – Comparativo Temporal entre Predições e Valores Reais do Modelo NARX/FIR no *Double Lane Change* do Pneu Dianteiro Direito em suas Variações de Velocidade




Figura 4.7 – Comparativo Temporal entre Predições e Valores Reais do Modelo NARX/FIR no *Double Lane Change* do Pneu Traseiro Direito em suas Variações de Velocidade




Figura 4.8 – Comparativo Temporal entre Predições e Valores Reais do Modelo NARX/FIR no *Slalom* do Pneu Dianteiro Direito em suas Variações de Velocidade




Figura 4.9 – Comparativo Temporal entre Predições e Valores Reais do Modelo NARX/FIR no *Slalom* do Pneu Traseiro Direito em suas Variações de Velocidade

modelos melhores, já que terá mais características, ou se para a predição de forças das rodas, um intervalo menor já possui as características suficientes para isso. As variações do intervalo de extração das características feitas nesse trabalho foram de $\pm 10^\circ$, $\pm 20^\circ$, $\pm 35^\circ$, onde todos os três casos utilizaram a resolução de 2.5° para a seleção dos ângulos de rotação do pneu, e consequentemente, a obtenção das acelerações nos respectivos ângulos de rotação.

As Figuras 4.10 e 4.11 demonstram graficamente os boxplots gerados pelas métricas MAPE e R^2 de 10 modelos distintos por pneu, com as suas predições das três forças para as cinco condições de operação utilizadas para validação, sem avaliar o efeito da variação da velocidade. Assim como já visto anteriormente, os gráficos que não apresentam valores para a força F_x se dá em decorrência da limitação do gráfico, e para os casos em questão os boxplots estão acima dessa limitação. Os valores das métricas para as condições de operação *Slalom* e *Double Lane Change* são referentes a velocidade de 60 kph. Inicialmente, vale notar que a qualidade da predição das forças pelos modelos utilizando qualquer um dos três intervalos avaliados está ligada diretamente as forças predominantes em cada condição de operação. De modo geral, é possível perceber que a utilização do intervalo $\pm 10^\circ$ resultou em modelos menos precisos, com boxplots que se apresentam mais esparsadamente, indicando maior variância nos seus resultados. Além disso, também é perceptível que, em boa parte dos casos, o intervalo $\pm 10^\circ$ apresentou uma distribuição de resultados com uma qualidade inferior se comparado com os resultados obtidos com os intervalos $\pm 20^\circ$ e $\pm 35^\circ$. Por outro lado, ao analisar a distribuição dos resultados utilizando os intervalos $\pm 20^\circ$ e $\pm 35^\circ$ para a extração de características para os modelos, os resultados se apresentam pareados, estatisticamente não sendo possível inferir sobre qual é melhor ou pior entre si. Entretanto, é visto que o aumento do intervalo em 15 graus, dado a diferença dos intervalos, não refletiu em ganhos significativos, o que implica que $\pm 20^\circ$ já é suficiente para a obtenção das características para a predição das forças das rodas do veículo a partir das acelerações do pneu inteligente. Conclui-se então que, para os quatro pneus, avaliando as duas métricas, a utilização dos intervalos $\pm 20^\circ$ e $\pm 35^\circ$ não tiveram diferenças estatisticamente comprovadas, dado a distribuição dos seus respectivos boxplots. Por outro lado, a redução do intervalo para $\pm 10^\circ$ demonstrou uma queda significativa na qualidade dos modelos.




Figura 4.10 – Comparativo da Métrica MAPE - Modelos NARX/FIR via MGGP Treinados Com Diferentes Intervalos de Características




Figura 4.11 – Comparativo da Métrica R^2 - Modelos NARX/FIR via MGPP Treinados Com Diferentes Intervalos de Características

4.4 Comparativo entre Diferentes Abordagens dos Modelos NARX/FIR

Nessa seção é apresentado o comparativo entre três abordagens distintas para a construção de modelos NARX/FIR a partir do algoritmo MGPP. A primeira comparação se dá em virtude do uso de diferentes operadores de atraso disponíveis para a modelagem das forças. Já o segundo caso, é em vista de modelos construídos para a predição de quaisquer um dos quatro pneus do veículo, ao invés de modelos específicos por pneu. O intuito dessas comparações é inferir se o uso de mais de um atraso para os modelos resulta em ganhos de desempenho, além de analisar se é possível obter um modelo com bom desempenho para os quatro pneus ao mesmo tempo, a partir do seu treinamento com informações também dos quatro pneus. Todos

os comparativos são feitos utilizando o intervalo de $\pm 35^\circ$ de rotação do pneu para a extração de características.

Nas Figuras 4.12 e 4.13, o primeiro grupo de modelos, legendado nos gráficos apenas como “mggp” são os resultados dos modelos treinados com os operadores de atraso q1, q2, q3, q4 e q5. No segundo caso, apresentado na legenda como `mggp_one_lag` refere ao uso de apenas um operador de atraso (q1) para a construção dos modelos. Para esses dois primeiros casos, treinou-se modelos exclusivos por pneu, ou seja, ele foi treinado com dados exclusivos por pneu, e validado também em dados apenas do pneu ao qual foi treinado. Já o terceiro caso, denominado como `mggp_all_tires` são indivíduos que foram treinados utilizando dados dos quatro pneus ao mesmo tempo.

Na maioria dos boxplots, é perceptível que os resultados apresentados por `mggp_one_lag` tem menos variância do que “mggp” e até mesmo apresenta resultados superiores em alguns casos. Isso demonstra que, para a predição das forças, a utilização de mais que um operador de atraso trouxe um espaço de busca maior para o MGGP, porém sem ganhos. Por outro lado, utilizar apenas um atraso trouxe maior precisão para os resultados dos modelos.

Os modelos treinados para os quatro pneus simultaneamente, apresentou resultados competitivos com os modelos específicos por pneus. Embora seja possível perceber algumas ocasionalidades de resultados que são estatisticamente inferiores aos outros dois comparativos, devido ao não cruzamento de quartis entre os boxplots, ainda são resultados próximos entre si. Há situações específicas em que a predição dos modelos `mggp_all_tires` foram superiores aos outros dois, como a predição de F_z para o pneu FR na condição de operação Direção em Linha Reta (*Straight Driving*), mas acontece geralmente o cruzamento entre um ou entre os outros dois modelos comparativos, fazendo com que não seja possível determinar estatisticamente qual é melhor. Com isso, os modelos `mggp_all_tires` também demonstram potencial em sua aplicação para a predição de forças, além do ponto positivo por ser apenas um modelo geral, ao invés de um modelo específico. Novamente, vale a ressalva de que a qualidade das predições está ligada diretamente às forças predominantes de cada condição de operação.

4.5 Comparativo entre Modelos NARX/FIR e Modelos de Machine Learning

Como visto no referencial teórico, é usual utilizar técnicas de Aprendizado de Máquinas para a construção de *Soft Sensors*. Dessa forma, nessa seção serão comparados os resultados ob-




Figura 4.12 – Comparativo da Métrica R^2 - Modelos NARX/FIR c/ Multi Atrasos, c/ um Atraso, e Modelos Para Todos os Pneus

tidos pelos modelos construídos a partir do algoritmo MGGP em contraponto com os modelos obtidos pelos algoritmos de aprendizado de máquina MLP, LSTM e GRU. Após a otimização dos hiperparâmetros dos algoritmos de aprendizado de máquinas utilizando o Optuna, obteve-se os parâmetros apresentados nas Tabelas 4.3 e 4.4. Na Tabela 4.3 é ilustrado os hiperparâmetros das arquiteturas treinadas com o propósito comparativo com os modelos gerados pelo MGGP que foram treinados utilizando até o quinto operador de atraso. Ademais, a Tabela 4.4 apresenta os hiperparâmetros das arquiteturas comparativas com os modelos gerados pelo MGGP que foram treinados utilizando apenas um atraso. Para o comparativo com a abordagem multi atrasos, os modelos LSTM, GRU e MLP foram treinados com um janelamento de 70. Esse valor foi definido pelo atraso máximo a ser utilizado pelos modelos MGGP, multiplicado pelo



Figura 4.13 – Comparativo da Métrica R^2 - Modelos NARX/FIR c/ Multi Atrasos, c/ um Atraso, e Modelos Para Todos os Pneus

seu tamanho máximo, definido nos parâmetros iniciais como 15. Dessa forma, está disponível para os modelos MGGP o uso de até 70 atrasos.

Entre as duas abordagens de uso de atraso para os modelos de aprendizado de máquinas, é possível observar que os modelos com um atraso precisaram de um número maior de neurônios ocultos. Além disso, os valores de *Batch Size* ficaram menores se comparado com a abordagem com mais de um atraso. Isso demonstra uma maior dificuldade dos modelos para reconhecer os padrões utilizando apenas um atraso, tendo em vista que precisaram de mais neurônios, e uma atualização utilizando menos rodadas de dados.

As Figuras 4.14 e 4.15 mostram os resultados dos modelos de aprendizado de máquinas comparado com os resultados obtidos pelos modelos polinomiais a partir do MGGP, avaliados sob as métricas MAPE e R^2 , todos utilizando multi atrasos. Avaliando as forças predominantes

Tabela 4.3 – Melhores Hiperparâmetros por Modelos treinados com Multi Atrasos

Modelo	Pneu	Hidden Units	Dropout Rate	Learning Rate	Batch Size
MLP	FR	56	0,0169	2.524e-3	256
	FL	80	0,0116	1.825e-3	256
	RR	88	0,0894	1.895e-3	128
	RL	72	0,0142	2.097e-3	256
GRU	FR	80	0,0544	8.926e-4	128
	FL	96	0,0137	5.865e-4	128
	RR	48	0,0135	8.300e-4	32
	RL	64	0,0305	4.927e-4	32
LSTM	FR	88	0,0768	1.269e-3	256
	FL	56	0,0106	1.424e-4	32
	RR	96	0,0782	4.278e-3	256
	RL	80	0,0180	1.622e-4	32

Tabela 4.4 – Melhores Hiperparâmetros por Modelo e Pneu (Um Atraso)

Modelo	Pneu	Hidden Units	Dropout Rate	Learning Rate	Batch Size
MLP	FR	64	0,0255	9.241e-3	64
	FL	80	0,0338	7.859e-4	32
	RR	88	0,0536	3.387e-4	32
	RL	88	0,0498	4.054e-3	64
GRU	FR	96	0,0396	2.943e-3	64
	FL	96	0,0129	2.619e-4	32
	RR	96	0,0287	1.864e-3	32
	RL	88	0,0103	8.954e-4	32
LSTM	FR	96	0,0386	2.948e-3	64
	FL	96	0,0395	3.284e-4	32
	RR	96	0,0334	1.419e-3	32
	RL	80	0,0322	3.429e-3	64

de cada condição de operação, é perceptível que os modelos via MGGP obtiveram resultados melhores, dado que os boxplots apresentam médias abaixo dos demais modelos, além do não cruzamento de quartis entre os resultados, sendo possível assim, defini-lo como melhores resultados estatisticamente.




Figura 4.14 – Comparativo da métrica MAPE - Modelos via MGGP, LSTM, GRU e MLP Treinados com Multi Atrasos

4.6 Análise do Uso das Acelerações por Ângulo de Rotação do Pneu

Estabelecido o intervalo de rotação do pneu para a extração de características e a resolução em graus, essa seção visa apresentar uma análise demonstrando o uso das características para as predições das forças das rodas utilizando os intervalos $\pm 20^\circ$ e $\pm 35^\circ$ para a extração das acelerações por ângulo de rotação do pneu.



Figura 4.15 – Comparativo da métrica R^2 - Modelos via MGGP, LSTM, GRU e MLP Treinados com Multi Atrasos

As Figuras 4.18 e 4.19 mostram a seleção de características usadas pelos 10 modelos criados a partir do algoritmo MGGP utilizando os intervalos $\pm 20^\circ$ e $\pm 35^\circ$ de rotação do pneu para a predição das forças da roda dianteira esquerda do veículo. Na Figura 4.18, para a modelagem de F_x , pode-se observar a maioria dos modelos escolheram características nos intervalos de -20° a -10° e de 5° a 10° da aceleração X. Ademais, quando se observa a seleção de características com o intervalo maior, conforme ilustrado na Figura 4.19 ainda se observa uma predominância da seleção da aceleração X no ângulo 5° da rotação do pneu. Em torno do ângulo -17° também houve 4 modelos que a utilizaram na modelagem. Isso é um demonstrativo de que esses ângulos específicos merecem destaque tendo em vista que foram consideravelmente importantes refletindo padrões necessários para a modelagem de F_x . Ainda sobre a modelagem de F_x , um comportamento similar acontece com acelerações Z em torno dos ângulos -7.5°




Figura 4.16 – Comparativo da métrica MAPE - Modelos via MGGP, LSTM, GRU e MLP Treinados com Um Atraso

a 5° , -17.5° a -12.5° e 20° que também aparecem selecionados pela maioria dos modelos, mesmo utilizando o intervalo maior para a extração das características. Isso acontece porque a aceleração Z tem relação direta com F_x . A variação de F_x se dá pelos momentos de aceleração ou frenagem do veículo. Nesses momentos, também ocorre a transferência de carga nas rodas, refletindo na variação da leitura do acelerômetro em Z.

Para a modelagem de F_y , a aceleração X em torno dos ângulos -17.5° a -12.5° , e a aceleração Y de -15° a -7.5° também aparecem utilizadas pela maioria dos 10 modelos treinados, tanto utilizando o intervalo $\pm 20^\circ$ quanto $\pm 35^\circ$. Por último, para a modelagem de F_z , comparando o uso das características nos intervalos $\pm 20^\circ$ e $\pm 35^\circ$, a aceleração Y nos ângulos -2.5° , 2.5° e 7.5° são fortemente utilizadas em ambos os casos por quase todos os modelos. A aceleração Z em 20° é bastante selecionada utilizando o intervalo $\pm 20^\circ$ enquanto para o



Figura 4.17 – Comparativo da métrica R^2 - Modelos via MGGP, LSTM, GRU e MLP Treinados com Um Atraso

intervalo $\pm 35^\circ$ é fortemente selecionado o ângulo 22.5° . A seleção da aceleração Z acontece pelo mesmo motivo visto para F_x , a transferência de carga. A diferença que se dá, é que a transferência de carga em frenagens e acelerações é longitudinal, enquanto em movimentos laterais, a transferência de carga também ocorre lateralmente.

Com esse levantamento de utilização dos ângulos de rotação do pneu com suas respectivas acelerações, é possível observar uma seleção comum para a modelagem de todas as três forças. Em sua maioria, são selecionados ângulos de rotação negativa, que antecedem o ponto 0° de máximo contato com o solo. A seleção de ângulos positivos acontecem para a modelagem de F_x que seleciona ângulos positivos da aceleração Z para sua modelagem, e para F_y que seleciona ângulos positivos da aceleração Y. Estes levantamentos abrem fronteiras para estudos




Figura 4.18 – Uso das Características no Intervalo $\pm 20^\circ$ de Rotação do Pneu Dianteiro Esquerdo




Figura 4.19 – Uso das Características no Intervalo $\pm 35^\circ$ de Rotação do Pneu Dianteiro Esquerdo

futuros que investigam de forma ainda mais sistemática as acelerações nos respectivos ângulos de rotação dos Pneus Inteligentes, e como isso é associado às forças atuantes na roda.

O Anexo B apresenta a mesma análise gráfica para os outros três Pneus Inteligentes que compõem o veículo de estudo. Nestas imagens, pode-se ver um comportamento semelhante ao descrito anteriormente, onde ângulos negativos são priorizados, e intervalos específicos apare-

cem sendo selecionados em ambos os intervalos $\pm 20^\circ$ e $\pm 35^\circ$ para a extração das acelerações por ângulo de rotação do pneu.

4.7 Custo Computacional *Versus* Complexidade

A aplicação real de um modelo está diretamente ligado a sua viabilidade. Dentre vários fatores, modelos que possuem um menor custo computacional acaba ganhando mais visibilidade, dado que para estes casos, não é necessário um alto nível de processamento. Os benefícios aumentam quando se obtém modelos que apresentam respostas mais rápidas, sendo reflexo do seu menor nível de complexidade.

A Tabela 4.5 mostra os valores do tempo médio necessário para o treinamento de cada modelo, assim como sua média dos parâmetros. Por um lado, o algoritmo MGGP demanda mais de 32 minutos para a execução e modelagem das forças, enquanto os algoritmos de aprendizado de máquinas GRU, LSTM e MLP não ultrapassam 5 minutos, sendo uma diferença muito expressiva de tempo para os respectivos treinamentos. Todavia, a expressividade se inverte quando se compara a quantidade de parâmetros dos modelos. Para os algoritmos de aprendizado de máquina, os parâmetros são compreendidos como todos os pesos internos das redes e seus bias. Para o algoritmo MGGP consideraram-se como parâmetros a quantidade dos θ presentes em cada expressão. Com isso, o GRU apresenta mais de 260 mil parâmetros, o LSTM mais de 290 mil e o MLP com mais de 1 milhão e 650 mil parâmetros. Em contrapartida, os modelos NARX/FIR criados pelo algoritmo MGGP possuíram 63 parâmetros. Dessa forma, é possível concluir que o tempo necessário para o treinamento dos modelos utilizando o MGGP é altamente compensado pelo seu nível reduzido de parâmetros. FLOPs (*FLoating-point Operations*) é outra métrica que se pode avaliar os algoritmos. Qualquer operação realizada entre números de ponto flutuante, como soma, subtração, multiplicação ou divisão, contabiliza FLOPs. Com isso, quanto menor for o número de FLOPs, menor é o custo computacional do modelo. A tabela mostra uma diferença expressiva na quantidade reduzida de FLOPs do MGGP se comparado com os outros algoritmos de aprendizado de máquina. Isso se justifica, novamente, pela simplicidade dos modelos criados pelo algoritmo MGGP. Em última análise, a coluna que apresenta os tempos de predição dos modelos, demonstra novamente o tempo reduzido demandado pelos modelos obtidos a partir do MGGP se comparados com os demais.

Tabela 4.5 – Comparação dos Modelos: Tempo de Treinamento, N° de Parâmetros e FLOPs

Modelo	Tempo de Treinamento (Min)	N° de Parâmetros	FLOPs	Tempo de Predição (ms)
GRU	$3,9 \pm 0,3$	263045 ± 93915	134625 ± 32611	$0,808 \pm 0,055$
LSTM	$3,7 \pm 0,5$	291341 ± 90688	169929 ± 33710	$0,766 \pm 0,035$
MLP	$3,8 \pm 0,6$	1656785 ± 274371	1137917 ± 183103	$3,346 \pm 0,183$
MGGP	$32,6 \pm 3,5$	63	$206,5 \pm 7,7$	$0,166 \pm 0,007$

Ressalta-se que, a implementação do algoritmo MGGP não possui técnicas semelhantes ao *EarlyStopping* como foi implementado no treinamento do LSTM, GRU e MLP de forma que haja a interrupção do treinamento caso o critério de baixos indícios de melhoria no decorrer das épocas seja atendido. Com isso, é possível que o tempo demandado do algoritmo MGGP pudesse ser menor, caso houvesse a técnica similar implementada. O mesmo é válido para os tempos de predição, onde as funções utilizadas pelos algoritmos de aprendizado de máquinas são funções otimizadas e de alto nível de implementação, enquanto a função de predição utilizada pelo algoritmo MGGP ainda poderia ser bastante aperfeiçoada. Se o foco voltar-se para poderio para identificação de padrões, o algoritmo MGGP também apresenta um carácter de alto potencial. É visto nos resultados que os modelos NARX/FIR via MGGP foram superiores aos outros comparados. Com isso, o MGGP conseguiu modelos que foram superiores, porém, com uma quantidade muito menor de parâmetros.

5 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho investigou a capacidade de modelagem NARX/FIR das forças F_x , F_y e F_z das rodas do veículo utilizando o algoritmo evolucionário MGGP, a partir das acelerações por ângulo de rotação do pneu inteligente. A abordagem principal visou modelos específicos por cada pneu do veículo. Os modelos NARX/FIR se mostraram eficientes em prever as forças predominantes em cada uma das condições de operação utilizadas para a validação dos modelos.

Os resultados mostraram que os modelos NARX/FIR aumentam sua precisão nas previsões, proporcionalmente com o aumento da velocidade do veículo. Isso é um ponto positivo, pois o aumento da velocidade também implica no aumento do risco de incidentes indesejados. Se a modelagem melhora suas previsões com o aumento da velocidade, por consequência, as técnicas de controle que fazem uso dessa modelagem também se beneficiam, buscando manter o veículo sob condições normais de pilotagem.

Foi avaliada a capacidade do MGGP em modelar as forças a partir das acelerações por ângulo de rotação do pneu utilizando os diferentes intervalos de rotação $\pm 10^\circ$, $\pm 20^\circ$ e $\pm 35^\circ$. Através da análise comparativa dos resultados dos modelos, observou-se que o uso do intervalo $\pm 10^\circ$ reflete em perdas significativas de robustez dos modelos, enquanto para os modelos que obtiveram as acelerações dos respectivos intervalos $\pm 20^\circ$ e $\pm 35^\circ$ não demonstraram diferenças estatísticas que comprovem serem superiores ou inferiores entre si para a predição das forças predominantes em cada uma das cinco condições de operação validadas.

Analisando os modelos NARX das forças gerados pelo algoritmo MGGP, observou-se que, os modelos para uma das forças apresentou uma quantidade significativa de termos autor-regressivos das outras forças. Esse resultado confirma que a abordagem MIMO é realmente útil para a modelagem das forças, possibilitando a utilização das interrelações entre as forças.

Os modelos NARX/FIR que foram treinados com o espaço de busca abrangendo até o quinto operador de atraso, em comparativo com o treinamento que se limitou a apenas um operador de atraso foi visto que ampliar os atrasos não reflete proporcionalmente em modelos ainda mais capazes de prever as forças nas condições de operação. Os resultados mostram, na verdade, que o uso de multi atrasos, em alguns casos, deixou os modelos polinomiais mais complexos. Sendo assim, o uso de apenas um atraso é suficiente nesse contexto, e traz modelos mais interpretáveis.

A extração das acelerações por ângulo de rotação se mostra eficiente em capturar características das forças. A análise de uso destas acelerações evidenciam que existem ângulos que capturam de forma mais apropriada a dinâmica da manobra, como, por exemplo, os ângulos que correspondem ao início e fim de contato com o solo. Os modelos NARX/FIR selecionaram mais acelerações Z para os modelos da força F_x enquanto mais acelerações X são vistas nos modelos para as forças F_z . Isso é um demonstrativo claro do acoplamento entre as forças, onde F_x depende da carga nominal e suas variações que se dão pelos movimentos de aceleração e frenagens. Por outro lado, a aceleração X também não está ligada apenas à força F_x , ela também reflete as deformações induzidas por F_z .

O treinamento dos modelos NARX/FIR capazes de prever a dinâmica dos quatro pneus simultaneamente apresentou resultados próximos dos outros modelos treinados especificamente para cada pneu. Em termos de aplicabilidade é visto ainda mais ganho, pois ao invés de ser processado quatro equações diferentes, uma só é suficiente para a predição da dinâmica dos quatro pneus.

Para além, os modelos NARX/FIR via MGGP se mostraram superiores aos outros modelos que se deram a partir das técnicas de aprendizado de máquina LSTM, GRU e MLP, que também são utilizadas para a construção de *Soft Sensors*. Os resultados mostram que o ganho é em termos das métricas de avaliação, mas também em interpretabilidade dado o polinômio gerado pelo MGGP a partir das entradas e dos termos autorregressivos. Embora os modelos via MGGP demandam muito mais tempo de treinamento se comparado aos outros via aprendizado de máquinas, no final obtêm-se modelos que são muito menos complexos e que na aplicação, demandam de um custo computacional muito menor também.

Como trabalhos futuros, é possível explorar ainda mais os ângulos de rotação do pneu para a predição das forças, mudando a resolução utilizada dentro do intervalo de extração. Além disso, visando modelos ainda mais interpretáveis, e com um custo computacional ainda menor, pode-se explorar técnicas como *Forward Regression Orthogonal Estimator* (FROE) para a remoção de termos que tem baixa contribuição para a predição final da modelagem. Trabalhos futuros também podem fazer uso das modelagens obtidas aqui como modelos dinâmicos juntamente com Filtro de Kalman para predição mais robusta das forças do veículo.

APÊNDICES

APÊNDICE A – ANÁLISE DA RELAÇÃO ENTRE FORÇA, ACELERAÇÃO E VELOCIDADE EM *DOUBLE LANE CHANGE* E *SLALOM*

O intuito deste apêndice é demonstrar o comportamento das acelerações dos pneus inteligentes em detrimento da variação das forças das rodas e da velocidade do veículo. Essa análise se dá para as duas condições de operação que mais estressam lateralmente os pneus, *Double Lane Change* e *Slalom*. As Figuras 1 e 2 demonstram, respectivamente, a variação do ângulo de esterçamento do veículo na condição *Double Lane Change* em 30 kph e em 60 kph. Já as Figuras 9 e 10 demonstram a variação do ângulo de esterçamento, porém, na condição *Slalom* em 30 kph e 60 kph. Como o ângulo de esterçamento pode ser entendido como o ângulo de rotação do volante do veículo, os gráficos demonstram a manobra realizada pelo veículo no tempo. É interessante notar que, em ambos os casos de condições de operação, embora ocorra a variação da velocidade, o intervalo de variação do ângulo de esterçamento se mantém próxima.

Analizando a aceleração X juntamente com a correspondência da força F_x pela Figura 3 obtida a 30 kph para a condição de operação *Double Lane Change* e pela Figura 11 para a condição *Slalom* também a 30 kph, não há evidência que o comportamento dinâmico se distingue a medida com que a velocidade aumenta, e consequentemente, o intervalo das forças F_x aplicadas ao pneu. O que é observável é quando se compara o gráfico gerado a 30 kph e os gráficos a 60 kph, conforme podem serem vistos nas Figuras 6 e 14 para ambas as condições de operação. Neste caso, os picos da aceleração X que são os indicativos do início e fim de contato com solo aumentam sua magnitude a medida que a velocidade também aumenta. Sendo assim, em 30 kph é visto picos menores do que no gráfico gerado com a velocidade 60 kph.

A aceleração Y e a força F_y , por sua vez, é possível identificar certo padrão no gráfico quando a velocidade está em 60 kph, como pode ser visto nas Figuras 7 e 15. Graficamente, as forças de maiores escalas positivas se encontram com valores de aceleração superior no intervalo de $\pm 10^\circ$, onde é justamente o intervalo dos ângulos que correspondem ao contato com o solo. Quanto mais negativa é a força F_y , menor será o valor das leituras de aceleração. Essa caracterização também pode ser vista nas Figuras 4 e 12 que apresentam as condições de operação na velocidade 30 kph, mas com menos intensidade.

Por último, existe um padrão claro que acontece nas acelerações Z a medida que a velocidade aumenta, e aumenta assim as magnitudes das forças F_z aplicadas ao pneu. Nas

Figuras 8 e 16 nota-se para todos os quatro pneus que, quanto maior for a força F_z aplicada ao pneu, maior é a abertura da curva de acelerações por ângulo de rotação do pneu que indica o momento de contato com o solo e assim, quanto menor for a força menor também é essa abertura. Fisicamente essa é a exata dinâmica esperada. Entende-se a força F_z como a força que pressiona a roda do veículo ao solo. Assim, quanto maior for a força, mais contato o pneu terá com o solo, justificando essa maior amplitude dos ângulos de rotação em contato com o solo. De forma análoga, quanto menor F_z , menos contato o pneu tem com o solo durante sua rotação. As Figuras 5 e 13 mostram a variação das acelerações pelas forças na velocidade 30 kph, o qual não é possível ver de forma tão clara o padrão dinâmico esperado.

É visto anteriormente, em especial para as acelerações Y e Z que o padrão entre as acelerações e as forças fica mais visível com o aumento da velocidade. Isso se dá porque, quanto maior for a velocidade, aumenta também as forças aplicadas nos pneus do veículo.

É possível perceber também a presença de um viés (bias) nos dados referentes ao pneu RR, embora esse fato não tenha refletido nos resultados dos modelos NARX/FIR. Isso é explicado porque ao equacionar os modelos polinomiais, o algoritmo MGGP possui a capacidade de ajustar o viés ligado ao modelo através do θ_1 presente nos modelos, o qual é o bias do modelo. Sendo assim, os modelos NARX/FIR para o pneu RR terão o valor de θ_1 maior do que para os outros pneus no intuito de compensar esse bias existente nos dados.




Figura 1 – Variação do ângulo de esterçamento no movimento *Double Lane Change* em 30 kph




Figura 2 – Variação do ângulo de esterçamento no movimento *Double Lane Change* em 60 kph




Figura 3 – Relação entre Força Longitudinal e Acelerações no eixo X do Pneu Inteligente no Movimento *Double Lane Change* em 30 kph




Figura 4 – Relação entre Força Lateral e Acelerações no eixo Y do Pneu Inteligente no Movimento *Double Lane Change* em 30 kph




Figura 5 – Relação entre Força Vertical e Acelerações no eixo Z do Pneu Inteligente no Movimento *Double Lane Change* em 30 kph




Figura 6 – Relação entre Força Longitudinal e Acelerações no eixo X do Pneu Inteligente no Movimento *Double Lane Change* em 60 kph




Figura 7 – Relação entre Força Lateral e Acelerações no eixo Y do Pneu Inteligente no Movimento *Double Lane Change* em 60 kph




Figura 8 – Relação entre Força Vertical e Acelerações no eixo Z do Pneu Inteligente no Movimento *Double Lane Change* em 60 kph




Figura 9 – Variação do ângulo de esterçamento no movimento *Slalom* em 30 kph




Figura 10 – Variação do ângulo de esterçamento no movimento *Slalom* em 60 kph




Figura 11 – Relação entre Força Longitudinal e Acelerações no eixo X do Pneu Inteligente no Movimento *Slalom* em 30 kph




Figura 12 – Relação entre Força Lateral e Acelerações no eixo Y do Pneu Inteligente no Movimento *Slalom* em 30 kph




Figura 13 – Relação entre Força Vertical e Acelerações no eixo Z do Pneu Inteligente no Movimento *Slalom* em 30 kph




Figura 14 – Relação entre Força Longitudinal e Acelerações no eixo X do Pneu Inteligente no Movimento *Slalom* em 60 kph




Figura 15 – Relação entre Força Lateral e Acelerações no eixo Y do Pneu Inteligente no Movimento *Slalom* em 60 kph




Figura 16 – Relação entre Força Vertical e Acelerações no eixo Z do Pneu Inteligente no Movimento *Slalom* em 60 kph

APÊNDICE B – ANÁLISE DE CARACTERÍSTICAS DAS CONDIÇÕES DE OPERAÇÃO VEICULAR

Cada condição de operação traz consigo suas especificidades dinâmicas, e isso reflete diretamente na leitura das grandezas físicas durante sua execução. Com isso, esse Apêndice tem o intuito de detalhar a ocorrência de cada uma das condições de operação registradas no banco de dados.

A Figura 17 apresenta as características na condição de operação *Direção em Linha Reta*. Nesta condição de operação, observa-se um cenário predominantemente caracterizado por movimento longitudinal, com o veículo trafegando majoritariamente em linha reta. O ângulo de esterçamento permanece próximo de zero durante grande parte do ensaio, apresentando apenas pequenas correções pontuais, associadas a ajustes do condutor. A velocidade longitudinal e a velocidade no eixo X apresentam-se similarmente com momentos de constância, e situações de desaceleração que vai a 0, e depois acelera novamente até chegar em outro momento de velocidade constante. As acelerações longitudinais exibem variações compatíveis com as mudanças de velocidade, com picos associados a frenagens e retomadas. Já a aceleração lateral permanece próxima de zero na maior parte do tempo, reforçando o caráter essencialmente longitudinal desta condição.

A variação das características na condição de operação *Slalom* é visto na Figura 18. É possível observar pela variação do ângulo de esterçamento as oscilações periódicas refletindo a sequência contínua de manobras que caracterizam como *Slalom*. Os picos maiores do ângulo de esterçamento indicam possivelmente uma manobra de retorno do veículo. Como nessa condição de operação é estressado principalmente as componentes laterais das grandezas físicas, é visto o reflexo do movimento diretamente na velocidade e aceleração lateral. A velocidade longitudinal apresenta um comportamento relativamente estável, com as quedas que ocorrem nos momentos de retorno do veículo. Como essa condição de operação se destaca pela forte excitação dinâmica lateral, ela evidencia o acoplamento claro entre esterçamento, velocidade lateral e aceleração lateral.

Na Figura 19 é visto a mesma análise, porém, para a condição de operação *Double Lane Change*. Observa-se no gráfico a presença de eventos bem definidos e de curta duração no ângulo de esterçamento, além de dois picos que representam dois momentos de contorno realizado pelo veículo. Nesses momentos também ocorre a queda acentuada da velocidade do




Figura 17 – Variação das Características da Condição de Operação Direção em Linha Reta

veículo, e o aumento da velocidade lateral devido à natureza do movimento de curva. O Gráfico evidencia de forma clara quais manobras de *Double Lane Change* foram realizadas durante a amostragem dos sinais, além de quais manobras foram realizadas em 30, 45 e 60 kph. A aceleração lateral do veículo demonstra relação direta com o movimento, caracterizando de forma clara as manobras. A aceleração longitudinal, por outro lado, caracteriza os momentos de frenagem do veículo.

Na sequência é apresentado o gráfico das variações das características na condição de operação Curvas Constantes na Figura 20. Observa-se que, embora o ângulo de esterçamento assuma valores médios aproximadamente constantes em determinados intervalos, há a presença de variações oscilatórias mais bruscas em momentos específicos do ensaio. Esse comporta-




Figura 18 – Variação das Características da Condição de Operação *Slalom*

mento é consequência da mudança do sentido da curva, da esquerda para a direita, ao longo de uma volta completa realizada pelo veículo, o que exige uma rotação mais acentuada do volante durante o retorno. Esse efeito é refletido não apenas no ângulo de esterçamento, mas também nas demais características, como a velocidade lateral e a aceleração lateral, que apresentam variações coerentes com a inversão do movimento curvilíneo. A velocidade longitudinal mantém-se relativamente constante, caracterizando um regime próximo do estacionário, enquanto as acelerações longitudinais exibem baixa variabilidade. A aceleração lateral permanece elevada durante os trechos de curva, evidenciando a sustentação das forças laterais nos pneus mesmo com a alternância do sentido da trajetória.




Figura 19 – Variação das Características da Condição de Operação *Double Lane Change*

A Figura 21 apresenta as variações das características na condição de operação Curvas Constantes com Frenagem em Curva. De forma análoga ao caso de curvas constantes, observa-se a alternância do sentido da curva entre esquerda e direita, claramente evidenciada pelo ângulo de esterçamento, que apresenta regiões positivas e negativas, além de variações internas associadas às correções do condutor. Essa inversão do sentido da trajetória também se reflete na velocidade lateral e na aceleração lateral, cujos sinais acompanham a mudança do movimento curvilíneo. Adicionalmente, a aplicação de frenagem durante a curva provoca quedas acentuadas da velocidade longitudinal, enquanto a aceleração longitudinal apresenta picos negativos significativos. A combinação desses efeitos evidencia o acoplamento entre esforços longitudi-




Figura 20 – Variação das Características da Condição de Operação Curvas Constantes

nais e laterais no pneu, caracterizando um regime dinâmico mais severo, no qual a frenagem influencia diretamente a resposta lateral do veículo.

Por fim, a Figura 22 apresenta a variação das características na condição de operação Condução Aleatória. Diferentemente das demais condições, observa-se um comportamento altamente variável e não periódico em todas as grandezas analisadas. O ângulo de esterçamento apresenta oscilações de diferentes amplitudes e durações, sem um padrão repetitivo bem definido, refletindo a diversidade de manobras realizadas. A velocidade longitudinal exibe sucessivas acelerações e desacelerações, enquanto a velocidade lateral assume valores variados, indicando a alternância entre trechos retilíneos, curvas suaves e manobras mais severas. As acelerações longitudinal e lateral apresentam ampla variabilidade, com picos distribuídos ao longo




Figura 21 – Variação das Características da Condição de Operação Curvas Constantes com Fre-nagem

de todo o ensaio, caracterizando uma condição de elevada excitação dinâmica do sistema. Essa condição resulta em um conjunto de dados diversificado, representativo de múltiplos regimes de operação veicular.




Figura 22 – Variação das Características da Condição de Operação Direção Aleatória

APÊNDICE C – RELAÇÃO HISTERÉTICA ENTRE A FORÇA LATERAL E O ÂNGULO DE DESLIZAMENTO LATERAL DO VEÍCULO

Como apresentado na seção de dinâmica veicular do referencial teórico, a força lateral F_y das rodas do veículo está fortemente associada ao ângulo de deriva α . Por sua vez, o ângulo de deslizamento lateral do veículo (β) resulta da contribuição combinada dos ângulos de deriva individuais de cada pneu, além de outras variáveis relacionadas à dinâmica do veículo.

Os pneus veiculares, por terem a borracha como principal elemento estrutural, apresentam comportamento de deformação viscoelástica. Esse comportamento implica que a resposta do pneu não depende apenas das forças aplicadas instantaneamente, mas também do histórico de deformação, bem como de fatores como tempo e temperatura.

Em função dessa característica viscoelástica, a relação entre a força lateral F_y e o ângulo de deriva α apresenta comportamento histerético, especialmente sob condições dinâmicas. Considerando que o ângulo de deslizamento lateral do veículo β está diretamente correlacionado aos ângulos de deriva dos pneus, e que o banco de dados utilizado não disponibiliza a medição direta de α , esta seção propõe a análise do comportamento histerético a partir da relação entre F_y e β .

As Figuras 23 e 24 apresentam a relação entre a força lateral F_y e o ângulo de deslizamento lateral β para as quatro rodas do veículo durante as manobras de *Double Lane Change* e *Slalom*, respectivamente, ambas realizadas à velocidade de 60 kph. Observa-se graficamente a formação de laços característicos, indicando a presença de histerese entre as duas variáveis analisadas. O espalhamento e irregularidades observadas nas curvas $F_y \times \beta$ é esperado, uma vez que o ângulo de deslizamento lateral β representa um estado global do veículo, influenciado por múltiplas variáveis dinâmicas. Dessa forma, diferentes condições de operação dos pneus podem resultar em valores distintos de F_y para um mesmo β , conferindo maior dispersão ao comportamento observado.




Figura 23 – Relação histerética de F_y e β dos quatro pneus na condição de operação *Double Lane Change*.




Figura 24 – Relação histerética de F_y e β dos quatro pneus na condição de operação *Slalom*.

ANEXOS

ANEXO A – VALORES DE θ DOS MODELOS NARX/FIRTabela 1 – Valores dos Parâmetros θ para os Modelos NARX/FIR Multi Atrasos do pneu Dianteiro Direito

θ_i	F_x	F_y	F_z
θ_1	$-2,13884 \times 10^{-01}$	$-2,68973 \times 10^{+00}$	$5,55817 \times 10^{+00}$
θ_2	$-1,15739 \times 10^{+01}$	$-1,23614 \times 10^{+02}$	$-1,17005 \times 10^{+07}$
θ_3	$3,87965 \times 10^{+03}$	$-1,93638 \times 10^{+02}$	$-6,22846 \times 10^{+04}$
θ_4	$4,19148 \times 10^{+01}$	$-2,34701 \times 10^{+00}$	$-5,61594 \times 10^{+01}$
θ_5	$5,80995 \times 10^{+01}$	$7,98927 \times 10^{+08}$	$-1,22242 \times 10^{+01}$
θ_6	$-6,88663 \times 10^{+02}$	$3,45026 \times 10^{+01}$	$-3,78993 \times 10^{+01}$
θ_7	$3,37029 \times 10^{+01}$	$2,14046 \times 10^{+03}$	$4,00791 \times 10^{+00}$
θ_8	$-2,38225 \times 10^{+01}$	$-3,31731 \times 10^{+01}$	$8,96298 \times 10^{+00}$
θ_9	$4,63593 \times 10^{-02}$	$1,23773 \times 10^{+02}$	$-6,65713 \times 10^{+02}$
θ_{10}	$3,12006 \times 10^{+02}$	$2,09826 \times 10^{+10}$	$1,08213 \times 10^{+02}$
θ_{11}	$2,63033 \times 10^{+01}$	$3,60061 \times 10^{+04}$	$9,59680 \times 10^{+00}$
θ_{12}	$-4,32185 \times 10^{+01}$	$-1,28377 \times 10^{+02}$	$-2,44313 \times 10^{+01}$
θ_{13}	$1,66556 \times 10^{+00}$	$1,31036 \times 10^{+01}$	$-1,55604 \times 10^{+01}$
θ_{14}	$6,27125 \times 10^{+02}$	$3,90295 \times 10^{+08}$	$1,03141 \times 10^{+02}$
θ_{15}	$2,01385 \times 10^{+01}$	$1,59403 \times 10^{+01}$	$-2,98292 \times 10^{-02}$
θ_{16}	$-6,50849 \times 10^{+01}$	$-8,98874 \times 10^{+01}$	$-6,62275 \times 10^{+02}$
θ_{17}	$1,17927 \times 10^{-01}$	$1,74646 \times 10^{+02}$	$5,38049 \times 10^{-01}$
θ_{18}	$2,05768 \times 10^{+00}$	$2,04363 \times 10^{+03}$	$-4,49555 \times 10^{+01}$
θ_{19}	$-4,83482 \times 10^{+07}$	$3,41979 \times 10^{-01}$	$1,20939 \times 10^{+01}$
θ_{20}	$-4,02247 \times 10^{+01}$	$2,73401 \times 10^{+02}$	$-1,59514 \times 10^{+01}$
θ_{21}	$-3,85525 \times 10^{+01}$	$-7,35993 \times 10^{+02}$	$-1,35221 \times 10^{+01}$

Tabela 2 – Valores dos Parâmetros θ para os Modelos NARX/FIR um Atraso do pneu Dianteiro Direito

θ_i	F_x	F_y	F_z
θ_1	$-5,06895 \times 10^{-02}$	$-4,14499 \times 10^{+00}$	$4,78336 \times 10^{+00}$
θ_2	$-1,64582 \times 10^{+03}$	$5,54841 \times 10^{+01}$	$9,80404 \times 10^{+01}$
θ_3	$-3,11855 \times 10^{+01}$	$6,42260 \times 10^{-01}$	$-7,53968 \times 10^{+01}$
θ_4	$-3,21145 \times 10^{+01}$	$4,84365 \times 10^{+00}$	$-7,41904 \times 10^{+00}$
θ_5	$5,26137 \times 10^{+01}$	$8,17853 \times 10^{+01}$	$-6,03091 \times 10^{+01}$
θ_6	$-1,10579 \times 10^{+02}$	$-6,04675 \times 10^{+01}$	$-5,12378 \times 10^{+01}$
θ_7	$-6,99974 \times 10^{+01}$	$1,02685 \times 10^{+02}$	$1,03044 \times 10^{+02}$
θ_8	$-2,87588 \times 10^{+01}$	$2,35904 \times 10^{+00}$	$1,05460 \times 10^{+02}$
θ_9	$4,97042 \times 10^{+01}$	$-7,66864 \times 10^{+01}$	$2,59402 \times 10^{+00}$
θ_{10}	$5,09516 \times 10^{+01}$	$1,46680 \times 10^{+03}$	$-4,32780 \times 10^{+03}$
θ_{11}	$2,49715 \times 10^{+04}$	$-5,23862 \times 10^{+01}$	$-1,93757 \times 10^{+01}$
θ_{12}	$3,04198 \times 10^{+01}$	$2,08105 \times 10^{+02}$	$1,28818 \times 10^{+01}$
θ_{13}	$1,82293 \times 10^{+01}$	$4,94598 \times 10^{+01}$	$-5,72947 \times 10^{+01}$
θ_{14}	$-1,50880 \times 10^{+01}$	$-1,06573 \times 10^{+02}$	$-8,91845 \times 10^{+02}$
θ_{15}	$1,11560 \times 10^{+01}$	$-5,20902 \times 10^{+02}$	$-1,48728 \times 10^{+02}$
θ_{16}	$-7,34722 \times 10^{+01}$	$1,56287 \times 10^{+03}$	$2,57963 \times 10^{+03}$
θ_{17}	$-3,16544 \times 10^{+01}$	$1,36904 \times 10^{+01}$	$7,20304 \times 10^{+01}$
θ_{18}	$-6,68169 \times 10^{+00}$	$3,68485 \times 10^{+01}$	$4,50860 \times 10^{+03}$
θ_{19}	$2,64641 \times 10^{+01}$	$2,70479 \times 10^{+08}$	$-6,27535 \times 10^{+01}$
θ_{20}	$2,30245 \times 10^{+01}$	$-7,98378 \times 10^{+01}$	$2,36766 \times 10^{+02}$
θ_{21}	$-1,23122 \times 10^{+01}$	$-1,01061 \times 10^{+02}$	$-2,91587 \times 10^{+01}$

ANEXO B – USO DAS CARACTERÍSTICAS POR INTERVALO DE ROTAÇÃO DOS PNEUS




Figura 25 – Uso das Características no Intervalo $\pm 20^\circ$ de Rotação do Pneu Dianteiro Direito




Figura 26 – Uso das Características no Intervalo $\pm 35^\circ$ de Rotação do Pneu Dianteiro Direito




Figura 27 – Uso das Características no Intervalo $\pm 20^\circ$ de Rotação do Pneu Traseiro Esquerdo




Figura 28 – Uso das Características no Intervalo $\pm 35^\circ$ de Rotação do Pneu Traseiro Esquerdo




Figura 29 – Uso das Características no Intervalo $\pm 20^\circ$ de Rotação do Pneu Traseiro Direito




Figura 30 – Uso das Características no Intervalo $\pm 35^\circ$ de Rotação do Pneu Traseiro Direito

ANEXO C – COMPARATIVO GRÁFICO ENTRE PREDIÇÃO TEMPORAL E REAL DAS FORÇAS EM DIFERENTES CONDIÇÕES DE OPERAÇÃO




Figura 31 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Curvas Constantes com Frenagens do Pneu Dianteiro Esquerdo




Figura 32 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Curvas Constantes do Pneu Dianteiro Esquerdo




Figura 33 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Direção em Linha Reta do Pneu Dianteiro Esquerdo




Figura 34 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Direção Aleatória do Pneu Dianteiro Esquerdo




Figura 35 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Curvas Constantes do Pneu Traseiro Esquerdo




Figura 36 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Direção em Linha Reta do Pneu Traseiro Esquerdo




Figura 37 – Comparativo Entre Predição e valor Real das Forças Na Condição de Operação Direção Aleatória do Pneu Traseiro Esquerdo

ANEXO D – VARIAÇÃO DAS ACELERAÇÕES NO PNEU INTELIGENTE POR ÂNGULO DE ROTAÇÃO




Figura 38 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação *Double Lane Change*




Figura 39 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação *Double Lane Change*




Figura 40 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação *Double Lane Change*




Figura 41 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação *Double Lane Change*




Figura 42 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação *Double Lane Change*




Figura 43 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação *Double Lane Change*




Figura 44 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção em Linha Reta




Figura 45 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção em Linha Reta




Figura 46 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção em Linha Reta




Figura 47 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção em Linha Reta




Figura 48 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção em Linha Reta




Figura 49 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção em Linha Reta




Figura 50 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação *Slalom*




Figura 51 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação *Slalom*




Figura 52 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação *Slalom*




Figura 53 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação *Slalom*




Figura 54 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação *Slalom*




Figura 55 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação *Slalom*




Figura 56 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens




Figura 57 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens




Figura 58 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens




Figura 59 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens




Figura 60 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens




Figura 61 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes com Frenagens




Figura 62 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes




Figura 63 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes




Figura 64 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Curvas Constantes




Figura 65 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes




Figura 66 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes




Figura 67 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Curvas Constantes




Figura 68 – Acelerações em X do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção Aleatória




Figura 69 – Acelerações em Y do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção Aleatória




Figura 70 – Acelerações em Z do Pneu Inteligente Dianteiro Esquerdo Na Condição de Operação Direção Aleatória




Figura 71 – Acelerações em X do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção Aleatória




Figura 72 – Acelerações em Y do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção Aleatória




Figura 73 – Acelerações em Z do Pneu Inteligente Traseiro Esquerdo Na Condição de Operação Direção Aleatória

REFERÊNCIAS

- AGUIRRE, L. A. **Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais**. 4. ed. [S.l.]: Editora UFMG, 2015.
- AHMAD, N. *et al.* Reviews on various inertial measurement unit (imu) sensor applications. **International Journal of Signal Processing Systems**, v. 1, n. 2, p. 256–262, 2013.
- AKIBA, T. *et al.* Optuna: A next-generation hyperparameter optimization framework. In: **Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. [S.l.: s.n.], 2019.
- ARI, D.; ALAGÖZ, B. B. A review of genetic programming: Popular techniques, fundamental aspects, software tools and applications. **Sakarya University Journal of Science**, Sakarya University, v. 25, n. 2, p. 397–416, 2021.
- BARBOSA, B. H. G. *et al.* Lateral force prediction using gaussian process regression for intelligent tire systems. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, IEEE, v. 52, n. 8, p. 5332–5343, 2021.
- BENGIO, Y. *et al.* **Deep learning**. [S.l.]: MIT press Cambridge, MA, USA, 2017. v. 1.
- BISHOP, C. M.; NASRABADI, N. M. **Pattern recognition and machine learning**. [S.l.]: Springer, 2006. v. 4.
- CAI, Z.; CHEN, B.; YANG, J. Adaptive least-squares methods for convection-dominated diffusion-reaction problems. **Computers & Mathematics with Applications**, Elsevier, v. 173, p. 141–150, 2024.
- CASTRO, H. C. d. A modified mggp algorithm for structure selection of narmax models. 2021.
- CASTRO, H. C. de; BARBOSA, B. H. G. Multi-gene genetic programming for structure selection of polynomial narmax models. In: **Congresso Brasileiro de Automática-CBA**. [S.l.: s.n.], 2020. v. 2, n. 1.
- CLOSE, C. M.; FREDERICK, D. K.; NEWELL, J. C. **Modeling and analysis of dynamic systems**. [S.l.]: John Wiley & Sons, 2001.
- CLOVER, C.; BERNARD, J. Longitudinal tire dynamics. **Vehicle system dynamics**, Taylor & Francis, v. 29, n. 4, p. 231–260, 1998.
- Continental. **ContiSense and ContiAdapt - Concept Tires**. 2025. Acesso em: 19 nov. 2025. Disponível em: <https://www.continental-tires.com/about/technologies-and-innovations/concept-tires/ContiSense-ContiAdapt/>.
- CUNHA, B.; FERREIRA, D. D.; BARBOSA, B. H. Desenvolvimento de soft sensor para poços de petróleo usando mggp. **XVI Brazilian Conference on Computational Intelligence**, 2023.
- CURRERI, F.; PATANE, L.; XIBILIA, M. G. Soft sensor transferability: A survey. **Applied Sciences**, MDPI, v. 11, n. 16, p. 7710, 2021.

- DERNER, E. *et al.* Constructing parsimonious analytic models for dynamic systems via symbolic regression. **Applied Soft Computing**, Elsevier, v. 94, p. 106432, 2020.
- DEY, R.; SALEM, F. M. Gate-variants of gated recurrent unit (gru) neural networks. In: IEEE. **2017 IEEE 60th international midwest symposium on circuits and systems (MWSCAS)**. [S.l.], 2017. p. 1597–1600.
- FAISAL, A. *et al.* Understanding autonomous vehicles. **Journal of transport and land use**, JSTOR, v. 12, n. 1, p. 45–72, 2019.
- FUJIWARA, K.; KANO, M.; HASEBE, S. Development of correlation-based pattern recognition algorithm and adaptive soft-sensor design. **Control Engineering Practice**, Elsevier, v. 20, n. 4, p. 371–378, 2012.
- GANDOMI, A. H.; ALAVI, A. H. A new multi-gene genetic programming approach to nonlinear system modeling. part i: materials and structural engineering problems. **Neural Computing and Applications**, Springer, v. 21, n. 1, p. 171–187, 2012.
- GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems**. [S.l.]: "O'Reilly Media, Inc.", 2022.
- GREENWOOD, P. M.; LENNEMAN, J. K.; BALDWIN, C. L. Advanced driver assistance systems (adas): Demographics, preferred sources of information, and accuracy of adas knowledge. **Transportation research part F: traffic psychology and behaviour**, Elsevier, v. 86, p. 131–150, 2022.
- HARVEY, C. *et al.* Lessons from natural flight for aviation: then, now and tomorrow. **Journal of experimental biology**, The Company of Biologists Ltd, v. 226, n. Suppl_1, p. jeb245409, 2023.
- HE, J.; ROJAS, C. R.; HJALMARSSON, H. A weighted least-squares method for non-asymptotic identification of markov parameters from multiple trajectories. **arXiv preprint arXiv:2405.04258**, 2024.
- HIRSCHFELD, P. A.; MALVEZZI, F. Modelagem e análise da dinâmica veicular para avaliação de dirigibilidade. 2022.
- IGNATIOUS, H. A.; KHAN, M. *et al.* An overview of sensors in autonomous vehicles. **Procedia Computer Science**, Elsevier, v. 198, p. 736–741, 2022.
- JAZAR, R. N. **Vehicle dynamics: theory and application**. [S.l.]: Springer Nature, 2025.
- JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**, American Association for the Advancement of Science, v. 349, n. 6245, p. 255–260, 2015.
- KEESMAN, K. J. **System identification: an introduction**. [S.l.]: Springer Science & Business Media, 2011.
- KHAN, M. E.; KHAN, F. A comparative study of white box, black box and grey box testing techniques. **International Journal of Advanced Computer Science and Applications**, Science and Information (SAI) Organization Limited, v. 3, n. 6, 2012.

KIM, I. *et al.* Nanophotonics for light detection and ranging technology. **Nature nanotechnology**, Nature Publishing Group UK London, v. 16, n. 5, p. 508–524, 2021.

KONG, D. *et al.* Vehicle lateral velocity estimation based on long short-term memory network. **World electric vehicle journal**, MDPI, v. 13, n. 1, p. 1, 2021.

LANHAM, M. **Evolutionary Deep Learning: Genetic algorithms and neural networks**. [S.l.]: Simon and Schuster, 2023.

LE-YI, W.; WEN-XIAO, Z. System identification: new paradigms, challenges, and opportunities. **Acta Automatica Sinica**, Elsevier, v. 39, n. 7, p. 933–942, 2013.

LI, F. *et al.* Two infill criteria driven surrogate-assisted multi-objective evolutionary algorithms for computationally expensive problems with medium dimensions. **Swarm and Evolutionary Computation**, Elsevier, v. 60, p. 100774, 2021.

LJUNG, L. *et al.* Deep learning and system identification. **IFAC-PapersOnLine**, Elsevier, v. 53, n. 2, p. 1175–1181, 2020.

Michelin. **Michelin Track Connect**. 2025. Acesso em: 19 nov. 2025. Disponível em: <https://africa.michelin.com/en/auto/home-auto/michelin-track-connect>.

Michelin. **Track Connect: The Smart Tire System**. 2025. Acesso em: 19 nov. 2025. Disponível em: <https://www.michelinman.com/auto/why-michelin/technological-innovations/trackconnect>.

MORONEY, L. **Ai and machine learning for coders**. [S.l.]: O'Reilly Media, 2020.

MOTA, F. L. de O.; CASTRO, H. C. de; BARBOSA, B. H. G. Identificação de um sistema de bomba hidráulica utilizando mggp multi-objetivo. In: **Simpósio Brasileiro de Automação Inteligente-SBAI**. [S.l.: s.n.], 2021. v. 1, n. 1.

NORGAARD, M. *et al.* **Neural networks for modelling and control of dynamic systems: a practitioner's handbook**. [S.l.]: Springer, 2000. v. 1.

NOSOUHIAN, S.; NOSOUHIAN, F.; KHOSHOUEI, A. K. A review of recurrent neural network architecture for sequence learning: Comparison between lstm and gru. Preprints, 2021.

OGATA, K. **Modern control engineering**. [S.l.]: Prentice hall, 2010.

ORUH, J.; VIRIRI, S.; ADEGUN, A. Long short-term memory recurrent neural network for automatic speech recognition. **IEEE Access**, IEEE, v. 10, p. 30069–30079, 2022.

PACEJKA, H. **Tire and vehicle dynamics**. [S.l.]: Elsevier, 2005.

PEREIRA, P. A. G. d. S. **Revisão da literatura aprofundada e atual sobre o Sistema Global de Navegação por Satélite (GNSS)**. Tese (Doutorado), 2023.

Pirelli. **Pirelli Cyber Tyre é premiado como a tecnologia de pneus mais inovadora no AutoTech Breakthrough Awards 2024**. 2024. Acesso em: 19 nov. 2025. Disponível em: <https://www.pirelli.com/tyres/pt-br/news/2025/10/13/pirelli-cyber-tyre-e-premiado-como-a-tecnologia-de-pneus-mais-inovadora-no-autotech-breakthrough-aw>

Pirelli. **Pneus inteligentes: Bosch e Pirelli unem suas forças**. 2025. Acesso em: 19 nov. 2025. Disponível em: <https://www.pirelli.com/global/pt-br/road/carros/pneus/pneus-inteligentes-bosch-e-pirelli-unem-suas-forcas-148296/>.

QUAN, Z. *et al.* Tire-road friction coefficient estimation method design for intelligent tires equipped with pvdf piezoelectric film sensors. **Sensors and Actuators A: Physical**, Elsevier, v. 349, p. 114007, 2023.

RAJAMANI, R. **Vehicle dynamics and control**. [S.l.]: Springer Science & Business Media, 2011.

RIBEIRO, A. H.; AGUIRRE, L. A. Shooting methods for parameter estimation of output error models. **IFAC-PapersOnLine**, Elsevier, v. 50, n. 1, p. 13998–14003, 2017.

RILL, G.; CASTRO, A. A. **Road vehicle dynamics: fundamentals and modeling with MATLAB®**. [S.l.]: Crc Press, 2020.

SAE International. **SAE Levels of Driving Automation™ Clarity and Refinements**. 2021. Acesso em: 19 nov. 2025. Disponível em: <https://www.sae.org/news/blog/sae-levels-driving-automation-clarity-refinements>.

SANTOS, R. A. d. *et al.* Classificação de superfície de rodovias utilizando técnicas de aprendizado de máquinas em pneus inteligentes. In: **XVII Congresso Brasileiro de Inteligência Computacional**. [S.l.: s.n.], 2025. v. 1, p. 1–8. CBIC2025.

SANTOS, R. A. d. *et al.* Multi-gene genetic programming para modelagem MIMO não linear das vibrações de uma aeronave F16 no solo. In: **XVII Simpósio Brasileiro de Automação Inteligente**. São João Del Rey: [s.n.], 2025. v. 1, p. 1–8. SBAI2025.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. **Neural networks**, Elsevier, v. 61, p. 85–117, 2015.

SCHWEIGER, G. *et al.* Modeling and simulation of large-scale systems: A systematic comparison of modeling paradigms. **Applied Mathematics and Computation**, Elsevier, v. 365, p. 124713, 2020.

SHAOSEN, S. *et al.* Enhancing battery health estimation using model selection criteria-based genetic programming. **Journal of Energy Storage**, Elsevier, v. 102, p. 114077, 2024.

SOUZA, F. A.; ARAÚJO, R.; MENDES, J. Review of soft sensor methods for regression applications. **Chemometrics and Intelligent Laboratory Systems**, Elsevier, v. 152, p. 69–79, 2016.

TIGADI, A. *et al.* Advanced driver assistance systems. **International Journal of Engineering Research and General Science**, v. 4, n. 3, p. 151–158, 2016.

VARGAS, J. *et al.* An overview of autonomous vehicles sensors and their vulnerability to weather conditions. **Sensors**, MDPI, v. 21, n. 16, p. 5397, 2021.

VARGHESE, J. Z.; BOONE, R. G. *et al.* Overview of autonomous vehicle sensors and systems. In: SN. **International Conference on Operations Excellence and Service Engineering**. [S.l.], 2015. v. 2015.

VIEHWEGER, M. *et al.* Vehicle state and tyre force estimation: demonstrations and guidelines. **Vehicle system dynamics**, Taylor & Francis, v. 59, n. 5, p. 675–702, 2021.

WILLIAMS, B. Automated driving levels. Wiley-IEEE Press, 2021.

WIRSANSKY, E. **Hands-On Genetic Algorithms with Python: Applying genetic algorithms to solve real-world deep learning and artificial intelligence problems**. [S.l.]: Packt Publishing Ltd, 2020.

XIAO, L.; GAO, F. A comprehensive review of the development of adaptive cruise control systems. **Vehicle system dynamics**, Taylor & Francis, v. 48, n. 10, p. 1167–1192, 2010.

XIONG, Y.; YANG, X. A review on in-tire sensor systems for tire-road interaction studies. **Sensor review**, Emerald Publishing Limited, v. 38, n. 2, p. 231–238, 2018.

XU, N.; ASKARI, H.; KHAJEPOUR, A. **Intelligent Tire Systems**. [S.l.]: Springer, 2022.

XU, N. *et al.* Tire slip angle estimation based on the intelligent tire technology. **IEEE transactions on vehicular technology**, IEEE, v. 70, n. 3, p. 2239–2249, 2021.

XU, N. *et al.* Tire slip state estimation under combined conditions using intelligent tire technology. **IEEE Transactions on Instrumentation and Measurement**, IEEE, 2025.

XU, N. *et al.* A soft sensor for estimating tire cornering properties for intelligent tires. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, IEEE, v. 53, n. 10, p. 6056–6066, 2023.

YAN, Z. *et al.* High-dimensional expensive optimization by kriging-assisted multiobjective evolutionary algorithm with dimensionality reduction. **Information Sciences**, Elsevier, p. 121620, 2024.

YEONG, D. J. *et al.* Sensor and sensor fusion technology in autonomous vehicles: A review. **Sensors**, MDPI, v. 21, n. 6, p. 2140, 2021.