



RHUAN CARLOS SILVA DE SOUZA

**PREDIÇÃO DA FORÇA LATERAL EM PNEUS INTELIGENTES
A PARTIR DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA**

LAVRAS – MG

2025

RHUAN CARLOS SILVA DE SOUZA

**PREDIÇÃO DA FORÇA LATERAL EM PNEUS INTELIGENTES A PARTIR DE TÉCNICAS DE
APRENDIZAGEM DE MÁQUINA**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em 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. Danton Diego Ferreira

Coorientador

LAVRAS – MG

2025

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Souza, Rhuan Carlos Silva

Predição da força lateral em pneus inteligentes a partir de técnicas de aprendizagem de máquina / Rhuan Carlos Silva de Souza. 2025.

101 p. : il.

Orientador: Prof. Dr. Bruno Henrique Groenner Barbosa.

Coorientador: Prof. Dr. Danton Diego Ferreira.

Dissertação(mestrado acadêmico)- Universidade Federal de Lavras, 2025.

Bibliografia.

1. pneus inteligentes. 2. aprendizagem de máquina. 3. decomposição de modo empírico. I. Barbosa, Bruno Henrique Groenner. II. Ferreira, Danton Diego. III. Título.

RHUAN CARLOS SILVA DE SOUZA

PREDIÇÃO DA FORÇA LATERAL EM PNEUS INTELIGENTES A PARTIR DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA

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

APROVADA em 28 de Agosto de 2024.

Prof. Dr. Bruno Henrique Groenner Barbosa	UFLA
Prof. Dr. Danton Diego Ferreira	UFLA
Prof. Dr. Murillo Ferreira dos Santos	CEFET-MG
Prof. Dr. Daniel Augusto Pereira	UFLA

Documento assinado digitalmente
 **BRUNO HENRIQUE GROENNER BARBOSA**
Data: 02/04/2025 14:59:49-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Bruno Henrique Groenner Barbosa
Orientador

Prof. Dr. Danton Diego Ferreira
Co-Orientador

LAVRAS – MG
2025

RESUMO

Pneus inteligentes são pneus que apresentam sensores em sua estrutura capazes de comunicar com os sistemas avançados de assistência ao motorista para fins de estimação de parâmetros e estados dos veículos. Este projeto tem como objetivo obter um modelo para estimar a força lateral em um pneu inteligente por meio de técnicas de Aprendizagem de Máquina, a partir de sinais de aceleração medidos, onde estes sinais de aceleração apresentam níveis elevados de ruídos que impactam o processo de estimação. Para isso, é proposta a reconstrução do sinal a partir do uso da heurística adaptativa EMD (*Empirical Mode Decomposition*) para cada rotação do pneu, com configurações distintas que consideram a aplicação opcional de um filtro *Butterworth* passa-baixa a 400Hz. A reconstrução dos sinais foi aplicada nos sinais de aceleração nos eixos x , y e z correspondentes a aproximadamente uma volta completa do pneu (0° e $359,5^\circ$), mas também para uma faixa da rotação do pneu ($145,5^\circ$ e $215,0^\circ$) correspondente a valores mais próximos da região de contato do pneu com solo. Assim, para avaliar cada configuração proposta foram utilizados os modelos de aprendizagem de máquina *Random Forest* (**RF**) e *Gaussian Process Regression* (**GPR**) para estimação da força lateral e as métricas NRMS (*Normalize Root Mean Square Error*) e coeficiente de determinação r^2 para verificar o desempenho de cada modelo de aprendizagem proposto. Os dois melhores modelos encontrado ao aplicar o **RF** e **GPR**, destacando-se os que incorporam a etapa de reconstrução de sinais e uso de informação fora da região de contato pneu-solo, apresentaram NRMSE iguais a 16,33% e 16,57%, respectivamente, e r^2 de 0,91 e 0,90, respectivamente. Estes resultados ressaltam a capacidade dos modelos de explicar a força lateral a partir dos sinais de aceleração, evidenciando a importância dos dados coletados fora da região de contato pneu-solo. Comparados aos resultados de Barbosa et al. (2022), os modelos demonstraram desempenho robusto, especialmente os que integraram a reconstrução dos sinais por meio da EMD, destacando seu potencial na melhora da predição da força lateral.

Palavras-chave: Pneus Inteligentes, decomposição de modo empírico, floresta aleatória, regressão do processo gaussiano

ABSTRACT

Intelligent tires are tires that feature sensors within their structure capable of communicating with advanced driver assistance systems for the purpose of estimating parameters and states of vehicles. This project aims to develop a model to estimate the lateral force in a intelligent tire using Machine Learning techniques, based on measured acceleration signals, which exhibit high levels of noise that impact the estimation process. To achieve this, the reconstruction of the signal is proposed through the use of the adaptive heuristic EMD (*Empirical Mode Decomposition*) for each tire rotation, with distinct configurations that optionally consider the application of a low-pass *Butterworth* filter at 400Hz. The reconstruction of the signals was applied to the acceleration signals along the x , y , and z axes corresponding to approximately one complete tire rotation (0° to 359.5°), as well as to a specific rotation interval of the tire (145.5° to 215.0°) that aligns more closely with the contact region of the tire with the ground. To evaluate each proposed configuration, Machine Learning models such as *Random Forest* (**RF**) and *Gaussian Process Regression* (**GPR**) were used to estimate the lateral force, with NRMSE (*Normalized Root Mean Square Error*) and the coefficient of determination r^2 metrics to assess the performance of each proposed learning model. The two best models obtained using **RF** and **GPR**, particularly those incorporating the signal reconstruction step and information from outside the tire-ground contact region, exhibited NRMSEs of 16.33% and 16.57%, respectively, with r^2 values of 0.91 and 0.90, respectively. These results highlight the models' ability to explain the lateral force based on acceleration signals, emphasizing the significance of data collected outside the tire-ground contact region. Compared to the results of Barbosa et al. (2022), the models demonstrated robust performance, especially those integrating signal reconstruction via EMD, underscoring its potential in improving the prediction of lateral force.

Keywords: *Intelligent tires, empirical mode decomposition, random forest regression, gaussian process regression*

INDICADORES DE IMPACTO

Este trabalho apresenta um significativo impacto social ao abordar a segurança viária, considerando que os acidentes rodoviários são uma das principais causas de morte em todo o mundo, com previsões que colocam essa estatística entre as cinco maiores até 2030. Com um custo econômico de cerca de 3% do produto interno bruto na maioria dos países, a pesquisa sobre sistemas de assistência ao motorista (ADAS) e pneus inteligentes se torna essencial. Ao desenvolver uma metodologia para modelar e prever as forças laterais na interação pneu-solo, utilizando técnicas de aprendizado de máquina, o trabalho não apenas visa melhorar a segurança veicular, mas também possibilita um avanço tecnológico significativo na comunicação entre veículos e suas condições operacionais. A introdução de pneus inteligentes, que atuam como uma fonte ativa de informação, potencializa o controle e a eficácia dos ADAS, permitindo uma resposta mais rápida e precisa em situações críticas. Os resultados obtidos podem influenciar positivamente as comunidades, especialmente em áreas com alta incidência de acidentes, ao reduzir o número de fatalidades e lesões, além de otimizar a mobilidade urbana. Além disso, as inovações propostas têm o potencial de impulsionar a indústria automotiva em direção a uma era mais sustentável e segura, beneficiando a economia local através da criação de empregos e fomento a novas tecnologias, enquanto promove uma cultura de conscientização sobre a segurança nas estradas. As estimativas de melhorias na segurança rodoviária e a preservação da vida humana refletem o valor social intrínseco deste trabalho, destacando sua relevância para a sociedade contemporânea e futura.

IMPACT INDICATORS

This work presents a significant social impact by addressing road safety, considering that road accidents are one of the leading causes of death worldwide, with projections placing this statistic among the top five by 2030. With an economic cost of around 3% of the gross domestic product in most countries, research on Advanced Driver Assistance Systems (ADAS) and intelligent tires becomes essential. By developing a methodology to model and predict lateral forces in the tire-road interaction, using machine learning techniques, the work not only aims to improve vehicle safety but also enables a significant technological advancement in communication between vehicles and their operating conditions. The introduction of intelligent tires, which act as an active source of information, enhances the control and effectiveness of ADAS, allowing for a faster and more accurate response in critical situations. The results obtained can positively influence communities, especially in areas with a high incidence of accidents, by reducing the number of fatalities and injuries, as well as optimizing urban mobility. Additionally, the proposed innovations have the potential to drive the automotive industry towards a more sustainable and safe era, benefiting the local economy through job creation and the promotion of new technologies, while fostering a culture of awareness about road safety. The estimated improvements in road safety and the preservation of human life reflect the intrinsic social value of this work, highlighting its relevance for contemporary and future society.

LISTA DE FIGURAS

Figura 1.1 – Ilustração da região de contato pneu-solo (<i>contact patch</i>).	16
Figura 2.1 – Sistema de coordenadas de um veículo de quatro rodas	19
Figura 2.2 – Sistema de coordenada de forças atuantes em um pneu	21
Figura 2.3 – Distribuição da força F_z sobre a área de contato em um pneu em repouso	22
Figura 2.4 – Distribuição da força normal F_z sobre a área de contato em um pneu em movimento com ω sendo a velocidade angular do pneu	22
Figura 2.5 – Pneu sobre ação de um força lateral	23
Figura 2.6 – Relação força lateral,vertical e ângulo de deriva	23
Figura 2.7 – Exemplo de curva de resposta do filtro <i>Butterworth</i> passa-baixa com frequência de corte igual a 400 Hz, marcado pela linha vertical em verde	28
Figura 2.8 – Exemplo de processo de <i>sifting</i> ou peneiração realizado pelo o algoritmo EMD a partir de um sinal qualquer. a) é o sinal original $x(t)$ a ser decomposto em IMF's. b) é a identificação dos extremos superiores, pontos em azul, e inferior, pontos em vermelhos. c) é a representação dos envelopes, $u_{ki}(t)$ e $l_{ki}(t)$ gerados e com o valor médio, m_{ki} , gerado a partir destes envelopes.	31
Figura 2.9 – Exemplo de árvore de regressão com a finalidade de demonstração, em que o conjunto de dados apresenta somente uma única <i>feature</i> que é J	34
Figura 3.1 – Sistema de testes e aquisição de dados de pneus inteligentes, em que o acelerômetro tria-axial apresentado na figura está acoplado no interior do pneu.	41
Figura 3.2 – Sinais de entrada para a geração dos sinais de aceleração e força lateral do conjunto de treinamento. Na qual apresenta os seguintes sinais: a)Ângulo de de deriva em graus variando de forma triangular aplicada ao pneu; b)Velocidade linear do pneu em km/h de rolamento do pneu variando ao longo das rotações; c) Força vertical F_z em N aplicada sobre o pneu, medida obtida a partir do ensaio realizado por (BARBOSA et al., 2022).	43
Figura 3.3 – Janelas de dados dentro e fora da região de contato. As áreas que estão fora da região de contato estão tracejada em preto, já a região tracejada em rosa corresponde à região dentro do <i>contact patch</i> onde a variável <i>tag</i> recebe o valor unitário.	44

Figura 3.4 – Sinais de entrada para a geração do conjunto de dados de validação, na qual apresenta os seguintes sinais: a) Ângulo de deriva variando em degraus ao longo das rotações de um pneu; b) Velocidade linear do pneu em km/h de rolamento do pneu variando ao longo das rotações; c) Força vertical F_z em N aplicada sobre o pneu, medida obtida a partir do ensaio realizado por (BARBOSA et al., 2022).	45
Figura 3.5 – Forças laterais (F_y) do sinal medido para o conjunto de dados de treinamento e de validação, em que: a) é a força lateral medida para os dados de treinamento; b) força lateral do conjunto de dados de validação.	46
Figura 3.6 – Fluxograma da metodologia de análise, cujo objetivo é entender o comportamento das IMF's do sinal após a filtragem por um filtro PB de 400 Hz.	48
Figura 3.7 – Fluxograma da metodologia de análise, cujo objetivo é estudar o comportamento das IMF's para o sinal sem nenhum tratamento anterior.	48
Figura 3.8 – Definição de um ciclo completo do pneu. As amostras dentro da área tracejada correspondem a um ciclo completo do pneu.	50
Figura 3.9 – Representação dos sinais de aceleração típicos nos eixos x, y e z para uma situação onde há ocorrência mínima de ruído para um tempo qualquer.	52
Figura 3.10 – Fluxograma da metodologia proposta para o processo de estimação da força lateral(F_y). .	53
Figura 3.11 – Demonstração do processo de codificação para obtenção de 720 pontos para cada sinal de aceleração, esses pontos correspondem aos ângulos de rotação do pneu entre 0° à $359,5^\circ$, na qual são os atributos e dados de entrada dos modelos de aprendizagem de máquina. A linha tracejada preta apresenta a "janela"de dados de um ciclo completo do pneu e que esses pontos são extraídos.	56
Figura 3.12 – Demonstração do processo de codificação para obtenção de 140 pontos para cada sinal de aceleração, esses pontos correspondem aos ângulos de rotação do pneu entre $145,5^\circ$ à 215° , na qual são os atributos e dados de entrada dos modelos de aprendizagem de máquina. A linha tracejada em laranja representa o conjunto ("janela") de dados de um ciclo completo do pneu, já a verde apresenta, aproximadamente, a região onde os pontos são extraídos nesta etapa.	57

Figura 3.13 – Representação dos pontos correspondente as faixas de valores 0° à $359,5^\circ$ em um pneu inteligente juntamente com a representação gráfica dos sinais de aceleração nos eixos x , y e z . E cada ponto tem o seguinte significado: o ponto A é igual a 0° ; B é igual a $145,5^\circ$; C corresponde o ponto de contato do pneu, equivalente ao ângulo de 180° ; D é igual a 215° ; e E é igual a $359,5^\circ$	57
Figura 4.1 – Representação de um conjunto de dados, instância de número 500, correspondente a um ciclo completo obtido a partir do conjunto de dados de treinamento para a_x , a_y e a_z	60
Figura 4.2 – Representação de um conjunto de dados, instância de número 500, com a aplicação de filtro PB de 400 Hz para os sinais aceleração a_x , a_y e a_z . Sendo que: a) , e) e i) são ciclos completo sem nenhum processo de filtragem para a_x , a_y e a_z , respectivamente; b), f) e j) são amostras filtradas das acelerações pertencentes ao eixo x , y e z ; c), g) e k) são os domínios da frequência das amostras sem filtragem para os sinais aceleração a_x , a_y e a_z , respectivamente; d), h) e l) são os domínios da frequência das amostras filtradas para os eixos x , y e z , respectivamente.	61
Figura 4.3 – Funções intrínsecas obtidas para a_x para o ângulo de deriva igual a -2° e carga igual 6240 N. Figuras com o objetivo de exemplificar as IMF's obtidas via decomposição empírica.	62
Figura 4.4 – Funções intrínsecas obtidas para a_y para o ângulo de deriva igual a -2° e carga igual 6240 N. Figuras com o objetivo de exemplificar as IMF's obtidas via decomposição empírica.	63
Figura 4.5 – Funções intrínsecas obtidas para a_z para o ângulo de deriva igual a -2° e carga igual 6240 N. Figuras com o objetivo de exemplificar as IMF's obtidas via decomposição empírica.	64
Figura 4.6 – Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu sem aplicar nenhuma filtragem para o ângulo de deriva igual a -2° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z	65

Figura 4.7 – Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu filtrado por um filtro PB de 400 Hz de 5ª ordem para o ângulo de deriva igual a -2° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z	67
Figura 4.8 – Sinais de aceleração, para o ângulo de deriva igual a 2° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.	69
Figura 4.9 – Sinais de aceleração filtrados, para o ângulo de deriva igual a 2° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.	70
Figura 4.10 – Sinais de aceleração, para o ângulo de deriva igual a 10° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.	71
Figura 4.11 – Sinais de aceleração filtrados, para o ângulo de deriva igual a 10° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.	72
Figura 4.12 – <i>Boxplots</i> de 10 <i>folds</i> para NRMSE dos melhores modelos encontrados para diferentes tipos de codificações e modelos de aprendizagem de máquinas. O triângulo verde presente nos <i>boxplots</i> é a média dos valores de NRMSE de cada modelo.	74
Figura 4.13 – <i>Boxplots</i> de 10 <i>folds</i> para r^2 dos melhores modelos encontrados para diferentes tipos de codificações e modelos de aprendizagem de máquinas. O triângulo verde presente nos <i>boxplots</i> é a média dos valores de r^2 de cada modelo.	75
Figura 4.14 – Atributos selecionados a partir do PLS-VIP para 3 distintas configurações de modelos. Os atributos entre 0 e 719 são provenientes de a_x , 720 à 1439 são de a_y e 1440 à 2159 são de a_z . a) MFC720PV ; b) MFEC720PV-1 ; c) MFEC720PV-2	77
Figura 4.15 – Contribuição de cada atributo em % para o processo de estimação de F_y . a) MFC720PV ; b) MFEC720PV-1 ; c) MFEC720PV-2	78
Figura 4.16 – Representação gráfica dos resultados de testes para os 4 modelos com os melhores desempenhos encontrados. a) MFC720PV-RF ; b) MFEC720PV-1-RF ; c) MFC720PV-GPR ; d) MFEC720PV-2-GPR	79
Figura 4.17 – Representação gráfica dos resultados ao utilizar o conjunto de dados de validação para os 4 modelos com os melhores desempenhos encontrados. a) MFC720PV-RF ; b) MFEC720PV-1-RF ; c) MFC720PV-GPR ; d) MFEC720PV-2-GPR	81

Figura 1 –	Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu sem aplicar nenhuma filtragem para o ângulo de deriva igual a 2° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z	90
Figura 2 –	Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu filtrado por um filtro PB de 400 Hz de 5^a o para o ângulo de deriva igual a 2° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z	91
Figura 3 –	Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu sem aplicar nenhuma filtragem para o ângulo de deriva igual a 8° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z	92
Figura 4 –	Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu filtrado por um filtro PB de 400 Hz de 5^a o para o ângulo de deriva igual a 8° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) é a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z	93
Figura 5 –	Sinais de aceleração, para o ângulo de deriva igual a 1° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.	94
Figura 6 –	Sinais de aceleração filtrados, para o ângulo de deriva igual a 1° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5^a ordem com a soma das IMF's obtidas via EMD.	95
Figura 7 –	Sinais de aceleração, para o ângulo de deriva igual a -2° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.	96
Figura 8 –	Sinais de aceleração filtrados, para o ângulo de deriva igual a -2° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5^a ordem com a soma das IMF's obtidas via EMD.	97
Figura 9 –	Sinais de aceleração, para o ângulo de deriva igual a 9° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.	98

Figura 10 – Sinais de aceleração filtrados, para o ângulo de deriva igual a 9° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.	99
Figura 11 – Sinais de aceleração, para o ângulo de deriva igual a -10° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.	100
Figura 12 – Sinais de aceleração filtrados, para o ângulo de deriva igual a -10° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.	101

LISTA DE TABELAS

Tabela 3.1 – Descrição dos dados.	42
Tabela 3.2 – Nome e as principais configurações dos modelos propostos apresentados no fluxograma da Figura 3.10.	54
Tabela 3.3 – As diferentes configurações utilizadas para a reconstrução do sinal a partir das IMF's obtidas via EMD, em que a é o índice da IMF escolhida para ser o início da soma e b é o índice da IMF escolhida para ser o fim da soma	55
Tabela 4.1 – Resultados de NRMSE e r^2 para os 4 modelos com os melhores desempenhos encontrados para o conjunto de dados de validação.	80

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	17
1.2	Estruturado Trabalho	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Pneus e a sua dinâmica	19
2.1.1	Sistemas de coordenadas de um veículo de quatro rodas	19
2.1.2	Força Longitudinal	20
2.1.3	Força Vertical	20
2.1.4	Força Lateral e Ângulo de Deriva	21
2.2	Pneus inteligentes - Revisão Bibliográfica	24
2.2.1	Estimação de Forças dos pneus	24
2.2.2	Estimação de estados diversos	25
2.3	Filtros	27
2.4	<i>Empirical Mode Decomposition</i>	29
2.5	Aprendizagem de Máquina	30
2.5.1	<i>Random Forest</i>	33
2.5.2	<i>Gaussian Process Regression</i>	35
2.6	<i>Partial Least Squares</i>	38
3	MATERIAIS E MÉTODOS	41
3.1	Materiais	41
3.1.1	Conjunto de dados de treinamento	41
3.1.2	Conjunto de dados de validação	42
3.1.3	Linguagem de programação e recursos computacionais	47
3.2	Métodos	48
3.2.1	Análise Exploratória	48
3.2.1.1	Segmentação das amostras por ciclo	49
3.2.1.2	Filtro passa-baixa de 400Hz	49
3.2.1.3	EMD	51
3.2.2	Modelagem	53
3.2.2.1	EMD	54
3.2.2.2	Codificação das janelas de dados de 0° à 359,5°	55

3.2.2.3	Codificação das janelas de dados de $145,5^\circ$ à 215°	55
3.2.2.4	PLS-VIP	56
3.2.2.5	Estimação de F_y	58
4	RESULTADOS E DISCUSSÃO	59
4.1	Análise Exploratória	59
4.2	Modelagem	73
5	Considerações finais	82
	REFERÊNCIAS	84
	APENDICE A – Energia das IMF's em pontos de operações distintos	90
	APENDICE B – Somas das funções intrínsecas para a reconstrução do sinais	94


1 INTRODUÇÃO

Os acidentes rodoviários são a oitava causa de morte no mundo para qualquer faixa etária de idade. Essas mortes não estão ligadas a nenhum tipo de doença pré-existente e é estimado que, em 2030, ela se torne a quinta no mundo (MALAQUIAS et al., 2022). Além de causar um impacto social relativo à perda humana, há também um custo econômico em torno de 3% do produto interno bruto, na maioria dos países (WANKE; GIL-ALANA; TAN, 2022). Portanto, uma das maneiras que podem vir a minimizar e/ou eliminar estes acidentes é o emprego de sistemas que torne os veículos cada vez mais seguros.

Partindo desse pressuposto, uma maneira de garantir essa segurança nos veículos é por meio de sistemas de assistência ao motorista (ou *Driver Assistance System* ou *ADAS*) (KHAN; LEE, 2019). Estes sistemas têm a função de evitar o manuseio incorreto do ser humano em determinadas pistas e condições (MOUJAHID et al., 2018).

Os sistemas de assistências atuais são constituídos por quatro principais componentes, quais sejam: sistema de assistência ao estacionar, vigilância ao motorista, controle lateral e longitudinal (MOUJAHID et al., 2018). São exemplos de ADAS o Sistema de Prevenção a Colisão (*Collision Avoidance System*) e o Sistema de Trava de Emergência (*Emergency Braking System*) (SINGH; ARAT; TAHERI, 2012). Logo, para o melhor uso desses sistemas, deve-se conhecer as condições que a região chamada de *contact patch* ou de interface pneu-solo, como pode ser observado na Figura 1.1 (YANG et al., 2022).

Figura 1.1 – Ilustração da região de contato pneu-solo (*contact patch*).



. Fonte: autor

Os pneus atuais são considerados estruturas passivas em veículos, ou seja, são projetados e testados de forma rigorosa para que sejam capazes de sofrer ações externas e conferir segurança, controlabilidade e conforto aos ocupantes dos veículos. Dessa forma, não há nenhuma troca de informações ou estado dos pneus para o sistema de assistência ao motorista. Assim, existe a necessidade dos pneus se tornarem cada vez mais

uma fonte de informação para os sistemas de assistência ao motorista, surgindo os pneus inteligentes (GUO et al., 2019). Os pneus inteligentes apresentam sensores acoplados à sua estrutura, ou seja, são estruturas ativas, já que se comunicam com o ADAS e participam ativamente na estimação de parâmetros e estados presentes na interface pneu-solo, podendo melhorar o controle do veículo por meio desses sistemas (LEE; TAHERI, 2017).

A pressão interna do pneu ao longo de um trajeto, a carga aplicada no pneu em diferentes solos, entre outros são exemplos de parâmetros que podem a ser estimados. A partir dos de pneus inteligentes pode se basear na modelagem cinemática, este tipo de modelagem tem como foco utilizar a relação cinemática existente entre o veículo e o sinal medido pelo sensor presente nos pneus para determinar os parâmetros desejados na região de interface pneu-solo (GRÄBER et al., 2019).

Nessa modelagem não há um conhecimento *a priori* sobre os parâmetros e estados do veículo e o solo em que o pneu se encontra (GUO et al., 2019). O processo de construção de um modelo de estimação pode se basear em uma modelagem caixa-preta, ou seja, é construído um modelo a partir dos sinais de entrada e de saída que se deseja estimar e, nessa modelagem, não há conhecimento sobre o sistema que a partir dos dados de entrada gerou a saída (AGUIRRE, 2007).

Assim, nesse processo de modelagem pode-se utilizar técnicas de aprendizagem de máquina para o processo de estimação, já que essas técnicas se baseiam somente na relação de sinal de entrada e saída, sendo que o trabalho de Xu et al. (2023) é um exemplo do uso de métodos de aprendizagem de máquina para esse processo.

A predição e/ou classificação de estados pelo sistema de assistência ao motorista, ao utilizar os pneus inteligentes, apresenta como vantagem o não conhecimento de parâmetros e estados iniciais do veículo (JEONG et al., 2021a).

No entanto, a identificação dos modelos a partir de sinais provenientes de sensores é afetada pelos ruídos e vieses inerentes aos sensores utilizados em situações reais (SINGH; ARAT; TAHERI, 2019). Os sinais e os ruídos presentes medidos pelos sensores apresentam características não estacionárias e estocásticas, já que ao longo da trajetória do veículo há variação de velocidade, do tipo de solo que o pneu se encontra, de pressão, de carga sobre os pneus e entre outros parâmetros. Dessa forma, os sinais em um determinado ciclo do pneu não apresenta o mesmo comportamento que o seu anterior.

1.1 Objetivos

Este trabalho tem como objetivo principal a identificação de um modelo caixa-preta para estimar as forças laterais presentes na interação pneu-solo a partir de um conjunto de dados experimentais de um

pneu inteligente instrumentado com um acelerômetro tri-axial. Para o presente trabalho, não se conhece as partes que constituem o sistema gerador da saída, por exemplo: a estrutura do pneu, das relações dinâmicas e cinemáticas presentes na interação pneu-solo, tipo do solo e entre outras características. Assim, os objetivos específicos são:

- Desenvolver uma metodologia de reconstrução do sinal a partir de uma heurística adaptativa, *Empirical Mode Decomposition*, sem conhecimento *a priori* da dinâmica e cinemática veicular para remover ou minimizar a influência dos ruídos, já que estes ruídos variam a cada rotação do pneu na região de contato;
- desenvolver um modelo de aprendizagem de máquina para prever a força lateral F_y , pois é uma das forças que afetam o controle do veículo e segurança, principalmente, em curvas;
- Análise de dados sobre como diferentes valores de cargas aplicadas para o mesmo ângulo de deriva afetam os sinais de aceleração;
- Análise dos atributos que contribuem para o processo de estimação da força lateral, observando a contribuição das medições fora da região pneu-solo.

1.2 Estruturado Trabalho

A estrutura deste trabalho está dividida da seguinte forma

- Capítulo 1 - Introdução: são apresentadas as motivações e os objetivos do trabalho.
- Capítulo 2 - Fundamentação Teórica: é apresentada a base teórica para o desenvolvimento deste trabalho.
- Capítulo 3 - Materiais e Métodos: apresenta os materiais e a metodologia proposta para o desenvolvimento do presente trabalho.
- Capítulo 4 - Resultados e Discussão: é o capítulo responsável em apresentar os resultados preliminares da metodologia proposta.
- Capítulo 5 - Considerações Finais: apresenta as considerações finais sobre a metodologia proposta e dos resultados preliminares apresentados.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Pneus e a sua dinâmica


Pneumáticos ou somente pneus são estruturas que fazem a interface de um veículo com o solo, mas, além disso, possuem a função de fornecer estabilidade ao veículo ao longo do caminho, conforto aos passageiros, entre outras funcionalidades (PUGLIESE, 2015). A estrutura e composição dos pneus foram evoluindo ao longo dos tempos, desde estruturas constituídas de materiais rígidos, como madeira e aço, ao que é largamente utilizado atualmente, estruturas compostas por um conjunto de materiais flexíveis, como: borracha, tecido, nylon, fibras metálicas e entre outras (PUGLIESE, 2015; SANTOS, 2019).

Além das funcionalidades supracitadas existe uma demanda crescente para que os pneus se tornem cada vez mais ativos no processo de controle de um veículo, surgindo assim os pneus inteligentes (BARBOSA et al., 2022). Estes pneumáticos apresentam sensores em seu interior, como acelerômetros tri-axiais, capazes de medir a aceleração nos três eixos dimensionais (x , y e z). Com estes sensores é possível estimar outros parâmetros, que são melhores descritos na seção 2.2, necessários para melhorar a controlabilidade do veículo (PUGLIESE, 2015). As Seções 2.1.1 até 2.1.4 apresentam o sistema de coordenadas adotado para um veículo de quatro rodas e de um de seus pneus e sua dinâmica.

2.1.1 Sistemas de coordenadas de um veículo de quatro rodas

Os sistemas de coordenadas utilizado neste trabalho para um veículo de quatro rodas foi estabelecido pela SAE (*Society of Automotive Engineers*) como é apresentado na Figura 2.1.

Figura 2.1 – Sistema de coordenadas de um veículo de quatro rodas



Fonte: adaptado de (GILLESPIE, 1992)

A Figura 2.1 mostra o ponto de origem, o Centro de Gravidade (CG) do veículo automotor, onde tem-se o eixo x no sentido longitudinal em direção à frente do veículo como sentido positivo (OLEGARIO, 2017). Já o eixo z , ortogonal aos demais, é vertical apontado em direção ao solo e o eixo y , também perpendicular aos demais eixos, se apresenta de forma lateral ao veículo (OLEGARIO, 2017).

A Figura 2.1 também apresenta no seu sistema de coordenadas os momentos em cada eixo, quais sejam: rolamento no eixo x , guinada no eixo z e arfagem no eixo y (BARRETO, 2015). Estes momentos na figura são representados, respectivamente, pelas variáveis p , r e q (OLEGARIO, 2017).

Com o sistema de coordenadas apresentado para o veículo, é possível obter um sistema de coordenadas para um único pneu que compõem este veículo seguindo o padrão SAE, como pode ser observado na Figura 2.2.

A Figura 2.2 apresenta as forças e ângulos em que o pneu de um automotor pode apresentar em certo percurso, sendo que este presente trabalho focará nas forças F_x , F_y e F_z , mas também no ângulo de deriva (*slip angle*).

2.1.2 Força Longitudinal


A força longitudinal (F_x) se relaciona com a aceleração e desaceleração do veículo, frenagem ou tração, respectivamente. Este tipo de força ocorre longitudinalmente entre a interação do pneu-solo. Esta interação ocorre quando o torque gerado pelo motor ou freios do automotor é transmitido aos pneus, onde a interação entre o plano de contato do pneu com o solo provoca a ação de aceleração ou de frenagem (BAUTISTA, 2015).

2.1.3 Força Vertical

A força vertical ou força peso corresponde à força existente sobre um único pneu (GILLESPIE, 1992). Devido às características do pneu e a carga sobre os mesmos, uma região é deformada dentro a interação pneu-solo, chamada de área de contato (BAUTISTA, 2015), como pode ser observado na Figura 2.3. Contudo, em movimento, esta área se deforma de acordo com o movimento, Figura 2.4 (BARRETO, 2015).

Assim, a distribuição da força vertical sobre os pneus não é constante e sim varia de acordo com os processos de aceleração, desaceleração, ângulo de deriva, cambagem e entre outros.

Figura 2.2 – Sistema de coordenada de forças atuantes em um pneu




Fonte: adaptado de (GILLESPIE, 1992)

2.1.4 Força Lateral e Ângulo de Deriva

A força lateral F_y , também chamada de força de curva (GILLESPIE, 1992), é um tipo força que ocorre sobre os pneus de um veículo para manter o equilíbrio dinâmico e fazer com que o veículo permaneça na trajetória (JAZAR, 2008). A presença desta força ocasiona uma deformação no pneu que altera seu sentido do movimento em relação à trajetória do veículo, ou seja, em relação ao eixo x , surgindo o ângulo de deriva ou *slip angle*, como pode ser observado na Figura 2.5.


A força lateral depende de fatores, como, por exemplo, as características construtivas do pneu (largura, tamanho, tipo de pneu), a carga e pressão interna em cada um dos pneus que o veículo possui (GILLES-

Figura 2.3 – Distribuição da força F_z sobre a área de contato em um pneu em repouso



Fonte: adaptado de (JAZAR, 2008)

Figura 2.4 – Distribuição da força normal F_z sobre a área de contato em um pneu em movimento com ω sendo a velocidade angular do pneu




Fonte: adaptado de (JAZAR, 2008)

PIE, 1992). Entre estes fatores mencionados, a força lateral possui uma forte dependência da força vertical do pneu ao longo do percurso, por consequência, afeta o equilíbrio dinâmico do veículo em sua trajetória, principalmente em trajetórias curvas.


Pode-se observar na Figura 2.8 que em baixos valores de ângulos de derivas (α), em torno de 5° , a relação entre a força lateral e ângulo de deriva é aproximadamente linear, porém, acima deste valor o comportamento é não-linear. Logo, determinar o valor máximo de carga que o pneu suporta é de grande importância para o equilíbrio da dinâmica lateral do veículo e segurança dos usuários (PACEJKA, 1989).

Figura 2.5 – Pneu sobre ação de um força lateral



Fonte: adaptado de (GILLESPIE, 1992)

Figura 2.6 – Relação força lateral, vertical e ângulo de deriva



Fonte: adaptado de (JAZAR, 2008)

2.2 Pneus inteligentes - Revisão Bibliográfica

Os pneus inteligentes são estruturas que, além de serem projetados como um pneu comum, possuem em sua composição sensores acoplados no seu interior. Os sinais obtidos por esses pneus são utilizados para estimar parâmetros e/ou estados que não são viáveis de serem obtidos diretamente (YANG et al., 2022), esse fato pode acontecer devido ao custo ou a redução significativa do tempo de vida útil de um sensor específico.

Portanto, as seções a seguir são apresentados alguns trabalhos relacionados com o uso de pneus inteligentes para estimação de forças e outros estados presentes na região pneu-solo.

2.2.1 Estimação de Forças dos pneus

O trabalho de Anup Cherukuri (2017) utiliza sensores de aceleração acoplados ao pneu, no caso um acelerômetro triaxial, ou seja, um sensor capaz de medir as acelerações nos eixos x, y e z. Para estimar as forças e pressões nos pneus, foi desenvolvido um modelo para estimar esses parâmetros utilizando o software *Matlab* e o modelo é validado utilizando uma simulação no *CarSim*, um simulador de veículos leves, obtendo uma boa correlação entre os sinais medidos e estimados.

No estudo de Zhou et al. (2021), foi desenvolvido um modelo para estimar a força longitudinal com base nas informações sobre a tensão presente na região de interface pneu-solo. O modelo foi validado ao comparar as forças estimadas com as medidas, utilizando os sinais coletados para obter os dados de tensão. Os resultados demonstraram que o modelo proposto é capaz de prever com precisão a força longitudinal.

Barbosa et al. (2022) utilizam um acelerômetro triaxial e a partir dos sinais de aceleração e do método de estimação *Gaussian Process Regression*, um método de aprendizagem de máquina, estimam a força lateral presente no pneu do veículo com um certo intervalo de incerteza, sendo este intervalo útil para melhorar projetos de controladores de veículos.

O modelo de estimação visto em Xu et al. (2022) tem como foco o uso de diferentes métodos de aprendizagem de máquina juntamente a um sensor de aceleração triaxial no interior de um pneu e a metodologia proposta é capaz de prever as forças lateral, vertical e longitudinal presentes no pneu ao entrar em contato com o solo.

O trabalho de Cheng et al. (2020) propõe a construção de um estimador de forças, sendo este processo de estimação realizado com um conjunto de estimadores de diferentes tipos dividido em três blocos. Um dos blocos utiliza sinais provenientes de sensores presente nos pneus para a estimação da força longitudinal do pneu da identificação do raio efetivo do pneu e um controlador PID.

Os modelos de estimação apresentados nos trabalhos de Jeong et al. (2019) e Jeong et al. (2021b) focam na predição de valores da força peso. O primeiro, a partir de um modelo de pneu de anel flexível e sinais de aceleração advindos de um acelerômetro, é estimada a força de carga sobre o pneu em várias condições; já o segundo trabalho, por meio de um pneu inteligente é predito o ângulo de cambagem entre o pneu e o solo, sendo que a partir deste ângulo prediz a força vertical estática e dinâmica sobre o pneu em um modelo de anel flexível. Além do modelo proposto em Jeong et al. (2021b) prever a força, ele é também capaz de determinar outros parâmetros de um veículo como o ponto e a altura do centro de gravidade.

Zhao et al. (2021) desenvolvem um modelo de predição da força vertical a partir das informações de deflexão do pneu, da variação de altura do piso e da altura da cavidade no centro de contato do pneu-solo, sendo o modelo desenvolvido de alta precisão. Gu et al. (2022) desenvolvem um modelo de previsão de força vertical baseado em pneus inteligentes, sendo utilizados métodos de controle e análise de elementos finitos para a predição dos parâmetros de pressão de inflação, velocidade, carga, desgaste da banda de rodagem e deslocamento radial, sendo que os resultados destes métodos são entradas de três redes neurais distintas para, assim, estimar a força vertical. A partir desta metodologia é identificado que a rede neural que possuía as entradas baseadas na pressão e deslocamento radial apresentou os melhores resultados e o menor tempo de execução da força estimada.

A partir dos trabalhos mencionados é possível notar a importância da estimação da força para uma possível melhora do conforto e segurança dos passageiros em diferentes tipos de solos e condições, mais informações sobre a predição de força podem ser obtidas nos trabalhos de Singh e Taheri (2019) e Viehweger et al. (2021) que apresentam uma revisão de diferentes técnicas.

2.2.2 Estimação de estados diversos

O processo de estimação, ao usar pneus inteligentes, não se limita a predição de força, mas também para estimação de outros parâmetros, como: ângulo de deriva, pressão dos pneus, momentos, estado do solo que o pneu se encontra, entre outros parâmetros. Assim, esta seção descreve alguns artigos que focam nos variados processos de predição para os diferentes parâmetros e estados que um pneu pode apresentar ao estar em contato com o solo.

A presença da força lateral ocasiona uma deformação no pneu que altera seu sentido do movimento em relação à trajetória do veículo, ou seja, em relação ao sentido longitudinal do pneu, surgindo o ângulo de deriva ou *slip angle* (GILLESPIE, 1992; JAZAR, 2008).

O trabalho de Garcia-Pozuelo et al. (2017b) utiliza um método de lógica *Fuzzy* para estimar tanto o ângulo de deriva quando a força peso ocorrida na interface pneu-solo, sendo o modelo *Fuzzy* proposto capaz de fornecer informações sobre esses parâmetros a partir de um pneu inteligente.

Já o trabalho de Xu et al. (2021) estima o *slip angle* a partir de cinco técnicas de aprendizagem de máquinas, em que as entradas destes modelos são sinais de aceleração provenientes de um acelerômetro *MEMS* (*Micro Electro Mechanical System*) e os procedimentos de estimação podem estimar ângulos de até 10 graus.

O artigo de Niskanen e Tuononen (2017) apresenta um processo de estimação da região de deslizamento na interface de contato pneu-solo a partir de sinais de aceleração de um pneu inteligente, estes sinais foram obtidos a partir de diferentes tipos de solos e manobras do veículo.

Já o trabalho de Lee et al. (2021) apresentam uma metodologia que utiliza um acelerômetro triaxial presente no interior de um pneu para fornecer sinais de aceleração para uma rede neural convolucional (*Convolutional Neural Network*) para o processo de classificação do tipo de superfície que o pneu se encontra.

Kim et al. (2020) propõem uma metodologia que utiliza sinais de aceleração e um modelo de rede neural para prever a condição da estrada. O sinal de aceleração é convertido para o domínio da frequência a partir da Transformada Rápida de Fourier (*Fast Fourier Transform*), sendo utilizado como entrada do modelo construído.

O trabalho de Khaleghian (2017) emprega diferentes métodos de aprendizagem, como modelos de lógica *Fuzzy* e rede neural artificial, utilizando sinais provenientes de pneus inteligentes para estimar características do solo na interface de interação pneu-solo.

A tensão ou deformação sobre pneus pode ser utilizada para prever ou classificar diferentes parâmetros e estados dos pneus. A metodologia desenvolvida por Mendoza-Petit et al. (2020) desenvolve um sistema de lógica *Fuzzy* e utiliza sinais de deformação provenientes de um pneu inteligente, sendo capaz de estimar o comprimento e raio efetivo de contato do pneu com solo. Yunta et al. (2018) utilizam sensores de deformação para prever informações acerca da perda de aderência do pneu e o coeficiente de atrito lateral, demonstrando a relação entre a tensão sobre os pneus com a força lateral e longitudinal. O trabalho de Lee e Taheri (2019) utiliza sinais de tensão e um modelo para estimar características físicas de um pneu, em que ao longo de um trajeto de um veículo estas características não permanecem estáticas, como: a rigidez da correia e da parede lateral, e a distribuição de pressão de contato.

O trabalho de Zhu, Han e Zhao (2019) utiliza acelerômetros triaxiais fixados internamente a um pneu inteligente. A partir das informações dos sinais de aceleração advindas do aro do pneu no domínio da

frequência é gerado um modelo para identificar a pressão existente nos pneus. Os resultados obtidos estão próximos ao dos resultados de valor real de pressão.

Em Zhang et al. (2020) é desenvolvido um modelo baseado em rede neural e, a partir de dados de aceleração e de deformação, a profundidade da abrasão dos pneus é estimada, ou seja, o desgaste do pneu em contato com o solo ao longo de um trajeto.

Os trabalhos de Askari et al. (2019) e Yang et al. (2022) são revisões sobre o uso de pneus inteligentes para diferentes usos e sensores, sendo o primeiro trabalho foca em demonstrar trabalhos de pneus inteligentes baseado nos efeitos elétricos e magnéticos para o processo de estimação, sensoriamento e coleta de energia a partir do uso de pneus. Já o segundo artigo revisa os trabalhos em que o pneu inteligente é utilizado para estimar as características relacionadas à interação pneu e solo, por final os autores propõem soluções para a melhora dos processos de estimação e do total aproveitamento do uso de sensores presentes nos pneus.

2.3 Filtros

Filtros são estruturas presentes em sistemas analógicos ou digitais que tem como função remover e/ou minimizar a presença de valores indesejados (ruídos), ou extrair valores desejados em sinais provenientes de variadas fontes. Esse processo de remoção ou minimização ocorre a partir da escolha de um valor, ou uma faixa quando se quer remover duas ou mais frequências, de frequência, comumente chamada de frequência de corte (f_c), selecionando as frequências a serem removidas ou extraídas (NETO, 2003).

Os filtros podem ser classificados como passa-baixa, passa-alta, passa-faixa e rejeita faixa e realizam os seguintes processos de filtragem:

- **Passa-baixa:** seleciona as componentes do sinal que apresentam frequência menores que a da frequência de corte e atenua as demais do sinal (NETO, 2003);
- **Passa-alta:** seleciona as componentes do sinal que apresentam frequência acima da frequência de corte e atenua as demais do sinal (NETO, 2003);
- **Passa-faixa:** seleciona as componentes do sinal que apresentam frequências que se encontram entre frequências de interesse e as demais são atenuadas (NETO, 2003);
- **Rejeita-faixa:** atenua as componentes do sinal que apresentam frequências que se encontram entre frequências de interesse e seleciona as demais (NETO, 2003). Este tipo de filtro apresenta um caso especial chamado filtro *notch*, o qual remove uma única frequência específica.


Assim, conhecendo os tipos e as funções dos filtros, é necessário escolher um modelo matemático para a modelagem dos mesmos para serem empregados em sistemas analógicos ou digitais. Como exemplo, tem-se o filtro *Butterworth*, utilizado neste trabalho. Este modelo tem como característica não apresentar ondulações na curva de resposta no processo de remoção, atenuação ou de extração de frequências no processo de filtragem, assim, possuindo maior estabilidade (RIZZO, 2014).

Para exemplificar o comportamento de um filtro tipo *Butterworth* a equação a seguir representa o modelo matemático para um passa-baixa no domínio da frequência:

$$|H(j\omega)| = \frac{K_{PB}}{\sqrt{1 + (\frac{j\omega}{j\omega_c})^{2n}}}, \quad (2.1)$$

em que $|H(j\omega)|$ é a magnitude do ganho em função da frequência, ω_c é a frequência de corte, n é a ordem do filtro e K_{PB} é o ganho do filtro. A partir da equação pode ser observado que ao aumentar a ordem do filtro, além dos valores de frequência de corte e de ganho permanecerem constantes, este modelo aproxima-se de um filtro passa-baixa ideal (apresenta uma curva característica que se aproxima a um retângulo e sem nenhuma oscilação), como é demonstrado na Figura 2.7.

Figura 2.7 – Exemplo de curva de resposta do filtro *Butterworth* passa-baixa com frequência de corte igual a 400 Hz, marcado pela linha vertical em verde



2.4 Empirical Mode Decomposition

O algoritmo *Empirical Mode Decomposition* é utilizado para decomposição de um sinal independente de suas características para obtenção de funções de modos intrínsecos, também chamadas *Intrinsic Mode Functions* ou IMFs, presente no sinal a ser decomposto (LEI et al., 2013). Para um sinal ser considerado uma IMF deve apresentar as seguintes características:

- O número de extremos, máximos e mínimos, presente no sinal deve ser igual ao número de cruzamentos do sinal em zero ou este número diferir por pelo menos 1 (CHAUDHARI; NALBALWAR; SHETH, 2016);
- O valor médio do envelope ao utilizar os valores extremos, máximos e mínimos, presentes no sinal, em que este envelope é definido ao utilizar o método de interpolação *spline* cúbica, deve ser igual a zero, para qualquer ponto do sinal (MARTINS, 2011).

Ao se aplicar o EMD em um determinado sinal não há necessidade de um conhecimento *a priori* sobre o mesmo (LEI et al., 2013), ou seja, não há necessidade de se conhecer a sua composição, sua origem e entre fatores, logo, o algoritmo é adaptativo a qualquer sinal (MARTINS, 2011). A decomposição de um sinal é feita a partir de um processo chamado "peneiração" ou *sifting* (CRESPO, 2018; LEI et al., 2013), que consiste nos seguintes passos:

1. Para a definição da $imf_i(t)$ o algoritmo determina os pontos de extremos, tanto o superior quando o inferior, presentes no sinal, $x(t)$ (ou resíduo inicial $r_1(t)$) (LEI et al., 2013), como é apresentado na Figura 2.8.b);
2. A partir da escolha dos extremos são gerados os envelopes superior, $u_{ki}(t)$, e o inferior, $l_{ki}(t)$, a partir da técnica de interpolação chamada *spline* cúbica (LARA, 2022), como pode ser visto na Figura 2.8.c);
3. É calculado o valor do envelope médio, m_{ki} , a partir da equação (MARTINS, 2011):

$$m_{ki}(t) = \frac{u_{ki}(t) - l_{ki}(t)}{2}; \quad (2.2)$$

4. Calcula-se o candidato $h_{ki}(t)$ a imf_i a partir da equação (MARTINS, 2011):

$$h_{ki}(t) = r_i(t) - m_{ki}(t); \quad (2.3)$$

5. Se $h_{ki}(t)$ apresentar as características já citadas de uma IMF, então $imf_i(t) = h_{ki}(t)$. Se não atender repete-se o passo 1 até o 4, em que vez de se utilizar $x(t)$ para determinar um novo candidato é utilizado $h_{k+1i}(t)$, até que $h_{k+1i}(t)$ atenda os requisitos para ser considerando uma função intrínseca (LEI et al., 2013), como apresentado na equação a seguir:

$$h_{k+1i}(t) = h_i(t) - m_{k+1i}(t); \quad (2.4)$$

6. Para se obter a próxima $imf_{i+1}(t)$, deve-se primeiro calcular o próximo resíduo $r_{i+1}(t)$:

$$r_{i+1}(t) = r_i(t) - imf_i(t), \quad (2.5)$$

em que se repete os passos de 1 a 5, até que seja uma função monotônica no final deste processo (DUARTE, 2020)

Assim, a partir desse passo-a-passo é possível reconstruir o sinal original a partir da soma das IMF's obtidas mais o resíduo monotônico, $r_{i+1}(t)$, obtido no final do processo de decomposição (DUARTE, 2020; MARTINS, 2011):

$$x(t) = \sum imf_i(t) + r_{i+1}(t). \quad (2.6)$$


As primeiras funções intrínsecas obtidas ao implementar o EMD são as que apresentam os valores de magnitude em alta frequência, as demais IMF's obtidas apresentam magnitudes em baixa frequências quando comparadas com as primeiras funções obtidas no processo de decomposição, este fato é uma das principais características do algoritmo EMD (DUARTE, 2020). Assim, é possível selecionar as funções desejáveis para ser utilizada em uma determinada aplicação.

Portanto, o EMD é um algoritmo que apresenta a vantagem de não se ter um conhecimento *a priori* do sinal e ser um método adaptativo ao próprio sinal (MARTINS, 2011), porém, apresenta a desvantagem de gerar alguns casos, em IMF's não ortogonais, logo, deixa-se de ser independente e uma função obtida pode estar misturada à outra função já gerada ou que irá ser gerada (LEI et al., 2013).

2.5 Aprendizagem de Máquina

Atualmente, com a crescente evolução de *smartphones*, computadores e dispositivos inteligentes, por exemplo, relógios, óculos, casas e pneus, o qual é o foco do presente trabalho, há um aumento diário

Figura 2.8 – Exemplo de processo de *sifting* ou peneiração realizado pelo o algoritmo EMD a partir de um sinal qualquer. a) é o sinal original $x(t)$ a ser decomposto em IMF's. b) é a identificação dos extremos superiores, pontos em azul, e inferior, pontos em vermelhos. c) é a representação dos envelopes, $u_{ki}(t)$ e $l_{ki}(t)$ gerados e com o valor médio, m_{ki} , gerado a partir destes envelopes.



Fonte: autor

no volume de dados pelo o mundo. Com esta quantidade expressiva de dados tornou-se possível extrair informações a partir dos mesmos com a mineração de dados.

A mineração de dados consiste no processo de obter a informação contidas em uma massa de dados, em que este processo é dividido nas etapas de pré-processamento, extração de características e pós-processamento dos dados (CHAVES, 2012), que são descritas a seguir:

1. **Pré-processamento:** é a etapa que consiste na padronização de arquivos onde os dados estão contidos e de limpeza dos mesmos para se adequar ao algoritmo e/ou metodologia aplicada na etapa de extração (CHAVES, 2012);
2. **Extração:** é a etapa que consiste na aplicação de um algoritmo e/ou metodologia para extração de características a partir dos dados devidamente pré-processados (CHAVES, 2012);
3. **Pós-processamento:** é a fase que se analisa as informações obtidas na etapa anterior, com o foco em analisar se alcançou um objetivo previamente determinado (CHAVES, 2012).

Na etapa de extração, é necessário o uso de aprendizagem de máquina, que tem como foco construir modelos computacionais, a partir de um único ou vários algoritmos, capazes de aprender e se adaptar a uma base de dados pré-processada obtendo as informações contidas nesta base (CHAVES, 2012; STANGE, 2011). Os algoritmos utilizados na construção dos modelos de aprendizagem de máquinas podem ser classificados como:

- **Supervisionado:** é o tipo de aprendizagem realizada a partir do conhecimento da saída desejada. Assim, o algoritmo de aprendizagem de máquina reconhece um padrão a partir dos dados de entrada e de saída desejada para prever ou classificar a saída estimada pelo algoritmo (STANGE, 2011);
- **Não-supervisionado:** é o tipo de aprendizagem realizada sem o conhecimento da saída desejada. Logo, o algoritmo, a partir da base dados, estima a possível saída ao aprender os erros e acertos obtidos de forma iterativa ao longo do processo de aprendizagem (RAMINELLI; SANTOS, 2019);
- **Reforço:** possui conhecimento de forma incerta sobre o comportamento que a saída desejada deve possuir. Assim, é um tipo de aprendizagem por tentativa e erro, sendo que a partir dos dados de entrada e um índice de desempenho, gerado de forma iterativa ao longo do processo de aprendizagem, que definirá o valor ótimo da saída desconhecida (SERRA, 2004);
- **Semi-supervisionado:** é o tipo de aprendizagem que possui parcialmente conhecimento da saída desejada para alguns exemplos. Esta aprendizagem classifica ou prediz os valores para dados registrados e a partir disto estima a saída para os registros não conhecidos (PIRES, 2017).

Assim, os algoritmos de aprendizagem de máquinas supervisionados utilizados no presente trabalho para geração de modelos de aprendizagem de máquina para a predição da força lateral, F_y , são: *Random Forest* (Floresta Aleatória ou RF) e *Gaussian Process Regressor*. Estes algoritmos são melhores descritos nas seções a seguir.

2.5.1 *Random Forest*

O algoritmo *Random Forest* (Floresta Aleatória ou RF) é um algoritmo que se baseia na geração de um modelo a partir do treinamento de diferentes árvores de decisão (*decision tree*) resultando diferentes preditores (BIAU; SCORNET, 2016), já que essas árvores são treinadas a partir de uma amostra aleatória da base de dados de treinamento contendo todas as características (ou *features*).


Devido a esse comportamento de gerar um modelo a partir de grupos de classificadores ou preditores, o RF é rotulado como *ensemble* (MARTELETTO, 2022). Ele é utilizado tanto para construção de modelos de classificação ou de predição, sendo que o processo de classificação se dá na escolha do melhor classificador por votação e de regressão é a média dos resultados de cada preditor para se obter o modelo final (BREIMAN, 2001).

A Floresta Aleatória é um modelo gerado a partir de um grupo de modelos de árvores de decisão. A árvore de decisão tem como princípio de funcionamento a segmentação dos dados em regiões que não se sobrepõem a partir dos conjuntos de atributos presentes na base de dados a ser treinada, em que este processo de segmentação acontece até classificar ou prever todas as observações presentes no conjunto de dados (NICOLA, 2021; SOUZA; SANTOS, 2021). Outra forma de compreender este algoritmo é a partir de um grafo de "árvore", como apresentado na Figura 2.9.

Assim, para a construção de uma simples árvore de decisão tem-se as seguintes características:

- Inicia-se por um nó chamado de "raiz", sendo escolhido uma característica com maior importância do conjunto de dados para se iniciar a árvore (MARTELETTO, 2022);
- A partir do primeiro teste do nó raiz são gerados nós internos ou folhas, em que estes nós internos podem ser novos testes a partir de novas características relevantes ao modelo. Valores a se testar e novos nós internos podem surgir a partir de nós internos anteriores (BONILLA, 2020);
- As folhas são o objetivo final da árvore de decisão, já que representam um valor de uma classe ou valor estimado de um processo de regressão, em que as folhas podem surgir a partir do nó raiz ou de um nó interno (POLI, 2023);

Figura 2.9 – Exemplo de árvore de regressão com a finalidade de demonstração, em que o conjunto de dados apresenta somente uma única *feature* que é J



Fonte: autor.

- Um caminho qualquer do nó raiz até uma folha representa uma regra de classificação ou de regressão presente em uma árvore (POLI, 2023).

Para o processo de regressão, a escolha das características com maior importância para a construção do modelo ao longo do treinamento utiliza, na maioria dos algoritmos de árvores de regressão, o MSE (*Minimum Squared Error* ou Mínimo Erro Quadrático) (BONILLA, 2020), como apresentado, na Equação 2.7:

$$MSE = \sum_{k=1}^N (y_k - \hat{y}_k)^2 \quad (2.7)$$

em que y_k é o valor alvo do k -ésimo termo da variável com número de amostras igual a N e $\hat{y}_k$ é a variável alvo estimada pela árvore no processo de treinamento.

No processo de seleção dos atributos mais relevantes dependem da relação entre $\hat{y}_k$ e os valores de corte únicos correspondentes para cada atributo. Nesse contexto, o atributo que apresenta o menor MSE é escolhido para a criação de um nó interno (BONILLA, 2020).

No processo de aprendizagem pode ocorrer o processo de *overfitting*, ou seja, o modelo se adapta aos dados de treinamento e não estima novos valores alvos corretamente para novas observações (MARTELETTO, 2022; POLI, 2023). Já que árvore de decisão pode criar inúmeras folhas, não há um limite máximo dependendo do algoritmo de árvore utilizado, ou seja, as folhas correspondem somente a valores alvos estimados dos dados de treinamento (BONILLA, 2020).

Assim, os algoritmos de **RF** apresentam dois conceitos para a sua construção que são: *bagging* (ou *bootstrap aggregating*) e *random split selection* (HASTIE; TIBSHIRANI; FRIEDMAN, 2009), em que apresentam as seguintes características:

- *Bagging*: etapa que se treina distintos modelos de *decision tree* a partir de diferentes bases de treinamentos, em que essas bases são geradas de forma aleatória (BREIMAN, 2001; HASTIE; TIBSHIRANI; FRIEDMAN, 2009; GENUER; POGGI; TULEAU-MALOT, 2010). São reutilizados nesses casos, certos conjuntos para treinamento de novas árvores;
- *Random Split Selection*: este conceito é aplicado para geração de conjuntos de dados de treinamento aleatórios com uma parcela das *features* do conjuntos de dados de entrada (BIAU; SCORNET, 2016).

Dessa forma, o algoritmo de floresta aleatória, ao aplicar estes conceitos na sua construção, evita a ocorrência do *overfitting* apresentado pela árvore de decisão e apresentam, de forma geral, melhor desempenho que os algoritmos de árvore de decisão para conjuntos de dados massivos (BONILLA, 2020).

2.5.2 Gaussian Process Regression

Gaussian Process (ou Processo Gaussiano ou GP) é um processo estocástico pertencente a família de modelos *bayesianos* (SWILER et al., 2020), em que se baseia em um conjunto de variáveis aleatórias x com uma distribuição gaussiana (WILLIAMS; RASMUSSEN, 2006; SWILER et al., 2020). Esse processo comumente apresenta uma distribuição f baseada em uma função de média $m(x)$ e de covariância (ou *kernel*) $k(x, x')$, em que x, x' da última função apresenta a covariância das variáveis em pontos diferentes presente no conjunto, este fato é traduzido pela equação (WILLIAMS; RASMUSSEN, 2006):

$$f \sim GP(m, k). \quad (2.8)$$

A partir de um Processo Gaussiano é possível construir modelos de regressão chamados *Gaussian Process Regression* para se obter uma função $f(x)$ para a estimação de novos valores a partir de um conjunto de observações $\mathbf{y} = \{y_1, y_2, y_3, \dots, y_N\}$ podendo vir a apresentar dependência a um variável aleatória $\mathbf{x} = \{x_1, x_2, x_3, \dots, x_N\}$ ou com várias variáveis $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_M\}$, em que N é número de valores aleatórios e M é o número de variáveis (SWILER et al., 2020; KUSS, 2006).

Logo, para se entender o funcionamento deve-se partir das seguintes relações lineares (SCHULZ; SPEEKENBRINK; KRAUSE, 2018):

$$f(\mathbf{x}) = \mathbf{x}\mathbf{w}^T, \quad (2.9)$$

$$\mathbf{y} = f(\mathbf{x}) + \varepsilon, \quad (2.10)$$

em que ε é um ruído ou viés presente nas observações $\mathbf{y}$, na qual se considera ser aproximadamente gaussiano $N(0, \sigma_\varepsilon^2)$ com média μ_ε igual a zero e variância igual a σ_ε^2 ; $\mathbf{w}$ é um vetor de pesos a ser estimado (WILLIAMS; RASMUSSEN, 2006; SWILER et al., 2020; SCHULZ; SPEEKENBRINK; KRAUSE, 2018).

Ao aplicar o GP na Equação 2.9, deixa-se de definir o parâmetro de pesos $\mathbf{w}$ para definir o modelo de regressão. A equação será aproximada pela distribuição apresentada na Equação 2.8 para definir a função $f(x)$ da Equação 2.10, como pode ser visto na Equação 2.11 (SCHULZ; SPEEKENBRINK; KRAUSE, 2018):

$$f(\mathbf{x}) \sim GP(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}')), \quad (2.11)$$

em que tem-se as seguintes definições para as funções de média $m(\mathbf{x})$ e *kernel* $k(\mathbf{x}, \mathbf{x}')$ (SWILER et al., 2020):

$$m(\mathbf{x}) = E[f(\mathbf{x})], \quad (2.12)$$

$$k(\mathbf{x}, \mathbf{x}') = E[(f(\mathbf{x}) - m(\mathbf{x}))(f(\mathbf{x}') - m(\mathbf{x}'))]. \quad (2.13)$$

Logo, a partir dos princípios apresentados e dado um conjunto de dados conhecido $D = \{\mathbf{X}, \mathbf{y}\}$ e com função da média $m(\mathbf{X})$, para fins de simplificação, é possível estimar $f(\mathbf{X}^*)$ de novos valores aleatórios $\mathbf{X}^*$ usando a seguinte relação (WILLIAMS; RASMUSSEN, 2006; SCHULZ; SPEEKENBRINK; KRAUSE, 2018; SWILER et al., 2020):

$$\begin{bmatrix} f(\mathbf{X}^*) \\ \mathbf{y} \end{bmatrix} \sim N \left(0, \begin{bmatrix} K(\mathbf{X}, \mathbf{X}) + \sigma_\varepsilon^2 \mathbf{I} & K(\mathbf{X}, \mathbf{X}^*) \\ K(\mathbf{X}^*, \mathbf{X}) & K(\mathbf{X}^*, \mathbf{X}^*) \end{bmatrix} \right). \quad (2.14)$$

A matriz de variância apresentado na distribuição gaussiana na Equação 2.14 é constituído dos seguintes elementos:

- $K(\mathbf{X}, \mathbf{X}) + \sigma_\varepsilon^2 \mathbf{I}$, corresponde a covariância da variável dependente $\mathbf{y}$, na qual $\mathbf{I}$ é a matriz de identidade com valores iguais a 1 na diagonal principal (SCHULZ; SPEEKENBRINK; KRAUSE, 2018). Uma

matriz de covariância ou *kernel* tem o seguinte formato (SCHULZ; SPEEKENBRINK; KRAUSE, 2018):

$$K(\mathbf{X}, \mathbf{X}) = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & k(\mathbf{x}_1, \mathbf{x}_2) & k(\mathbf{x}_1, \mathbf{x}_3) & \cdots & k(\mathbf{x}_1, \mathbf{x}_M) \\ k(\mathbf{x}_2, \mathbf{x}_1) & k(\mathbf{x}_2, \mathbf{x}_2) & k(\mathbf{x}_2, \mathbf{x}_3) & \cdots & k(\mathbf{x}_2, \mathbf{x}_M) \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ k(\mathbf{x}_N, \mathbf{x}_1) & k(\mathbf{x}_N, \mathbf{x}_2) & k(\mathbf{x}_N, \mathbf{x}_3) & \cdots & k(\mathbf{x}_N, \mathbf{x}_M) \end{bmatrix}; \quad (2.15)$$

- $K(\mathbf{X}, \mathbf{X}^*)$, corresponde a matriz da função *kernel* entre as variáveis aleatórias já existentes $\mathbf{X}$ e com os valores das variáveis presentes dos novos valores $\mathbf{X}^*$;
- $K(\mathbf{X}^*, \mathbf{X})$, é a matriz da função de covariância entre os novos valores $\mathbf{X}^*$ e os já existentes $\mathbf{X}$ (SCHULZ; SPEEKENBRINK; KRAUSE, 2018);
- $K(\mathbf{X}^*, \mathbf{X}^*)$, é a matriz da função *kernel* entre os valores novos das variáveis aleatórias obtidas para o processo de estimação (SCHULZ; SPEEKENBRINK; KRAUSE, 2018).

A partir da Equação 2.14, a função $f(\mathbf{X}^*)$ tem distribuição normal aproximadamente igual a (WILLIAMS; RASMUSSEN, 2006; SCHULZ; SPEEKENBRINK; KRAUSE, 2018):

$$f(\mathbf{X}^*) | \mathbf{X}, \mathbf{y}, \mathbf{X}^* \sim N(\mu_{f^*}, \Sigma_f^*) \quad (2.16)$$

em que μ_{f^*} e Σ_f^* são média e a covariância de $f(\mathbf{X}^*)$, descritas, respectivamente, por:

$$\mu_{f^*} \sim K(\mathbf{X}^*, \mathbf{X}^*) [K(\mathbf{X}, \mathbf{X}) + \sigma_\epsilon^2 \mathbf{I}]^{-1} \mathbf{y}, \quad (2.17)$$

e

$$\Sigma_f^* = K(\mathbf{X}^*, \mathbf{X}^*) - K(\mathbf{X}^*, \mathbf{X}) [K(\mathbf{X}, \mathbf{X}) + \sigma_\epsilon^2 \mathbf{I}]^{-1} K(\mathbf{X}, \mathbf{X}^*). \quad (2.18)$$

Assim, pode-se observar nas Equações 2.16, 2.17 e 2.18 o processo de estimação de estimação pelo GPR é não paramétrica (SWILER et al., 2020; WILLIAMS; RASMUSSEN, 2006; SCHULZ; SPEEKENBRINK; KRAUSE, 2018), já que não é estimado um parâmetro para uma função linear clássica utilizada em um modelo *bayesiano*. Utiliza-se os dados já existentes para predições futuras, mas também uma função *kernel*, que impacta diretamente o desempenho do modelo a ser obtido. Um exemplo de função de covariância a ser utilizada é a função *Matérn* expressa por :

$$k(x, x') = \frac{2^{1-\nu}}{\Gamma(\nu)} \left(\frac{\sqrt{2\nu d(x, x')}}{l} \right)^\nu K_\nu \left(\frac{\sqrt{2\nu d(x, x')}}{l} \right) \quad (2.19)$$

sendo ν e l parâmetros de controle, na quais são positivos e constantes, K_ν é a função *Bessel* modificada de ordem ν , $d(x, x')$ representa a distância *euclidiana* entre duas variáveis aleatórias presente no mesmo conjunto de dados, e $\Gamma(\nu)$ a função Gamma (KANAGAWA et al., 2018; CHEN; DING; TUO, 2022; WILLIAMS; RASMUSSEN, 2006).

Portanto, o GPR é um modelo de aprendizagem de máquina que possui a vantagem que trabalhar com número de amostras pequenos e casos que há mais de uma variável aleatória para ser utilizada para estimação (SWILER et al., 2020). Porém, apresenta como desvantagem o custo computacional de ordem $O(N^3)$ e o uso da memória para salvar os dados de treinamento, já que de acordo com o tamanho de amostras aleatórias coletadas e número de variáveis aumenta-se o tempo para obter os resultados para novas estimações (LIU et al., 2020).

2.6 Partial Least Squares

Partial Least Squares (ou PLS ou Mínimos Quadrados Parciais) é um dos métodos que pode ser utilizado no processo de *feature engineering* (DONG; LIU, 2018) na construção de modelos de aprendizagem de máquina, em que tem como princípio a definição de um modelo de regressão linear, com o objetivo de maximizar a correlação da relação de um conjunto de variáveis independentes ou *features* $\mathbf{X}$ e variáveis dependentes ou alvos, podendo ser uni-variável y ou multivariável $\mathbf{Y}$ (HELLAND, 1990; ABDI, 2010; GALINDO-PRIETO; ERIKSSON; TRYGG, 2015).

A construção do modelo de regressão a partir do PLS que maximiza a correlação ocorre a partir da definição de estruturas latentes tanto para $\mathbf{X}$ e y , como é apresentado por:

$$\mathbf{X} = \sum_{j=1}^A \mathbf{t}_j \mathbf{p}_j^T + \mathbf{E}, \quad (2.20)$$

$$\mathbf{X} = \mathbf{TP}^T + \mathbf{E}, \quad (2.21)$$

em que $\mathbf{X}$, $\mathbf{t}_j$ e $\mathbf{p}_j$ são os vetores de *scores* e de *loadings*, respectivamente, da variável independente $\mathbf{X}$, onde j varia de 1 à A , em que A é o número de componentes latentes a ser definido, e $\mathbf{E}$ é a matriz de resíduos obtida após a obtenção dos valores das variáveis latentes $\mathbf{t}$ e $\mathbf{p}$ para $\mathbf{X}$ (GELADI; KOWALSKI, 1986; LI; MORRIS;

MARTIN, 2002). $\mathbf{T}$ e $\mathbf{P}$ são as matrizes de *scores* e *loadings*, respectivamente (GELADI; KOWALSKI, 1986), de $\mathbf{X}$.

$$\mathbf{y} = \sum_{j=1}^A \mathbf{u}_j \mathbf{q}_j^T + \mathbf{F}, \quad (2.22)$$

$$\mathbf{y} = \mathbf{U} \mathbf{Q}^T + \mathbf{F}, \quad (2.23)$$

sendo $\mathbf{y}$ é o vetor da variável dependente ou alvo, já $\mathbf{u}_j$ e $\mathbf{q}_j$ são os vetores de *scores* e de *loadings*, respectivamente, de $\mathbf{y}$, e $\mathbf{F}$ é a matriz de resíduos obtida no final do processo de obtenção das variáveis latentes relacionadas com as variáveis dependentes (ABDI, 2010). $\mathbf{U}$ e $\mathbf{Q}$ são as matrizes de *scores* e *loadings*, respectivamente (GELADI; KOWALSKI, 1986), de $\mathbf{y}$.

Para obtenção do modelo de regressão e das variáveis latentes apresentadas nas Equações 2.20 à 2.23 deve-se aplicar um algoritmo iterativo, assim, pode-se aplicar o *NIPALS* (*Nonlinear Iterative Partial Least Squares*), conforme descrito em Martins (2013), Geladi e Kowalski (1986), Abdi (2010) e Wold (1975). Portanto, no final das iterações ou a convergência do algoritmo são obtidas as componentes latentes da matriz $\mathbf{X}$, apresentando A colunas, sendo que estas componentes apresentam as características que melhor irão predizer $\mathbf{y}$.

A partir das variáveis latentes obtidas para a construção do modelo, pode-se definir quais *features* presentes em $\mathbf{X}$ possuem maior importância para predizer $\mathbf{y}$. Logo, é possível selecionar previamente estas *features* para o processo de regressão. Esse processo de seleção pode ser realizado ao empregar o método *VIP* (*Variable Importance in Projection*) como é exposto em Gosselin, Rodrigue e Duchesne (2010), Mahieu, Qannari e Jaillais (2023) e Mehmood et al. (2012). A importância de cada característica presente em $\mathbf{X}$ é dada por:

$$\mathbf{VIP}_m = \sqrt{M \frac{\sum_{a=1}^A (\mathbf{q}_a^2 \mathbf{t}_a^T \mathbf{t}_a) (w_{aj} \|\mathbf{w}_j\|)}{\sum_{a=1}^A (\mathbf{q}_a^2 \mathbf{t}_a^T \mathbf{t}_a)}}, \quad (2.24)$$

sendo $\mathbf{w}_a$ vetor pesos de carregamento, $\mathbf{q}_a$ o vetor de carga (*loadings*) da variável dependente $\mathbf{y}$ e $\mathbf{t}_a$ o vetor de pontos (*scores*) da variável independente $\mathbf{X}$ (MEHMOOD et al., 2012). A número de componentes, j e m varia de 1 à M número de características de $\mathbf{X}$ (MEHMOOD et al., 2012), em que as características selecionadas são aquelas que apresentam $\mathbf{VIP}_m$ maior ou igual a 1 (MAHIEU; QANNARI; JAILLAIS, 2023)

Portanto, o PLS é um algoritmo que pode ser utilizado tanto para seleção de *features* e redução de dimensionalidade de $\mathbf{X}$. Assim, o modelo construído pelo PLS tem como vantagem: geração de componentes

latentes ortogonais entre si, robustos a ruídos ou a falta de dados presentes em algumas ou todas *features*, redução da dimensionalidade e entre outras (MARTINS, 2013; PIROUZ, 2006). Como desvantagens possui o não conhecimento da distribuição do modelo de predição gerado, já que não ocorre o processo de validação do modelo (PIROUZ, 2006).

3 MATERIAIS E MÉTODOS

Este capítulo descreve os materiais e métodos utilizados para o desenvolvimento e implementação deste trabalho. Primeiramente, são apresentados o conjunto de dados e recursos computacionais utilizados para o desenvolvimento do trabalho. E por fim é apresentada a metodologia implementada tanto para análise do conjunto de dados e modelagem para a estimação da força lateral.


3.1 Materiais

Esta seção detalha os conjuntos de dados e a linguagem de programação utilizadas.

3.1.1 Conjunto de dados de treinamento

O conjunto de dados utilizado neste trabalho para analisar o comportamento de um pneu inteligente e para o processo de modelagem para estimação da força lateral é composto por valores medidos provenientes de ensaios realizados com pneus em uma plataforma de testes *MTS Flat-Trac*, conforme descrito em Barbosa et al. (2022) e apresentado na Figura 3.1. Esta figura apresenta o processo de aquisição dos sinais de aceleração de um pneu inteligente com um acelerômetro tri-axial acoplado no seu interior, assim, os sinais elétricos gerados são regularizados e convertidos via um regulador de tensão e um *slip ring*. Por fim, os sinais elétricos são adquiridos por uma placa de aquisição de dados *NI DAQ* e convertidos para os sinais de aceleração a_x , a_y e a_z . Juntamente, com esse processo de aquisição dos sinais de aceleração são obtidas as forças F_x , F_y e F_z pela plataforma *MTS Flat-Trac*.

Figura 3.1 – Sistema de testes e aquisição de dados de pneus inteligentes, em que o acelerômetro tria-axial apresentado na figura está acoplado no interior do pneu.



Fonte: Adaptado de (BARBOSA et al., 2022)

Os ensaios foram realizados variando o ângulo de deriva entre -10° e 10° , com diferentes velocidades (30 e 60 km/h) e cargas aplicadas (2080 N, 4160 N e 6240 N), conforme apresentado na Figura 3.2. Este conjunto de dados é composto por 1.796.122 amostras obtidas com uma taxa de amostragem de 10 kHz com 8 variáveis, como pode ser visto na Tabela 3.1.

Tabela 3.1 – Descrição dos dados.

Sinais	Significado
$a_x(g)$	aceleração no eixo x(m/s^2)
$a_y(g)$	aceleração no eixo y(m/s^2)
$a_z(g)$	aceleração no eixo z(m/s^2)
$F_y(g)$	Força lateral (N)
tag	Sinal que indica o acelerômetro percorrendo o <i>contact patch</i>
$F_z(g)$	Força vertical (N)
SA	<i>Slip Angle</i> ($^\circ$)
Vr	Velocidade linear do pneu (km/h)

Os sinais de aceleração adquiridos possuem duas regiões para cada ciclo do pneu: uma que corresponde ao percurso do acelerômetro dentro da região onde o pneu está em contato com a superfície, chamada de *contact patch*, e outra com dados de medição de aceleração fora da região de contato, conforme pode ser visto na Figura 3.3.


A variável *tag* apresentada nessa figura tem como finalidade indicar o momento no tempo que o pneu esteve em contato com o solo, ou seja, se a variável apresentar um valor igual a 1 em um certo período de tempo então os sinais a_x , a_y e a_z são pertencentes a região de contato pneu-solo, caso contrário, os sinais estão fora dessa região. Além da Figura 3.3 apresentar as regiões fora e dentro da interface pneu-solo, pode-se notar visualmente que em ambas as regiões há presença de ruídos nos sinais de aceleração.

3.1.2 Conjunto de dados de validação

Para a validação do modelo final a ser obtido a partir do conjunto de dados apresentado anteriormente é utilizado um segundo conjunto de dados, obtido pelo mesmo sistema de aquisição apresentado na Figura 3.1 e realizado por (BARBOSA et al., 2022), logo, possuindo os mesmos campos de saídas apresentado na Tabela 3.1. Porém, foi variado o comportamento e os valores empregados para obtenção desse conjunto de dados.

A Figura 3.4 apresenta as representações gráfica dos sinais ângulo de deriva, velocidade linear e força vertical, respectivamente, em (a), (b) e (c), utilizados ao longo dos ensaios para obtenção dos dados de validação. Nesses sinais, o ângulo de deriva varia em forma de degraus entre -8° e 8° , a velocidade linear

Figura 3.2 – Sinais de entrada para a geração dos sinais de aceleração e força lateral do conjunto de treinamento. Na qual apresenta os seguintes sinais: a) Ângulo de deriva em graus variando de forma triangular aplicada ao pneu; b) Velocidade linear do pneu em km/h de rolamento do pneu variando ao longo das rotações; c) Força vertical F_z em N aplicada sobre o pneu, medida obtida a partir do ensaio realizado por (BARBOSA et al., 2022).




Fonte: autor

varia entre 29,75 e 60,12, e a força vertical varia entre os diferentes ensaios com os intervalos entre 2.036,62 e 2.123,17, 4.114,61 e 4.238,19, e por último alternando 6.200,22 e 6.323,17.

Este conjunto de dados apresenta 5.093.649 amostras adquiridas em uma frequência de amostragem igual a 10 kHz. O conjunto de dados de treinamento e validação se diferem pela forma que são geradas,


Figura 3.3 – Janelas de dados dentro e fora da região de contato. As áreas que estão fora da região de contato estão tracejadas em preto, já a região tracejada em rosa corresponde à região dentro do *contact patch* onde a variável *tag* recebe o valor unitário.



Fonte: autor


já que, o ângulo de deriva dos dados de treinamento varia de forma triangular e o de validação varia de forma de degraus. Além disso, a força vertical, mesmo apresentando faixa de valores aproximados em ambos os conjuntos de dados, há uma maior variação da força empregada ao longo das rotações no dado de treinamento. Portanto, os sinais de saída apresentarão comportamento diferentes, e esta diferenciação pode ser notada a partir da Figura 3.5 que apresenta o sinal F_y para conjunto de dados de treinamento e de validação, respectivamente, em (a) e (b).

Figura 3.4 – Sinais de entrada para a geração do conjunto de dados de validação, na qual apresenta os seguintes sinais:
a) Ângulo de deriva variando em degraus ao longo das rotações de um pneu; b) Velocidade linear do pneu em km/h de rolamento do pneu variando ao longo das rotações; c) Força vertical F_z em N aplicada sobre o pneu, medida obtida a partir do ensaio realizado por (BARBOSA et al., 2022).



Fonte: autor

Figura 3.5 – Forças laterais (F_y) do sinal medido para o conjunto de dados de treinamento e de validação, em que: a) é a força lateral medida para os dados de treinamento; b) força lateral do conjunto de dados de validação.



Fonte: autor

3.1.3 Linguagem de programação e recursos computacionais

A linguagem de programação utilizada neste trabalho é a linguagem Python 3.10, utilizando o *Pycharm* 2023.1 como ambiente de desenvolvimento para a implementação do algoritmo em um *notebook Dell* com um processador *Intel Core* i5 com 8 GB de memória RAM. As seguintes bibliotecas foram utilizadas:

- **numpy**: possui a finalidade de trabalhar com vetores e matrizes;
- **pandas**: é utilizada para manipulação de dados de um determinado conjunto de dados;
- **matplotlib.pyplot**: é utilizada para visualização de gráficos;
- **scipy.signal**: é aplicada neste trabalho para realizar o processo de filtragem do sinal manipulando os módulos *firwin* e *lfiler*, onde o primeiro determina os parâmetros utilizados para o filtro *FIR*, já o último realiza o processo de filtragem a partir dos parâmetros calculados pelo o primeiro módulo;
- **math**: lida com operações matemáticas;
- **sklearn.ensemble.RandomForestRegressor**: classe utilizada para obtenção de modelos de aprendizagem de máquina *Random Forest* para operações de regressão;
- **sklearn.gaussian_process.GaussianProcessRegressor**: classe utilizada para obtenção de modelos de aprendizagem de máquina *Gaussian Process Regression*;
- **sklearn.model_selection.RandomizedSearchCV**: classe utilizada para o processo de refinamento de hiper-parâmetros de modelos de aprendizagem de máquinas, em que define-se para cada hiper-parâmetro uma faixa de valores possíveis, de forma prévia, e a melhor combinação, baseado nestas faixas de valores, é feita de forma aleatória após um número pré-determinado de execuções a serem feitas.
- **PyEMD.EMD**: classe utilizada para obter as funções intrínsecas de um dado sinal.

3.2 Métodos

Esta seção descreve tanto os métodos aplicados para se realizar a análise exploratória quando o processo de obter o modelo para se estimar a força lateral (F_y) a partir do conjunto de dados citado na Seção 3.1.1.

3.2.1 Análise Exploratória

Esta seção apresenta os dois fluxogramas, Figuras 3.6 e 3.7, para se analisar o conjunto de dados apresentado na Seção 3.1.1, que foram baseadas nas análises realizadas por Souza e Barbosa (2022).

Figura 3.6 – Fluxograma da metodologia de análise, cujo objetivo é entender o comportamento das IMF's do sinal após a filtragem por um filtro PB de 400 Hz.





Figura 3.7 – Fluxograma da metodologia de análise, cujo objetivo é estudar o comportamento das IMF's para o sinal sem nenhum tratamento anterior.



Os fluxogramas apresentados nas Figuras 3.6 e 3.7 têm como objetivo apresentar as etapas de forma sucinta dos procedimentos realizados para se analisar os dados em dois aspectos, com e sem filtro PB de 400 Hz, respectivamente. Assim, a descrição de cada etapa de ambos os fluxogramas são apresentadas nas seções a seguir.


3.2.1.1 Segmentação das amostras por ciclo

Esta etapa correspondente à "Aquisição de janelas de dados corresponde a uma volta completa do pneu", que se dá partir dos valores da variável *tag*, descrito na Tabela 3.1, são obtidas as amostras, ou "janelas de dados", dos sinais que correspondem a um ciclo completo do pneu. Esta volta completa do pneu corresponde a uma faixa de valores anterior e após a região de contato, como pode ser observado na Figura 3.8. Assim, a etapa 1 descrita em ambas metodologias apresentadas nas Figuras 3.6 e 3.7 tem como objetivo obter um ciclo completo de um pneu, em que este ciclo apresenta valores dentro e fora da região de contato.

3.2.1.2 Filtro passa-baixa de 400Hz

Foi implementado um filtro do tipo *Butterworth* passa-baixa de ordem 5 com frequência de corte igual a 400 Hz. Etapa 2 apresentada na Figura 3.6, com a finalidade de remover ou reduzir a influência de ruídos em alta frequência. Essa filtragem ocorre nas amostras correspondentes a um ciclo completo obtido na etapa anterior. Esse filtro é o mesmo utilizado por Barbosa et al. (2022).

Figura 3.8 – Definição de um ciclo completo do pneu. As amostras dentro da área tracejada correspondem a um ciclo completo do pneu.



Fonte: autor

3.2.1.3 EMD

A etapa **3** presente nos fluxogramas apresentados nas Figuras 3.6 e 3.7 tem como objetivo identificar padrões de comportamentos presentes nas funções intrínsecas e a qualidade dos sinais reconstruídos. Primeiramente, é realizada uma análise com finalidade de se observar os padrões de energia das IMF's geradas em ambas metodologias, em que se obtém a energia da mediana de cada conjunto de ângulos de derivas para específicas forças verticais, sinais descritos na Figura 3.2, ou seja, é escolhida a mediana de um conjunto de valores de ângulos de derivas que estão em torno de um valor inteiro, por exemplo, 1° , -1° , 2° , -2° , para diferentes faixas de forças verticais aplicadas. A energia de cada função gerada é calculada por:

$$E_i = \sum_{k=1}^N |imf_k|^2, \quad (3.1)$$

em que E_i é a energia do sinal para uma específica IMF, N é o número de amostras obtidas em um conjunto de dados correspondente a um ciclo completo e imf é uma função intrínseca obtida a partir do uso da EMD.


Por último, com a finalidade de determinar a qualidade dos sinais obtidos é realizada a análise a partir do uso da EMD, na qual se soma as IMF's obtidas em cada ciclo completo, sendo que a primeira função obtida para cada ciclo em ambas metodologias não é utilizada no processo de reconstrução. Assim, a equação a seguir demonstra o processo realizado:

$$S_j = \sum_{k=a}^b imf_{kN}, \quad (3.2)$$

em que S_j é a soma das funções para um conjunto de dados j , $\mathbf{a}$ é o índice da IMF escolhida para ser o início da soma, sendo diferente de 1, já que a primeira função apresenta geralmente sinais em alta frequência como já apresentado na Seção 2.4, e menor que M . Por último, $\mathbf{b}$ é o índice da IMF final da soma, a qual é menor ou igual a M , que é o número de funções obtidas ao se aplicar a EMD.

Portanto, as somas obtidas são comparadas com sinais de referência apresentados pela Figura 3.9 para verificar a qualidade das mesmas

Figura 3.9 – Representação dos sinais de aceleração típicos nos eixos x, y e z para uma situação onde há ocorrência mínima de ruído para um tempo qualquer.




Fonte: adaptado de (BARBOSA et al., 2022)

3.2.2 Modelagem

A Figura 3.10 apresenta o fluxograma, de forma simplificada, das diferentes configurações de modelos utilizadas para o processo de estimação da força lateral (F_y). Já a Tabela 3.2 apresenta os nomes dos modelos a serem construídos com suas respectivas características.

Figura 3.10 – Fluxograma da metodologia proposta para o processo de estimação da força lateral (F_y).



Fonte: autor

A marcação ● presente na Tabela 3.2 demonstra que determinada característica está presente no modelo apresentado na coluna *Modelos*. Assim, os caracteres presentes na nomenclatura dos modelos possuem os seguintes significados:

- **M**: modelo que apresenta a etapa de aquisição de dados correspondente a uma volta completa do pneu;
- **F**: etapa com a presença do filtro *Butterworth* PB de 400 Hz de 5ª ordem;
- **E**: etapa correspondente a reconstrução do sinal a partir do uso das IMF's obtidas via EMD;
- **C720**: passo presente no modelo que tem a função de codificar os sinais a_x , a_y e a_z para que correspondam aos ângulos entre 0° à 359,5° (ciclo completo);
- **C140**: passo presente no modelo que tem a função de codificar os sinais a_x , a_y e a_z para que correspondam aos ângulos entre 145,5° à 215° (*contact patch*), em que esta faixa de ângulos se baseou nas faixas de ângulos utilizadas por Barbosa et al. (2022) e Xu et al. (2022);
- **PV**: estágio presente para a seleção de características, após o processo de codificação, a partir do PLS com VIP.

As etapas de "Aquisição de "janelas" de dados correspondente a uma volta completa do pneu" (M) e "Filtro PB de 400 Hz" (F) já foram descritas nas Seções 3.2.1.1 e 3.2.1.2, respectivamente. As demais etapas presente no fluxograma da Figura 3.10 e Tabela 3.2 são melhores detalhadas nas seções a seguir.

Tabela 3.2 – Nome e as principais configurações dos modelos propostos apresentados no fluxograma da Figura 3.10.

Modelos	Aquisição de "janelas" de dados de uma volta completa do pneu	Filtro PB de 400 Hz	EMD	Codificação das janelas de 0° à 359,5°	Codificação das janelas de 145.5° à 215°	PLS - VIP
MFC720	●	●		●		
MFEC720	●	●	●	●		
MEC720	●		●	●		
MFC720PV	●	●		●		●
MFEC720PV	●	●	●	●		●
MEC720PV	●		●	●		●
MFC140	●	●			●	
MFEC140	●	●	●		●	
MEC140	●		●		●	
MFC140PV	●	●			●	●
MFEC140PV	●	●	●		●	●
MEC140PV	●		●		●	●

3.2.2.1 EMD

Esta etapa corresponde ao processo de reconstrução do sinal a partir do uso das funções intrínsecas e baseada na Equação 3.2, já citada anteriormente na Seção 3.2.1.3. A reconstrução do sinal se dá a partir de diferentes configurações, como é demonstrado na Tabela 3.3.

O modelo com a seguinte nomenclatura, por exemplo, **MEC720PV-7**, significa que é um modelo sem a utilização do filtro passa-baixa de 400 Hz, apresenta o uso da EMD para a reconstrução do sinal de aceleração com base na soma das funções intrínsecas existentes entre e a começar pela 4^a e a terminar na *M*-ésima função. Por final é realizado um processo de codificação que irá conter 720 amostras, ou seja, do ciclo completo, para cada sinal de aceleração, que é melhor descrita na seção a seguir, com o seletor de características PLS-VIP.

Portanto, esta etapa no processo de modelagem consiste em reconstruir os sinais de aceleração correspondente a um ciclo completo de a_x , a_y e a_z sem ou com o mínimo de ruído a partir das diferentes configurações apresentadas na Tabela 3.3.

Tabela 3.3 – As diferentes configurações utilizadas para a reconstrução do sinal a partir das IMF's obtidas via EMD, em que **a** é o índice da IMF escolhida para ser o início da soma e **b** é o índice da IMF escolhida para ser o fim da soma

Configuração	a	b
1	2	M
2	2	$M - 1$
3	2	$M - 2$
4	3	M
5	3	$M - 1$
6	3	$M - 2$
7	4	M
8	4	$M - 1$
9	4	$M - 2$
10	5	M
11	5	$M - 1$
12	5	$M - 2$


3.2.2.2 Codificação das janelas de dados de 0° à $359,5^\circ$

Este passo consiste em codificar os sinais de aceleração a_x , a_y e a_z , obtidos pelas etapas anteriores que o antecedem, com a função de obter pontos dentro do ciclo completo de pneu com resolução de 0.5° . A partir do processo de codificação são obtidos 720 pontos, equivalente à faixa de 0° , ponto **A**, à $359,5^\circ$, ponto **E**, como apresentado na Figura 3.13 que é a representação ilustrativa desses pontos ao longo dos sinais de aceleração em um pneu inteligente, para cada sinal de aceleração. Os sinais são concatenados após o processo descrito, como pode ser observado na Figura 3.11, que apresenta de forma simplificada a codificação e concatenação dos sinais expostos nesta etapa. Portanto, os sinais obtidos nesse processo são independentes do tempo e a partir de cada uma das 720 amostras de aceleração são possíveis obter atributos, ângulos de rotação do pneu pertencente a cada sinal, a serem usados nos modelos de aprendizagem de máquina.

3.2.2.3 Codificação das janelas de dados de $145,5^\circ$ à 215°

Esta etapa, semelhante ao processo de codificação citado na Seção 3.2.2.2, consiste em codificar os sinais de aceleração a_x , a_y e a_z , com a finalidade de que cada ponto dentro do conjunto de dados corresponda à 0.5° da rotação do pneu. A partir deste processo de codificação são obtidos 140 pontos, equivalente à $145,5^\circ$, ponto **B**, à 215° , ponto **D**, como apresentado na Figura 3.13, correspondente à área em torno da região de contato pneu-solo, ponto **C**, para cada sinal de aceleração. Os sinais são concatenados após o processo descrito, obtendo 420 pontos, como pode ser observado na Figura 3.12. Portanto, a partir da codificação, os sinais são independentes do tempo e cada uma das 420 amostras de aceleração são possíveis

Figura 3.11 – Demonstração do processo de codificação para obtenção de 720 pontos para cada sinal de aceleração, esses pontos correspondem aos ângulos de rotação do pneu entre 0° à 359,5°, na qual são os atributos e dados de entrada dos modelos de aprendizagem de máquina. A linha tracejada preta apresenta a "janela" de dados de um ciclo completo do pneu e que esses pontos são extraídos.




Fonte: autor

obter os atributos, ângulos de rotação do pneu pertencente a cada sinal, a serem usados nos modelos de aprendizagem de máquina.

3.2.2.4 PLS-VIP


Este passo consiste na seleção de características via o uso do PLS - VIP, já explicado na Seção 2.6, em que a partir das componentes latentes obtidas ao aplicar o PLS nos dados codificados é utilizado o VIP, Equação 2.24, para identificação das variáveis, atributos, com maior importância para geração dessas componentes. As características selecionadas são aquelas que possuem o $VIP \geq 1$.

Figura 3.12 – Demonstração do processo de codificação para obtenção de 140 pontos para cada sinal de aceleração, esses pontos correspondem aos ângulos de rotação do pneu entre $145,5^\circ$ à 215° , na qual são os atributos e dados de entrada dos modelos de aprendizagem de máquina. A linha tracejada em laranja representa o conjunto ("janela") de dados de um ciclo completo do pneu, já a verde apresenta, aproximadamente, a região onde os pontos são extraídos nesta etapa.



Fonte: autor

Figura 3.13 – Representação dos pontos correspondente as faixas de valores 0° à $359,5^\circ$ em um pneu inteligente juntamente com a representação gráfica dos sinais de aceleração nos eixos x , y e z . E cada ponto tem o seguinte significado: o ponto **A** é igual a 0° ; **B** é igual a $145,5^\circ$; **C** corresponde o ponto de contato do pneu, equivalente ao ângulo de 180° ; **D** é igual a 215° ; e **E** é igual a $359,5^\circ$



Fonte: autor

3.2.2.5 Estimação de F_y

O processo de estimação da força lateral, F_y , é realizado por dois algoritmos de aprendizagem de máquina, o *Random Forest* (**RF**) e o *Gaussian Process Regression* (**GPR**). No processo de estimação são utilizados como dados de entrada os sinais obtidos nas etapas anteriores e como de saída a força lateral (F_y). Assim, se o modelo apresentar a nomenclatura, por exemplo, igual a **MEC720PV-7-RF**, significa que apresenta as configurações já citadas, mas também utiliza o modelo de aprendizagem de máquina *Random Forest* na sua composição.

Para avaliar os modelos a serem implementados é utilizada o *Normalize Root Mean Squared Error* (NRMSE)(XU et al., 2023), representado por

$$NRMSE(\%) = 100 \frac{\sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2}}{y_{max}}, \quad (3.3)$$

em que y_k é a força lateral medida na k -ésima amostra, $\hat{y}_k$ é a força predita pelos modelos desenvolvidos, N é o número de amostras do dado de saída e y_{max} é o valor máximo da força lateral medidamm. Essa medida de erro é empregada juntamente com o método de *k-Fold* (OJALA; GARRIGA, 2010), em que é definido o número de *folds* igual a 10.

Além da medida NRMSE utilizada para avaliar os modelos implementados, é também utilizado o coeficiente de determinação (r^2) (MARTINS, 2018), representado por

$$r^2 = 1 - \frac{\sum_{k=1}^N (\hat{y}_k - \bar{y})^2}{\sum_{k=1}^N (y_k - \bar{y})^2}, \quad (3.4)$$

em que $\bar{y}$ é a média da força lateral medida.

Por fim, para auxiliar a escolha do melhor modelo a ser validado é utilizado o método de *Turkey* (ABDI; WILLIAMS, 2010), com a finalidade de identificar se há significância estatística entre a média dos valores de NRMSE encontrados para o melhor modelo observado com os demais implementados. Assim, os modelos **RF** e **GPR** que apresentarem melhores resultados relacionados ao NRMSE e r^2 serão validados utilizando o conjunto de dados de validação, citado na Seção 3.1.2.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados das metodologias propostas, em que é dividido em duas seções: Análise Exploratória e Modelagem.


4.1 Análise Exploratória

Os resultados das análises exploratórias se baseiam nos dois fluxogramas apresentados nas Figuras 3.6 e 3.7, em que ambos os fluxos apresentam em comum a etapa de aquisição de um conjunto de dados, **1**, correspondente a uma volta completa do pneu, apresentando valores dentro e fora da região de contado, como é observado na Figura 4.1. Nessa etapa foram obtidos 1145 conjuntos de dados.

A Figura 4.2 apresenta os sinais de aceleração nos eixos x, y, z, respectivamente, de uma amostra correspondente a um ciclo completo com seu respectivo sinal filtrado, em que o processo de filtragem está presente no fluxograma da Figura 3.6. Além disso, são apresentados os sinais correspondentes no domínio da frequência sem passar pelo processo de filtragem e após passar pelo filtro. Pode-se notar a efetividade da remoção do ruído em alta frequência, superiores a 400 Hz, nos sinais de aceleração a_x , a_y e a_z , porém, há ainda presença de ruído em baixa frequência.

A partir da aquisição das amostras correspondentes a um ciclo completo foi possível analisar a energia das IMF's, as Figuras 4.3, 4.4 e 4.5 exemplificam o comportamento das funções obtidas para a_x , a_y e a_z , respectivamente, dos sinais de aceleração filtrados e não filtrados em variados ângulos de derivas e cargas. Onde, é possível identificar que as 3 primeiras IMF's, para os 3 sinais de aceleração, apresentam as maiores magnitudes e a presença de boa parte do ruído, podendo indicar que o processo de decomposição foi capaz de discernir o ruído presente em alta frequência. A Figura 4.6 apresenta a energia das IMF's obtidas nos pontos de operação com ângulo de deriva em torno de -2° para as cargas de 2080 N, 4160 N e 6240 N, para os conjuntos de dados iguais a 57, 646 e 303, respectivamente, ao se aplicar a metodologia apresentada na Seção 3.1.1.

Figura 4.1 – Representação de um conjunto de dados, instância de número 500, correspondente a um ciclo completo obtido a partir do conjunto de dados de treinamento para a_x , a_y e a_z .



Fonte: autor

Figura 4.2 – Representação de um conjunto de dados, instância de número 500, com a aplicação de filtro PB de 400 Hz para os sinais aceleração a_x , a_y e a_z . Sendo que: a) , e) e i) são ciclos completo sem nenhum processo de filtragem para a_x , a_y e a_z , respectivamente; b), f) e j) são amostras filtradas das acelerações pertencentes ao eixo x, y e z; c), g) e k) são os domínios da frequência das amostras sem filtragem para os sinais aceleração a_x , a_y e a_z , respectivamente; d), h) e l) são os domínios da frequência das amostras filtradas para os eixos x, y e z, respectivamente.






Figura 4.3 – Funções intrínsecas obtidas para a_x para o ângulo de deriva igual a -2° e carga igual 6240 N. Figuras com o objetivo de exemplificar as IMF's obtidas via decomposição empírica.




Fonte: autor

Figura 4.4 – Funções intrínsecas obtidas para a_y para o ângulo de deriva igual a -2° e carga igual 6240 N. Figuras com o objetivo de exemplificar as IMF's obtidas via decomposição empírica.




Fonte: autor

Figura 4.5 – Funções intrínsecas obtidas para a_z para o ângulo de deriva igual a -2° e carga igual 6240 N. Figuras com o objetivo de exemplificar as IMF's obtidas via decomposição empírica.



Fonte: autor

Figura 4.6 – Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu sem aplicar nenhuma filtragem para o ângulo de deriva igual a -2° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z .



Fonte: autor


Já a Figura 4.7 mostra a energia das IMF's nos mesmos pontos de operação descritos, contudo, corresponde aos sinais de aceleração filtrados por um filtro passa baixa *Butterworth* de 5ª ordem com frequência de corte igual a 400 Hz.

Ao observar a energia dos sinais obtidos pode-se notar que mesmo apresentando ângulos de derivas iguais, -2° , a amplitude da energia e o número de IMF's variam de acordo com a carga aplicada no pneu, em que isto ocorre tanto para os sinais filtrados e não filtrados. Mas também, há uma diferença quando é comparado o número de funções intrínsecas obtidas a partir dos sinais de aceleração sem aplicar o filtro passa-baixa, Figura 4.6, com o número de funções para sinais filtrados, Figura 4.7, em que o último grupo apresenta um número menor de funções, como esperado, já que são sinais tratados a partir do uso de um filtro.

Nota-se que, para as diferentes cargas aplicadas, variam-se os índices das funções com maior e menor energia entre as acelerações a_x , a_y e a_z , este fato ocorre tanto para o sinal filtrado quando para o não filtrado. Portanto, quando algumas funções apresentam um nível elevado de energia, isso pode indicar que são úteis para a reconstrução do sinal, pois podem estar isentas de ruído ou conter informações relevantes, embora apresentem ruído, o que, por sua vez, pode aumentar o nível de energia do sinal. O Apêndice A apresenta mais exemplos do emprego da metodologia em diferentes ângulos de derivas e cargas que complementam a análise feita a partir da energia das funções intrínsecas obtidas pelo EMD.

As Figuras 4.8 e 4.9 apresentam os sinais de acelerações a_x , a_y e a_z para o ângulo de deriva igual a 2° em uma carga igual a 6240 N, correspondendo aos conjuntos de dados iguais a 514, 251 e 370, respectivamente, com as suas respectivas reconstruções dos sinais obtidas a partir das funções intrínsecas ao utilizar o método de decomposição empírica, apresentando diferentes reconstruções para distintos índices **a** e **b**, ao utilizar a Equação 2.6. A primeira figura possui o sinal não filtrado com seus respectivos sinais reconstruídos, observa-se que as diferentes reconstruções apresentam o comportamento dos sinais típicos apresentados na Figura 3.9, porém o processo de reconstrução do sinal para diferentes índices **a** e **b** não foram suficientes para a remoção do ruído, em que isto ocorre tanto para a_x , a_y e a_z .

Figura 4.7 – Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu filtrado por um filtro PB de 400 Hz de 5^a o para o ângulo de deriva igual a -2° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z .




Fonte: autor

Já a Figura 4.9 apresenta o sinal filtrado e a reconstrução do sinal para diferentes índices **a** e **b**, apresentando o comportamento dos sinais típicos de aceleração, contudo o processo de reconstrução, para alguns casos, gerou sinais distorcidos em relação ao sinal original, logo, são gerados sinais que não possuem o comportamento do sinal original. Contudo, o sinal a_x reconstruído com índice **a** e **b** iguais a 4 e M apresentou o formato típico esperado, sem a presença de ruído e sem distorção em relação ao sinal original. Esse comportamento também é observado para os sinais a_y e a_z quando **a** e **b** são iguais a 3 e $M - 1$, portanto, indicando que para diferentes sinais de aceleração o processo, de reconstrução do sinal pode ser utilizado a partir de faixas de índices ou funções intrínsecas específicas para cada sinal.


As Figuras 4.10 e 4.11 apresentam os sinais de acelerações a_x , a_y e a_z para o ângulo de deriva igual a 10° em uma carga de 6240 N, correspondendo ao conjunto de dados igual a 566, 825 e 1086, respectivamente, com as suas respectivas soma das funções intrínsecas obtidas pelo EMD. A primeira figura possui o sinal não filtrado e a segunda o sinal filtrado, sendo que ambos os casos se distanciam do formato do sinal esperado apresentado pela Figura 3.9, exceto para a_z para o sinal filtrado, já que para esse ângulo de deriva há uma relação não-linear para uma carga aplicada no pneu, assim, há uma relação não-linear entre ângulo de deriva maior que 8° com uma carga superior a 4000 N, como pode ser visto na Figura 2.6. Portanto, a EMD pode gerar funções intrínsecas misturadas entre si, ou seja, uma função gerada pode conter mais de uma IMF que pode vir a surgir nas etapas seguintes de decomposição. Logo, os sinais reconstruídos para esses casos podem não gerar sinais de aceleração sem ou com a presença mínima de ruído ou que se aproximem do sinal típico apresentado na Figura 3.9.

Figura 4.8 – Sinais de aceleração, para o ângulo de deriva igual a 2° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.




Fonte: autor

Figura 4.9 – Sinais de aceleração filtrados, para o ângulo de deriva igual a 2° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.




Para ângulos de deriva entre -8° e 8° é possível obter sinais de a_z reconstruídos que possuam o comportamento dos sinais de aceleração esperados. Figura 3.9, porém, dependendo dos índices **a** e **b** escolhidos, é possível obter sinais reconstruídos distorcidos em relação ao sinal original. Portanto, devido à essa característica, o processo de modelagem utiliza os valores de ângulos de deriva dentro dessa faixa independente da força vertical aplicada. O Apêndice B apresenta mais resultados do processo de reconstrução, corroborando as afirmações descritas.

Figura 4.10 – Sinais de aceleração, para o ângulo de deriva igual a 10° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.



Fonte: autor

Figura 4.11 – Sinais de aceleração filtrados, para o ângulo de deriva igual a 10° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.



Fonte: autor

4.2 Modelagem


Esta seção tem como objetivo apresentar os resultados do processo de modelagem descrito na Seção 3.2.2. A partir das tabelas 3.2 e 3.3 e o uso dos modelos de aprendizagem de máquina *Random Forest* e *Gaussian Process Regression* são implementados 200 modelos com distintas configurações. As Figuras 4.12 e 4.13 apresentam os gráficos de *boxplot* do NRMSE e r^2 , respectivamente, para os modelos com diferentes codificações.

Observa-se nas Figuras 4.12 e 4.13 que os melhores modelos contendo **RF** e **GPR**, com os menores valores médios de NRMSE e r^2 mais próximos de 1, são:

- **MFC720PV-RF**: $\overline{NRMSE} = 20,7783 \pm 5,1371\%$ e $\overline{r^2} = 0,8634 \pm 0,0583$;
- **MFEC720PV-1-RF**: $\overline{NRMSE} = 22,4633 \pm 2,7753\%$ e $\overline{r^2} = 0,8439 \pm 0,0356$;
- **MFEC720PV-2-GPR**: $\overline{NRMSE} = 30,1601 \pm 15,8880\%$ e $\overline{r^2} = 0,6668 \pm 0,3573$;
- **MFC720PV-GPR**: $\overline{NRMSE} = 26,3905 \pm 12,2846\%$ e $\overline{r^2} = 0,7547 \pm 0,2748$.


Aplicando o método de *Turkey* entre os modelos **MFC720PV-RF** e **MFEC720PV-1-RF** obtém-se um valor de p igual a 1, dessa forma, não há significância estatística entre as médias entre os modelos, ou seja, pode-se utilizar qualquer um desses modelos contendo **RF** para o processo de validação que não haverá impacto na estimação. O mesmo ocorre entre os modelos **MFEC720PV-2-GPR** e **MFC720PV-GPR**, porém com valor de p igual a 0,835.

Figura 4.12 – *Boxplots* de 10 *folds* para NRMSE dos melhores modelos encontrados para diferentes tipos de codificações e modelos de aprendizagem de máquinas. O triângulo verde presente nos *boxplots* é a média dos valores de NRMSE de cada modelo.



Fonte: autor

Figura 4.13 – *Boxplots* de 10 *folds* para r^2 dos melhores modelos encontrados para diferentes tipos de codificações e modelos de aprendizagem de máquinas. O triângulo verde presente nos *boxplots* é a média dos valores de r^2 de cada modelo.




Fonte: autor

Com relação aos 4 modelos com o melhor desempenho, é possível notar 3 distintas configurações com e sem o uso da EMD independentes dos modelos de aprendizagem utilizados, que são: **MFC720PV**, **MFEC720PV-1** e **MFEC720PV-2**. Essas 3 configurações utilizam PLS-VIP para selecionar características, sendo que a Figura 4.14 apresenta os atributos selecionados provenientes de a_x , a_y e a_z para cada configuração, já a Figura 4.15 apresenta a porcentagem de contribuição dos sinais de aceleração do eixo x, y e z para o processo de estimação da força lateral.

Nota-se na Figura 4.14 que as configurações **MFC720PV**, **MFEC720PV-1** e **MFEC720PV-2** são selecionados atributos de a_y aproximadamente iguais do centro do *contact path* até o final da rotação do pneu, ou seja, seleciona-se ângulos de rotação do pneu fora e dentro da região de contato pneu-solo. O mesmo ocorre para os ângulos pertencentes a a_z . Já para a_x são selecionados os ângulos no centro do *contact patch* para **MFC720PV**, contudo, para as configurações **MFEC720PV-1** e **MFEC720PV-2** selecionam aproximadamente a mesma quantidade de atributos e quanto fora da região de contato do pneu-solo. A Figura 4.15 comprova os fatos apresentados anteriormente, mas também demonstra que nas configurações onde se aplica a EMD para o processo de reconstrução dos sinais de aceleração dos eixo x, y e z aumentou-se a contribuição, de forma significativa, dos atributos de a_x e reduziu a de a_z , quando comparado com a configuração sem o uso da EMD. Isso pode indicar que o processo de reconstrução do sinal a_x obteve valores de aceleração sem a presença de ruído e não distorcidos em relação ao sinal original, porém, para a_z , há um indício de que os sinais reconstruídos, para os índices **a** e **b** escolhidos para essas configurações com EMD, podem estar distorcidos em relação ao sinal original para atributos fora da região de interface pneu-solo.


A Figura 4.16 apresenta os resultados de teste dos melhores modelos encontrados para **MFC720PV-RF** ($NRMSE = 11,4603\%$ e $r^2 = 0,96036$), **MFEC720PV-1-RF** ($NRMSE = 18,6486\%$ e $r^2 = 0,8967$), **MFEC720PV-2-GPR** ($NRMSE = 15,4186\%$ e $r^2 = 0,9191$) e **MFC720PV-GPR** ($NRMSE = 16,4303\%$ e $r^2 = 0,9033$). Esses modelos contribuíram para a explicação de F_y com base nos conjuntos de dados de teste, uma vez que apresentaram valores de r^2 superiores a 0,89. Dentre eles, o modelo **MFC720PV-RF** destacou-se ao ajustar-se a 96,03% dos dados do conjunto de treinamento. Já a Figura 4.17 apresenta os resultados ao utilizar o conjunto de validação para 3300 instâncias de dados correspondentes a um ciclo completo, na qual a Tabela 4.1 apresenta os resultados de NRMSE e r^2 .

Figura 4.14 – Atributos selecionados a partir do PLS-VIP para 3 distintas configurações de modelos. Os atributos entre 0 e 719 são provenientes de a_x , 720 à 1439 são de a_y e 1440 à 2159 são de a_z . a) **MFC720PV**; b) **MFEC720PV-1**; c) **MFEC720PV-2**.




Fonte: autor

Figura 4.15 – Contribuição de cada atributo em % para o processo de estimação de F_y . a) **MFC720PV**; b) **MFEC720PV-1**; c) **MFEC720PV-2**.



Fonte: autor

Figura 4.16 – Representação gráfica dos resultados de testes para os 4 modelos com os melhores desempenhos encontrados. a) **MFC720PV-RF**; b) **MFEC720PV-1-RF**; c) **MFC720PV-GPR**; d) **MFEC720PV-2-GPR**.



Fonte: autor

Tabela 4.1 – Resultados de NRMSE e r^2 para os 4 modelos com os melhores desempenhos encontrados para o conjunto de dados de validação.

Modelos	NRMSE	r^2
MFC720PV-RF	17,2883	0,8939
MFEC720PV-1-RF	16,3322	0,9053
MFC720PV-GPR	17,8063	0,8875
MFEC720PV-2-GPR	16,5740	0,9025

Ao observar o comportamento dos sinais preditos nas Figuras 4.16 e 4.17, os modelos apresentam dificuldades para estimar valores de força lateral presente nos picos e nos vales do sinal, já que essas regiões apresentam alto valor de ângulo de deriva, acima de 6° . Contudo, essa situação é acentuada no processo de estimação do conjunto de dados de validação para as rotações superiores a 2400, já que nestas rotações além de conter valores elevados de ângulos de derivas também possui um alto valor de carga, entre 6200,22 e 6323,17, sendo aplicada no pneu, corroborando os fatos apresentados por Barbosa et al. (2022) e Xu et al. (2022).


Pode-se notar também que os intervalos de confiança obtidos, tanto para teste e validação, para os modelos contendo **GPR** estão muito próximos dos valores preditos de força, não englobando os valores medidos de F_y , portanto, o modelo considera os erros de predição existentes nos picos e nos vales como predições confiáveis o que não deveria ocorrer.

Os valores obtidos para o NRMSE e r^2 para o conjunto de dados de validação, apresentados na Tabela 4.1, demonstram que os modelos **MFC720PV-RF**, **MFEC720PV-1-RF**, **MFEC720PV-2-GPR** e **MFC720PV-GPR** possuem uma boa capacidade de estimar a força lateral para diferentes ângulos de deriva e cargas elevadas, pontos de operação onde há uma relação não-linear entre o ângulo de deriva e a força lateral, conforme mostrado na Figura 2.6.

Esses modelos apresentam erros inferiores a 20% e ajustam-se às amostras de dados. No entanto, ao comparar esses resultados com os obtidos no trabalho de Barbosa et al. (2022), que alcançou um NRMSE de 7,91%, observa-se que os modelos estão aquém das expectativas de estimativa, principalmente os que utilizam **GPR**, que apresentam intervalos de confiança baixos. No entanto, é importante destacar que os resultados dos quatro modelos diferem daqueles apresentados por Barbosa et al. (2022) devido à faixa de ângulos de deriva utilizada, neste trabalho, consideram-se ângulos que estão entre $-8,1^\circ$ a $8,1^\circ$, enquanto Barbosa et al. (2022) utilizam valores entre $-8,0^\circ$ a $8,0^\circ$, assim, o presente trabalho utilizou mais pontos de trabalhos do que os autores.

Por fim, os modelos evidenciam a influência das informações fora da região de contato pneu-solo, dado que, durante o processo de estimação, essas informações são utilizadas e apresentam uma contribuição

Figura 4.17 – Representação gráfica dos resultados ao utilizar o conjunto de dados de validação para os 4 modelos com os melhores desempenhos encontrados. a) **MFC720PV-RF**; b) **MFEC720PV-1-RF**; c) **MFC720PV-GPR**; d) **MFEC720PV-2-GPR**.



Fonte: autor

significativa no processo de estimação, como pode ser visto nas Figuras 4.14 e 4.15, sendo que, em contraponto, o trabalho de [Barbosa et al. \(2022\)](#) considera apenas pontos próximos à interface solo-pneu. Além disso, os resultados também destacam o benefício da decomposição empírica para a reconstrução dos sinais de aceleração filtrados pelo filtro PB de 400 Hz de 5ª ordem, uma vez que esses modelos apresentaram os melhores desempenhos durante a validação, como pode ser observado em 4.1.

5 CONSIDERAÇÕES FINAIS

O presente projeto apresentou variados modelos em caixa preta de estimação da força lateral, mas também foi capaz de avaliar o impacto das informações contidas fora da região de contato pneu-solo nesse processo de estimação, essas implementações se deram ao utilizar sinais de aceleração de pneus inteligentes, em que são estruturas ativas que se comunicam com o sistema de assistência ao motorista (ADAS). Os sistemas constituídos por pneus inteligentes podem garantir uma maior segurança e conforto ao condutor e aos ocupantes dos veículos.

Observou-se nas análises de energia e nas reconstruções dos sinais, há uma variação dos pontos de energia de menor e maior magnitude entre as funções intrínsecas por ângulo de deriva e carga, mas também foi possível obter sinais sem ruídos ao utilizar a EMD para a reconstrução do sinal a partir dos sinais previamente filtrados. Contudo, identificou-se que existe uma variação entre os índices **a** e **b** utilizados no processo de reconstrução para cada sinal de aceleração para a obtenção de sinais reconstruídos que possuem o comportamento típico sem distorção, logo, é um indício que para cada sinal de aceleração deve se utilizar IMF's específicas.

No processo de modelagem foram obtidos quatro modelos, dentre os 200 implementados, com os melhores resultados para o NRMSE e r^2 , em que são: **MFC720PV-RF**, **MFEC720PV-1-RF**, **MFEC720PV-2-GPR** e **MFC720PV-GPR**. Ambos os modelos contendo **RF** não possuem significância estatística entre as suas médias quando se aplica o método de *Turkey*, o mesmo ocorre para os modelos contendo **GPR**. Os melhores resultados de testes foram:

- **MFC720PV-RF**: $NRMSE = 11,4603\%$ e $r^2 = 0,96036$;
- **MFEC720PV-1-RF**: $NRMSE = 18,6486\%$ e $r^2 = 0,8967$;
- **MFEC720PV-2-GPR**: $NRMSE = 15,4186\%$ e $r^2 = 0,9191$;
- **MFC720PV-GPR**: $NRMSE = 16,4303\%$ e $r^2 = 0,9033$.

Esses resultados foram obtidos ao se utilizar atributos que estão presentes tanto dentro e fora da região de contato pneu-solo, em que houve uma contribuição considerável no processo de estimação dos 4 modelos as variáveis pertencentes a a_y e a_z , sendo algo esperado já que há uma relação entre a força lateral e vertical, como pode ser visto na Figura 2.6, em que a_z apresenta uma relação com a F_z . Assim, demonstrando que os sinais de aceleração que estão tanto dentro e fora da região de interface pneu-solo é capaz de explicar, F_y no centro do *contact patch*, já que os os modelos obtidos possuem um valor elevado de r^2 .

O processo de validação dos quatro modelos com melhores resultados citados utilizou o conjunto de dados de validação descrito na Seção 3.1.2 e obteve os resultados apresentados na Figura 4.17 e na Tabela 4.1. Observa-se na Figura 4.17 que os quatro modelos apresentam dificuldades em estimar regiões com operações críticas, ou seja, regiões com altos ângulos de deriva, superiores a 6° , e forças verticais acima de 6000 N. Os resultados apresentados na Tabela 4.1 mostram valores de NRMSE superiores aos encontrados na literatura, visto que o trabalho de Barbosa et al. (2022) obteve um NRMSE de 7,91%. Contudo, deve-se ressaltar que os modelos implementados foram treinados utilizando valores de *slip angle* entre $-8,1^\circ$ e $8,1^\circ$ e validados com ângulos no intervalo e iguais a $-8,0^\circ$ a $8,0^\circ$. Já o trabalho de Barbosa et al. (2022) utilizou valores de *slip angle* entre $-8,0^\circ$ e $8,0^\circ$ para o processo de validação, demonstrando que o processo de modelagem apresentado neste trabalho utiliza-se mais pontos em regiões críticas.

Além disso, os modelos **MFEC720PV-1-RF** e **MFEC720PV-2-GPR**, que incluem a etapa de reconstrução dos sinais de aceleração filtrados a partir da decomposição empírica, apresentam os melhores resultados no processo de validação da estimação da força lateral. Isso sugere que foi possível reconstruir alguns sinais de a_x , a_y e a_z com a presença mínima ou ausência de ruído em baixa frequência, melhorando, consequentemente, o desempenho dos modelos. Portanto, demonstra-se que o uso da EMD permite a reconstrução de sinais sem ou com ruído mínimo sem a necessidade de conhecimento *a priori* dos dados, adaptando-se aos próprios dados, especialmente para os sinais de aceleração utilizados neste trabalho, que são estocásticos e não-estacionários.

Assim, este trabalho demonstra que os sinais de aceleração fora da região de contato pneu-solo impactam a predição da força lateral, F_y , uma vez que os modelos utilizados empregam atributos presentes nesta região para o processo de estimação. Além disso, observa-se que, tanto na análise do processo de reconstrução dos sinais quanto nos resultados de teste e validação dos modelos que utilizam a etapa de reconstrução utilizando EMD, foram obtidos bons resultados.

No entanto, é necessário aprofundar os estudos dessa ferramenta para usar funções intrínsecas específicas para a reconstrução de cada sinal de aceleração dos eixos x , y e z , em vez de utilizar uma faixa de índices única para todos os sinais. Assim, para trabalhos futuros, sugere-se que, juntamente com a EMD, sejam utilizados métodos de otimização, como algoritmos genéticos, otimização por colônia de partículas, colônia de formigas, entre outros.

REFERÊNCIAS

- ABDI, H. Partial least squares regression and projection on latent structure regression (pls regression). **Wiley interdisciplinary reviews: computational statistics**, Wiley Online Library, v. 2, n. 1, p. 97–106, 2010.
- ABDI, H.; WILLIAMS, L. J. Tukey's honestly significant difference (hsd) test. **Encyclopedia of research design**, Sage Thousand Oaks, CA, v. 3, n. 1, p. 1–5, 2010.
- ACOSTA, M.; KANARACHOS, S.; FITZPATRICK, M. E. A virtual sensor for integral tire force estimation using tire model-less approaches and adaptive unscented Kalman filter. **ICINCO 2017 - Proceedings of the 14th International Conference on Informatics in Control, Automation and Robotics**, v. 1, n. July, p. 386–397, 2017.
- AGUIRRE, L. **Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais**. [S.l.]: Editora UFMG, 2007. ISBN 9788570415844.
- Anup Cherukuri. Intelligent Tire Based Tire Force Characterization and its Application in Vehicle Stability and Performance. 2017.
- ASKARI, H. et al. Tire Condition Monitoring and Intelligent Tires Using Nanogenerators Based on Piezoelectric, Electromagnetic, and Triboelectric Effects. **Advanced Materials Technologies**, v. 4, n. 1, p. 1–19, 2019. ISSN 2365709X.
- 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**, p. 1–12, 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**, v. 52, n. 8, p. 5332–5343, 2022.
- BARRETO, R. L. P. Simulação de Ângulos de Deriva e Dinâmica Veicular Lateral Utilizando Modelo de Quatro Rodas com Restrições Geométricas e Cinemáticas. 2015.
- BAUTISTA, C. D. R. Observadores de Estado para Estimção de Atrito Pneu/Solo. 2015.
- BIAU, G.; SCORNET, E. A random forest guided tour. **Test**, Springer, v. 25, p. 197–227, 2016.
- BONILLA, C. J. C. **Uma introdução aos sistemas de recomendação: modelos matemáticos, algoritmos e aplicações**. Tese (Doutorado) — [sn], 2020.
- BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, p. 5–32, 2001.
- CHAUDHARI, H.; NALBALWAR, S.; SHETH, R. A review on intrinsic mode function of emd. In: IEEE. **2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)**. [S.l.], 2016. p. 2349–2352.
- CHAVES, B. B. Estudo Do Algoritmo Adaboost De Aprendizagem De Máquina Aplicado a Sensores E Sistemas Embarcados. p. 137, 2012.
- CHEN, H.; DING, L.; TUO, R. Kernel packet: An exact and scalable algorithm for gaussian process regression with matern correlations. **Journal of machine learning research**, v. 23, n. 127, p. 1–32, 2022.

CHENG, S. et al. A hierarchical estimation scheme of tire-force based on random-walk SCKF for vehicle dynamics control. **Journal of the Franklin Institute**, Elsevier Ltd, v. 357, n. 18, p. 13964–13985, 2020. ISSN 00160032. Disponível em: <<https://doi.org/10.1016/j.jfranklin.2020.10.030>>.

CRESPO, J. H. A. **Utilização do método de decomposição empírico no processamento de dados de mobilidade urbana**. Tese (Doutorado), 2018.

DONG, G.; LIU, H. **Feature engineering for machine learning and data analytics**. [S.l.]: CRC press, 2018.

DUARTE, F. S. L. G. **Decomposição de séries temporais preservando o viés determinístico**. Tese (Doutorado) — Universidade de São Paulo, 2020.

GALINDO-PRIETO, B.; ERIKSSON, L.; TRYGG, J. Variable influence on projection (vip) for oppls models and its applicability in multivariate time series analysis. **Chemometrics and intelligent laboratory systems**, Elsevier, v. 146, p. 297–304, 2015.

GARCIA-POZUELO, D. et al. A novel strain-based method to estimate tire conditions using fuzzy logic for intelligent tires. **Sensors (Switzerland)**, v. 17, n. 2, p. 1–16, 2017. ISSN 14248220.

GARCIA-POZUELO, D. et al. A strain-based method to estimate slip angle and tire working conditions for intelligent tires using fuzzy logic. **Sensors (Switzerland)**, v. 17, n. 4, 2017. ISSN 14248220.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. **Analytica chimica acta**, Elsevier, v. 185, p. 1–17, 1986.

GENUER, R.; POGGI, J.-M.; TULEAU-MALOT, C. Variable selection using random forests. **Pattern recognition letters**, Elsevier, v. 31, n. 14, p. 2225–2236, 2010.

GILLESPIE, T. D. **Fundamentals of vehicle dynamics**. Warrendale, PA: Society of Automotive Engineers, Inc, 1992. ISBN 1560911999.

GOSSELIN, R.; RODRIGUE, D.; DUCHESNE, C. A bootstrap-vip approach for selecting wavelength intervals in spectral imaging applications. **Chemometrics and Intelligent Laboratory Systems**, Elsevier, v. 100, n. 1, p. 12–21, 2010.

GRÄBER, T. et al. A hybrid approach to side-slip angle estimation with recurrent neural networks and kinematic vehicle models. **IEEE Transactions on Intelligent Vehicles**, IEEE, v. 4, n. 1, p. 39–47, 2019.

GU, T. et al. The Vertical Force Estimation Algorithm Based on Smart Tire Technology. 2022.

GUO, H. et al. A review of estimation for vehicle tire-road interactions toward automated driving. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, IEEE, v. 49, n. 1, p. 14–30, 2019. ISSN 21682232.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. Random forests. In: _____. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. New York, NY: Springer New York, 2009. p. 587–604. ISBN 978-0-387-84858-7. Disponível em: <https://doi.org/10.1007/978-0-387-84858-7_15>.

HELLAND, I. S. Partial least squares regression and statistical models. **Scandinavian journal of statistics**, JSTOR, p. 97–114, 1990.

JAZAR, R. N. **Vehicle dynamics: theory and application**. [S.l.: s.n.], 2008. v. 51. 51–6199–51–6199 p. ISSN 0009-4978. ISBN 9780387742434.

JEONG, D. et al. Tire dimensionless numbers for analysis of tire characteristics and intelligent tire signals. **Mechanical Systems and Signal Processing**, v. 161, p. 107927, 2021. ISSN 0888-3270. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327021003228>>.

JEONG, D. et al. Estimation of tire load and vehicle parameters using intelligent tires combined with vehicle. **Survival Driving**, v. 70, p. 69–72, 2021.

JEONG, D. et al. Load Estimation of Intelligent Tires Equipped with Acceleration Sensors. **SAS 2019 - 2019 IEEE Sensors Applications Symposium, Conference Proceedings**, IEEE, p. 1–5, 2019.

KANAGAWA, M. et al. Gaussian processes and kernel methods: A review on connections and equivalences. **arXiv preprint arXiv:1807.02582**, 2018.

KHALEGHIAN, M. The Application of Intelligent Tires and Model Based Estimation Algorithms in Tire-Road Contact Characterization. 2017.

KHAN, M. Q.; LEE, S. A comprehensive survey of driving monitoring and assistance systems. **Sensors**, MDPI, v. 19, n. 11, p. 2574, 2019.

KIM, H. J. et al. A road condition classification algorithm for a tire acceleration sensor using an artificial neural network. **Electronics (Switzerland)**, v. 9, n. 3, 2020. ISSN 20799292.

KUSS, M. **Gaussian process models for robust regression, classification, and reinforcement learning**. Tese (Doutorado) — echnische Universität Darmstadt Darmstadt, Germany, 2006.

LARA, H. S. **Identificação de Arritmias Cardíacas por Decomposição Empírica por Modos e Regressão Logística**. Tese (Doutorado) — [sn], 2022.

LEE, D. et al. Intelligent tire sensor-based real-time road surface classification using an artificial neural network. **Sensors**, v. 21, n. 9, 2021. ISSN 14248220.

LEE, H.; TAHERI, S. Intelligent tires? a review of tire characterization literature. **IEEE Intelligent Transportation Systems Magazine**, IEEE, v. 9, n. 2, p. 114–135, 2017.

LEE, H.; TAHERI, S. A novel approach to tire parameter identification. **Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering**, v. 233, n. 1, p. 55–72, 2019. ISSN 20412991.

LEI, Y. et al. A review on empirical mode decomposition in fault diagnosis of rotating machinery. **Mechanical systems and signal processing**, Elsevier, v. 35, n. 1-2, p. 108–126, 2013.

LI, B.; MORRIS, J.; MARTIN, E. B. Model selection for partial least squares regression. **Chemometrics and Intelligent Laboratory Systems**, Elsevier, v. 64, n. 1, p. 79–89, 2002.

LIU, H. et al. When gaussian process meets big data: A review of scalable gps. **IEEE transactions on neural networks and learning systems**, IEEE, v. 31, n. 11, p. 4405–4423, 2020.

MAHIEU, B.; QANNARI, E. M.; JAILLAIS, B. Extension and significance testing of variable importance in projection (vip) indices in partial least squares regression and principal components analysis. **Chemometrics and Intelligent Laboratory Systems**, Elsevier, v. 242, p. 104986, 2023.

MALAQUIAS, E. O. et al. Accidents on brazilian highways: Identification and classification of their causes from machine learning. 2022.

- MARTELETTO, S. R. **Técnicas de seleção de atributos através de Random Forests: um estudo de caso para detecção de tendências em séries temporais financeiras**. Tese (Doutorado) — Universidade de São Paulo, 2022.
- MARTINS, E. Coeficiente de determinação. **Revista Ciência Elementar**, v. 6, n. 1, p. 24, 2018.
- MARTINS, J. P. A. **Desenvolvimento de softwares, algoritmos e diferentes abordagens quimiométricas em estudos de QSAR**. Tese (Doutorado) — [sn], 2013.
- MARTINS, L. G. N. Não-estacionariedade de séries temporais turbulentas e a grande variabilidade dos fluxos nas baixas frequências. 2011.
- MEHMOOD, T. et al. A review of variable selection methods in partial least squares regression. **Chemometrics and intelligent laboratory systems**, Elsevier, v. 118, p. 62–69, 2012.
- MENDOZA-PETIT, M. F. et al. A strain-based intelligent tire to detect contact patch features for complex maneuvers. **Sensors (Switzerland)**, v. 20, n. 6, p. 1–24, 2020. ISSN 14248220.
- MOUJAHID, A. et al. Machine learning techniques in adas: A review. In: **2018 International Conference on Advances in Computing and Communication Engineering (ICACCE)**. [S.l.: s.n.], 2018. p. 235–242.
- NETO, C. d. C. N. Integração das equações diferenciais do filtro Digital de Butterworth mediante algoritmo de quadratura numérica de ordem elevada. 2003.
- NICOLA, M. J. **Adoção de random forest e regressão linear para previsão de falhas em equipamentos agrícolas**. Tese (Doutorado) — Universidade de São Paulo, 2021.
- NISKANEN, A. J.; TUONONEN, A. J. Detection of the local sliding in the tyre-road contact by measuring vibrations on the inner liner of the tyre. **Measurement Science and Technology**, IOP Publishing, v. 28, n. 5, 2017. ISSN 13616501.
- OJALA, M.; GARRIGA, G. C. Permutation tests for studying classifier performance. **Journal of machine learning research**, v. 11, n. 6, 2010.
- OLEGARIO, N. Estudo da dinâmica de veículo protótipo de 3 rodas urbano. p. 1–76, 2017.
- PACEJKA, H. B. Tyre and vehicle dynamics laboratory. **SAE Technical Papers**, 1989. ISSN 26883627.
- PIRES, J. M. N. G. Aprendizagem Profunda: Estudo e Aplicações. 2017. Disponível em: <<http://rdpc.uevora.pt/bitstream/10174/23224/1/Mestrado-EngenhariaInformática-JoãoMiguelNevesGusmãoPires-Aprendizag>>.
- PIROUZ, D. M. An overview of partial least squares. **Available at SSRN 1631359**, 2006.
- POLI, P. d. C. R. **Previsibilidade da direção do preço intradiário do bitcoin com modelos de random forest**. Tese (Doutorado) — Universidade de São Paulo, 2023.
- PUGLIESE, D. P. Não uniformidades de pneus e sua influência em baixas e altas velocidades 88/2015. 2015.
- RAMINELLI, D. G. d. T. L.; SANTOS, B. S. dos. Aplicação de técnicas de mineração de dados e aprendizagem de máquina no mercado de ações: Uma revisão sistemática. **IX Congresso Brasileiro de Engenharia de Produção**, 2019.

- RIZZO, V. H. D. Sistema de aquisição e processamento digital de sinais para sons corporais. 2014. Disponível em: <<http://repositorio.roca.utfpr.edu.br/jspui/handle/1/5705>>.
- SANTOS, J. C. Análise dos esforços nos pneus de um veículo a partir de seus dados de GPS. p. 283, 2019.
- SCHULZ, E.; SPEEKENBRINK, M.; KRAUSE, A. A tutorial on gaussian process regression: Modelling, exploring, and exploiting functions. **Journal of Mathematical Psychology**, Elsevier, v. 85, p. 1–16, 2018.
- SERRA, M. R. G. Aplicações de Aprendizagem por Reforço em Controle de Tráfego Veicular. 2004.
- SINGH, K. B.; ARAT, M. A.; TAHERI, S. Enhancement of collision mitigation braking system performance through real-time estimation of tire-road friction coefficient by means of smart tires. **SAE International Journal of Passenger Cars - Electronic and Electrical Systems**, SAE International, v. 5, p. 607–624, 9 2012. ISSN 19464622.
- SINGH, K. B.; ARAT, M. A.; TAHERI, S. Literature review and fundamental approaches for vehicle and tire state estimation*. **Vehicle System Dynamics**, v. 57, n. 11, p. 1643–1665, 2019. ISSN 17445159.
- SINGH, K. B.; TAHERI, S. Accelerometer Based Method for Tire Load and Slip Angle Estimation. **Vibration**, v. 2, n. 2, p. 174–186, 2019.
- SOUZA, R. C. S. d.; BARBOSA, B. H. G. **IMPLEMENTAÇÃO DE UM FILTRO ADAPTATIVO PARA SINAIS DE ACELERAÇÃO DE PNEUS INTELIGENTES**. Dissertação (Trabalho de Conclusão de Curso (Graduação em Engenharia de Controle e Automação Bacharelado)) — Universidade Federal de Lavras, 2022.
- SOUZA, V. F.; SANTOS, T. C. B. dos. Processo de Mineração de Dados Educacionais aplicado na Previsão do Desempenho de Alunos: Uma comparação entre as Técnicas de Aprendizagem de Máquina e Aprendizagem Profunda. **Revista Brasileira de Informática na Educação**, v. 29, p. 519–546, 2021. ISSN 1414-5685.
- STANGE, R. L. Adaptatividade em Aprendizagem de Máquina: Conceitos e Estudo de Caso. p. 85, 2011. Disponível em: <<http://http://www.teses.usp.br/teses/disponiveis/3/3141/tde-02072012-175054/pt-br.php>>.
- SWILER, L. P. et al. A survey of constrained gaussian process regression: Approaches and implementation challenges. **Journal of Machine Learning for Modeling and Computing**, Begel House Inc., v. 1, n. 2, 2020.
- VIEHWEGER, M. et al. Vehicle state and tyre force estimation: demonstrations and guidelines. **Vehicle System Dynamics**, v. 59, n. 5, p. 675–702, 2021. ISSN 17445159.
- WANKE, P. W.; GIL-ALANA, L. A.; TAN, Y. Trends in road accidents on brazil's highways: Evidence of persistence. **Preprints.org**, Iberoamericana/Vervuert Editorial, 2022.
- WILLIAMS, C. K.; RASMUSSEN, C. E. **Gaussian processes for machine learning**. [S.l.]: MIT press Cambridge, MA, 2006. v. 2.
- WOLD, H. Soft modelling by latent variables: the non-linear iterative partial least squares (nipals) approach. **Journal of Applied Probability**, Cambridge University Press, v. 12, n. S1, p. 117–142, 1975.
- XU, N. et al. Tire Force Estimation in Intelligent Tires Using Machine Learning. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 23, n. 4, p. 3565–3574, 2022. ISSN 15580016.

XU, N. et al. Tire Slip Angle Estimation Based on the Intelligent Tire Technology. **IEEE Transactions on Vehicular Technology**, v. 70, n. 3, p. 2239–2249, 2021. ISSN 19399359.

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.

YANG, S. et al. A Survey of Intelligent Tires for Tire-road Interaction Recognition. **IEEE Transactions on Intelligent Vehicles**, IEEE, PP, n. 8, p. 1, 2022. ISSN 23798858.

YUNTA, J. et al. A strain-based method to detect tires' loss of grip and estimate lateral friction coefficient from experimental data by fuzzy logic for intelligent tire development. **Sensors (Switzerland)**, v. 18, n. 2, p. 1–19, 2018. ISSN 14248220.

ZHANG, H. et al. Abrasion status prediction with BP neural network based on an intelligent tire system. **2020 4th CAA International Conference on Vehicular Control and Intelligence, CVCi 2020**, n. 978, p. 619–622, 2020.

ZHAO, Q. et al. Research on load prediction model construction method of the tire condition monitoring system. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Springer Berlin Heidelberg, v. 43, n. 12, 2021. ISSN 18063691.


ZHOU, H. et al. A strain-based method to estimate longitudinal force for intelligent tires by using a physics-based model. **Journal of Mechanical Engineering/Strojniški Vestnik**, v. 67, n. 4, 2021.

ZHU, B.; HAN, J.; ZHAO, J. Tire-pressure identification using intelligent tire with three-axis accelerometer. **Sensors (Switzerland)**, v. 19, n. 11, 2019. ISSN 14248220.

APÊNDICE A – Energia das IMF's em pontos de operações distintos


As figuras a seguir apresenta exemplos da energia das funções intrínsecas para sinais de aceleração filtrados ou não.

Figura 1 – Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu sem aplicar nenhuma filtragem para o ângulo de deriva igual a 2° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z .




Fonte: autor

Figura 2 – Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu filtrado por um filtro PB de 400 Hz de 5ª para o ângulo de deriva igual a 2° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z .




Fonte: autor

Figura 3 – Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu sem aplicar nenhuma filtragem para o ângulo de deriva igual a 8° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z .



Fonte: autor

Figura 4 – Energia das IMF's obtidas a partir dos sinais de aceleração correspondentes a uma volta completa do pneu filtrado por um filtro PB de 400 Hz de 5ª para o ângulo de deriva igual a 8° para as cargas iguais a 2080 N, 4160 N e 6240 N. E a) é a energia das funções intrínsecas para a_x , b) energia das funções intrínsecas para a_y e c) a energia das funções intrínsecas para a_z .




Fonte: autor

APÊNDICE B – Somas das funções intrínsecas para a reconstrução do sinais


As figuras a seguir apresentam exemplos da reconstrução do sinal de aceleração a partir das IMF's obtidas via EMD para diferentes índices **a** e **b**, na qual os exemplos são para os ângulos de derivas 1° , -2° , 9° e -10° , para sinais filtrados e não filtrados para a carga igual a 6240 N.

Figura 5 – Sinais de aceleração, para o ângulo de deriva igual a 1° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.




Fonte: autor

Figura 6 – Sinais de aceleração filtrados, para o ângulo de deriva igual a 1° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.




Fonte: autor

Figura 7 – Sinais de aceleração, para o ângulo de deriva igual a -2° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.




Fonte: autor

Figura 8 – Sinais de aceleração filtrados, para o ângulo de deriva igual a -2° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.




Fonte: autor

Figura 9 – Sinais de aceleração, para o ângulo de deriva igual a 9° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.




Fonte: autor

Figura 10 – Sinais de aceleração filtrados, para o ângulo de deriva igual a 9° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.




Fonte: autor

Figura 11 – Sinais de aceleração, para o ângulo de deriva igual a -10° com a carga igual a 6240 N, sem aplicação de filtro com a soma das IMF's obtidas via EMD.



Fonte: autor

Figura 12 – Sinais de aceleração filtrados, para o ângulo de deriva igual a -10° com a carga igual a 6240 N, por filtro PB de frequência de corte igual a 400 Hz de 5ª ordem com a soma das IMF's obtidas via EMD.



Fonte: autor