



RHUAN CARLOS SILVA DE SOUZA

**IMPLEMENTAÇÃO DE UM FILTRO
ADAPTATIVO PARA SINAIS DE ACELERAÇÃO
DE PNEUS INTELIGENTES**

LAVRAS – MG

2022

RHUAN CARLOS SILVA DE SOUZA

**IMPLEMENTAÇÃO DE UM FILTRO ADAPTATIVO PARA SINAIS DE
ACELERAÇÃO DE PNEUS INTELIGENTES**

Monografia apresentada à Universidade Federal de
Lavras, como parte das exigências do Curso de
Engenharia Controle e Automação, para a obtenção
do título de Bacharel

Prof. Dr. Bruno Henrique Groenner Barbosa
Orientador

LAVRAS – MG

2022

RHUAN CARLOS SILVA DE SOUZA

**IMPLEMENTAÇÃO DE UM FILTRO ADAPTATIVO PARA SINAIS DE
ACELERAÇÃO DE PNEUS INTELIGENTES**

Monografia apresentada à Universidade Federal de
Lavras, como parte das exigências do Curso de
Engenharia Controle e Automação, para a obtenção
do título de Bacharel

APROVADA em 13 de Janeiro de 2022.

Prof. Dr. Bruno Henrique Groenner Barbosa UFLA
Prof. Dr. Danton Diego Ferreira UFLA
Prof. Dr. Belisario Nina Huallpa UFLA

Prof. Dr. Bruno Henrique Groenner Barbosa
Orientador

**LAVRAS – MG
2022**

RESUMO

Os pneumáticos ou pneus, como comumente conhecidos, são importantes estruturas existente em veículos, já que estão diretamente presentes na interação pneu-solo. Atualmente essas estruturas são modeladas, projetadas e testadas de forma rigorosa para garantir o controle, segurança e conforto aos passageiros presentes no veículo. Entretanto, elas não participam ativamente nos sistemas de assistência ao motorista (ADAS), pois não fornecem informações sobre a interação pneu-solo. Este fato está mudando com o surgimento dos pneus inteligentes que, ao contrário dos pneus tradicionais, interagem com os sistemas de assistência ao motorista ao fornecerem informações sobre a interação pneu-solo, melhorando a segurança e o controle dos veículos, principalmente em situações extremas. A partir de sensores inseridos no interior dos pneus e métodos heurísticos, as forças atuantes no veículo podem ser estimadas e utilizadas pelo ADAS. Nesse sentido, este trabalho tem como objetivo estimar a força lateral em um veículo a partir de sinais de aceleração nos eixos x , y e z , fornecidos por um acelerômetro (sensor de aceleração) triaxial localizado no interior de um pneu. A estimação da força é influenciada pelos ruídos que se apresentam nos sinais fornecidos pelo sensor, assim, o foco deste trabalho é desenvolver e aplicar um filtro adaptativo que seja capaz de melhorar a precisão da estimação de forças. Assim, é aplicada uma rede neural artificial para estimar a força lateral a partir de um processo de predição do sinal de aceleração devidamente filtrado por um filtro *Butterworth* rejeita-faixa de segunda ordem, o qual apresentou um dos menores erros de predição (NRMSE ou *Normalize Root Mean Square Error*), em torno de 15%, comparado a outros métodos de predição de força lateral implementados neste trabalho. Contudo, no geral apresentou valores altos para os erros de predição, acima de 10%, para todos os métodos implementados, assim, sendo necessário um estudo aprofundado sobre a melhor maneira de realizar a filtragem dos sinais de aceleração para estimação da força lateral.

Palavras-chave: Pneus Inteligentes. Filtro Adaptativo. Aprendizagem de Máquina.

LISTA DE FIGURAS

Figura 2.1 – Diagrama de corpo livre de um corpo em repouso	14
Figura 2.2 – Diagrama de corpo livre de um corpo ao aplicar uma força \vec{f} .	15
Figura 2.3 – Sistema de coordenadas de um veículo de quatro rodas	17
Figura 2.4 – Sistema de coordenada de forças e momentos atuantes em um pneu	18
Figura 2.5 – Distribuição da força F_z sobre a área de contato em um pneu em repouso	19
Figura 2.6 – Distribuição da força normal F_z sobre a área de contato em um pneu em movimento com ω sendo a velocidade angular do pneu	20
Figura 2.7 – Pneu sobre ação de um força lateral	21
Figura 2.8 – Relação força lateral,vertical e ângulo de deriva	22
Figura 2.9 – Exemplo de curva de resposta do filtro Butterworth passa-baixa	25
Figura 2.10 – Exemplo de um neurônio artificial	28
Figura 2.11 – Exemplo de saída de um função sigmoidal	29
Figura 2.12 – Exemplo de RNA tipo <i>feedforward</i>	29
Figura 3.1 – Ensaio composto pelo pneu inteligente e sistema <i>MTS Flat-Trac</i> [®] para variação dos parâmetros de entrada para obtenção do <i>dataset</i>	30
Figura 3.2 – <i>Slip angle</i> em graus variando de forma triangular aplicada ao pneu	32
Figura 3.3 – Força vertical F_z em N aplicada sobre o pneu, medida obtida a partir do ensaio realizado por (BARBOSA et al., 2021)	33
Figura 3.4 – Velocidade linear do pneu em km/h de rolamento do pneu va- riando ao longo do tempo	34
Figura 3.5 – Corte dos sinais de acelerações com seus respectivos valores de <i>tags</i>	36

Figura 3.6 – Janelas de dados que correspondem a rotação do pneu ao longo do tempo, na qual a região em vermelha representa o sinal de aceleração fora da região de contato. A região em verde representa os sinais de aceleração dentro do <i>contact patch</i> . . .	37
Figura 3.7 – Fluxograma do processo de obtenção do modelo de rede neural artificial para estimação da força lateral	38
Figura 3.8 – Área de contato de pneu entre os pontos A e E	41
Figura 3.9 – Arquitetura de rede neural artificial proposta para ser implementada neste trabalho. A entrada $[a_x/a_y/a_z]$ representa uma janela de dados codificada, na qual a_x , a_y e a_z apresenta 140 pontos cada. Já as camadas escondidas correspondem as camadas de 50 e 40 neurônios, por final a saída F_Y representa a força lateral a ser estimada	43
Figura 4.1 – Média dos valores de janelas de aceleração fora da região de contato	44
Figura 4.2 – Média quadrática dos valores de janelas de aceleração fora da região de contato	45
Figura 4.3 – Valor máximos de janelas de aceleração fora da região de contato	45
Figura 4.4 – Valor mínimos de janelas de aceleração fora da região de contato	46
Figura 4.5 – Valor de desvio padrão das janelas de aceleração fora da região de contato	46
Figura 4.6 – FFT das janelas agrupadas do sinal aceleração do eixo x fora da área de contato	48
Figura 4.7 – FFT das janelas agrupadas do sinal aceleração do eixo x fora da área de contato filtrado por filtro PB <i>Butterworth</i> de segunda ordem com $f_c = 400\text{Hz}$	49
Figura 4.8 – FFT das janelas agrupadas do sinal aceleração do eixo y fora da área de contato	50

Figura 4.9 – FFT das janelas agrupadas do sinal aceleração do eixo y fora da área de contato filtrado por filtro PB <i>Butterworth</i> de segunda ordem com $f_c = 400\text{Hz}$	51
Figura 4.10 – FFT das janelas agrupadas do sinal aceleração do eixo z fora da área de contato	52
Figura 4.11 – FFT das janelas agrupadas do sinal aceleração do eixo z fora da área de contato filtrado por filtro PB <i>Butterworth</i> de segunda ordem com $f_c = 400\text{Hz}$	53
Figura 4.12 – Frequências de pico após a filtragem com um filtro PB <i>Butterworth</i> de segunda ordem com $f_c = 400\text{Hz}$	54
Figura 4.13 – Valor de NRMSE em % dos dados de validação para quatro tipos diferentes de filtragem com 10 modelos de dados diferentes	54
Figura 4.14 – Boxplot do valor de NRMSE em % dos dados de validação para quatro tipos diferentes de filtragem com 10 modelos de dados diferente	55

LISTA DE TABELAS

Tabela 3.1 – Nomenclatura, significado e as funções medidas coletadas no algoritmo de aprendizagem de máquina	31
---	----

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Objetivos	11
1.2	Estrutura do Trabalho	12
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	Força e Momento	13
2.2	Pneus e a sua dinâmica	16
2.2.1	Sistemas de coordenadas de um veículo de quatro rodas	17
2.2.2	Força Longitudinal	18
2.2.3	Força Vertical	19
2.2.4	Força Lateral e Ângulo de Deriva	20
2.3	Pneus inteligentes	21
2.4	Filtros	23
2.5	Aprendizagem de Máquina	25
2.5.1	Rede Neural Artificial	27
3	MATERIAIS E MÉTODOS	30
3.1	Materiais	30
3.1.1	Dataset	30
3.1.2	Linguagem de programação e bibliotecas	31
3.2	Metodologia	33
3.2.1	Detalhamento do problema	34
3.2.2	Análise exploratória	35
3.2.3	Modelagem	38
3.2.3.1	Filtro PB com frequência de 400Hz	38
3.2.3.2	Normalização dos sinais para possuir média nula e obtenção de frequência do valor de pico fora da área de contato	39
3.2.3.3	Filtragem por filtro rejeita-faixa e/ou <i>notch</i>	39
3.2.3.4	Codificação dos sinais a_x, a_y e a_z	40

3.2.3.5	Mediana do sinal de força F_y	41
3.2.3.6	Normalização dos dados	41
3.2.3.7	Modelo e treinamento do modelo	42
3.2.3.8	Avaliação do modelo	42
4	RESULTADOS E DISCUSSÃO	44
4.1	Análise exploratória	44
4.2	Modelagem	48
5	CONCLUSÃO	56
	REFERÊNCIAS	58

1 INTRODUÇÃO

Pneumáticos ou, como são normalmente chamados, pneus, são estruturas compostas, por exemplo, por borracha, *nylon*, fios de aço, entre outros componentes. Estas estruturas são projetadas e construídas de forma rigorosa para garantir a segurança e qualidade ao serem utilizadas em qualquer veículo. No entanto, são estruturas passivas nos veículos, ou seja, sofrem ação de forças externas e internas sem que os sistemas dos veículos tenha algum conhecimento sobre as mesmas.

Nos últimos anos, houve o surgimento de pneumáticos atuando como estruturas ativas, ou seja, sofrem ação das forças e reportam para os sistemas dos veículos a partir de informações de sensores, estes pneus são nomeados como pneus inteligentes. É importante conhecer estas informações de forças que agem sobre essas estruturas, pois o pneu é o único componente do veículo que se encontra em contato com o solo e nesta interação pneu-solo, área de contato, há o surgimento de forças, como a força longitudinal, a lateral e a de carga. Estas forças, em muitos casos, afetam a controlabilidade do veículo, principalmente a lateral, consequentemente afetando a segurança e o conforto dos passageiros.

As informações fornecidas por sensores acoplados nos pneus inteligentes são transmitidas para os sistemas de controle chamados de *ADAS (advanced driver-assistance systems* ou sistema de assistência ao motorista), os quais estimam as forças já citadas através de métodos dinâmicos ou cinemáticos. Os métodos dinâmicos são métodos em que se conhece a dinâmica ou utilizam de modelos simplificados da interação do pneu-solo, contudo apresentam a desvantagem de não ser possível conhecer por totalidade em situações reais esta dinâmica. Já no método cinemático, não é necessário conhecer esta dinâmica do pneu com o solo, podendo ser utilizados métodos de aprendizagem de máquinas para a estimação destas forças, como uma rede neural artificial (XU et al., 2020), máquina de vetores de suporte (SVM), Processos Gaussianos (BARBOSA et al., 2021) e entre

outros métodos. Porém, a estimação de forças é afetada pelo ruído presente nestes sinais transmitidos para esses sistemas.

Logo, em situações reais em que o pneu entra em contato com diferentes solos, o processo de estimação das forças, principalmente a lateral, que é o foco deste trabalho, é afetado pelos ruídos e vieses presentes na área de contato. Assim, é necessário utilizar um método de filtragem adaptativa, pois a cada interação entre o pneu e solo são obtidos ruídos em faixas de frequências distintas, logo, é necessário ter um filtro específico para cada interação, que seja capaz de filtrar este ruído inerente aos sensores a cada contato ao solo.

1.1 Objetivos

O presente trabalho de conclusão de curso tem como objetivo principal estimar a força lateral presente na interação pneu-solo a partir de um conjunto de dados real de um pneu inteligente instrumentado com um acelerômetro. Os objetivos específicos deste trabalho são:

- analisar o comportamento dos sinais de aceleração fora da área de contato do pneu ao solo e entender a influência destes sinais como ruído na interface pneu-solo;
- desenvolver um método de filtragem adaptativa, utilizando um filtro estático para filtrar os ruídos em baixa frequência, já que estes ruídos variam a cada rotação do pneu na região de contato, logo, necessário aplicar um filtro para distintos para as faixas de frequências encontradas em cada rotação. Estas faixas de frequências são encontradas no objetivo anterior;
- desenvolver um modelo de aprendizagem de máquina para prever a força lateral F_y , pois é uma das forças que afetam a controlabilidade do veículo, assim, a sua segurança.

1.2 Estrutura do Trabalho

A estrutura deste trabalho está dividida da seguinte forma

- **Introdução:** são apresentadas as motivações e os objetivos do trabalho.
- **Fundamentação Teórica:** é apresentada a base teórica em que o trabalho se baseia.
- **Materiais e Métodos:** apresenta os materiais e metodologias para o desenvolvimento deste trabalho.
- **Resultados e Discussão:** é o capítulo responsável em apresentar os resultados da metodologia empregada e as discussões em torno desses resultados.
- **Conclusão:** apresenta as considerações finais do trabalho desenvolvido e implementado.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Força e Momento

Sir Isaac Newton formulou três leis intituladas *Leis de Newton*, em sua homenagem, nas quais são a base da Mecânica Clássica (AGUIAR, 2010; TAYLOR, 2005). As premissas destas três leis são as seguintes:

- **Primeira Lei de Newton:** um corpo em repouso e em movimento uniforme permanece neste estado inicial até que o mesmo seja submetido a um agente que altere o seu estado (HALLIDAY; RESNICK; WALKER, 2012);
- **Segunda Lei de Newton:** a força é o produto da massa e aceleração de um corpo em um dado período de tempo (HALLIDAY; RESNICK; WALKER, 2012);
- **Terceira Lei de Newton:** as forças ocorrem em pares, ação e reação, ou seja, um objeto que é submetido a uma força também gera uma força de igual magnitude porém de sentido contrário (HALLIDAY; RESNICK; WALKER, 2012).

As leis e suas premissas apresentadas acima são baseadas em corpos de escalas macroscópicas e velocidades de movimentos muito menor que a velocidade da luz, já que para os casos de corpos de escala microscópicas e acima da velocidade da luz existem leis físicas específicas que explicam os fenômenos nestas condições. Logo, a força \vec{F} como é demonstrado pela **Segunda Lei de Newton** é ação de um agente externo que tem a capacidade de alterar o estado do movimento de um corpo de massa m (kg ou quilograma) com uma dada aceleração \vec{a} (m/s^2 ou metro por segundo quadrado) em um dado período de tempo (TAYLOR, 2005), como pode ser observado em

$$\vec{F} = m\vec{a} \quad (2.1)$$

na qual tanto \vec{F} e \vec{a} são grandezas vetoriais, ou seja, possuem um módulo, sentido e direção, logo, (2.1) pode ser reescrita em relação a suas componentes como é demonstrado a seguir:

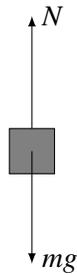
$$F_x = ma_x, \quad (2.2a)$$

$$F_y = ma_y, \quad (2.2b)$$

$$F_z = ma_z. \quad (2.2c)$$

A segunda e a terceira lei valida a **Primeira Lei de Newton**, pois um corpo em repouso ou em movimento uniforme, ou seja, não acelerado, apresenta forças que mantêm o corpo em equilíbrio como pode ser observado na Figura 2.1, na qual é um diagrama de corpo de um corpo em repouso em uma superfície sem atrito (SERWAY; JR, 2004).

Figura 2.1 – Diagrama de corpo livre de um corpo em repouso



Fonte: autor

A Figura 2.1 apresenta uma força peso do bloco que é dado pela relação mg , em que g é a aceleração da gravidade da Terra, na qual o bloco também gera uma força normal N com a mesma amplitude e direção, contudo com um sentido contrário ao peso. Portanto, um corpo em repouso apresenta forças externas que o mantêm em equilíbrio, logo, tem-se a seguinte relação (SERWAY; JR, 2004):

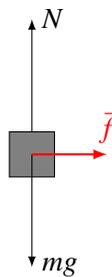
$$\sum_{i=1}^N \vec{F}_i = 0 \quad (2.3)$$

Assim, se uma força \vec{f} for aplicada ao corpo da Figura 2.1 em uma superfície sem atrito, como pode ser na Figura 2.2, as seguintes relações podem ser escritas:

$$\sum_{i=1}^N \vec{F}_i = \vec{f} \quad (2.4a)$$

$$\sum_{i=1}^N \vec{F}_i = m\vec{a} \quad (2.4b)$$

Figura 2.2 – Diagrama de corpo livre de um corpo ao aplicar uma força \vec{f}



Fonte: autor

As relações apresentadas em 2.3 e 2.4b podem ser também descritas por quantidade de movimento ou como também é chamado por momento. O momento \vec{p} é a relação da massa m e velocidade \vec{v} de um corpo, esta relação pode ser observada em

$$\vec{p} = m\vec{v} \quad (2.5)$$

em que tanto \vec{p} e \vec{v} são grandezas vetoriais e podem ser descritas por meio de suas componentes, como é demonstrado em (2.6a), (2.6b) e (2.6c) (HALLIDAY; RESNICK; WALKER, 2012).

$$p_x = mv_x, \quad (2.6a)$$

$$p_y = mv_y, \quad (2.6b)$$

$$p_z = mv_z. \quad (2.6c)$$

Portanto, derivando a velocidade em relação ao tempo,

$$\sum_{i=1}^N \vec{F}_i = m \frac{d\vec{v}}{dt} \quad (2.7)$$

obtém-se a aceleração, conseqüentemente, se a velocidade for constante é caracterizado que o corpo está em repouso ou em movimento uniforme, como descrito em 2.3, pois aceleração deste corpo é igual a zero. Ou se a velocidade deste mesmo corpo variar ao longo tempo pode-se inferir que o mesmo sofre a ação de um agente externo, como é descrito pela relação apresentada em 2.4b, pois a aceleração do mesmo é diferente de zero (TIPLER; MOSCA, 2009).

2.2 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, na qual evoluíram de estruturas constituídas de materiais rígidos, como madeira e aço, ao que é largamente utilizado atualmente, em que são estruturas compostas por um conjunto de materiais flexíveis, que são: borracha, tecido, por exemplo nylon, fibras metálicas e entre outras (PUGLIESE, 2015; SANTOS, 2019).

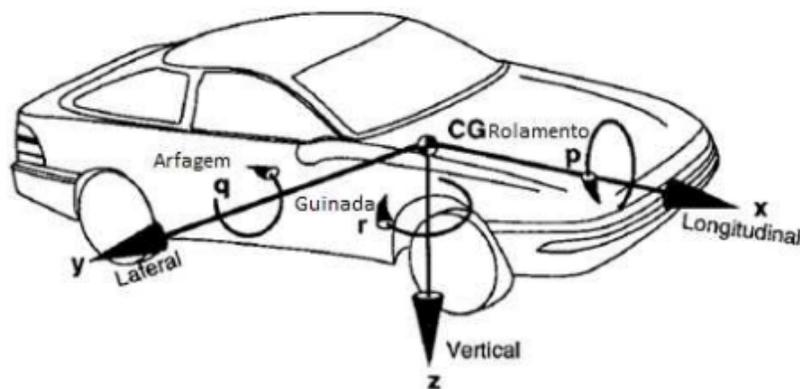
Além das funcionalidades supracitadas existe uma demanda crescente para que os pneus se tornem cada vez mais ativos no processo de controle de um veículo, logo, surgindo os pneus inteligentes. Estes pneumáticos apresentam sensores em seu interior, como acelerômetros tri-axiais, capazes de medir a aceleração nos três eixos dimensionais (x , y e z). Com estes sensores é possível estimar outros parâmetros necessários para melhorar a controlabilidade do veículo (PUGLIESE,

2015). As seções 2.2.1 até 2.2.3 apresentam o sistema de coordenadas adotado para um veículo de quatro rodas e de um de seus pneus e sua dinâmica.

2.2.1 Sistemas de coordenadas de um veículo de quatro rodas

Os sistemas de coordenadas utilizado neste trabalho para um veículo de quatro rodas foi estabelecido por SAE (*Society of Automotive Engineers*) como é apresentado na Figura 2.3.

Figura 2.3 – Sistema de coordenadas de um veículo de quatro rodas

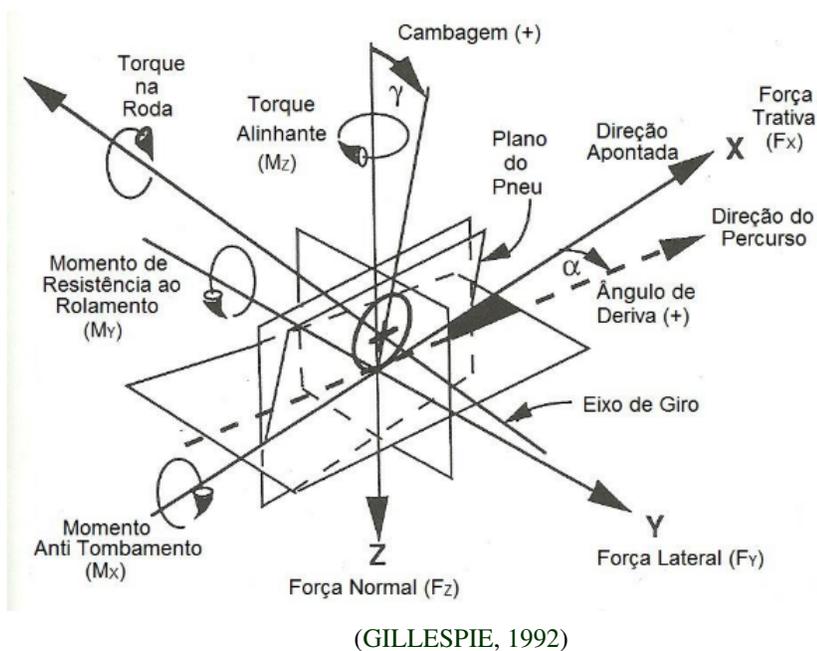


Fonte: (GILLESPIE, 1992)

A Figura 2.3 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 eixo, que se apresenta de forma lateral ao veículo (OLEGARIO, 2017). A Figura 2.3 também apresenta no seu sistema de coordenadas os seus momentos em cada eixo, quais sejam: de rolamento no eixo x , guinada no eixo z e de arfagem no eixo y (BARRETO, 2015). Estes momentos na figura são representados, respectivamente, pelas variáveis p , r e q (OLEGARIO, 2017).

Logo, 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 2.4

Figura 2.4 – Sistema de coordenada de forças e momentos atuantes em um pneu



A Figura 2.4 apresenta as forças, momentos e ângulos em que um 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*) representado pela letra grega α na figura.

2.2.2 Força Longitudinal

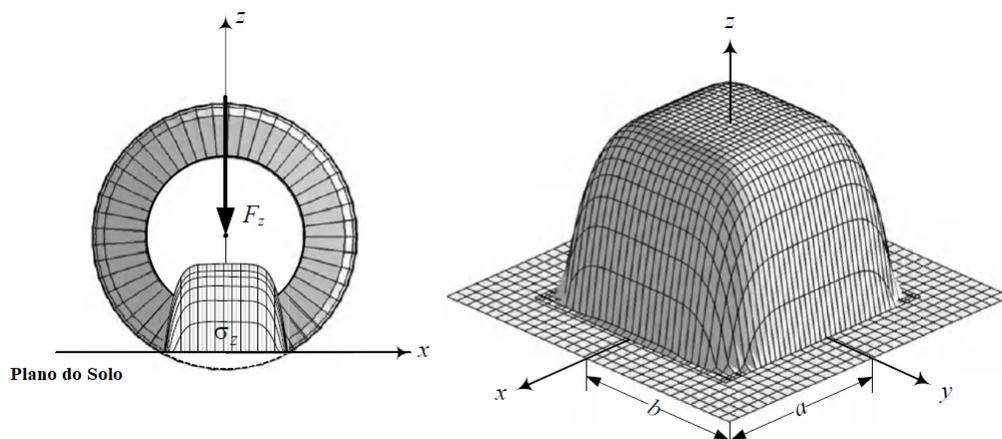
Força longitudinal (F_x) se relaciona com a aceleração e desaceleração do veículo, frenagem ou tração, respectivamente. Este tipo de força ocorre longitudinalmente entre a interação do pneu-solo, na qual esta interação ocorre quando o torque gerado pelo motor ou freios do automotor é transmitido aos pneus, onde a

interação entre o plano de contato do pneu com o solo provoca a ação de aceleração ou de freagem (BAUTISTA, 2015).

2.2.3 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 dentre a interação pneu-solo, chamada de área de contato (BAUTISTA, 2015), com um formato aproximadamente retangular com o veículo em repouso, como pode ser observado na Figura 2.5. Contudo, em movimento, esta área se desloca de acordo com o movimento, Figura 2.6 (BARRETO, 2015).

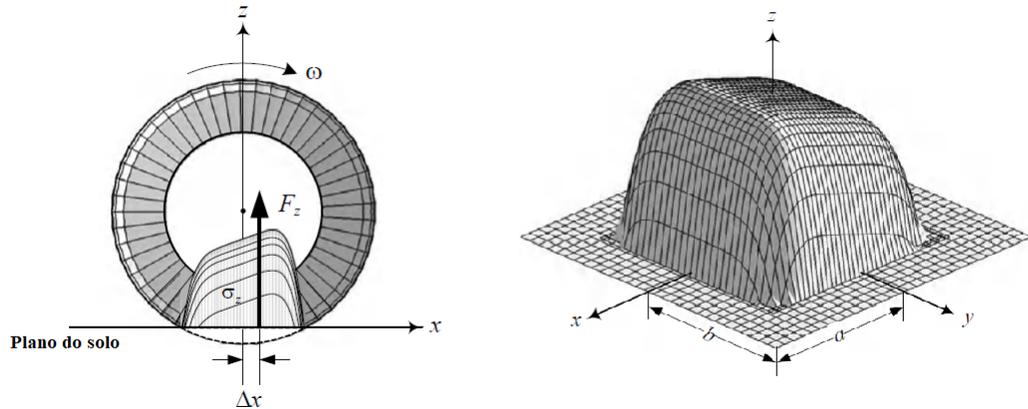
Figura 2.5 – Distribuição da força F_z sobre a área de contato em um pneu em repouso



Fonte: adaptado de (JAZAR, 2008)

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

Figura 2.6 – 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)

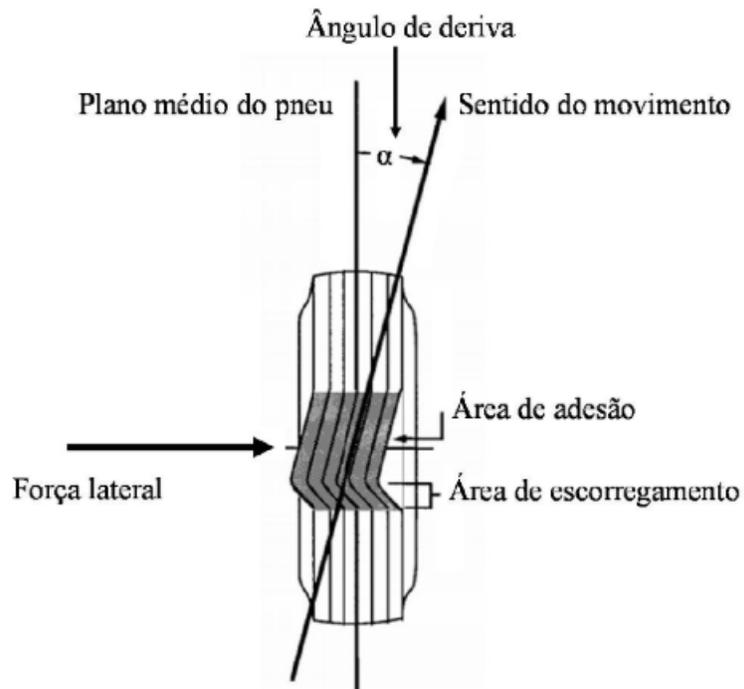
2.2.4 Força Lateral e Ângulo de Deriva

A força lateral F_y , ou como também é chamada 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 Fig. 2.7.

A força lateral depende de fatores, como: características construtiva do pneu (largura, tamanho, tipo de pneu), a carga e pressão interna em cada um dos pneus que o veículo possui (GILLESPIE, 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, em torno de 5° , a relação entre a força lateral e vertical é aproximadamente

Figura 2.7 – Pneu sobre ação de um força lateral



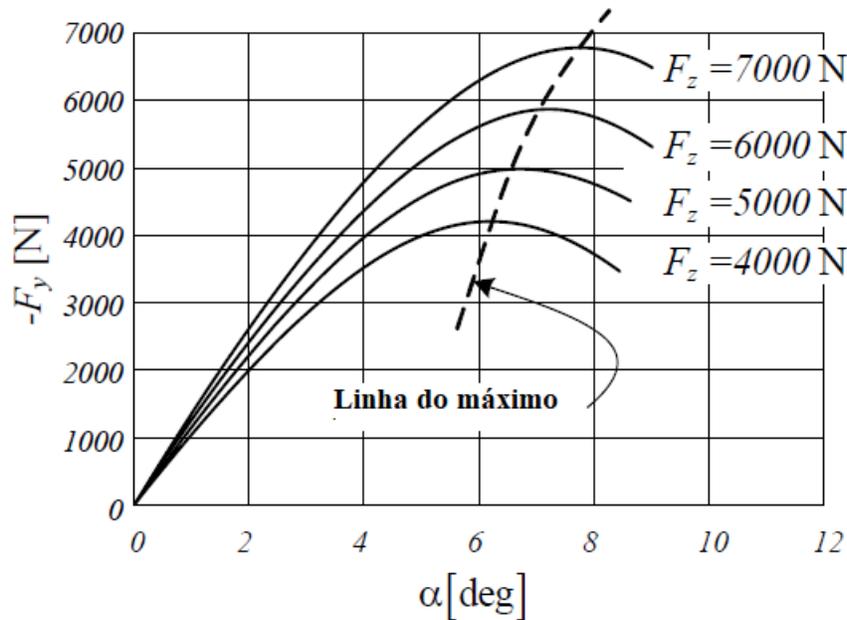
Fonte: (GILLESPIE, 1992)

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 vertical do veículo (PACEJKA, 1989) e segurança dos usuários.

2.3 Pneus inteligentes

Atualmente os pneus são considerados estruturas passivas em veículos, ou seja, são modelados, projetados e testados de forma rigorosa para que sejam capazes de sofrerem ações externas. Na presença destas ações devem conferir segurança, controlabilidade e conforto aos ocupantes dos veículos, consequentemente, não há nenhuma troca de informações ou estado dos pneus para o *sistema*

Figura 2.8 – Relação força lateral, vertical e ângulo de deriva



Fonte: adaptado de (JAZAR, 2008)

de assistência ao motorista (ou *driver assistance system* ou *ADAs*) (GUO et al., 2019).

Porém, este fato está mudando devido ao surgimento de pneus inteligentes, ao contrário dos pneus tradicionais, são estruturas ativas que interagem com *ADAs* através da troca de informações (SINGH; ARAT; TAHERI, 2019). Devido a esta troca de informações há uma melhora na segurança e controlabilidade do veículo, por exemplo, em situações extremas que ponham os ocupantes do veículo em perigo (GUO et al., 2019).

Os pneus inteligentes se baseiam na modelagem matemática, onde sensores e suas medições são utilizadas pelos *ADAs*. Neste tipo de modelagem, o processo de estimação se dá ao utilizar a relação cinemática existente entre o veículo e o sinal medido pelo o sensor para se determinar os parâmetros desejados na

região de interface pneu-solo (GUO et al., 2019), logo, não há um conhecimento *a priori* da dinâmica do veículo.

Os trabalhos de Barbosa et al. (2021), Xu et al. (2020) e Selmanaj et al. (2017) são exemplos de modelagem cinemática. O primeiro utiliza um acelerômetro triaxial (um tipo de sensor de aceleração que obtém medidas de aceleração nos eixos x , y e z), em que a partir destes sinais e do método *Gaussian Process Regression* estima-se a força lateral presente no pneu do veículo com intervalo de incerteza, comparando-o com outras técnicas de aprendizado de máquinas. Já o segundo, utiliza o mesmo tipo de sensor no interior do pneu, contudo compara três técnicas de aprendizagem de máquina para a estimação das forças lateral, vertical e longitudinal. E, por fim, o último trabalho utiliza a modelagem cinemática para obtenção do ângulo de deriva.

No entanto, como a identificação dos modelos se baseia na relação entre o estado de veículo com os sensores, as características estimadas são afetada pelos ruídos e vieses inerentes aos sensores utilizados em situações reais (SINGH; ARAT; TAHERI, 2019).

2.4 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. Um dos tipos destas estruturas é o filtro, que a partir de um valor de frequência, comumente chamada de frequência de corte(f_c), seleciona 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 remove as demais do sinal (NETO, 2003);
- **Passa-alta:** seleciona as componentes do sinal que apresentam frequência acima da frequência de corte e remove 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 removidas (NETO, 2003);
- **Rejeita-faixa:** remove 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).

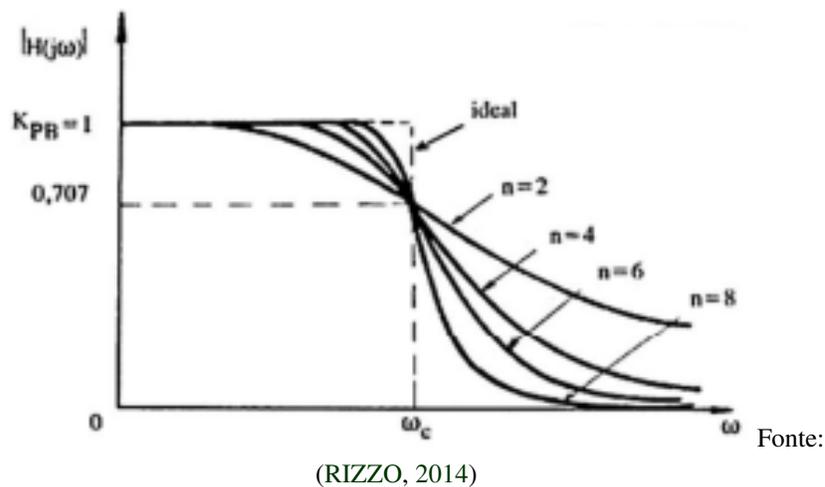
Para exemplificar o comportamento de um filtro tipo *Butterworth* a equação a seguir representa o modelo matemático para um passa-baixa no domínio da frequência:

$$|H(j\omega)| = \frac{K_{PB}}{\sqrt{1 + (\frac{j\omega}{j\omega_c})^{2n}}} \quad (2.8)$$

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 equa-

ção 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 retangular e sem nenhuma oscilação), como é demonstrado na Figura 2.9.

Figura 2.9 – Exemplo de curva de resposta do filtro Butterworth passa-baixa



2.5 Aprendizagem de Máquina

Atualmente, com a crescente evolução de *smartphones*, computadores e de dispositivos inteligentes, por exemplo, relógios, óculos, casas e pneus, o qual é o foco do presente trabalho, há um aumento diário no volume de dados pelo 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 informação e pós-processamento dos dados (CHAVES, 2012), que são descritos a seguir:

1. **Pré-processamento:** é a etapa que consiste na padronização de arquivos onde os dados estão contidos e de limpeza dos mesmo para se adequar com o 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 informações 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, já que é um ramo da inteligência computacional que tem como foco construir modelos computacionais, a partir de um único ou vários algoritmos, que são capazes de aprender e se adaptar a uma de base de dados pré-processada obtendo as informações contidas nesta base (CHAVES, 2012; RAMINELLI, Daniele Gonçalves de Toledo Luchetta; SANTOS, 2019; STANGE, 2011). Os algoritmos utilizados na construção dos modelos de aprendizagem de máquinas podem ser classificados como:

- **Supervisionado:** é o tipo de aprendizagem que consiste em já conhecer a 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 o algoritmo(STANGE, 2011);
- **Não-supervisionado:** é o tipo de aprendizagem que não se conhece a saída desejada. Logo, o algoritmo, a partir da base dados, estima a possível a saída ao aprender os erros e acertos obtidos de forma interativa ao longo do processo de aprendizagem (RAMINELLI, Daniele Gonçalves de Toledo Luchetta; SANTOS, 2019);

- **Reforço:** é aprendizagem que não se conhece a saída desejada. Assim, a partir dos dados de entrada e da saída do sistema que a realimenta o sistema de forma interativa durante todo o processo de aprendizagem irá determinar o valor ótimo para aprendizagem(SERRA, 2004);
- **Semi-supervisionado:** é o tipo de aprendizagem que não se conhece totalmente a saída desejada para alguns exemplos. Logo, esta aprendizagem classifica ou prediz os valores para dados registros e a partir disto estima a saída para os registros não conhecidos(PIRES, 2017).

Um dos algoritmos de aprendizagem máquina mais utilizados, tanto na aprendizagem supervisionada e não-supervisionada, e implementado neste trabalho para estimação da força lateral, é a rede neural artificial (*artificial neural network*). A seção 2.5.1 descreverá o conceito e o funcionamento desse algoritmo.

2.5.1 Rede Neural Artificial

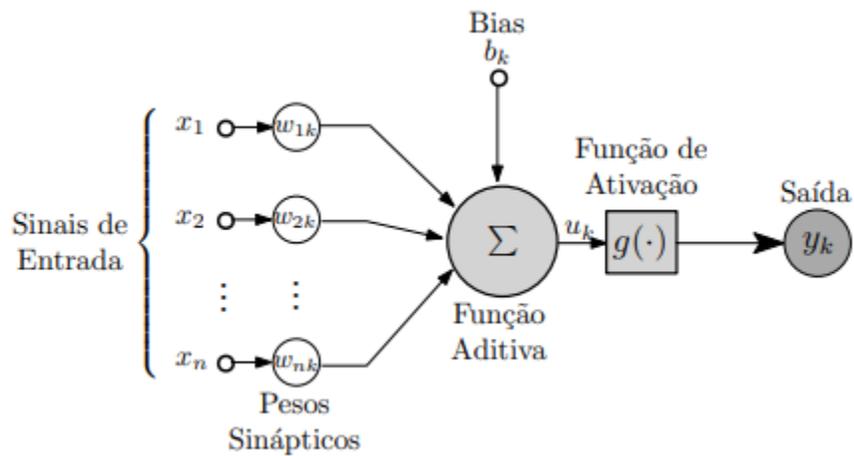
A rede neural artificial (RNA) é um algoritmo que se inspira no comportamento do cérebro humano, pois o cérebro possui características que são desejáveis para resolução de problemas complexos, em que, por exemplo, não é possível determinar um único modelo matemático para sua resolução. Uns dos exemplos destas características são a capacidade de aprender uma função sem ter tido um contato anterior, paralelismo do funcionamento das estruturas que o compõem, robustez a ruídos e entre outros (RAUBER, 2003).

Assim, como o cérebro humano, a RNA é composta por neurônios, porém estes são comumente chamados de *neurônios artificiais*, na quais são estruturas interconectadas uma as outras (PEREIRA; CUSTODIO, 2021). Um neurônio artificial é constituído pela combinação linear (somatório) entre a entrada x_k e seus respectivos pesos w_k , na qual a partir de uma função de ativação $g(\cdot)$ estima a sua saída y_k , este processo pode ser descrito pela a equação 2.9 e na Fig. 2.10

(RAUBER, 2003):

$$y_k = g\left(\sum_{k=1}^n x_k w_k\right). \quad (2.9)$$

Figura 2.10 – Exemplo de um neurônio artificial



Fonte: (FINKLER, 2017)

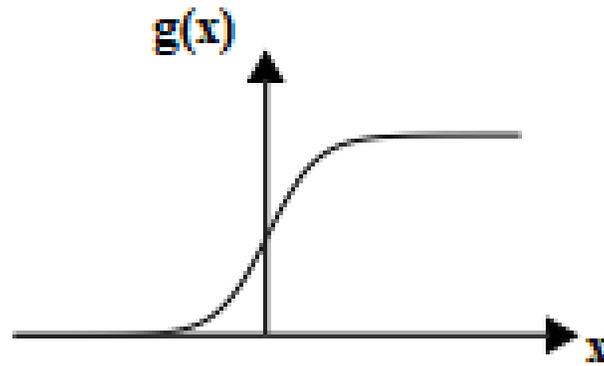
Uma das possíveis funções de ativação utilizadas na equação 2.9 é a função sigmoideal,

$$g(x) = \frac{1}{1 + e^{-x}} \quad (2.10)$$

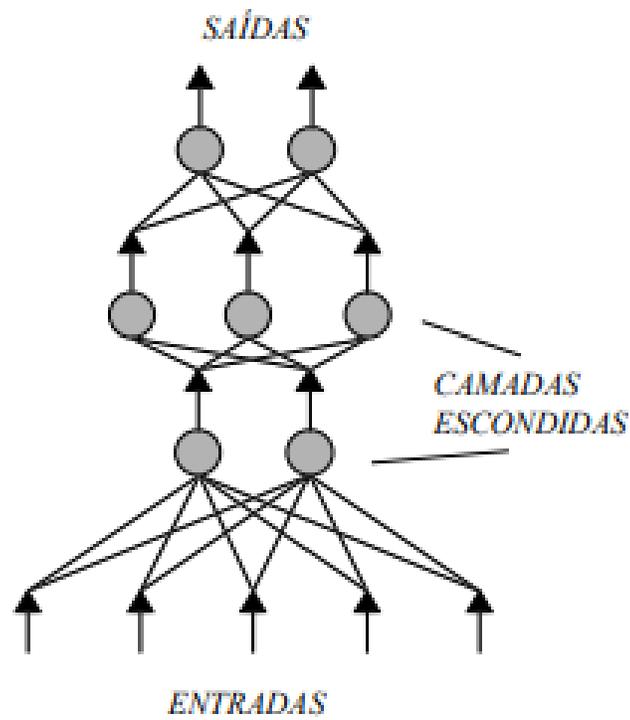
em que produz uma saída não-linear, contínua e diferenciável no conjunto dos números reais (RAUBER, 2003), conforme demonstrado no gráfico da Fig. 2.11.

Portanto, os conjuntos de neurônios artificiais presentes em uma RNA são interconectados, logo, esses conjuntos possuem diferentes arquiteturas. Contudo, no presente trabalho, será focado o modelo de arquitetura *feedforward* ou propagação para frente (RAUBER, 2003). Esta arquitetura de rede consiste na propagação unidirecional do sinal de entrada até a obtenção da saída final, esse sinal se propaga nas inúmeras camadas (*layers*) de neurônios presente na rede (FINKLER, 2017). As camadas existentes neste tipo de arquiteturas são chamadas de entrada (*input*), escondidas (*hidden*) e saída (*output*), como pode ser visto na Fig. 2.11.

Figura 2.11 – Exemplo de saída de um função sigmoidal



Fonte: adaptado de (RAUBER, 2003)

Figura 2.12 – Exemplo de RNA tipo *feedforward*

Fonte: (RAUBER, 2003)

3 MATERIAIS E MÉTODOS

O presente capítulo descreverá o problema, materiais e métodos utilizados para o desenvolvimento e implementação deste trabalho.

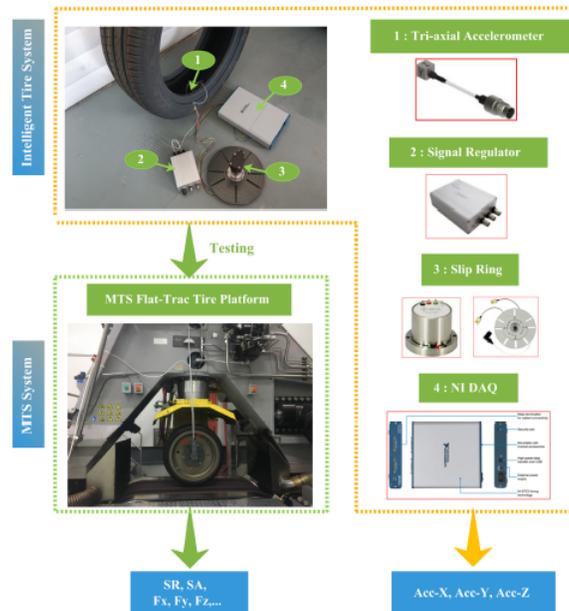
3.1 Materiais

Esta seção detalhará o conjunto de dados, linguagem de programação e bibliotecas utilizadas.

3.1.1 Dataset

O conjunto de dados usado neste trabalho é composto por valores medidos provenientes de um ensaio conforme descrito em Barbosa et al. (2021), na qual a Figura 3.1 apresenta o processo de obtenção do conjunto de dados. Este conjunto é composto por 1.796.122 amostras com 7 atributos, descritos na Tabela 3.1.

Figura 3.1 – Ensaio composto pelo pneu inteligente e sistema *MTS Flat-Trac*[®] para variação dos parâmetros de entrada para obtenção do *dataset*



Fonte: (BARBOSA et al., 2021)

Tabela 3.1 – Nomenclatura, significado e as funções medidas coletadas no algoritmo de aprendizagem de máquina

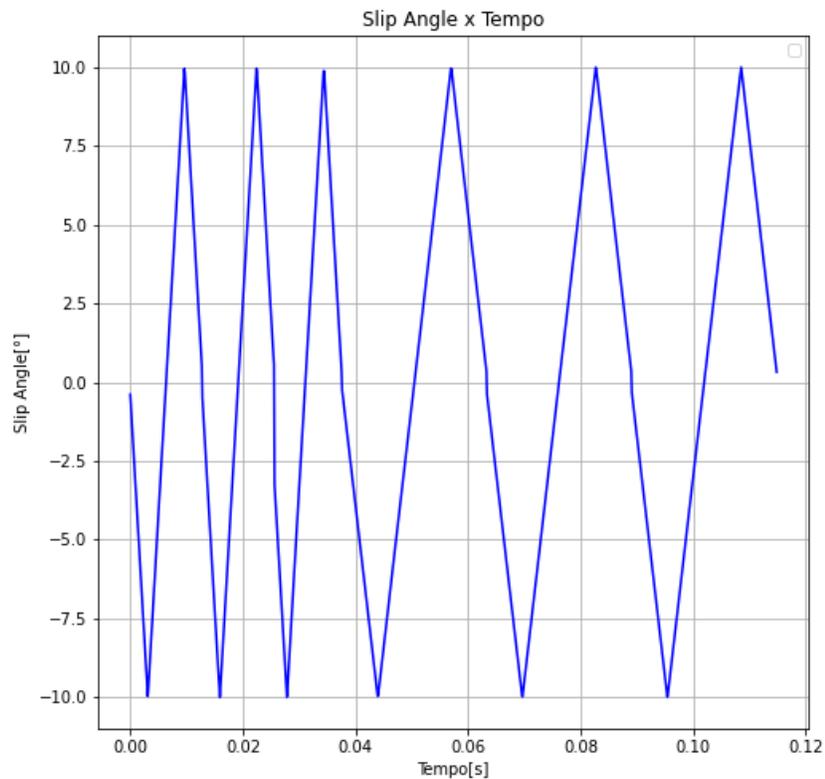
Medidas	Significado	Função no algoritmo de aprendizagem de máquina
ax(g)	aceleração no eixo x (m/s^2)	entrada da rede neural artificial
ay(g)	aceleração no eixo y (m/s^2)	entrada da rede neural artificial
az(g)	aceleração no eixo z (m/s^2)	entrada da rede neural artificial
Fx(N)	Força longitudinal (N)	-
Fy(N)	Força lateral (N)	saída da rede neural artificial
Fz(N)	Força vertical (N)	-
tag	Indica se a aceleração e as forças medidas estão dentro (1) ou não (0) da região denominada <i>decontact patch</i> (área de contato)	-

Para obter o *dataset* contendo as medidas descritas na Tabela 3.1 foi realizado um experimento com as seguintes características: o *slip angle* variando de forma triangular, como pode ser observado na Figura 3.2; a força vertical (F_z) variando entre 2000 e 6500 N sobre o pneu, como pode ser visto na Figura 3.4; e a velocidade linear da rotação do pneu variando entre 30 e 60 km/h, como pode ser visto na Figura 3.5. Assim, o conjunto de medidas listados na Tabela 3.1 correspondem aos dados de entradas e saídas, coletados a cada 0,0001 segundos.

3.1.2 Linguagem de programação e bibliotecas

Este trabalho foi desenvolvido e implementado no ambiente de desenvolvimento *Google Colab* utilizando a linguagem Python versão 3.7. Portanto, abaixo são listadas algumas das principais bibliotecas utilizadas para o desenvolvimento deste trabalho.

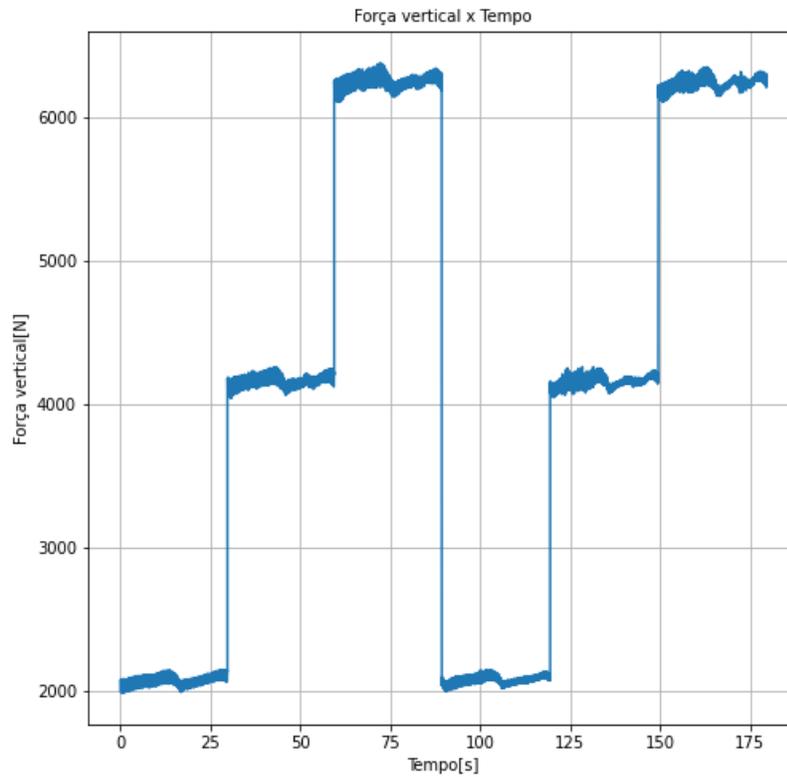
- **numpy**: possui a finalidade de trabalhar com vetores e matrizes;
- **pandas**: é utilizada para manipulação de dados de um determinado conjunto de dados;
- **matplotlib.pyplot**: é utilizada para visualização de gráficos;

Figura 3.2 – *Slip angle* em graus variando de forma triangular aplicada ao pneu

Fonte: autor

- **seaborn**: é usada para visualização de gráficos e manipulação de dados;
- **scipy.signal**: é aplicada neste trabalho para realizar o processo de filtragem do sinal manipulando os módulos *butter* e *lfilter*, onde o primeiro determina os parâmetros utilizados para o filtro *Butterworth*, já o último realiza o processo de filtragem que a partir dos parâmetros calculados por *butter*;
- **tensorflow.keras**: é usada para construção do modelo de rede neural artificial implementada neste trabalho;
- **math**: lida com operações matemáticas;

Figura 3.3 – Força vertical F_z em N aplicada sobre o pneu, medida obtida a partir do ensaio realizado por (BARBOSA et al., 2021)



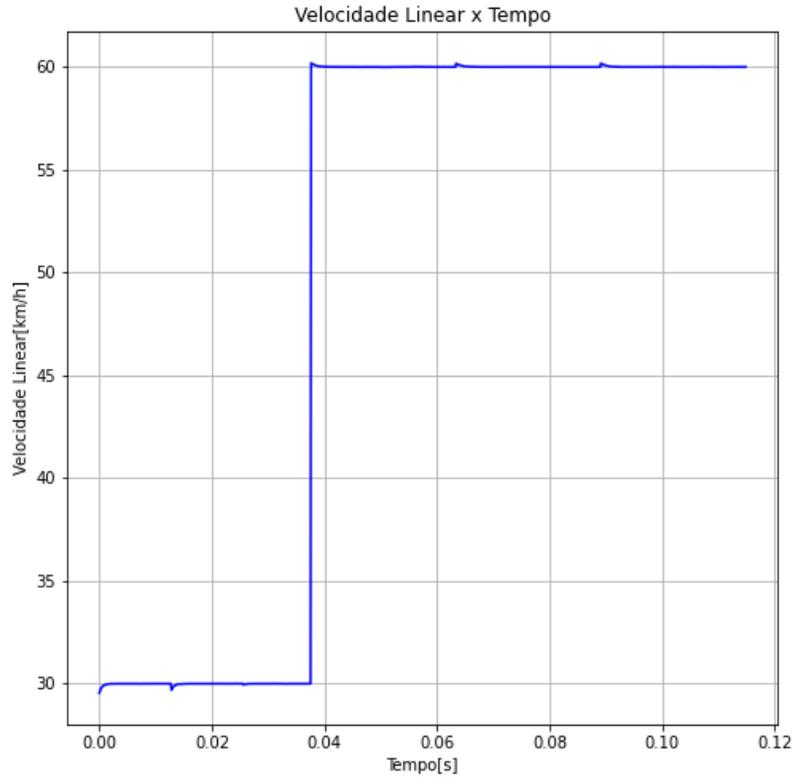
Fonte: autor

- **sklearn**: usada para separar o conjunto de dados pré-processado em dados de treinamento e teste, aplicar o processo de *cross validation* e cálculo de métricas.

3.2 Metodologia

Esta seção detalhará a metodologia de análise exploratória e solução do problema.

Figura 3.4 – Velocidade linear do pneu em km/h de rolamento do pneu variando ao longo do tempo



Fonte: autor

3.2.1 Detalhamento do problema

Como citado na seção 2.3, o processo de estimação de parâmetros é afetado pelos ruídos presentes nos sensores, consequentemente, os valores estimados se distanciam do valor real de um determinado parâmetro. Logo, este trabalho tem como um dos objetivos entender a influência dos sinais de aceleração fora da região de *contact patch* como fonte de ruído de baixa frequência para os sinais de aceleração dentro da região.

A região de contato sinalizada por 1 pela medida *tag* é a região, como citado na seção 2.2, onde o pneu e solo interagem e há presença das forças longitudinal, vertical e lateral. Assim, os valores de aceleração dentro desta região são utilizados para estimar estas forças, neste presente trabalho será focada somente a estimação da força lateral.

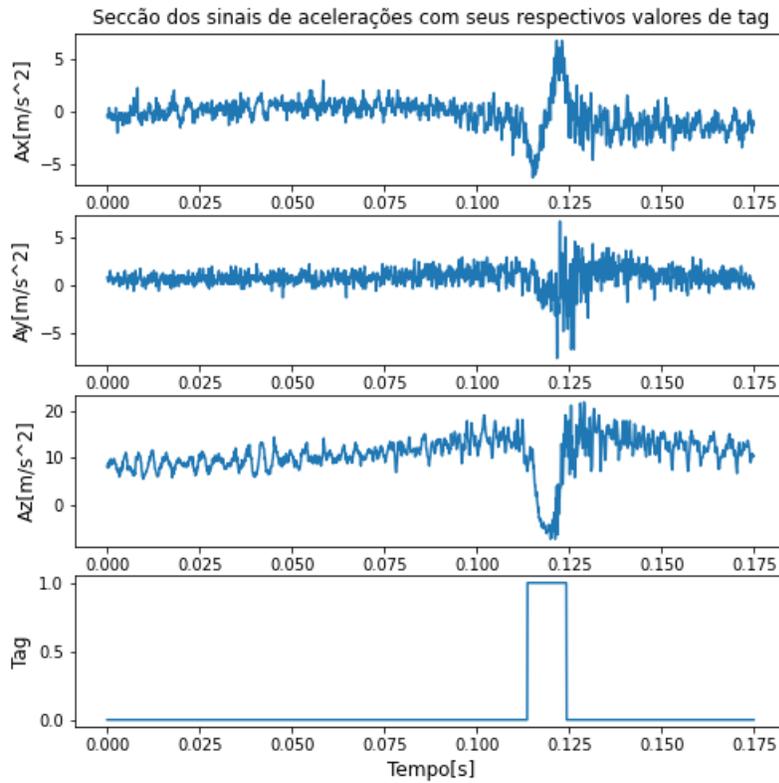
Portanto, para entender a influência dos sinais de acelerações fora da área de contato, *tag* igual 0, primeiro é realizada uma análise exploratória destes sinais. A partir dos resultados e observações feitas a partir dessa análise é realizado um processo de filtragem da aceleração dentro do *contact patch*, logo, a partir deste sinal filtrado é construído um modelo de rede neural para realizar o processo de estimação da força lateral. Estes processos serão melhor descritos nas seções seguintes.

3.2.2 Análise exploratória

Antes de realizar qualquer análise sobre os sinais de acelerações fora da área de contato, primeiro é necessário separar em "janelas" os sinais dentro e fora da região de contato, na qual este processo consiste em obter janelas de dados que correspondem a rotação do pneu dentro e fora da área de contato ao longo do tempo. Para exemplificar, a Figura 3.5 e 3.6 apresenta uma parte dos registros de sinais de acelerações do *dataset* utilizado, com suas respectivas *tags* ao longo do tempo. Os valores de acelerações que apresentam *tag* igual a 0 são consideradas janelas fora da região de *contact patch* para a_x , a_y e a_z . Já os sinais de aceleração nos três eixos que possuem *tag* igual a 1 correspondem às janelas de dados dentro da área de contato.

Portanto, com as janelas de valores fora da área de contato definidas, são aplicados os métodos abaixo em cada janela para entender e analisar o comportamento do sinal nessa região:

Figura 3.5 – Corte dos sinais de acelerações com seus respectivos valores de tags



Fonte: autor

- média simples:

$$\bar{x} = \frac{1}{N} \left(\sum_{k=1}^N x_k \right) \quad (3.1)$$

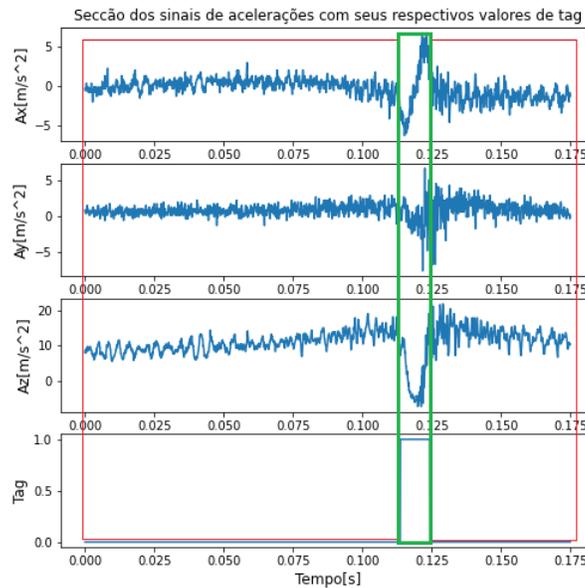
- média quadrática:

$$\bar{x} = \sqrt{\frac{1}{N} \left(\sum_{k=1}^N x_k^2 \right)} \quad (3.2)$$

- valor máximo:

$$x_{max} = \max(\mathbf{x}) \quad (3.3)$$

Figura 3.6 – Janelas de dados que correspondem a rotação do pneu ao longo do tempo, na qual a região em vermelha representa o sinal de aceleração fora da região de contato. A região em verde representa os sinais de aceleração dentro do *contact patch*



Fonte: autor

- **valor mínimo:**

$$x_{min} = \min(\mathbf{x}) \quad (3.4)$$

- **desvio padrão:**

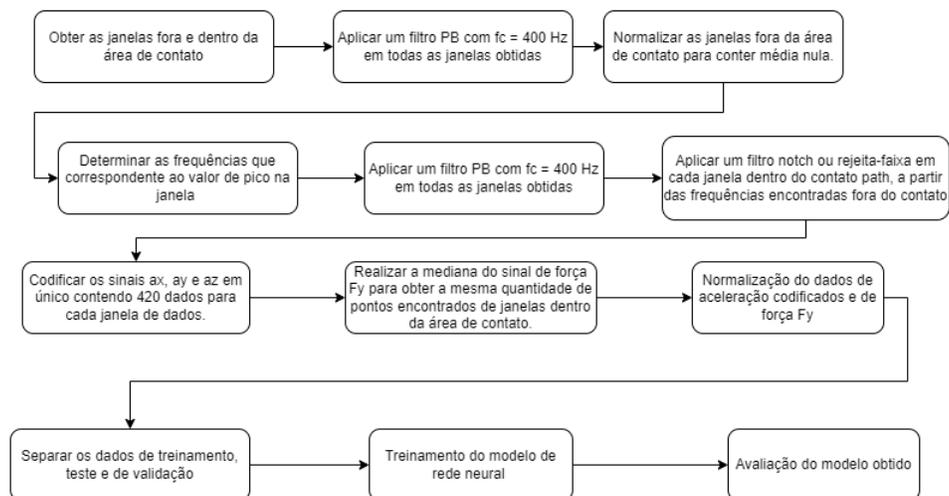
$$s = \sqrt{\frac{1}{N} \left(\sum_{k=1}^N (x_k - \bar{x})^2 \right)} \quad (3.5)$$

- obtendo a frequência da ocorrência do valor de pico a partir da Transformada Rápida de Fourier (*Fast Fourier Transform*) (LATHI, 2008) após o sinal ser filtrado por um filtro passa-baixa *Butterworth* de segunda ordem com frequência de corte de 400Hz, pois acima deste valor o sinal apresenta uma quantidade significativa de ruído.

3.2.3 Modelagem

O processo de obtenção do modelo de rede neural para estimação da força lateral é descrito no fluxograma da Figura 3.7. Cada etapa do fluxograma é melhor descrita nas seções a seguir.

Figura 3.7 – Fluxograma do processo de obtenção do modelo de rede neural artificial para estimação da força lateral



Fonte: autor

3.2.3.1 Filtro PB com frequência de 400Hz

Um filtro de passa-baixa *Butterworth* de segunda ordem com frequência de corte de 400 Hz é aplicado nesta etapa para remover qualquer ruído presente em alta frequência. Esse mesmo procedimento foi realizado em (BARBOSA et al., 2021).

3.2.3.2 Normalização dos sinais para possuir média nula e obtenção de frequência do valor de pico fora da área de contato

A normalização do sinal para possuir média nula, de acordo com as equações (3.6) e (3.7), é realizada para não ter a ocorrência de valores de picos em 0 Hz ao aplicar a Transformada Rápida de Fourier:

$$\mathbf{x} = \mathbf{x} - \bar{x} \quad (3.6)$$

$$\mathbf{x}_{\text{norm}} = \frac{\mathbf{x}}{\sqrt{\frac{1}{N}(\sum_{k=1}^N (x_k - \bar{x})^2)}} \quad (3.7)$$

Dessa forma, a partir das janelas da região fora da área de contato normalizadas, são obtidas as frequências que ocorrem os valores de picos em cada uma destas janelas.

3.2.3.3 Filtragem por filtro rejeita-faixa e/ou *notch*

Os valores de frequências de pico obtidos na etapa anterior são utilizados como frequência de corte para o filtro *notch Butterworth*, mas também como base para aplicação de três tipos diferentes de filtro rejeita-faixa de segunda ordem. Os três filtros rejeita-faixa utilizaram as seguintes frequências inferiores (f_i) e superiores (f_s):

1. f_i = frequência de pico - 10 Hz e f_s = frequência de pico + 10 Hz
2. f_i = frequência de pico - 50 Hz e f_s = frequência de pico + 50 Hz
3. f_i = frequência de pico - 100 Hz e f_s = frequência de pico + 100 Hz

A frequência do valor de pico das janelas fora da área de contato é utilizada como base para a criação dos filtros supracitados para cada janela de dados dentro da interface pneu-solo, já que se espera obter sinais filtrados por diferentes

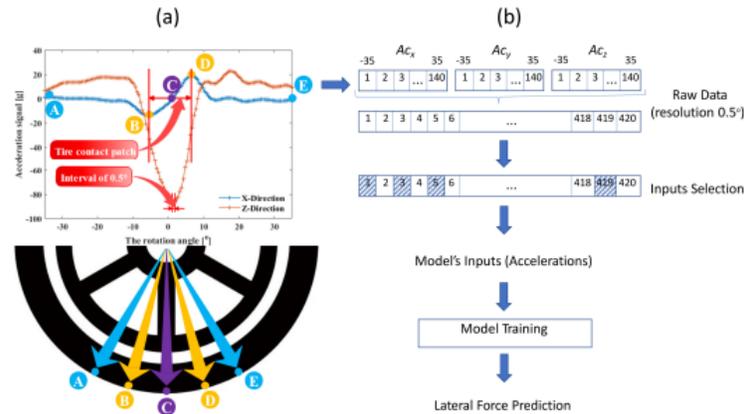
filtros para cada janela dentro dessa região, em que os filtros apresentam distintas frequências de corte. Assim, são aplicados os 4 filtros citados acima nas janelas de dados para os valores dentro da região de *contact patch*, conseqüentemente, obtendo 4 conjuntos de janelas de dados diferentes.

3.2.3.4 Codificação dos sinais a_x , a_y e a_z

De acordo com Xu et al. (2020) e Barbosa et al. (2021) para simplificar o modelo de rede neural a ser construído e garantir que as características obtidas sejam independentes da velocidade do pneu no solo é necessário obter um único sinal de aceleração que contenha 420 pontos, na qual este único sinal corresponde a codificação e junção dos sinais de aceleração do eixo x , y e z de uma dada janela de dados. Assim, este processo de codificação e junção é descrita a seguir:

- primeiro é necessário obter 140 pontos de dados em a_x , a_y e a_z de cada janela dentro da área de contato, os sinais de aceleração dessas janelas estão devidamente filtrados pelo passo anterior, na qual estes 140 pontos correspondem à resolução de $0,5^\circ$ por ponto dentro do ângulo de rotação da área de contato que é de 70° . Esta resolução é explicada pela Figura 3.8, os pontos A e E representa uma janela de dados dentro do *contact patch* e o ponto C é o centro desta região (BARBOSA et al., 2021), assim, entre os pontos A e E a formação de um ângulo de rotação máximo de 70° , -35° entre A e C e 35° entre C e E;
- determinados os pontos, os sinais de aceleração das três direções são unificados em único de 420 pontos, obtendo uma matriz de dados $N \times 420$, em que N corresponde ao número de janelas de dados de aceleração dentro de uma rotação do pneu dentro da área de contato.

Figura 3.8 – Área de contato de pneu entre os pontos A e E



Fonte: (BARBOSA et al., 2021)

3.2.3.5 Mediana do sinal de força F_y

Esta etapa consiste em obter um único dado de força lateral F_y para cada janela do sinal de aceleração obtida dentro da região de *contact patch*. Onde, primeiro, são obtidas os valores de força lateral em uma dada rotação do pneu dentro da região de contato, logo, são obtidas janelas de dados que correspondem a força lateral dentro da região de contato pneu-solo. Por final, é realizada a mediana de cada janela para obter uma única amostra de força por janela, consequentemente, através deste processo é obtido um vetor $N \times 1$ e que N corresponde ao número de janelas de dados obtido para os sinais de aceleração e de força dentro da área de contato.

3.2.3.6 Normalização dos dados

Esta etapa consiste na normalização dos dados na mesma escala, em que foi aplicada a normalização do tipo Min-Máx. Este tipo de normalização é uma transformação linear que é descrita pela equação (3.8), sendo aplicada tanto nos dados codificados e de força lateral adquiridos:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.8)$$

3.2.3.7 Modelo e treinamento do modelo

O modelo de rede neural artificial construído é baseado no uso da biblioteca **tensorflow.keras** do *Python*, em que apresenta a seguinte topologia: 420 neurônios na camada de entrada, correspondendo a matriz de aceleração codificada $N \times 420$, obtida nos passos anteriores; duas camadas escondidas contendo em cada camada 50 e 40 neurônios; e um neurônio na camada de saída, correspondendo ao vetor $N \times 1$ de força lateral, obtida no passo anterior.

A arquitetura da rede proposta foi alcançada após a execução de vários testes com o conjunto de dados utilizado neste trabalho, em que a Figura 3.9 apresenta a arquitetura de rede proposta. E cada um destes neurônios utiliza a função sigmoide como função de ativação. Este modelo utiliza como algoritmo de otimização o RMSprop (*Root Mean Square Propagation*) (XU et al., 2021).

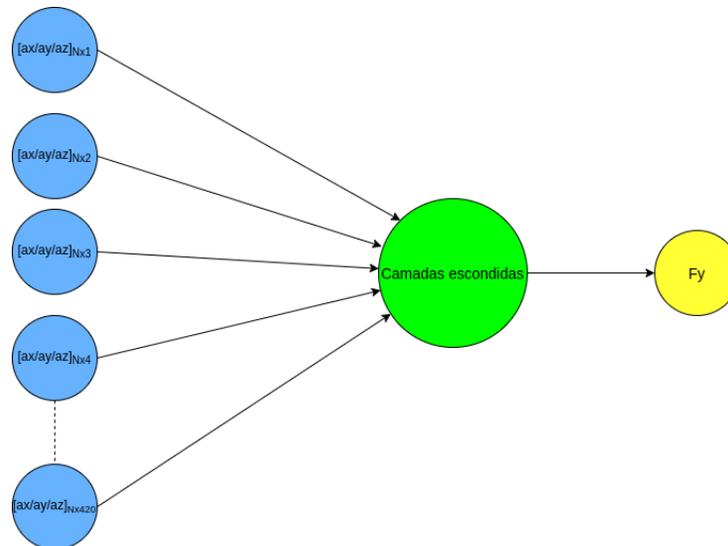
3.2.3.8 Avaliação do modelo

Para avaliar o desempenho do modelo são utilizados os dados de testes e de validação para estimar os valores de forças laterais, logo, a partir dos valores estimados e reais é utilizada a métrica NRMSE (*Normalize Root Mean Square Error*), equação (3.9), com a finalidade de avaliar o erro de predição da rede neural artificial construída:

$$NRMSE(\%) = 100 \frac{\sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2}}{y_{max}} \quad (3.9)$$

E para determinar diferentes erros de predição é aplicado o método *K-fold cross validation* (REFAEILZADEH et al., 2020) juntamente com a métrica de avaliação citada acima, sendo definido um valor de k igual a 10, assim, são

Figura 3.9 – Arquitetura de rede neural artificial proposta para ser implementada neste trabalho. A entrada $[a_x/a_y/a_z]$ representa uma janela de dados codificada, na qual a_x , a_y e a_z apresenta 140 pontos cada. Já as camadas escondidas correspondem as camadas de 50 e 40 neurônios, por final a saída F_Y representa a força lateral a ser estimada



Fonte: autor

obtidos 10 grupos de dados de treinamento e teste diferentes entre si para treinar e validar a rede neural. Conseqüentemente, são obtidos 10 modelos com valores de avaliações distintas. Este método é utilizado para entender o comportamento dos dados com diferentes tipos de filtragem e definir no geral qual obteve o melhor resultado.

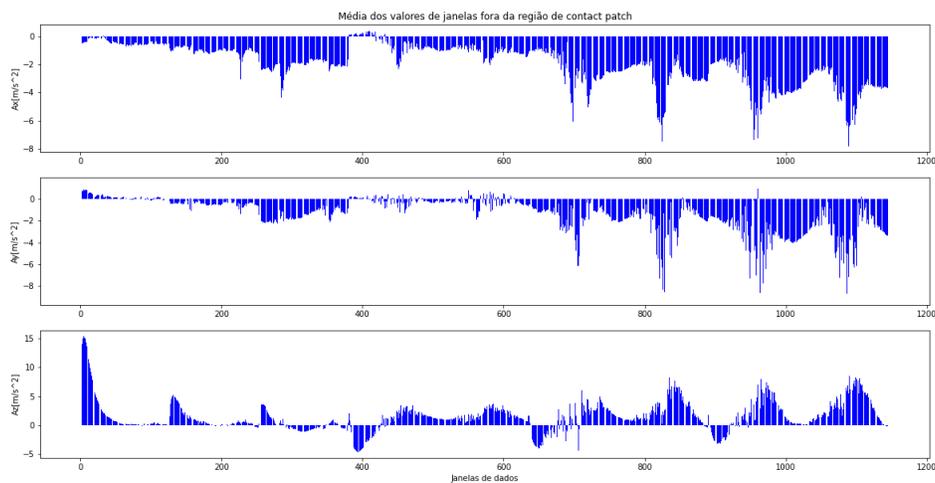
4 RESULTADOS E DISCUSSÃO

Este capítulo tem como foco mostrar e discutir os resultados obtidos a partir da análise de dados dos sinais de acelerações fora da região de contato e o processo de estimação de força lateral por um modelo de aprendizagem de máquina supervisionada do tipo rede neural artificial.

4.1 Análise exploratória

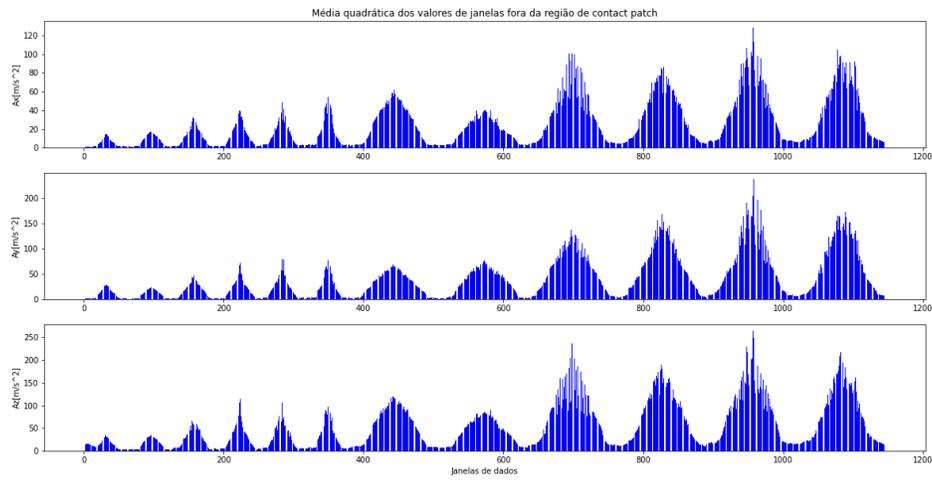
A partir do processo de janelamento dos sinais de aceleração são obtidos 1146 e 1145 janelas fora e dentro da região de contato, respectivamente. Assim, a Figura 4.1 representa a média simples das janelas de dados fora da região de *contact patch*, onde pode ser observado que as últimas janelas apresentam as maiores amplitudes em valores absolutos, já que correspondem à região em que a velocidade linear do pneu no ensaio foi de 60 km/h, de acordo com a Figura 3.4.

Figura 4.1 – Média dos valores de janelas de aceleração fora da região de contato



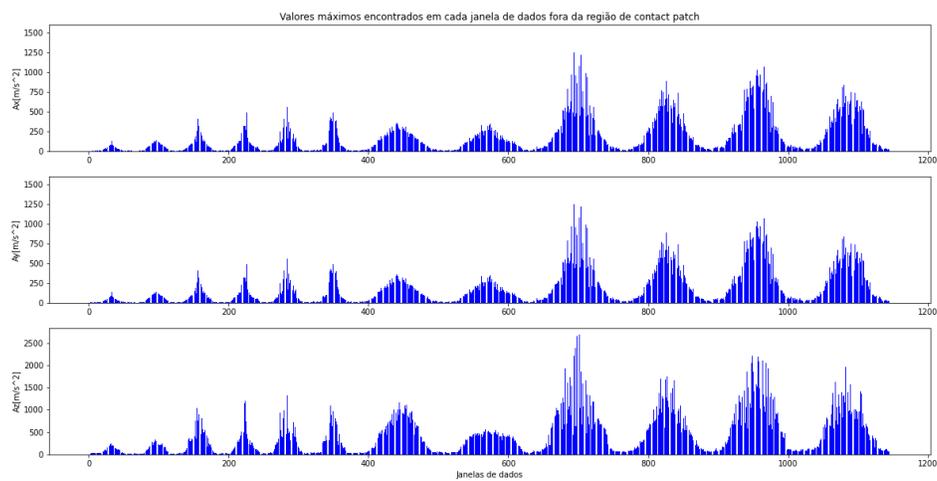
Fonte: autor

Figura 4.2 – Média quadrática dos valores de janelas de aceleração fora da região de contato



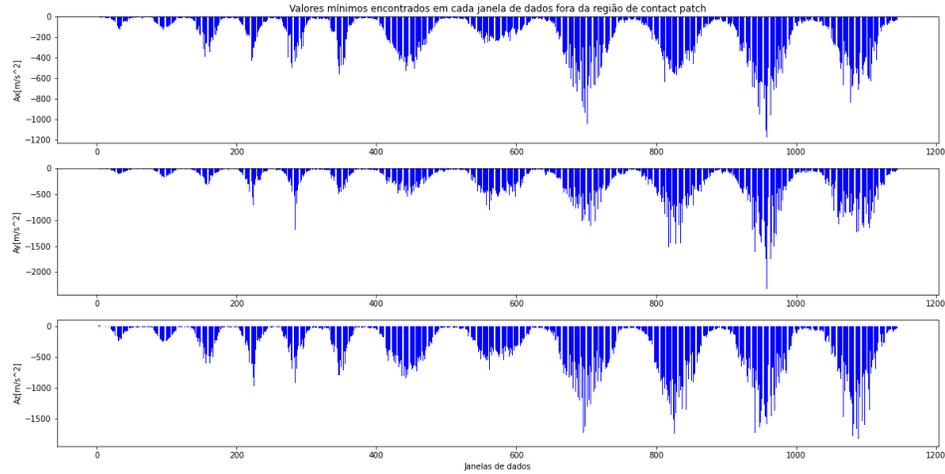
Fonte: autor

Figura 4.3 – Valor máximos de janelas de aceleração fora da região de contato



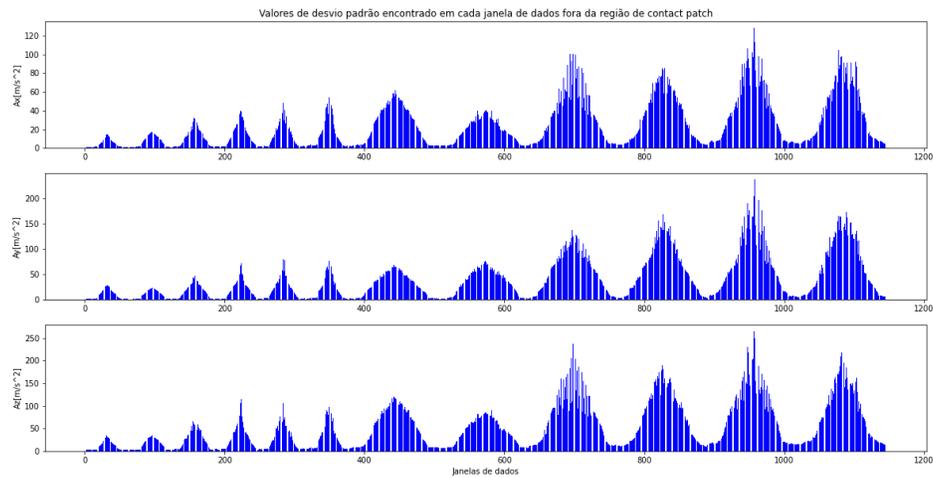
Fonte: autor

Figura 4.4 – Valor mínimo de janelas de aceleração fora da região de contato



Fonte: autor

Figura 4.5 – Valor de desvio padrão das janelas de aceleração fora da região de contato



Fonte: autor

As Figuras 4.2, 4.3, 4.4 e 4.5 representam, respectivamente, a média quadrática, máximo, mínimo e os desvio padrão das janelas fora da área de contato

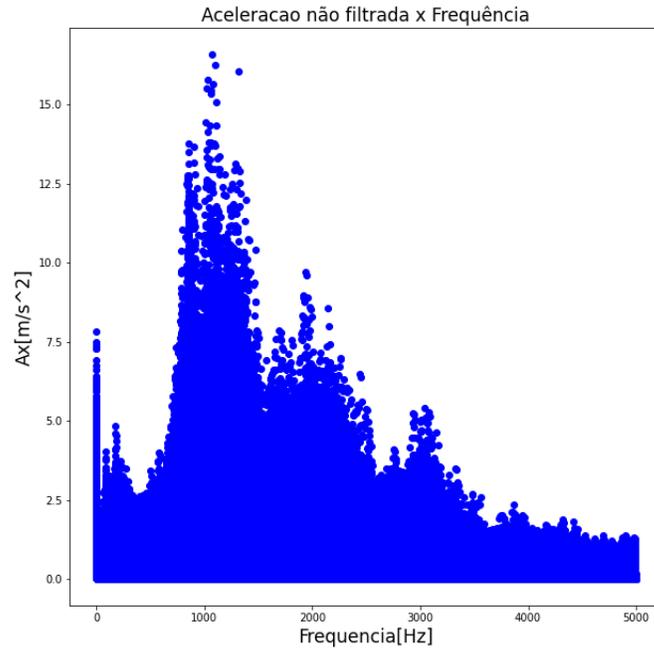
para a_x , a_y e a_z . Pode ser observado que estas figuras apresentam um comportamento semelhante. Este comportamento se dá pelos resultados das métricas de cada janela se agrupam de forma triangular, apresentando 12 agrupamentos e, conseqüentemente, é o número de semiciclos do sinal triangular do *slip angle* da Figura 3.2.

Os valores de média quadrática, máximo, mínimo e desvio padrão encontrados que apresentam as menores amplitudes em torno do grupo triangular são aqueles que apresentam o *slip angle* próximo ou igual a zero. Já os valores de maior amplitude nos grupos coincidem com os valores de picos do sinal triangular de entrada. As últimas janelas apresentam os maiores valores que as demais devido ao fato já citado para a média simples. Portanto, pode ser concluído que a região fora do *contact patch* é influenciada pelo o *slip angle* presente na área de contato e a velocidade linear do pneu.

A Transformada Rápida de Fourier fora da área de contato é aplicada e analisada para o sinal de aceleração nos três eixos, em que as Figuras 4.6, 4.8 e 4.10 mostram a transformada dos sinais originais sem ter aplicado um processo de filtragem. Já as Figuras 4.7, 4.9 e 4.11 apresentam os sinais fora da região de contato filtrados por um filtro passa-baixa *Butterworth* com f_c igual a 400Hz. A partir dessas seis figuras são observadas a presença de ruído em alta frequência no sinal, pois mesmo após a filtragem por um PB de 400 Hz os sinais de aceleração apresenta muita energia nas frequências maiores e próximas de 400 Hz. E isto é devido que nos sinais originais há presença de ruídos em alta frequência, acima de 400 Hz, logo, assim o filtro minimiza estes ruídos.

Assim, a Figura 4.12 apresenta os valores de frequências de picos para cada janela de dados fora da área de contato, onde são utilizadas para o processo de filtragem por um filtro *notch* e rejeita-faixa dentro da região do *contact patch* para estimação da força lateral F_y . E como era de se esperar há presença de valores de picos em baixa frequência, menor do que 400 Hz, em algumas janelas, logo, ao

Figura 4.6 – FFT das janelas agrupadas do sinal aceleração do eixo x fora da área de contato



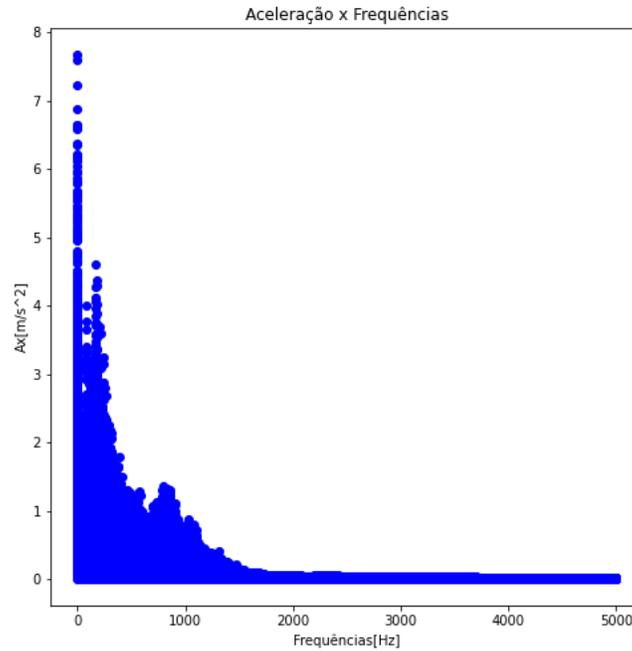
Fonte: autor

aplicar os filtros já citados espera-se remover valores a partir dessas frequências dentro da interface pneu-solo, na quais podem ser considerados ruídos em baixa frequência.

4.2 Modelagem

A partir do método *k-fold cross validation* pode ser visto que a matriz de entrada $N \times 420$ filtrada por um rejeita-faixa *Butterworth* de segunda ordem com a frequência de limite inferior e superior correspondendo à frequência dos valores de picos ± 10 Hz é o que apresentou melhor resultado comparado com os demais métodos de filtragem para a entrada da rede neural, este fato pode ser visto

Figura 4.7 – FFT das janelas agrupadas do sinal aceleração do eixo x fora da área de contato filtrado por filtro PB *Butterworth* de segunda ordem com $f_c = 400\text{Hz}$



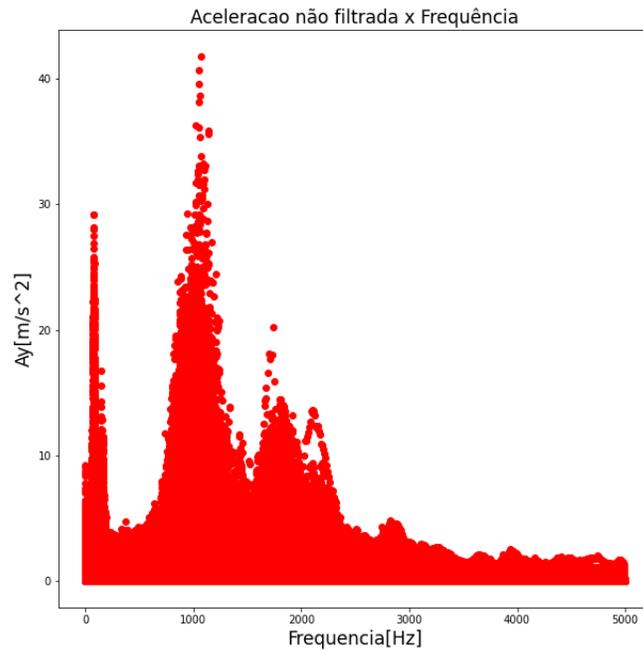
Fonte: autor

na Figura 4.13. E é possível notar que o melhor resultado para esse método de filtragem é o valor do erro de predição da força lateral abaixo de 15%.

Já a Figura 4.14 demonstra a distribuição do erro de predição obtido a partir do *k-fold* e que o melhor resultado do erro de predição já citado para o rejeita-faixa com frequência do valor de pico variando mais ou menos 10 Hz é considerado um *outlier*, ou seja, é considerado uma medida atípica para o erro de predição. Logo, a tendência do resultado do erro de predição com a entrada da rede neural filtrada por esse filtro é variar entre 20 e 30 %.

No entanto, no geral, para os quatro métodos, o valor de predição de erro NRMSE se manteve alto, demonstrando que a filtragem dentro do *contact patch* pela frequência do valor de pico das janelas de dados fora dessa região de inter-

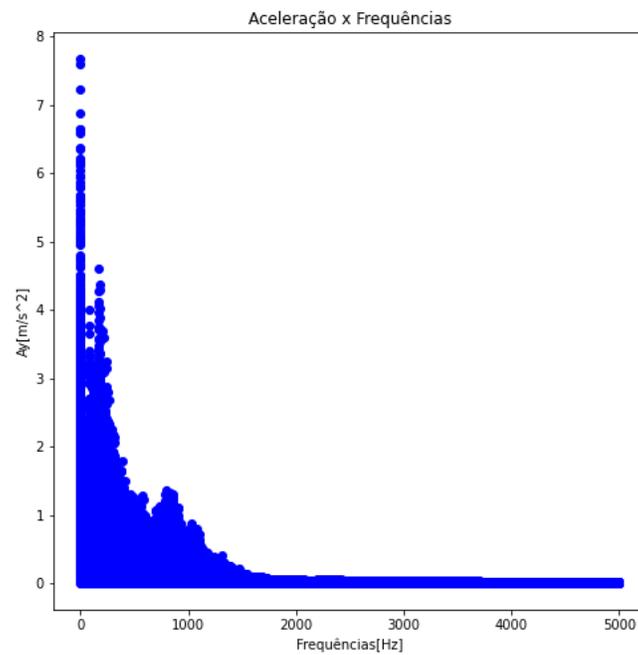
Figura 4.8 – FFT das janelas agrupadas do sinal aceleração do eixo y fora da área de contato



Fonte: autor

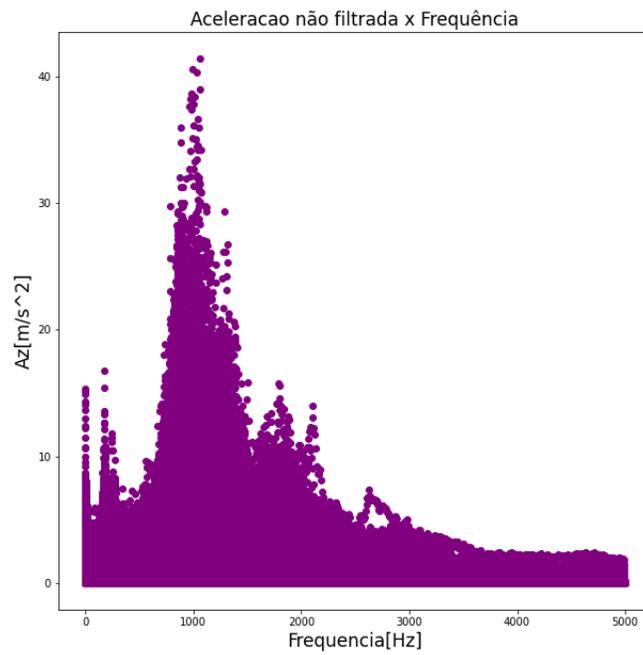
face pneu-solo não demonstrou ser suficiente para a melhora da predição da força lateral, pois apresenta erros acima de 10%. Logo, isto pode ser devido que em algumas rotações do pneu a frequência do valor de pico fora da região de contato acontece de ser um ruído dentro da região, porém em outras não, assim, se torna necessário aprofundar melhor os estudos sobre a influência da região fora da área de contato para a região de interação pneu-solo.

Figura 4.9 – FFT das janelas agrupadas do sinal aceleração do eixo y fora da área de contato filtrado por filtro PB *Butterworth* de segunda ordem com $f_c = 400\text{Hz}$



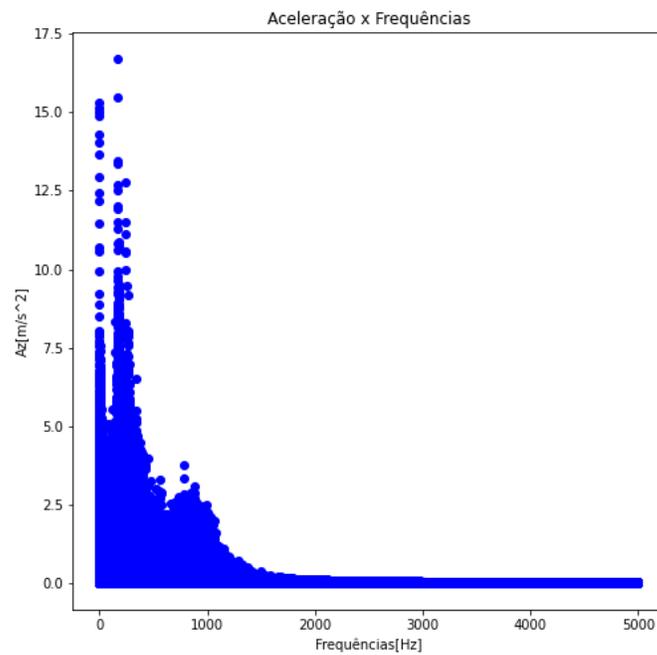
Fonte: autor

Figura 4.10 – FFT das janelas agrupadas do sinal aceleração do eixo z fora da área de contato



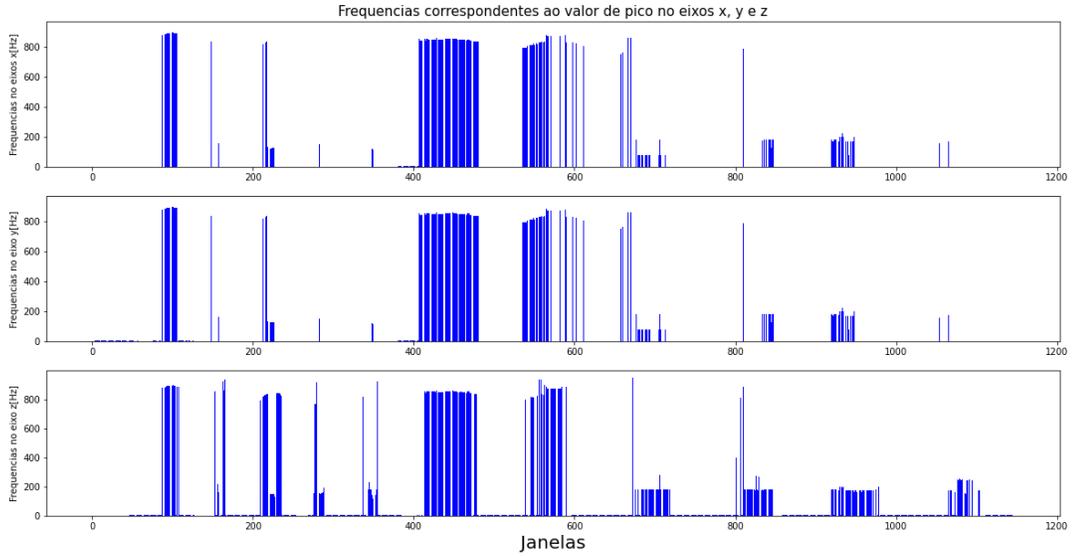
Fonte: autor

Figura 4.11 – FFT das janelas agrupadas do sinal aceleração do eixo z fora da área de contato filtrado por filtro PB *Butterworth* de segunda ordem om $f_c = 400\text{Hz}$



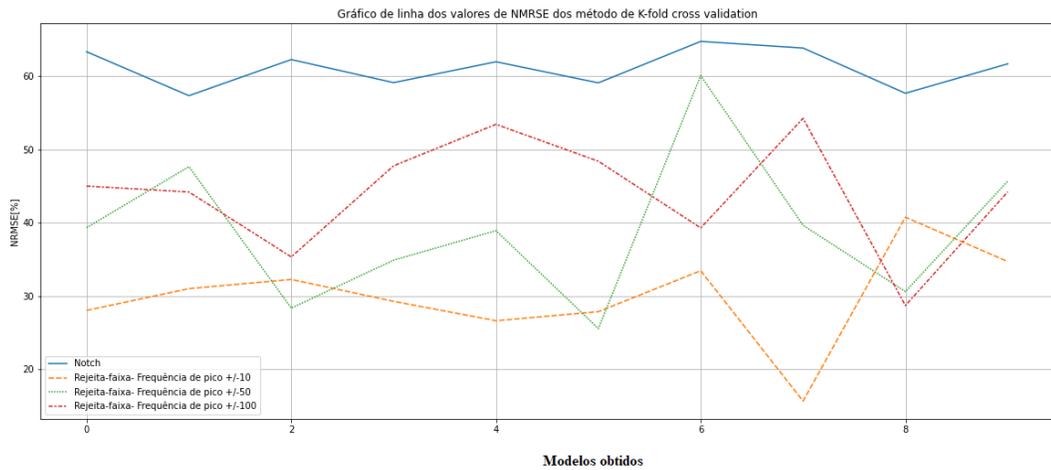
Fonte: autor

Figura 4.12 – Frequências de pico após a filtragem com um filtro PB *Butterworth* de segunda ordem com $f_c = 400\text{Hz}$



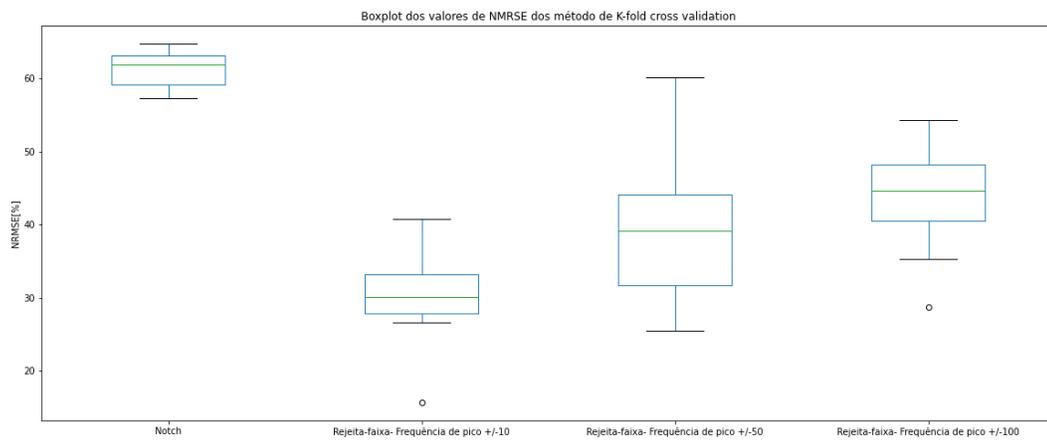
Fonte: autor

Figura 4.13 – Valor de NRMSE em % dos dados de validação para quatro tipos diferentes de filtragem com 10 modelos de dados diferentes



Fonte: autor

Figura 4.14 – Boxplot do valor de NRMSE em % dos dados de validação para quatro tipos diferentes de filtragem com 10 modelos de dados diferente



Fonte: autor

5 CONCLUSÃO

Este trabalho teve como objetivos: entender a influência do sinal de aceleração fora da área de contato do pneu e estimar a força lateral a partir da filtragem do sinal de aceleração do eixo x , y e z a partir de informações de frequências fora da região de *contact patch*. Assim, é observado que o sinais de aceleração medidos fora da área de contato é influenciada pelas condições que ocorrem na interface pneu-solo, em que é observado que, dentre os parâmetros de entrada, o ângulo de deriva e velocidade linear possuem maior impacto em relação ao comportamento e a amplitude dos sinais, respectivamente, ao observar as métricas de análise exploratória utilizadas.

Já dentre os quatro métodos para a estimação da força lateral F_y propostos, o melhor resultado foi utilizar um filtro *Butterworth* rejeita-faixa de segunda ordem variando a faixa de frequência do valor de pico, encontrada fora da região de contato, em mais ou menos 10 Hz. Contudo, o processo de estimação de força apresentou altos valores de erros de predição, acima de 10%, isto é devido que algumas rotações do pneu apresenta sinais de aceleração fora da área de contato que influenciam a interface pneu-solo, a partir de ruídos em baixa frequência, contudo em outras não. Portanto, é necessário melhor entender a influência que o sinal de aceleração fora da área de contato possui para a aceleração dentro da região de interação pneu-solo, onde é nesta interface que há ocorrência da força lateral aplicada sobre o pneu.

Como sugestão de trabalho de futuro, visando melhorar o método proposto neste trabalho de conclusão de curso, é o uso do algoritmo ICA (*Independent Component Analysis*), pois é um algoritmo capaz de separar sinais a partir de uma mistura de sinais, ou seja, sinais de uma determinada fonte misturado com um ruído ou por outras fontes de sinais. Logo, este algoritmo seria utilizado para estimar os sinais de aceleração em cada janela de dados sem e com ruídos, portanto, a partir do

ruído identificado filtrá-lo na região de *contact patch* e predizer a força lateral, verificando performance com as mesmas métricas utilizada neste trabalho.

REFERÊNCIAS

AGUIAR, M. A. M. D. Tópicos de Mecânica Clássica. n. November 2010, 2010.

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.

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 Estimação de Atrito Pneu/Solo. 2015.

CHAVES, B. B. Estudo Do Algoritmo Adaboost De Aprendizagem De Máquina Aplicado a Sensores E Sistemas Embarcados. p. 137, 2012.

FINKLER, A. C. APRENDIZAGEM DE MAQUINA APLICADA Á PREVISÃO DOS MOVIMENTOS DO IBOVESPA. v. 6, p. 5–9, 2017.

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

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.

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos de Física**. Rio de Janeiro, RJ: [s.n.], 2012. 1–338 p.

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.

LATHI, B. **Sinais e sistemas lineares**. [S.l.: s.n.], 2008. ISBN 9788577803910.

NETO, C. d. C. N. Integração das equações diferenciais do filtro Digital de Butterworth mediante algoritmo de quadratura numérica de ordem elevada. 2003.

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.

PEREIRA, G. C.; CUSTODIO, R. Redes neurais para regressão uni- e multivariada. **Revista Chemkeys**, v. 3, p. e021003, 2021.

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>>.

PUGLIESE, D. P. Não uniformidades de pneus e sua influência em baixas e altas velocidades 88/2015. 2015.

RAMINELLI, Daniele Gonçalves de Toledo Luchetta; SANTOS, B. d. S. Aplicação de Técnicas de Mineração de Dados e Aprendizagem de Máquina no Mercado de Ações : Uma Revisão Sistemática Application of Data Mining and Machine Learning Techniques in the Stock Market : A Systematic Review. **Congresso Brasileiro de Engenharia de Produção**, v. 9, 2019.

RAUBER, T. W. Redes neurais artificiais. **Sistemas Inteligentes: Fundamentos e Aplicações**, n. May, 2003. Disponível em: <<http://scholar.google.com/scholar?cluster=>>>.

REFAEILZADEH, P. et al. Encyclopedia of Database Systems. **Encyclopedia of Database Systems**, 2020.

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.

SELMANAJ, D. et al. Vehicle sideslip estimation: A kinematic based approach. **Control Engineering Practice**, Elsevier Ltd, v. 67, n. December 2016, p. 1–12, 2017. ISSN 09670661. Disponível em: <<http://dx.doi.org/10.1016/j.conengprac.2017.06.013>>.

SERRA, M. R. G. Aplicações de Aprendizagem por Reforço em Controle de Tráfego Veicular. 2004.

SERWAY, R. A.; JR, J. W. J. **Princípios de Física**. 5ª. ed. São Paulo, SP: [s.n.], 2004. 403 p. ISBN 8522103828.

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.

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>>.

TAYLOR, J. R. **Classical Mechanical**. [S.l.: s.n.], 2005. v. 53. 1689–1699 p.
ISSN 1098-6596. ISBN 9788578110796.

TIPLER, P. A.; MOSCA, G. **Física para cientista e engenheiros Vol 1 - Paul TIPLER e Gene Mosca**. 2009. 824 p.

XU, D. et al. Convergence of the RMSProp deep learning method with penalty for nonconvex optimization. **Neural Networks**, Elsevier Ltd, v. 139, p. 17–23, 2021. ISSN 18792782. Disponível em: <<https://doi.org/10.1016/j.neunet.2021.02.011>>.

XU, N. et al. Tire Force Estimation in Intelligent Tires Using Machine Learning. **IEEE Transactions on Intelligent Transportation Systems**, p. 1–10, 2020. ISSN 15580016.