

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
MESTRADO EM ENGENHARIA ELÉTRICA**

**LUCAS VACILOTTO BONFATI**

**ANÁLISE DO COMPORTAMENTO DO MOTORISTA BASEADO EM  
AQUISIÇÃO DE DADOS VEICULARES E INSTRUMENTAÇÃO  
ADICIONAL DO VEÍCULO**

**DISSERTAÇÃO**

**PONTA GROSSA**

**2021**

**LUCAS VACILOTTO BONFATI**

**ANÁLISE DO COMPORTAMENTO DO MOTORISTA BASEADO EM  
AQUISIÇÃO DE DADOS VEICULARES E INSTRUMENTAÇÃO  
ADICIONAL DO VEÍCULO**

**DRIVER BEHAVIOR ANALYSIS BASED ON VEHICLE DATA  
ACQUISITION AND ADDITIONAL VEHICLE INSTRUMENTATION**

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica, do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Sergio Luiz Stevan Jr.  
Coorientador: Prof. Dr. José Jair Alves Mendes Júnior

**PONTA GROSSA**

**2021**



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite que outros remixem, adaptem e criem a partir do trabalho para fins não comerciais, desde que atribuam o devido crédito e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



---

LUCAS VACILOTTO BONFATI

**ANÁLISE DO COMPORTAMENTO DO MOTORISTA BASEADO EM AQUISIÇÃO DE DADOS VEICULARES E INSTRUMENTAÇÃO ADICIONAL DO VEÍCULO**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Controle E Processamento De Energia.

Data de aprovação: 17 de Dezembro de 2021

Prof Sergio Luiz Stevan Junior, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Daniel Prado De Campos, - Universidade Tecnológica Federal do Paraná

Prof Hugo Valadares Siqueira, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Jose Jair Alves Mendes Junior, - Universidade Tecnológica Federal do Paraná

Prof Paulo Broniera Junior, Doutorado - Instituto Senai de Tecnologia de Informação e Comunicação Isttic

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 17/12/2021.

À memória de minha mãe, Roseane, que  
partiu deste mundo cedo demais.

## AGRADECIMENTOS

Os agradecimentos aqui elencados não serão capazes de contemplar todas as pessoas que, de uma forma ou outra, fizeram parte dessa caminhada, mas estejam certos do meu reconhecimento e gratidão a todos que estiveram ao meu lado em mais essa etapa.

Agradeço primeiramente a Deus pela vida, e por todas as oportunidades que Ele me concedeu e concede diariamente.

Aos meus familiares por todo o apoio que me foi dado em todos os momentos, sejam eles felizes ou tristes.

À minha namorada, que esteve ao meu lado no decorrer deste trabalho e sempre me incentivou, compartilhando as conquistas e dificuldades, além de compreender os momentos em que estive ausente.

Ao professor Dr. Sergio Luiz Stevan Jr., orientador deste trabalho, pela disponibilidade, por me proporcionar um imenso crescimento pessoal e intelectual, e o incentivo de sempre em todas as atividades.

Ao meu amigo e professor Dr. José Jair Alves Mendes Jr., coorientador deste trabalho, por toda a colaboração e auxílio no decorrer desta dissertação.

Aos voluntários que disponibilizaram seu tempo para participarem das coletas de dados, fundamentais para o êxito deste trabalho.

A todos meus amigos que estiveram ao meu lado durante essa jornada acadêmica, e aos integrantes do Centro de Instrumentação nas Engenharias Biomédica e Esportiva (CIEBE), onde pude trabalhar no desenvolvimento deste e tantos outros projetos, e fiz grandes amigos que levarei para a vida.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES pelo apoio financeiro (Código de Financiamento 001).

## RESUMO

Os automóveis atuais possuem dezenas de sensores para monitorar e melhorar o desempenho do veículo e comunicam-se através de redes veiculares (CAN) com várias centrais de eletrônicas de controle (ECU) que são responsáveis pelas tomadas de decisões. Atualmente, ainda é crescente o desenvolvimento de sensores para melhorar a segurança veicular ou personalizar a experiência do condutor. Este trabalho teve por objetivo a adaptação de um sistema para adquirir os dados de sensores do veículo, de sensores adicionais instalados neste e no condutor visando, com auxílio de reconhecimento de padrões, a identificação do motorista e análise de seu comportamento. Neste sentido, muitos dos sensores instalados de fábrica (como velocidade, posição do acelerador, torção do volante, monitoramento de frenagem, etc) podem ser monitorados para alcançar objetivos mais complexos, como avaliar as características do modo de condução do veículo. Entretanto, alguns outros sensores podem ser inseridos de modo a monitorar variáveis que não são habitualmente instrumentadas como o pedal do freio, o qual foi instrumentado para analisar sua dinâmica e avaliar sua importância neste processo de identificação de comportamento do motorista. Para validar e correlacionar os dados veiculares, na primeira fase foi instrumentado o pé do motorista com um sensor inercial e coletados sinais de eletromiografia de superfície da perna do condutor. Em uma segunda fase, foi instrumentado o volante para monitoramento de sua posição e o sensor inercial fixado no interior do veículo (simulação do sensor de guinada). Um protocolo experimental foi definido para buscar diferenciar dois padrões de condução (aqui chamados de calmo e agressivo) e verificar se é possível ainda identificar o condutor. Foram empregadas 3 diferentes ferramentas de classificação – SVM, *k*-NN e *Random Forests*. Diferentes combinações de parâmetros foram testadas a fim de avaliar o desempenho dos classificadores a partir de valores de acurácia e especificidade. Verificou-se que há resultados superiores na classificação de identidade quando são incluídos os dados do condutor, bem como na classificação de comportamento. Para a avaliação somente com os sensores no veículo, as taxas são superiores quando inclusos os dados do pedal do freio e do volante em comparação aos dados somente da CAN. Como resultados, quando combinados todos os atributos disponíveis obtidos do veículo tem-se taxas superiores para *Random Forests*, com valores de acurácia e especificidade, respectivamente, de 0,91 e 0,91 na identificação do comportamento; e de 0,94 e 0,74 na identificação do motorista. Quando associados, sendo feita inicialmente a classificação da identidade e, em sequência, do comportamento, obtiveram-se valores de acurácia superiores a 0,97.

**Palavras-chave:** análise de comportamento do condutor; eletromiografia de superfície; CAN; extração de atributos; reconhecimento de padrões.

## ABSTRACT

Today's cars have dozens of sensors to monitor and improve vehicle performance and communicate through vehicle networks (CAN) with various Electronic Control Unit (ECU) that are responsible for decision making. Currently, the development of sensors to improve vehicle safety or customize the driver's experience is still growing. The objective of this work was to adapt a system to acquire data from vehicle sensors, from additional sensors installed on the vehicle and on the driver, aiming, with the aid of pattern recognition, to identify the driver and analyze his behavior. In this sense, many of the factory-installed sensors (such as speed, throttle position, steering wheel torque, braking monitoring, etc). However, some other sensors can be inserted in order to monitor variables that are not usually instrumented, such as the brake pedal, which was instrumented to analyze its dynamics and assess its importance in this driver behavior identification process. In order to validate and correlate the vehicle data, in the first phase, the driver's foot was instrumented with an inertial sensor and surface electromyographic signals were collected from the driver's leg. In the second phase, the steering wheel was instrumented to monitor its position and the inertial sensor fixed inside the vehicle (to simulate the yaw rate sensor). An experimental protocol was defined to seek to differentiate two driving patterns (here called calm and aggressive modes) and to verify if it is still possible to identify the driver. Three different classification tools were used – SVM, k-NN and Random Forests. Different combinations of parameters were tested in order to evaluate the performance of the classifiers based on accuracy and specificity values. It was found that there are superior results in the identity classification when driver data are included, as well as in the behavior classification. For the evaluation with in-vehicle sensors only, rates are higher when including brake pedal and steering wheel data compared to CAN-only data. As a result, when all available attributes obtained from the vehicle are combined, higher rates for Bagged Tree are obtained, with accuracy and specificity values, respectively, of 0.91 and 0.91 for behavior identification; and of 0.94 and 0.74 for driver identification. When associated, initially with the classification of identity and, subsequently, of behavior, accuracy values greater than 0.97 were obtained.

**Keywords:** driver behavior analysis; feature extraction; surface electromyography; CAN; pattern recognition.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Graus de liberdade em um sistema tri-axial.....	27
Figura 2– Módulo inercial – 6050. ....	28
Figura 3: Procedimentos metodológicos para o desenvolvimento do trabalho proposto. Em (a) FASE 1 - estão descritos os passos e as principais características envolvendo a aquisição e o processamento de dados com os circuitos presentes tanto no carro quanto no motorista e em (b) FASE 2 - os passos e os processos envolvendo apenas os dados coletados no automóvel. ....	40
Figura 4 - Vista frontal da Central de Aquisição de Dados Automotivos utilizada no processo de aquisição deste trabalho. ....	45
Figura 5 – Diagrama de blocos do funcionamento da CADA e demais sensores. As conexões não especificadas são físicas. ....	47
Figura 6 – Posicionamento da CADA no veículo durante a realização dos testes. ....	48
Figura 7 – Esquemático interno do INA129 e suas ligações para a aquisição dos sinais de sEMG.....	49
Figura 8 – Esquemático do circuito de aquisição de sEMG, envolvendo as etapas de amplificação, filtragem e condicionamento do sinal com <i>offset</i> . ....	51
Figura 9 – Esquemático do circuito de alimentação do sistema de aquisição, baseado no circuito 555 que converte a tensão de uma bateria em uma fonte de tensão <i>dual supply</i> . ....	52
Figura 10 – Vista frontal dos circuitos desenvolvidos, sendo (a) do circuito de aquisição de sEMG e (b) a fonte utilizando o circuito integrado 555. ....	53
Figura 11 - Resultado da simulação do circuito de aquisição de sEMG. Em (a) é apresentado o sinal de entrada para o circuito, em (b) apresenta a resposta para em amplitude, com o deslocamento no eixo Y do sinal do circuito e em (c) a resposta em frequência do circuito. ....	54
Figura 12 – Comportamento do circuito de aquisição de sEMG. Em (a) é apresentada a resposta em amplitude do circuito e em (b) a resposta em frequência do circuito. ....	55
Figura 13 – Posicionamento do sensor de aquisição de sEMG no músculo tibial dos condutores e o eletrodo de referência alocado na região do joelho (fase 1). ....	56
Figura 14 – Posicionamento do sensor inercial nos condutores (fase 1). ....	57
Figura 15 –Instrumentação do freio, em que foi utilizado um potenciômetro deslizante. a) foto do sensor instalado no veículo; e b) diagrama de funcionamento do sensor acoplado ao pedal. ....	58
Figura 16 – Caracterização da instrumentação do pedal do freio. Quantização do sinal digitalizado/AD em relação a excursão do freio (cm). ....	59
Figura 17 - Instrumentação do volante, em que foi utilizado um potenciômetro rotativo multivoltas associado a engrenagens. Em (a) potenciômetro multivoltas (C) e engrenagens utilizadas (A para a barra de direção e B para o potenciômetro), e em (b) o sensor instalado na barra de direção. ....	60



Figura 18 - Média das aquisições dos sinais da excursão do volante, sendo a quantização do AD em relação a rotação do potenciômetro. ....	61
Figura 19 – Módulo do sensor inercial fixado no veículo. ....	62
Figura 20- Disposição dos sensores adicionais instalados no veículo. ....	62
Figura 21 - Detalhamento do trajeto utilizado nos testes .....	64
Figura 22 – Etapas do processamento dos dados da FASE 1 - análise envolvendo os sensores no motorista e no veículo. ....	65
Figura 23 – Processamento do sinal de sEMG para eliminar ruídos para o estágio de segmentação. Em (a) são apresentadas as detecções de ativações musculares por meio da técnica de <i>onset</i> e em (b) são apresentados os valores selecionados das respectivas ações musculares. ....	66
Figura 24 - Estágios e características da etapa de processamento de sinais para a FASE 2 - análise dos sinais apenas com os sinais do veículo. ....	70
Figura 25 – Exemplo de sinal de sEMG coletado durante uma aquisição completa do motorista no percurso em modo agressivo e o sinal obtido pelo potenciômetro no pedal do freio. Os valores dos conversores AD foram convertidos em seus respectivos valores em tensão. ....	73
Figura 26 – Exemplos de sinais em uma aquisição em modo calmo com os sinais de sEMG e do pedal do freio (a) e dos parâmetros obtidos da rede CAN (b). ...	74
Figura 27 - Distribuição de probabilidade para as características média RPM, máxima posição do acelerador, média posição de aceleração e máximo valor freio para os comportamentos calmo e agressivo. ....	75
Figura 28 – Resultados de acurácia e especificidade para os classificadores <i>Quadratic SVM</i> , <i>k-NN</i> e <i>Bagged Tree</i> para o caso envolvendo todas as características no processamento no reconhecimento da identidade do motorista e do seu comportamento. ....	80
Figura 29 – Resultados de acurácia e especificidade para os classificadores <i>Quadratic SVM</i> , <i>k-NN</i> e <i>Bagged Tree</i> para o caso envolvendo os atributos de entrada apenas com os dados do veículo no processamento. ....	81
Figura 30 – Resultados de acurácia e especificidade para os classificadores <i>Quadratic SVM</i> , <i>k-NN</i> e <i>Bagged Tree</i> para o caso envolvendo os atributos de entrada apenas com os dados do condutor no processamento. ....	82
Figura 31 – Resultados de acurácia e especificidade para os classificadores <i>Quadratic SVM</i> , <i>k-NN</i> e <i>Bagged Tree</i> para o caso envolvendo apenas os dados de EMG com os dados do condutor no processamento. ....	83
Figura 32 – Comparativo de desempenho dos classificadores para análise do comportamento do motorista. ....	87
Figura 33 - Comparativo de desempenho dos conjuntos de <i>features</i> para análise do comportamento do motorista. ....	88
Figura 34 - Comparativo de desempenho dos classificadores para análise da identificação do motorista. ....	89
Figura 35 – Comparativo de desempenho dos conjuntos para análise da identificação do motorista. ....	90

## LISTA DE TABELAS

Tabela 1 – Exemplos de alguns identificadores padrão do protocolo CAN.....	24
Tabela 2– Comparação entre as tecnologias de sensores inerciais MPU6050 e MPU9250. ....	27
Tabela 3 – Tipo de sinal e respectivos exemplos de atributos que podem ser extraídos. ....	31
Tabela 4 – Correlação entre Ação e tipo de condução do motorista, dividido em duas classes (cautelosa ou calma e menos cautelosa ou apressada).....	43
Tabela 5 - Atributos extraídos de cada um dos sensores para a entrada dos classificadores, na fase 1. ....	67
Tabela 6 – Conjuntos de atributos selecionados para avaliação da classificação da primeira análise.....	69
Tabela 7 – Atributos extraídos de cada um dos sensores/fontes de dados para a entrada dos classificadores, na fase 2. ....	71
Tabela 8 – Conjunto de características selecionadas para avaliação da classificação na fase 2.....	72
Tabela 9 - Valores de acurácia (A) e especificidade (S) para os classificadores utilizados para identificação da identidade do motorista. ....	77
Tabela 10 - Valores de acurácia (A) e especificidade (S) para os classificadores utilizados para identificação do comportamento do motorista.....	78
Tabela 11 - Valores de acurácia e especificidade para os classificadores utilizados para identificação do comportamento do motorista.....	86
Tabela 12 - Valores de acurácia e especificidade para os classificadores utilizados para identificação do motorista.....	88
Tabela 13 - Valores de acurácia para o comportamento dos motoristas por meio do sistema de reconhecimento de motorista e de comportamento simultaneamente. ....	90

## LISTA DE SIGLAS

ABS	<i>Anti-lock Braking System</i>
ADAS	<i>Advanced driver-assistance systems</i>
CADA	Central de aquisição de dados automotivos
CAN	<i>Controller Area Network</i>
CMRR	<i>Common Mode Rejection Ratio</i>
DLC	<i>Data Length Code</i>
ECG	Eletrcardiografia
ECU	<i>Electronic Control Unit</i>
EMG	Eletrmiografia
ESC	<i>Eletronic Stability Control</i>
GPS	<i>Global Positioning System</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IMU	<i>Inertial measurement unit</i>
IP	<i>Internet Protocol</i>
IPEA	Instituto de Pesquisa Econômica Aplicada
MEMS	<i>Micro-Electro-Mechanical Systems</i>
NHTSA	<i>National Highway Traffic Safety Administration</i>
PCI	Placa de circuito impresso
SMD	<i>Surface Mounted Device</i>
SVM	<i>Support Vector Machine</i>
UM	Unidade motora

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
<b>1.1</b>	<b>Objetivos</b>	<b>18</b>
1.1.1	Objetivo Geral	18
1.1.2	Objetivos Específicos	18
<b>1.2</b>	<b>Hipóteses</b>	<b>19</b>
<b>1.3</b>	<b>Organização</b>	<b>19</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>21</b>
<b>2.1</b>	<b>Comportamento do motorista</b>	<b>21</b>
<b>2.2</b>	<b>Rede de comunicação veicular CAN</b>	<b>22</b>
<b>2.3</b>	<b>Eletromiografia de superfície</b>	<b>24</b>
<b>2.4</b>	<b>Sensores inerciais</b>	<b>26</b>
2.4.1	MPU6050	28
<b>2.5</b>	<b>Processamento dos dados</b>	<b>29</b>
<b>2.6</b>	<b>Reconhecimento de padrões</b>	<b>34</b>
2.6.1	Classificador k-Vizinhos Próximos (k-NN).	34
2.6.2	Máquinas de Vetores Suporte (SVM)	36
2.6.3	Florestas Aleatórias	37
<b>2.7</b>	<b>Análise de desempenho dos classificadores</b>	<b>38</b>
<b>3</b>	<b>METODOLOGIA</b>	<b>40</b>
<b>3.1</b>	<b>Protocolo experimental</b>	<b>42</b>
3.1.1	Trechos do protocolo experimental	42
<b>3.2</b>	<b>Materiais</b>	<b>44</b>
3.2.1	Central de Aquisição de Dados Automotivos (CADA)	44
3.2.2	Instrumentação do Condutor	48
<u>3.2.2.1</u>	<u>Circuito de Aquisição de sEMG</u>	<u>48</u>
<u>3.2.2.2</u>	<u>Posicionamento dos eletrodos de EMG no condutor (Fase 1)</u>	<u>55</u>
<u>3.2.2.3</u>	<u>Posicionamento do módulo inercial no pé do condutor (Fase 1)</u>	<u>56</u>

3.2.3	Instrumentação do veículo.....	57
3.2.3.1	<u>Instrumentação do Pedal do Freio</u> .....	57
3.2.3.2	<u>Instrumentação do Volante</u> .....	59
3.2.4	Instalação do inercial no centro de massa do veículo (para Fase 2) .....	61
3.3	<b>___ Procedimento experimental específico – Fase 1</b> .....	63
3.4	<b>___ Procedimento experimental específico – Fase 2</b> .....	69
3.5	<b>___ Exemplo dos sinais coletados</b> .....	72
3.6	<b>___ Avaliação estatística</b> .....	74
4	<b>RESULTADOS E ANÁLISES</b> .....	76
4.1	<b>Fase 1 - análise com sensores instrumentados no veículo e no condutor</b> .....	76
4.1.1	Considerações a respeito da Fase 1. ....	84
4.2	<b>___ Fase 2 - análise com sensores instrumentados apenas no veículo</b> ...	85
5	<b>CONCLUSÕES</b> .....	91
	<b>REFERÊNCIAS</b> .....	93

## 1 INTRODUÇÃO

Desde o início do século XX com o início da popularização até sua consolidação como meio de transporte nos dias atuais, o automóvel já passou por diversas transições com o advento de novas tecnologias. Quando começou a ser produzido em série, era um item que apenas pessoas de elevado poder aquisitivo eram capazes de adquirir, e atualmente já pode ser encontrado em milhões de lares brasileiros (MELO, 2008).

Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE), o estado do Paraná contava, em dezembro de 2019, com uma população de aproximadamente 11,4 milhões de habitantes (IBGE, 2020). Na mesma data, o Departamento de Trânsito do Paraná (Detran-PR) divulgou que havia mais de 7,4 milhões de veículos licenciados no estado, sendo 4,3 milhões destes composto por automóveis (DETRAN-PR, 2020). Considerando os números totais, pode-se obter a taxa de 0,65 veículo/habitante, o que demonstra a uma expressiva quantidade de veículos automotores em circulação.

Com a crescente utilização dos automóveis, também ocorre o aumento do número de acidentes envolvendo veículos automotores e, conseqüentemente, de vítimas fatais. Dados do Ministério da Economia indicam que somente no ano de 2017, aproximadamente 36 mil pessoas perderam a vida em decorrência de acidentes de trânsito, enquanto que, no mesmo período, cerca de 65 mil foram vítimas de mortes violentas, tais como homicídios e latrocínios (IPEA, 2020a). Esses números retratam como é elevada a quantia de mortes no trânsito no país.

Além de vidas perdidas, também há os custos financeiros ocasionados em virtude de acidentes de trânsito e que aumentam de acordo com a gravidade do acidente. Dados do Instituto de Pesquisas Econômicas Aplicadas (IPEA) apontam que o custo anual dos acidentes ocorridos em rodovias e áreas urbanas é de aproximadamente R\$ 50 bilhões, sendo os dois mais significativos: os custos hospitalares e a perda de produção das vítimas (IPEA, 2020b). Além dos óbitos, mais de 300 mil pessoas sofrem lesões graves em decorrência dos acidentes.

A partir dos dados apresentados, fica evidente a necessidade de reduzir a quantidade de mortes, trazendo assim mais segurança aos motoristas, passageiros e pedestres. Campanhas de conscientização e uma melhor formação dos motoristas

são fatores que podem colaborar com tal objetivo, assim como aprimorar a segurança dos veículos pode ter impacto na proteção de seus ocupantes.

Um exemplo de dispositivo que trouxe mais segurança e passou a ser obrigatório em todos os veículos novos comercializados no Brasil a partir de 2014 é o freio ABS (do inglês, *Anti-lock Braking System*), que consiste em um sistema de frenagem que impede o travamento das rodas, permitindo ao motorista manter o controle da direção do veículo. Apesar de ser recente a exigência deste dispositivo no Brasil, essa tecnologia era encontrada em modelos mais sofisticados e importados, uma vez que em outros países já era um item obrigatório, como nos EUA desde 1995.

Da mesma forma que o ABS, outra tecnologia difundida no exterior e que tornou-se item de série nos veículos brasileiros em 2014 é o *airbag*, sendo a sua inclusão um fator responsável pelo encerramento da produção de alguns modelos de automóveis devido à complexidade e custo de adaptação para atendimento à nova legislação (BRASIL, 2009; CONTRAN, 2009). Exemplo dessa evolução é a Volkswagen Kombi, que depois de décadas de produção teve sua aposentadoria cancelada pela inviabilidade de implementação das exigências de segurança (DARIUS, 2015).

Estudos realizados pela Agência norte-americana de Administração de Segurança de Tráfego Rodoviário (NHTSA - *National Highway Traffic Safety Administration*) a partir de dados de acidentes entre os anos de 2000 a 2007 apontam que o uso combinado do cinto de segurança e do *airbag* reduz o risco de ferimentos em 61% em um acidente (NHTSA, 2009a). Também conduzido pelo mesmo órgão, outro estudo aponta que a presença do freio ABS em automóveis reduz em 6% o risco de envolvimento em acidentes (NHTSA, 2009b). Estatísticas como essas demonstram a importância de aprimorar a segurança dos veículos para preservação da integridade de condutores e passageiros.

Outro dispositivo que está presente em alguns modelos de veículos que traz mais segurança aos veículos e será item obrigatório em todos os novos comercializados no Brasil a partir de 2024 é o Controle Eletrônico de Estabilidade (ESC, do inglês *Electronic Stability Control*). Esse recurso é composto por sensores e atuadores que visam a manutenção da trajetória do veículo em situações em que pode haver a perda do controle da direção, e aliado com o *airbag*, traz grande benefício aos usuários dos veículos. Estudos apontam que 40% dos acidentes que envolvem perda

de controle da direção podem ser evitados para os veículos que são dotados com ESC (HØYE, 2011).

Paralelamente, dados da NHTSA apontam que 9% dos acidentes com vítimas fatais ocorridos nos Estados Unidos em 2017 envolveram condutores que estavam distraídos de alguma forma no momento do sinistro, como por exemplo em situações de alimentação ou interação com o sistema multimídia; e provavelmente tiraram os olhos por instantes da atenção da pista e sinalizações à sua volta (NHTSA, 2019).

Dentro do escopo veicular, são diversos os sistemas existentes com foco no aumento da segurança da condução e a tendência é de crescimento em desenvolvimento e aplicação de novas funcionalidades com o contínuo desenvolvimento tecnológico (ZIEBINSKI *et al.*, 2017).

Sistemas avançados de assistência ao motorista (ADAS - *Advanced Driver-Assistance systems*) podem ser interessantes ferramentas para prevenção de acidentes. Um desses sistemas é o de detecção de faixas, o qual monitora a trajetória do veículo e percebe quando ocorre involuntariamente a passagem pela faixa de rolagem e emite alertas sonoros. Em alguns sistemas caso o condutor não atue, o veículo realiza a correção da trajetória (ZIEBINSKI *et al.*, 2017).

Sistemas de detecção da distância ao veículo em frente (CIBERLIN *et al.*, 2019) e de detecção de ponto cego (CHEN; CHEN, 2009) também são exemplos de dispositivos com a finalidade de fornecer suporte ao motorista. O primeiro detecta quando a distância entre o veículo e o veículo imediatamente a frente torna-se não segura e, conseqüentemente, alerta o condutor, podendo em alguns casos reduzir a velocidade para prevenir acidentes. O segundo, visa detectar objetos que estejam fora do campo de visão do condutor nos espelhos retrovisores e alertá-lo para evitar manobras que possam trazer risco à sua segurança.

Além da distração, outro fator que está relacionado ao modo de condução do veículo e a segurança do trânsito é o padrão do comportamento do motorista. Dados da NHTSA apontam que 78,1% dos motoristas que participaram do estudo em 2017 relataram que tiveram ao menos algum comportamento agressivo na condução veicular, nos 12 meses anteriores (AAA FOUNDATION FOR TRAFFIC SAFETY, 2016).

Neste sentido há sistemas que realizam o monitoramento do motorista por meio de sensores instalados no volante que detectam a presença das mãos, há também os que utilizam sensores inerciais (MÜHLBACHER-KARRER *et al.*, 2016;



FARINELLI, 2019), e ainda em que câmeras são empregadas para reconhecimento de expressões faciais do condutor (ALSHAQAQI *et al.*, 2013), mas além de seu elevado custo são consideradas invasivas por fazerem uso da imagem do usuário.

A análise do comportamento do motorista deve ser realizada de maneira que, ao ser integrada ao sistema de segurança embarcado no veículo, evite emitir alertas desnecessários ao condutor (MCCALL; TRIVEDI, 2007). Sistemas com maior capacidade de predição do comportamento do motorista frente à alternância de situações recorrentes durante a condução o tornam mais confiável ao motorista, devido ao fato de atuarem quando há iminência de situações de risco e somente quando a intervenção realmente se faz necessária.

A fusão de sensores pode aprimorar esta análise. Mccall e Trivedi (2007), apresentaram um sistema para avaliar o quão crítica está a situação e a intenção do motorista em intervir, o qual baseava-se nos dados fornecidos pela rede veicular CAN (*Controller Area Network*), juntamente com dados de um sensor de posição acoplado ao acelerador e câmeras para monitorar a face do condutor e a via.

O uso de câmeras e microfones também pode ser empregado no monitoramento do nível de atenção do motorista quando submetido a atividades que exigem a atuação do condutor, tais como operar o rádio, olhar para o GPS (*Global Positioning System*), falar ao celular, entre outros. Os dados da rede CAN também são associados para análise e classificadores são empregados para identificar os trechos de direção normal e os em que há a realização de atividades secundárias durante o percurso (LI; JAIN; BUSSO, 2013).

Ainda com a utilização de câmeras, ela pode ser empregada no monitoramento do movimento do pé do motorista por meio da análise de vídeo, possuindo a vantagem de portar um maior detalhamento nas informações coletadas quando comparadas a sensores instalados diretamente no pedal (TRAN; DOSHI; TRIVEDI, 2012), proporcionando um menor intervalo de tempo para predição da pisada no pedal.

Há também a utilização de *smartphones* que possuem embarcados sensores como acelerômetros e giroscópios para detectar o comportamento agressivo na direção, estando o aparelho no interior do veículo. Visando a utilização em sistemas de direção segura, algoritmos são capazes de detectar o ângulo de guinada enquanto o motorista dirige e conseguem distinguir quando há direção perigosa com precisão superior a 90% (FU LI *et al.*, 2016).

*Smartphones* associados a algoritmos de aprendizagem de máquina neles embarcados também são utilizados para analisar trechos de direção dotados de realização de curvas, frenagens e acelerações bruscas, e mudanças repentinas de faixa na via (FERREIRA *et al.*, 2017), em que os algoritmos buscam definir os sensores e atributos de maior peso para obtenção dos resultados.

O monitoramento do comportamento de motoristas pode ser realizado por meio do cruzamento das informações geográficas com a ocorrência de aceleração e frenagem mais severas na condução do veículo, também com a coleta de dados dos sensores embarcados em *smartphones* (PETRAKI; ZIAKOPOULOS; YANNIS, 2020). Verificou-se que a velocidade média e o fluxo de tráfego têm impacto mais significativo na frequência destes eventos que os aspectos construtivos da via.

Além dos dados obtidos do veículo e de smartphones, há a possibilidade de instalação de sensores para aquisição de dados acerca do condutor, como dados de eletrocardiografia (ECG) (RODRIGUES *et al.*, 2010). Outros parâmetros como atividade eletrodérmica e eletroencefalografia podem ser utilizados para avaliar níveis de cansaço e estresse do motorista (REBOLLEDO-MENDEZ *et al.*, 2014), e esses dados serem utilizados por sistemas de auxílio, inclusive com comunicação a serviços de emergência em casos extremos.

Também podem ser empregadas unidades de medição inerciais (IMU, do inglês, *Inertial Measurement Unit*) instalados em pontos específicos, como nos braços, costas e cintura do condutor para avaliar seus movimentos, incluindo as variações de ângulos nos braços (LIU; WANG; QIU, 2020). A análise com o auxílio de algoritmos de aprendizagem de máquina (como *deep learning*), durante a direção em diferentes tipos de curvas, resultou em taxas de reconhecimento acima de 99% para ambos os casos (LIU; WANG; QIU, 2020).

Em termos de interação com o veículo, ressalta-se que apenas o pedal do acelerador é alvo de monitoramento constante e tem os dados disponibilizados no barramento, sendo que os pedais de embreagem e de freio não têm sido tratados na literatura como informação contínua habitualmente monitorada em veículos de passeio e, quando aparece, não é uma informação padronizada (KIM; BAEK, 2018). Assim, embora estejam disponíveis na CAN informações de velocidade e RPM do motor, da posição do pedal do acelerador, tenha-se os dados de frenagem das rodas (ABS) e de pressão de óleo de freio, não há monitoramento da posição deste pedal em função da ação do motorista. Ainda tem-se a dificuldade na obtenção de

determinados dados na CAN, do volante por exemplo, devido à codificação das informações presentes no barramento.

Dessa forma, o desenvolvimento de tecnologias que utilizem informações já disponíveis no veículo, bem como a inserção de novos equipamentos que visem aprimorar a análise do comportamento na condução do veículo, pode fornecer dados úteis a sistemas de auxílio ao condutor, trazendo maior segurança ao usuário.

Neste trabalho buscou-se identificar um conjunto de dados que permitisse classificar o perfil de direção do motorista, a partir de informações existentes no barramento CAN do veículo inerentes de sensores nativos, e da inserção de outros sensores instrumentados no veículo e no condutor. Em segundo plano, foi verificada a viabilidade de identificar o motorista a partir dos dados coletados. Os dados foram processados de forma off-line utilizando o *software* Matlab<sup>®</sup>.

## 1.1 Objetivos

O presente trabalho tem como objetivos os apresentados nas seções a seguir.

### 1.1.1 Objetivo Geral

Adaptar um sistema de aquisição de dados da CAN com instrumentação adicional do veículo e do condutor, para posterior análise de comportamento do motorista com auxílio de reconhecimento de padrões.

### 1.1.2 Objetivos Específicos

- Adaptar um sistema de aquisição de dados do automóvel obtidos através da CAN, com a inserção de instrumentação adicional;
- Desenvolver circuitos para aquisição de dados de posição do pedal de freio do veículo, da posição do pé do condutor (por meio de sensores inerciais), de sinais de eletromiografia de superfície (da perna do condutor) e da posição do volante;
- Desenvolver um protocolo experimental que permita uma análise preliminar de comportamento de condução;

- Coletar uma base de dados para análise de perfil de condução dos motoristas;
- Desenvolver estratégias de processamento de sinais e de reconhecimento de padrões para análise dos dados coletados;
- Utilizar os dados obtidos através da instrumentação do condutor para validar os dados obtidos do automóvel utilizados para classificar o perfil do motorista;
- Avaliar se com os dados obtidos é possível identificar tanto o motorista quanto o seu perfil de condução e quais sensores ou grupos de sensores auxiliam nesse processo.

## 1.2 Hipóteses

Este trabalho apresenta as seguintes hipóteses de pesquisa:

- É possível definir um conjunto de dados provenientes da CAN, dos sensores já monitorados e, através de algoritmos de aprendizagem de máquina, identificar o perfil de comportamento do motorista?
- A inserção de novos sensores ao veículo, em especial ao pedal de freio, pode melhorar os resultados desta classificação?
- Além de classificar comportamento em um conjunto de motoristas, seria possível identificar o motorista através de suas características em seu modo de direção?

## 1.3 Organização

Esta dissertação, após a apresentação da introdução, objetivos e hipótese está organizada em outros 4 capítulos, sendo que:

No Capítulo 2 são apresentados os principais conceitos a respeito do comportamento do motorista, além de conceitos de fundamentação envolvendo a aquisição de sinais provenientes da rede CAN e dos demais sensores (como inercial e de eletromiografia de superfície).

No Capítulo 3 são apresentados os materiais e métodos utilizados nesta pesquisa, detalhando a metodologia experimental em duas fases;

No Capítulo 4 são apresentados os resultados obtidos, realizando análises instrumentando o veículo e o motorista e posteriormente somente o motorista, conforme parâmetros descritos previamente na metodologia

Por último, no capítulo 5 são apresentadas as conclusões e considerações finais acerca desse trabalho.

## 2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão apresentadas as tecnologias utilizadas e a fundamentação necessária para embasar o desenvolvimento deste trabalho.

### 2.1 Comportamento do motorista

Dirigir um veículo depende basicamente de vários parâmetros em um sistema de malha fechada composto por motorista-veículo e pista. Naturalmente, as características e condições de uma via resultam em decisões instantâneas que o motorista precisa tomar, seja para mudar seu trajeto, seja para desviar um obstáculo, seja para desviar um congestionamento, ou mesmo inserir-se nele, ou ainda mudando sua velocidade para reduzir o tempo gasto. Da mesma forma, diversas características de faixa etária, experiência e emocionais do condutor também afetam suas decisões na direção. Desta forma, um motorista menos experiente pode ter uma resposta ao volante diferente de outro, quando exposto a uma situação de desconforto ou de pressão emocional (KUGE *et al.*, 2000). Para um mesmo motorista, o comportamento de dirigir pode mudar de situação para situação (ANGKITITRAKUL *et al.*, 2009), consoante o momento, o ambiente e seu próprio subconsciente.

Assim, pode-se dizer que, de alguma forma, todo motorista tem características próprias de direção (comportamentos distintos), ou seja, cada motorista tem sua característica de direção única (também conhecida como estilo de direção).

Alguns trabalhos relacionam movimentos da cabeça (SATHYANARAYANA *et al.*, 2008) e características faciais, como o movimento dos olhos (LI; JAIN; BUSSO, 2013), com a possibilidade de identificar o estado de condução do motorista em situações de fadiga, sonolência e/ou distração ao dirigir. Para este caso, o uso de sensores de visão (câmeras internas) pode ser necessário para buscar a detecção de um comportamento de condução anormal.

Diversos autores discutem a classificação do comportamento dos motoristas, consoantes características mais marcantes. Entre eles, Lu *et al.* (2009) propõem que os comportamentos de direção podem ser divididos em quatro categorias no que diz respeito às condições de limite de manuseio (condições além dos limites de aderência do pneu): cauteloso, médio, experiente e imprudente. Os autores propuseram um

parâmetro para avaliar o quanto a direção está próxima do limite de controle, em função do uso frequente ou não de acelerações e freadas abruptas e ações mais lentas ou rápidas. Já, um motorista é considerado imprudente se comportar-se de maneira descuidada e imprevisível durante o trajeto.

Por outro lado, Filev *et al.* (2011) propõem uma classificação em cauteloso, normal e agressivo, utilizando avaliações temporárias baseadas nos transientes das ações durante a direção.

Já, Raz *et al.* (2008) apresentam um sistema para analisar e avaliar o desempenho e a atitude de um motorista de veículo motorizado, baseado na avaliação das manobras, incluindo seguimento estável, aceleração, aproximação, frenagem e abertura, considerando a execução das manobras distribuídas em dois grupos: manobra executada com segurança e manobra executada perigosamente.

Considerando que a classificação de manobras utiliza inúmeras variáveis, tanto do veículo, quanto da pista, quanto do próprio motorista, isto induz a condições difíceis de caracterização e classificação, tornando algumas vezes a compreensão subjetiva.

Baseado nisso, compreende-se que o comportamento dos motoristas pode ser dividido mais claramente em duas classes: “normal / calma / cautelosa / ponderada” e “rápida / apressada / menos cautelosa / agressiva”. A grande diferença entre estas duas classes pode ser resumida nas ações mais ou menos abruptas realizadas pelos motoristas. Uma vez que o comportamento possa ser classificado, sistemas com esta capacidade podem prover auxílio à Sistemas Inteligentes de Aconselhamento ao Motorista (OBUHUMA; OKOYO; MCOYOWO, 2018; KHAN; LEE, 2019).

## **2.2 Rede de comunicação veicular CAN**

O protocolo CAN (do inglês *controller-area-network*) teve seu desenvolvimento iniciado na década de 80 e, com o passar dos anos, consolidou-se como padrão na comunicação entre os sistemas dos veículos. As Unidades de Controle Eletrônicas (ECU - do inglês *Electronic Control Unit*) são os dispositivos que realizam a aquisição dos dados provenientes dos diversos sensores existentes no veículo, e comunicam-se entre si por meio de um barramento composto por um par

trançado de condutores (LEEN; HEFFERNAN; DUNNE, 1999), o que o torna menos suscetível a interferências eletromagnéticas.

É padronizada a partir das ISO 11519 e ISO 11898, e por se tratar de uma topologia em barramento, permite que sejam inseridos novos dispositivos sem a necessidade de interromper o tráfego de dados da rede para tal. Ainda, por se tratar de barramento, a mesma informação proveniente de um sensor pode ser utilizada por mais de um sistema, proporcionando economia e simplificação.

Os condutores são denominados *CAN High* e *CAN Low* e são conectados por um terminador, um resistor de 120  $\Omega$ , para o correto funcionamento (RICHARDS, 2002). O primeiro condutor, *CAN High*, sempre possui tensão maior que 2,5 V; enquanto o *CAN Low* está sempre abaixo desse nível de tensão, e quando a diferença de tensão entre eles é próxima a zero tem-se um *bit* recessivo (1), senão tem-se um *bit* dominante (0).

A comunicação entre as partes envolvidas na rede se dá por meio de mensagens ou *frames* e é normatizada pela ISO 11898. Cada mensagem sempre possui um Identificador (ou ID - do inglês *Identifier*), que define o nível de prioridade da informação dentro do barramento, sendo o menor ID prioritário em relação ao maior, logo a transmissão de mensagens de menor prioridade só ocorre após a transmissão de um de maior prioridade.

A estrutura de uma mensagem CAN contém, além do ID já mencionado, outros dois itens. Um deles é chamado DLC (do inglês *Data Length Code*), que define a quantidade de *bytes* que aquela mensagem possui, e o outro é o espaço para Dados, que armazenam a informação específica da ECU que enviou a mensagem.

Cada informação que trafega na CAN é identificada por um *Parameter ID*, tais como rotações por minuto (RPM), velocidade, posição do acelerador, entre outros. Dentre as ECUs que compõem a rede há o mestre, que é responsável pelo controle e gerenciamento das informações presentes no barramento, como no controle dos níveis de prioridade, por exemplo (FARINELLI, 2019).

Alguns destes parâmetros são comuns aos diferentes fabricantes, mas nem todos, assim como alguns retornam valores codificados, necessitando de equipamentos específicos para sua leitura e interpretação.

Para a maioria dos parâmetros básicos, é possível conectar um dispositivo na rede CAN (por meio do conector OBD-2) e, conhecendo os identificadores de cada



parâmetro, questionar o barramento sobre esta informação para poder capturá-la da CAN.

A frequência máxima de aquisição de sinais da CAN depende basicamente da frequência do *software* de aquisição, em função da prioridade. Para sinais de menor prioridade, o tempo de monitoramento é de 200 ms (5 Hz), enquanto que sinais de maior prioridade (segurança) são monitorados habitualmente em intervalos de 1 ms (1000 Hz) (DE FABRITIIS; RAGONA; VALENTI, 2008).

Na tabela 1, a título de ilustração, apresentam-se os identificadores de algumas variáveis padronizadas no protocolo CAN (SONG; KIM, 2021).

**Tabela 1 – Exemplos de alguns identificadores padrão do protocolo CAN.**

Identificador	Descrição
0x0C	Rotação do motor (RPM)
0x0D	Velocidade do veículo
0x49	Posição do acelerador

Fonte: SONG; KIM (2021).

### 2.3 Eletromiografia de superfície

De acordo com De Luca (2006) e Kamen e Gabriel (2015), a Eletromiografia (EMG) pode ser definida como uma técnica de aquisição, processamento, estudo e uso do sinal elétrico das contrações musculares (DE LUCA, C., 2006; KAMEN; GABRIEL, 2015). A seguir, serão apresentados os aspectos da origem do sinal e os conceitos básicos da instrumentação e processamento deste biossinal.

O sinal de EMG é um biopotencial, com natureza bioelétrica (COHEN, 2000), originário das excitações voluntárias das unidades motoras (UMs). Uma UM é o conjunto de fibras musculares inervadas em um neurônio motor (motoneurônio- $\alpha$ ). O neurônio motor conduz o impulso nervoso até as fibras musculares esqueléticas e seu funcionamento está relacionado com os Potenciais de Ação (PAs).

Além de baixas amplitudes, o sinal de EMG de superfície (sEMG) possui forte tendência estocástica (mesmas entradas, saídas diferentes) e aparência ruidosa (NAJARIAN; SPLINTER, 2012), sendo necessário certos recursos para atenuar as referências e aumentar a qualidade do sinal. O sinal possui amplitudes que podem chegar até 10 mV (estando entre 50  $\mu$ V até 5 mV), com frequências iniciando entre 10

e 20 Hz, chegando até 500 Hz, com energia dominante entre 50 e 150 Hz (MERLETTI, ROBERTO; FARINA, 2016).

A instrumentação e a captação do sinal de sEMG inicia nos eletrodos fixados/posicionados na superfície da pele. Os eletrodos geralmente são feitos de materiais como prata ou cloreto de prata, aço inoxidável, ouro e são responsáveis por detectar os biopotenciais elétricos gerados pelos nervos e pelos músculos (MERLETTI, ROBERTO; FARINA, 2016; PEASE, 2008). Os eletrodos para a captação do sinal de EMG podem ser tanto invasivos quanto não-invasivos, sendo que a sEMG apenas estuda os sinais não-invasivos. Os eletrodos não invasivos podem ser secos ou possuírem um gel condutor, sendo que este estabelece uma ponte eletrolítica entre a superfície da pele com o eletrodo. Os eletrodos são conectados a conectores e cabos, responsáveis por levar o sinal até os circuitos de condicionamento (PEASE, 2008).

Para a aquisição dos sinais nos amplificadores, geralmente o modo bipolar de aquisição é utilizado. Nesse modo, são inseridos dois eletrodos na região do músculo em que se deseja medir e os sinais são captados, sendo extraída a diferença entre estes dois eletrodos. Este sinal, então, é amplificado contendo uma referência (ou terra) onde um eletrodo chamado de eletrodo de referência é colocado em uma região do corpo que seja neutra em relação ao músculo de interesse de obtenção do sinal de sEMG (KAMEN; GABRIEL, 2015; PEASE, 2008).

O estágio subsequente são os amplificadores diferenciais, em que os sinais dos eletrodos bipolares são amplificados em conjunto. Esses amplificadores possuem ganhos elevados devido às baixas amplitudes dos sinais de sEMG. Entre os amplificadores mais utilizados estão os amplificadores de instrumentação, os quais possuem elevado ganho de malha aberta, alta razão de rejeição em modo comum (CMRR, do inglês *Common Mode Rejection Ratio*) e alta impedância de entrada. A CMRR é necessária para atenuar ruídos que estejam presentes nos dois eletrodos (principalmente o ruído da rede elétrica de distribuição, 60 Hz) e a alta impedância de entrada garante que as interferências da pele e as distorções do sinal de sEMG sejam atenuadas (CARR; BROWN, 2001; PEASE, 2008).

O próximo passo é a filtragem do sinal, que geralmente é feita utilizando um filtro passa-banda, podendo ser tanto em *hardware* ou em algoritmos de *software* (PEASE, 2008). A banda de interesse dos sinais de sEMG está entre os valores de 10 Hz e 500 Hz (DE LUCA, C., 2006). Entre os ruídos que podem contaminar o sinal

estão os artefatos de movimento (em baixas frequências) e as interferências de sistemas de comunicação (como celulares e computadores) e de alimentação (como fontes). Após o sinal ser filtrado, é necessário que seja digitalizado e amostrado por um conversor analógico-digital.

Uma taxa amostragem apropriada permite que a distorção conhecida como *aliasing* possa ser atenuada e essa pode ser resolvida, segundo a teoria de amostragem, com a utilização de uma frequência de amostragem no mínimo duas vezes maior que a maior frequência do sinal. Como as maiores frequências do sinal de sEMG se encontram até 500 Hz (HAKONEN; PIITULAINEN; VISALA, 2015), o sinal pode ser amostrado com frequências partindo de 1000 amostras por segundo. A utilização de filtros se faz necessária para que ocorra a delimitação da banda, eliminando componentes maiores que as de interesse, além de sua função *anti-aliasing*.

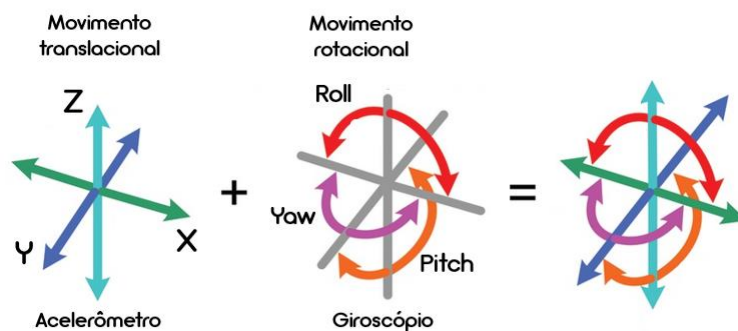
## 2.4 Sensores inerciais

Uma das formas de monitoramento de movimentação é realizada por meio da utilização dos sensores inerciais, os quais são baseados em acelerômetros e giroscópios.

O acelerômetro mede a aceleração translacional resultado da movimentação de uma massa, os quais normalmente são construídos baseados na tecnologia MEMS (*Micro-Electro Mechanical System*). Já o giroscópio mede a orientação angular e a variação causada pela movimentação do espaço inercial. Ambos se utilizam de sistemas de massa suspensa por mola, em que ocorre a movimentação da massa em relação à ações externas, gerando variações de capacitâncias monitoradas (LYNCH; MARCHUK; ELWIN, 2015).

Desta forma, os dispositivos compostos de giroscópios e acelerômetros possuem 6 graus de liberdade, permitindo que sejam monitorados/identificados movimentos rotacionais e translacionais, conforme ilustrado na Figura 1.

**Figura 1 – Graus de liberdade em um sistema tri-axial.**



Fonte: Adaptado de FUE *et al.* (2020).

Dentre as diversas tecnologias de sensores inerciais disponíveis no mercado, as mais comumente utilizadas são os dispositivos MPU6050 e o MPU9250, com suas características principais apresentadas na Tabela 2. Entre estes dois, em função do custo e maior facilidade de acesso, o MPU6050 será apresentado com maior detalhamento.

**Tabela 2– Comparação entre as tecnologias de sensores inerciais MPU6050 e MPU9250.**

	Eixos	Faixa de operação acelerômetro (g) <sup>1</sup>	Sensibilidade acelerômetro (LSB/g) <sup>2</sup>	Faixa de operação Giroscópio (dps) <sup>3</sup>	Sensibilidade giroscópio (LSB/dps)	Faixa de frequência (Hz)	Sensibilidade (%)	Densidade de ruído ( $\mu\text{g}/\sqrt{\text{Hz}}$ )	Resolução (bits)
MPU6050	6	±2 ±4 ±8 ±16	16.384 8.192 4.096 2.048	±250 ±500 ±1.000 ±2.000	131 65,5 32,8 16,4	500	±2	400	16
MPU9250	6	±2 ±4 ±8 ±16	16.384 8.192 4.096 2.048	±250 ±500 ±1.000 ±2.000	131 65,5 32,8 16,4	500	±2	300	16

Fonte: INVENSENSE (2016).

<sup>1</sup> g = Força gravitacional

<sup>2</sup> LSB = *Least Significant Bit per g* (Bit menos significante por g)

<sup>3</sup> dps = *Degrees per second* (Graus por segundo)


### 2.4.1 – MPU6050

O MPU6050 é um dispositivo com um microcontrolador dedicado pra monitorar um giroscópio tri-axial, um acelerômetro tri-axial, e um sensor de temperatura (-40 °C a +85 °C), com capacidade de digitalização dos 7 dados em 16 *bits* (ou seja, os valores lidos estarão sempre na faixa de -32768 e +32767), permitindo ajustar a faixa de operação para uma maior precisão para análise de movimentos rápidos ou lentos. A comunicação serial é feita por um barramento em padrão I<sup>2</sup>C dedicado com frequência de 400 kHz (INVENSENSE, 2016c).

É vendido em um módulo para prototipagem rápida que permite que projetos sejam desenvolvidos com maior velocidade e segurança. Um dos módulos comerciais é apresentado na Figura 2, o qual contém 8 pinos de interface, sendo eles:

- VCC – Pino de alimentação;
- GND – Pino de terra;
- SCL – Pino *Serial Clock*. Conecta-se ao pino SCL do microcontrolador;
- SDA – Pino *Serial Data*. Conecta-se ao pino SDA do microcontrolador;
- XDA – Pino auxiliar de *Serial Data*. Pino utilizado conectar outra interface I<sup>2</sup>C habilitando o pino SDA ao MPU6050;
- XCL – Pino auxiliar de *Serial Clock*. Pino utilizado conectar outra interface I<sup>2</sup>C habilitando o pino SCL ao MPU6050;
- AD0 – Pino do *bit* menos significativo do endereço do I<sup>2</sup>C; e
- INT – Pino de saída de interrupção digital.

**Figura 2– Módulo inercial – 6050.**



**Fonte: Autoria própria (2021).**

Para utilizar o dispositivo, o pino AD0 desconectado define que o endereço I<sup>2</sup>C do sensor é 0x68. Se uma tensão de 3,3V por conectada ao pino AD0, o endereço I<sup>2</sup>C do sensor é 0x69.

do dispositivo será alterado para 0x69, Tal possibilidade permite que dois módulos MPU6050 possam ser utilizados em um mesmo circuito.

As bibliotecas utilizam a escala padrão da aceleração é de +/- 2g, sendo que g é a força g (equivale a aproximadamente 9,8 m/s<sup>2</sup>). Para a rotação, a escala padrão é de +/- 250 graus/segundo. Portanto, o valor de +32767 para a aceleração, representa 2g e -32768 representa -2g. Os valores intermediários são lineares. Isto é, a metade de +32767 representa 1g. Para aplicações específicas, os parâmetros podem ser alterados ajustando os registradores de configuração do MPU6050.

Os valores da aceleração no eixo em g são dados pela Equação 1, e os valores da velocidade angular no eixo em graus por segundo, são dados pela Equação 2,

$$Aceleração = \frac{Dado\ acelerômetro}{SSF\ Acelerômetro} \quad (1)$$

$$Velocidade\ angular = \frac{Dado\ giroscópio}{SSF\ Giroscópio} \quad (2)$$

em que SSF é a Sensibilidade do Fator de Escala, tanto para o acelerômetro quanto para o giroscópio.

## 2.5 Processamento dos dados

Após a formação da base de dados, as informações adquiridas precisam passar por etapa de pré-processamento para serem submetidos aos classificadores.

A primeira etapa é a segmentação do sinal para que delimitações temporais (janelas) possam ser processadas. As amostras destas janelas passam por etapas de normalização e depois manipulação matemática para a extração de atributos (ou *features*, ou características) para só depois serem submetidas aos algoritmos de classificação. A seguir, tais processos são detalhados:

### a) Segmentação

A segmentação é a primeira etapa do pré-processamento do sinal, na qual, o sinal bruto é dividido em pequenos segmentos em função do tempo, de forma a delimitar a informação a ser matematicamente trabalhada. Existem diversas técnicas de segmentação de sinais. Entre as mais usais, citam-se dois métodos:

- i) a comparação do sinal por meio um valor de limiar (*threshold*) e através dele, detectar os picos ou vales do sinal e segmentá-lo (SHI; SHI; WANG, 2012); e
- ii) detectar a alteração do sinal e segmentá-lo em determinado período de tempo.

Para segmentação do sEMG, o limiar pode ser definido a partir da média da linha base e seu desvio padrão (SOLNIK *et al.*, 2010). Como dois limiares são aplicados para definir um segmento (amplitude e período mínimos), esse método é chamado de Segmentação por Limiar Duplo (DTOS).

Um dos parâmetros a serem ajustados consoante a aplicação é o tamanho temporal desta janela obtida. Janelas muito pequenas equivalem a um conjunto de dados muito grande, enquanto janelas muito grandes podem promover que características sejam mascaradas e assim limitar as condições de separabilidade dos classificadores.

#### b) Normalização

A normalização evita que valores que estão com altas amplitudes na distribuição dos atributos de entrada possam exercer grande influência durante a etapa de treinamento de um classificador, beneficiando uma certa classe em detrimento de outra. Uma das formas de normalização é padronizar o *range* das amostras entre o intervalo fechado de 0 a 1, que transforma o valor da amostra  $x$  para  $x_N$ , como apresentado na Equação 3.

$$x_N = \frac{x - \min(X)}{\max(X) - \min(X)} \quad (3)$$

em que:  $\min(X)$  é menor valor de todas as amostras do atributo ( $X$ ); e  $\max(X)$  é maior valor de todas as amostras do atributo ( $X$ ).

#### c) Atributos ou características (*features*) de um sinal

Muitos sinais estocásticos como sinais de sEMG ou sinais de sensores inerciais possuem uma natureza de difícil interpretação visual. Após a segmentação do sinal, aplicam-se operações matemáticas, com fins a reduzir a quantidade de dados para os classificadores e de modo que estes possuam métricas capazes de permitir a análise do comportamento do sinal (ANWARY; YU; VASSALLO, 2018). Este

processo denomina-se de extração de características, de atributos, ou, do termo em inglês, de *features*.

Além de evidenciar características intrínsecas do sinal, esse processo também auxilia na remoção de ruídos e informações indesejáveis para aumentar a eficácia dos sistemas de classificação (CHOWDHURY *et al.*, 2013; MENDES JUNIOR *et al.*, 2020; NAZMI *et al.*, 2016).

Para cada tipo de sinal, dezenas de atributos podem ser extraídos consoante à natureza e as características que o geraram. Considerando as ações/eventos existentes no escopo deste estudo, pode-se exemplificar como atributos:

**Tabela 3 – Tipo de sinal e respectivos exemplos de atributos que podem ser extraídos.**

Tipo do sinal/origem do dado	Alguns atributos correlacionados ao sinal
sEMG	<ul style="list-style-type: none"> <li>- Valor Médio Absoluto (MAV);</li> <li>- Diferença absoluta do valor de desvio padrão (DASDV);</li> <li>- Média quadrática (RMS);</li> <li>- Variância;</li> <li>- Raiz média quadrada (RMS).</li> </ul>
Sensores Inerciais	<ul style="list-style-type: none"> <li>- Diferença absoluta do valor de desvio padrão (DASDV);</li> <li>- Máximo e Mínimo;</li> <li>- Moda;</li> <li>- Valor Médio Absoluto (MAV);</li> <li>- Média quadrática (RMS);</li> <li>- Integral quadrada simples (SSI);</li> <li>- Comprimento de onda (WL).</li> </ul>
Velocidade, rotação, posição	<ul style="list-style-type: none"> <li>- Média;</li> <li>- Mediana;</li> <li>- Desvio padrão;</li> <li>- Cruzamento pelo zero.</li> </ul>
Movimento de volante, Movimento de pedais (velocidade / aceleração)	<ul style="list-style-type: none"> <li>- Média;</li> <li>- Mediana;</li> <li>- Desvio padrão;</li> <li>- Derivada.</li> </ul>

**Fonte: PHINYOMARK; PHUKPATTARANONT; LIMSAKUL (2012); HUDGINS; PARKER; SCOTT (1993).**

A escolha dos atributos de entrada pode ser feita por conhecimento empírico de sua utilização e seu desempenho quanto por métodos estatísticos, como análise de correlação, ou por algoritmos de busca e de seleção de atributos.

Dentre as dezenas de características possíveis, algumas serão detalhadas abaixo:



- a) Valor Médio Absoluto (do inglês, *Mean Absolute Value* – MAV): está relacionado ao disparo do sinal e é calculado por meio Equação 4 (HUDGINS; PARKER; SCOTT, 1993),

$$MAV = \frac{1}{N} \sum_{i=1}^N |A_i| \quad (4)$$

em que  $A_i$  refere-se a cada  $i$  dos  $N$  elementos do conjunto de dados.

- b) Raiz Quadrada Média (do inglês, *Root Mean Square* – RMS): é uma característica relacionada com a força, contração muscular e a potência do sinal. Ela é obtida por meio da Equação 5 (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012),

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N A_i^2} \quad (5)$$

em que  $A_i$  refere-se a cada  $i$  dos  $N$  elementos do conjunto de dados.

- c) Moda: apresenta como resultado o valor com maior ocorrência em um conjunto de dados (esse atributo é interessante para uma distribuição com muitos valores repetidos).
- d) Média Aritmética ( $\bar{x}$ ): é a soma de todos os dados de uma distribuição dividido pelo número de elementos desta, conforme Equação 6,

$$Média = \bar{x} = \frac{1}{N} \sum_{i=1}^N A_i \quad (6)$$

em que  $A_i$  refere-se a cada  $i$  dos  $N$  elementos do conjunto de dados.

- e) Mediana: é o ponto central de uma distribuição. Desta forma metade das observações são menores e metade das observações são maiores que a mediana. Para fazer o cálculo, deve-se primeiro ordenar as observações do menor valor para o maior valor. Se o número de observações for um número ímpar a mediana é a

observação (valor) central dessa lista ordenada. Se a distribuição for par, o cálculo da mediana, é obtido por  $(n + 1)/2$ , em que  $n$  é o número de observações.

- f) Máximo: é o valor máximo dentro de uma distribuição de dados, ou seja, o maior valor encontrado.
- g) Mínimo: é o valor mínimo dentro de uma distribuição de dados, ou seja, o menor valor encontrado.
- h) Amplitude (delta): é a diferença (*range*) entre o valor máximo e o valor mínimo de uma distribuição de dados.
- i) Integral: é o somatório da área de todos os sinais amostrados em um determinado intervalo no tempo. Como os dados são discretos, a integral equivale ao somatório de todos os pontos obtidos em um intervalo de tempo.
- j) Inclinação: pode ser obtida a partir de uma equação de primeiro grau, tal qual a equação da reta, e tem por resultado um coeficiente angular que corresponde à inclinação da reta.
- k) Entropia amostral: representa a irregularidade ou desordem de um sistema. Estatisticamente, representa o grau de incerteza presente em um sistema, dado por uma distribuição de probabilidades de eventos. Quanto maior o nível de incerteza e maior o valor da entropia. A entropia amostral (SamEn) também afere as similaridades de trechos de uma série temporal, atribuindo valores mais altos à maior irregularidade dos dados (LAKE *et al.*, 2002).
- l) Variância: O cálculo da variância ( $\sigma^2$ ) é obtido através da soma dos quadrados da diferença entre cada valor e a média aritmética, dividida pela quantidade de elementos observados em um conjunto de dados, conforme equação 7,

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (A_i - \bar{x})^2 \quad (7)$$

em que,  $A_i$  refere-se a cada  $i$  dos  $N$  elementos do conjunto de dados, e  $\bar{x}$  é a média aritmética do conjunto de  $N$  dados.

m) Desvio padrão: é uma medida que expressa o grau de dispersão de um conjunto de dados. Ou seja, o desvio padrão ( $\sigma$ ) indica o quanto um conjunto de dados é uniforme. Quanto mais próximo de 0 for o desvio padrão, mais homogêneo são os dados. É calculado através da raiz quadrada da variância.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (A_i - \bar{x})^2} \quad (8)$$

## 2.6 Reconhecimento de padrões

Os classificadores escolhidos foram os K-Vizinhos Próximos (k-NN), as Máquinas de Vetores Suporte (SVM) e as Árvores de Decisão (em modelos *ensembles* de Florestas Aleatórias). Estes três modelos de classificadores foram escolhidos por serem utilizados em trabalhos similares (AHMAD *et al.*, 2020; HALLAC *et al.*, 2017; HUANG; LUO; PENG, 2020).

A escolha dos classificadores também se baseou na disponibilidade dos classificadores no pacote específico (*classification tools*) do Matlab®.

### 2.6.1 Classificador k-Vizinhos Próximos (k-NN).

O método de classificação por k-Vizinhos Próximos é um dos métodos mais simples de classificação, já que não existem modelos a serem ajustados e depende da quantidade de dados em seu treinamento. Este classificador atua com base na proximidade de uma amostra com as outras amostras e é do tipo supervisionado,

sendo necessário já conhecer previamente os rótulos dos dados (conhecidos como *labels*) (GÉRON, 2019).

Nesse classificador, cada amostra apresentada ao algoritmo tem a sua distância calculada em relação para cada uma das amostras do conjunto separado durante o treinamento. Ao final, o conjunto das  $k$  amostras mais próximas, ou seja, aquelas que possuíram menor distância, são organizadas de forma crescente e a classe mais predominante é atribuída para essa nova instância de treinamento (BRUCE; BRUCE, 2019).

A escolha da quantidade de vizinhos é um dos parâmetros mais importantes desse tipo de classificador. Se a quantidade de vizinhos for muito baixa, pode-se estar sobreajustando o modelo, o qual pode incluir certa quantidade de ruído aos dados. Se o valor de  $k$  for muito elevado, os sinais podem ser muito suavizados e fazer com o classificador possa perder a visão mais localizada dos dados.

A segunda característica desse modelo é a métrica de distância, também chamada de similaridade (BRUCE; BRUCE, 2019). Geralmente, a métrica de distância mais utilizada, principalmente pelas suas vantagens de ser implementada com baixo custo computacional, é a distância Euclidiana ( $dist_{EUCL}$ ), a qual pode ser exemplificada para  $x$  e  $u$ , expressa como:

$$dist_{EUCL} = \sqrt{(x_1 - u_1)^2 + (x_2 - u_2)^2 + \dots + (x_p - u_p)^2} \quad (9)$$

em que:

$x_1, x_2, \dots, x_p$  são as posições de  $x$ ,

$u_1, u_2, \dots, u_3$  são as posições de  $u$  e,

1, 2 e 3 são as dimensões das variáveis.

É necessário que as amostras e os atributos estejam normalizados ou padronizadas, visto que o valor das amostras pode apresentar grande influência no processo do cálculo da distância (BRUCE; BRUCE, 2019).

Se a quantidade das amostras de treinamento for muito alta, o classificador pode ter um desempenho lento e ocupar muito espaço na memória já que se deve calcular as distâncias para todas as amostras.

Em termos de ferramentas disponíveis, como as encontradas no pacote (*classification tools*) do Matlab<sup>®</sup>, existem diferentes opções de *k*-NN, baseadas na quantidade de vizinhos, configuradas como: *fine k-NN*; *medium k-NN* e *coarse k-NN*.

- *Fine k-NN*: refere-se a um classificador de vizinho mais próximo que faz distinções finamente detalhadas entre classes com o número de vizinhos definido como “1”;
- *Medium k-NN*: refere-se a um classificador de vizinho mais próximo com menos distinções do que um *fine k-NN* com o número de vizinhos definido como 10;
- *Coarse k-NN*: refere-se a um classificador de vizinho mais próximo entre as classes, com o número de vizinhos definido como 100.

### 2.6.2 Máquinas de Vetores Suporte (SVM)

Os classificadores do tipo SVM são adequados para classificações de dados complexos e altamente explorados devido a sua solidez estatística. As SVMs buscam uma fronteira de separação de tal forma que o seu hiperplano ótimo possa separar duas classes contendo a maior distância entre as fronteiras de separação (por meio de um hiperplano ótimo) (GÉRON, 2019). Essa busca pelo hiperplano ótimo oferece menor chance de o sistema estar sobreajustado.

Considerando um caso linear com duas classes linearmente separáveis com duas dimensões, diversos planos podem ser traçados para que os dados possam ser separáveis. O melhor caso de separação ocorre quando as margens entre as fronteiras de decisão são mais largas o possível (GÉRON, 2019). As amostras que estão localizadas nas margens das fronteiras de separação são chamadas de vetores de suporte, sendo estas as amostras mais difíceis de serem encontradas. O processo de busca do melhor hiperplano é dado por meio de otimização (GÉRON, 2019). A dimensão do hiperplano de saída está diretamente relacionada com a quantidade de atributos de entrada dos dados.

Quando os dados não são linearmente separáveis e não há a possibilidade de encontrar um hiperplano que separe todos os dados de forma perfeita, é necessário envolver um valor de erro (ou tolerância) durante o processo de otimização

(KOUTROUMBAS; THEODORIDIS, 2008). Além disso, é necessário ajudar o tamanho das margens, sendo esse parâmetro chamado de  $C$  (THEODORIDIS *et al.*, 2010), o qual é inversamente proporcional ao tamanho das margens.

Devido a sua natureza, o SVM é um classificador binário e linear. Com relação a linearidade, pode-se utilizar outras funções que fazem o mapeamento dos dados de entrada e transformam a não-linearidade dos dados em um plano que tenha características mais lineares de forma que as suas fronteiras possam ser mais um tanto mais separáveis. É o caso das funções chamadas de *kernels*, em que os dados de entrada são projetados em um outro espaço dimensional (LORENA; DE CARVALHO, 2007). Entre as formas de como esses *kernels* podem atuar estão a utilização de funções polinomiais, Funções de Base Radial (RBF) gaussianos e sigmoidais. Após a escolha da função de mapeamento não linear, recai-se mais uma vez em um problema de otimização, já que não há nenhum parâmetro que indique a priori qual é melhor *kernel* a ser utilizado (THEODORIDIS *et al.*, 2010).

Como o SVM é um classificador binário, quando há mais de uma classe, é necessário realizar uma certa alteração em seu algoritmo. Em problemas de multiclass, o SVM pode ser expandido nos métodos de um-contra-todos (*one-versus-all*) e um-contra-um (*one-versus-one*). No primeiro, são construídos classificadores equivalentes à quantidade de classes, em que a classe é distinguida entre as demais. Na segunda abordagem, um classificador para cada par de classe é desenvolvido, sendo esta a mais computacionalmente custosa (GÉRON, 2019).

Em termos de ferramentas disponíveis no pacote (*classification tools*) do Matlab®, existem diferentes abordagens com relação à margem de fronteira, a qual pode ser linear ou não-linear (polinomial). Em especial, encontram-se como opções as *Linear SVM* (linear) e a *Quadratic SVM* (polinomial de grau 2).

### 2.6.3 Florestas Aleatórias

As Florestas Aleatórias (do inglês, *Random Forests*) são combinações de classificadores em formato de árvores em que seus valores dependem de um vetor amostrado aleatoriamente de forma independente e com a mesma distribuição para todas as árvores na floresta (BREIMAN, 2001). Geralmente, o método de treinamento para essas árvores é o método de *Bagging*. As árvores de decisão, que baseiam as

Florestas Aleatórias, são baseadas em um conjunto de regras usadas para classificar ou prever um resultado, as quais correspondem a divisão dos dados de forma sucessiva em sub-repartições. Essas repartições chegam até que só haja apenas uma classe, representando a classe à qual esse atributo representa (BRUCE; BRUCE, 2019).

O processo de *Bagging* tem como base que tirar a média de vários modelos ou de grupos de modelos pode ser mais preciso que o uso de apenas um único modelo. Então, o modelo de Florestas Aleatórias se baseia nas respostas de várias árvores de decisão. O modelo de *Bagging*, que significa “*bootstrap* agregador”, é baseado em um algoritmo de agrupamentos, os dados são reamostrados e os modelos são ajustados (BRUCE; BRUCE, 2019).

Devido a essa característica, reduz o nível de sobreajuste dos dados, o qual representa maior generalização dos modelos. Entretanto, esse modelo é um método chamado de “caixa-preta”, já que não se há controle dos parâmetros resultantes do modelo. Para evitar que os parâmetros ficam muito ajustados, a validação cruzada ajuda a melhorar esse problema e a selecionar os hiperparâmetros do processo de classificação, como número máximo de árvores e quantidade de divisão por árvore (GÉRON, 2019).

Com relação à quantidade de divisões, não há um número definido ou ideal para estes classificadores, devendo ser testados por meio de validação para cada modelo. A plataforma de desenvolvimento Matlab® separa a quantidade máxima de divisões pelos seguintes termos: Árvores Complexas (*Complex Tree* ou *Fine Tree*, em versões recentes) como modelos que possuem, no máximo, 100 divisões; e Árvores Simples (*Simple Tree* ou *Coarse Tree*, em versões recentes), como modelos que possuem 4 divisões ao máximo (MATHWORKS, 2021). Neste trabalho, definiu-se a nomenclatura de *Complex Tree* para os ensembles de *Decision Trees* com 100 divisões e *Bagged Tree* para os casos de *Simple Tree*.

## 2.7 Análise de desempenho dos classificadores

Os desempenhos dos classificadores foram avaliados tanto por meio da acurácia e da especificidade das classes, sendo calculadas por

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

e

$$Especificidade = \frac{TN}{FP + TN} \quad (11)$$

em que  $TP$  é o total de amostras que pertencem às classes que foram corretamente classificadas;  $TN$  é o total de amostras que não pertencem às classes que foram corretamente classificadas;  $FN$  representa o total de falsos negativos das amostras que não foram corretamente classificadas; e  $FP$  representa o total de falsos positivos das amostras que não foram corretamente classificadas.

Estes dois parâmetros foram escolhidos para a análise dos classificadores pois apresentam o quanto as classes foram corretamente classificadas (acurácia) e a qual a influência dos falsos positivos das classes durante o reconhecimento (especificidade).

Além de apontar a qualidade dos resultados dentro de um classificador, estes parâmetros de desempenho também são utilizados para análises estatísticas de equivalência entre os dados (como o Teste estatístico de Friedman e, posteriormente, e o Teste Post-hoc de Tukey), ou seja, de equivalência entre conjuntos de atributos de classificadores.

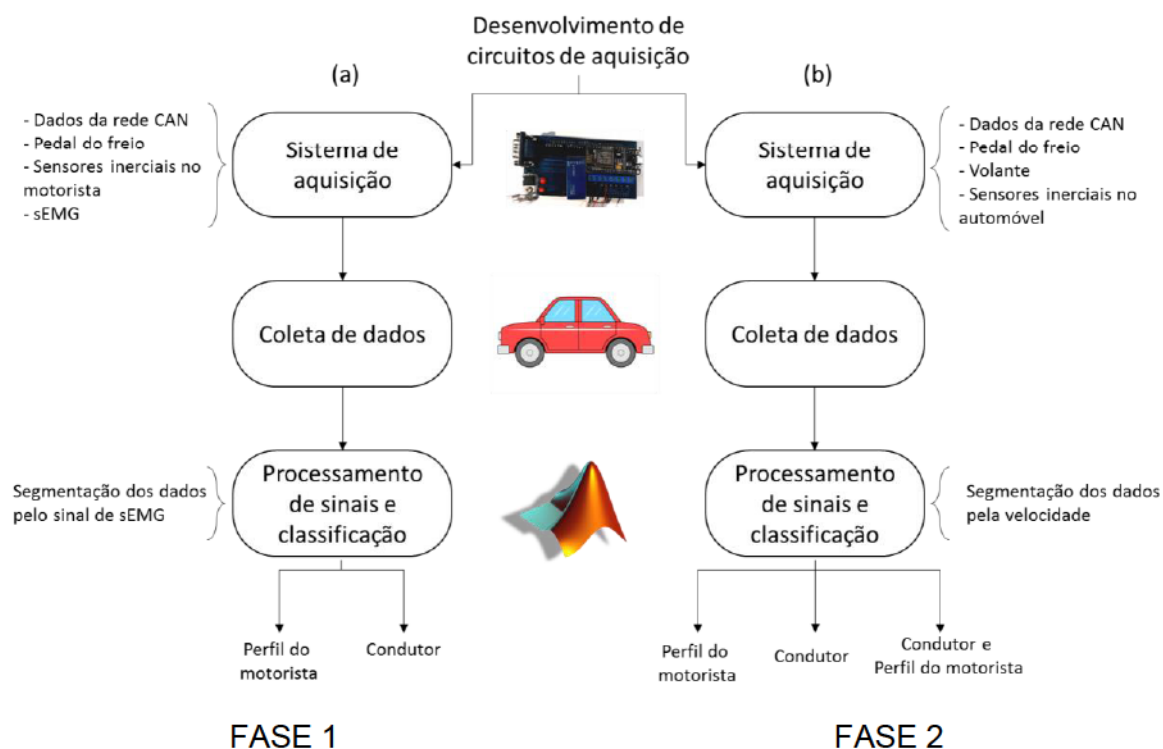


### 3 METODOLOGIA

Esta etapa possui como objetivo principal avaliar se é possível correlacionar os dados coletados no motorista com os dados da CAN e do pedal do freio, além de traçar um perfil de condução do motorista apenas com informações disponíveis no automóvel e o quanto a presença das informações coletadas no motorista influenciam no reconhecimento do perfil do motorista e do próprio condutor.

A Figura 3 apresenta os passos metodológicos deste trabalho. Duas análises principais foram desenvolvidas. Na primeira análise (Figura 3a), o sistema de aquisição coletou dados veiculares nativos da rede CAN, dados provenientes de instrumentação adicional do veículo (como curso de movimento do pedal do freio), e também sinais de instrumentação biomotora do motorista, estes advindos dos sinais musculares do tibial anterior e da movimentação do pé do motorista nos pedais (por meio de sensores inerciais).

**Figura 3: Procedimentos metodológicos para o desenvolvimento do trabalho proposto. Em (a) FASE 1 - estão descritos os passos e as principais características envolvendo a aquisição e o processamento de dados com os circuitos presentes tanto no carro quanto no motorista e em (b) FASE 2 - os passos e os processos envolvendo apenas os dados coletados no automóvel.**



Fonte: Autoria própria (2021).

Os sinais são coletados por meio de um sistema de aquisição de dados denominado neste trabalho como Central de Aquisição de Dados Automotivos (CADA). Posteriormente à conexão de todos os elementos para a aquisição, inicia-se o processo de coleta de sinais, no qual os motoristas são orientados para a realizar os padrões de comportamento distintos durante a direção do veículo. Estes dados são coletados para processamento *off-line* utilizando o *software* Matlab®.

Após a coleta, inicia-se o tratamento dos sinais, principalmente pelo desenvolvimento de estratégias de processamento, segmentando-os e extraíndo atributos relevantes para serem enviados para técnicas de reconhecimento de padrões. Nesta primeira fase, o critério de identificação dos sinais para a segmentação é a presença de sinal de EMG de superfície (sEMG). Com a extração das características, os classificadores são testados e as saídas são os dois perfis de condução dos motoristas (normal/calma/cautelosa e rápida/apressada/menos cautelosa) e a identificação do motorista apenas com os sinais obtidos. A proposta nesta fase é a obter uma correlação entre os dados exclusivamente do veículo (obtidos da rede CAN) e do motorista (movimento do pé direito através de sensor inercial e ação muscular desta perna através de sEMG). Uma vez obtida uma correlação satisfatória, poder-se-á retirar o monitoramento do condutor e aprofundar o monitoramento do veículo em relação ao seu comportamento.

Assim, a segunda análise, pautada pelos elementos da Figura 3b, possui o mesmo fluxo de informação com algumas alterações com relação aos dados coletados, o processamento desenvolvido e o resultado avaliado. O objetivo da segunda análise é verificar se apenas com os sinais provenientes do carro (dados da rede CAN) e com a inserção de novos sensores para obtenção de características do volante, do pedal de freio e do movimento do centro de massa (que são dados não presentes em todas as versões de automóveis, ou de difícil acesso a elas) haveria a possibilidade de que um sistema inteligente possa reconhecer o perfil de condução de um motorista, e também verificar a possibilidade de identificar primeiramente o condutor e posteriormente o seu perfil de condução. Além da alteração dos sinais coletados, o formato de segmentação dos dados foi desenvolvido baseado na velocidade do veículo: enquanto este está parado, não há extração de características; se em movimento, o sinal permite o início ou a retomada de sua segmentação.

### 3.1 Protocolo experimental

Os participantes deste trabalho (no número de 13) foram convidados a conduzir um veículo por um trajeto determinado, sob algumas orientações em um circuito fechado, em duas fases. Estes procedimentos estão de acordo com o projeto aprovado pelo Comitê de Ética de Pesquisa Envolvendo Seres Humanos da Universidade Tecnológica Federal do Paraná sob CAAE 50086021.8.0000.5547.

Na primeira fase, participaram 8 motoristas e foram coletados dados do veículo, de sensores fixados neste e de módulos sensores posicionados no pé e perna do condutor. Estes módulos, os quais se baseiam em sensores não invasivos, são responsáveis por realizar o registro de movimentação da perna ao pisar nos pedais. Os eletrodos de eletromiografia foram colados à pele (na altura do músculo tibial anterior) enquanto os sensores inerciais foram fixados junto à parte superior do pé por uma cinta de tiras duplas aderentes (tipo vélcro).

Na segunda fase participaram 10 motoristas, sendo 5 que já haviam participado da fase 1, e foram coletados dados do veículo e de sensores adicionais fixados neste. A partir da coleta dos dados destes sensores e dos sensores intrínsecos do veículo, etapas de processamento e classificação foram realizadas para investigar a possibilidade de identificação de padrões de movimentação (tipo de condução, identificação de movimentos, identificação do motorista).

#### 3.1.1 Trechos do protocolo experimental

Os participantes foram orientados a realizar a condução do veículo em condições distintas, contendo algumas ações pelas quais sua execução poderia ser dividida em duas classes. A primeira, nomeada de normal, calma ou cautelosa, e a segunda, com ações mais abruptas, nomeada por rápida, apressada ou menos cautelosa.

Das principais induções a padrões distintos de direção, destacam-se:

a) aceleração e retomadas: as acelerações podem ser lentas e graduais representando a normalidade, ou abruptas (mais enfática) representando pressa, seja

por desejo ou necessidade de ultrapassagem, ou mesmo por estar atrasado a um compromisso. Da mesma forma, após uma freada mais abrupta, uma retomada de aceleração mais intensa pode indicar pressa, redução de cautela ou mesmo nervosismo ao volante;

b) freadas e simulação de imprevistos: Freadas abruptas podem representar pressa ou o surgimento de imprevistos, como a redução de velocidade de um veículo à frente, ou o surgimento de um obstáculo repentino (seja um animal cruzando a pista, seja um buraco, uma lombada não visualizada, etc);

c) troca de faixas e ações de zigue-zague (trocas consecutivas de faixas): a velocidade da guinada do veículo durante as trocas de faixa, principalmente depois de uma ultrapassagem, pode representar ausência de cautela ou pressa, ou também indicar alguma situação de desconforto com outros motoristas;

Ainda, para melhor caracterizar as duas classes/padrões de comportamento de condição veicular, diversos procedimentos foram correlacionados e estão resumidos na Tabela 4:

**Tabela 4 – Correlação entre Ação e tipo de condução do motorista, dividido em duas classes (cautelosa ou calma e menos cautelosa ou apressada).**

Ação \ Tipo de condução	Normal / calma / cautelosa	Rápida / apressada / menos cautelosa
Aceleração inicial	Lenta / gradual	Abrupta / mais rápida
Freada	Lenta / gradual	Abrupta
Simulação de imprevisto	Freada lenta	Freada abrupta
Retomada	Lenta / gradual	Abrupta / mais rápida
Troca de faixa	Lenta / gradual	Movimento abrupto do volante
Zigue-zague (desvio de sinalizações/obstáculos)	Lenta / gradual	Movimento abrupto do volante
Passagem por obstáculo (lombada)	Lenta	Aproximação e retomada mais rápidos
Curva	Redução moderada de velocidade	Redução mínima de velocidade

**Fonte: Autoria própria (2021).**

Através destas ações, diferentes situações foram criadas para cada participante, de modo que, segundo suas habilidades e entendimento, houvesse diferenças entre comportamentos básicos de esterçamento do volante e de ações nos pedais (tanto de frenagem quanto de aceleração). Considerando que cada motorista atuou realizando conduções diferentes, segundo sua compreensão, tem-se uma dose de subjetividade para o conjunto de dados.


### **3.2 Materiais**

Para possibilitar as coletas de dados realizadas nas fases 1 e 2 foi necessário o desenvolvimento e implementação de alguns equipamentos, desde a instalação da central de aquisição de dados e sensores adicionais no veículo, até a instrumentação utilizada para monitorar o condutor.

#### **3.2.1 Central de Aquisição de Dados Automotivos (CADA)**

Desenvolvido por Farinelli (2019), a Central de Aquisição de Dados Automotivos (CADA) ilustrada na Figura 4, é um dispositivo implementado a partir da necessidade verificada de se ter um equipamento capaz de realizar a leitura e monitoramento de dados da rede CAN de automóveis, de sensores inerciais e também fosse compatível com a aquisição de dados analógicos, tais como sinais biológicos. O dispositivo é formado por uma central responsável pela aquisição dos dados e gerenciamento dos pacotes para transmissão e por um módulo adicional que conta com acelerômetro e giroscópio.

**Figura 4 - Vista frontal da Central de Aquisição de Dados Automotivos utilizada no processo de aquisição deste trabalho.**



**Fonte: Autoria própria (2021).**

Inicialmente, na concepção do seu projeto, foram definidos os requisitos necessários para o correto funcionamento, entre eles que o dispositivo deveria comunicar-se com um veículo via rede CAN, comunicar-se com outros módulos de sensoriamento inercial sem fio em um raio que abrangesse todo o interior do veículo, disponibilizar 6 canais para a conversão analógica-digital (A/D) para leitura de sinais analógicos de tensão entre 0 e 3,3 V e que todos os sensores conectados deveriam ser sincronizados por uma central para garantir a confiabilidade. Além disso, a central seria responsável por adquirir, gerar os pacotes e transmitir as informações para um computador a ela conectado.

A necessidade da central que realize o gerenciamento dos dados se deve ao fato de ser preciso garantir que requisitos temporais estariam assegurados e que a sincronia fosse mantida, por se tratar de dados de diferentes fontes. Dessa forma, foi possível realizar o escalonamento temporal e garantir o correto funcionamento e a confiabilidade dos dados obtidos.

A central de aquisição é dividida em 3 partes principais, sendo a primeira responsável pela comunicação com a rede CAN. Um conector OBD-II ligado ao veículo fornece ao microcontrolador MCP2515, por meio do transdutor TJA 1050 que transforma os dados provenientes da rede CAN em sinais TTL e envia via RS232, as informações em forma de *bits* que podem ser interpretados pelo MCP2515. Além disso, a central deve possuir compatibilidade com o protocolo de rede CAN ISO 11898, capacidade de operação a 500 kb/s conforme normatização para diagnóstico

automotivo SAE J1979, ser capaz de enviar e receber mensagens formatadas conforme a ISO 15765-2, e disponibilizar os dados a uma taxa de pelo menos 10 Hz quando requisitado pelo outro microcontrolador (ESP8266) que gerencia os dados e transmite ao computador.

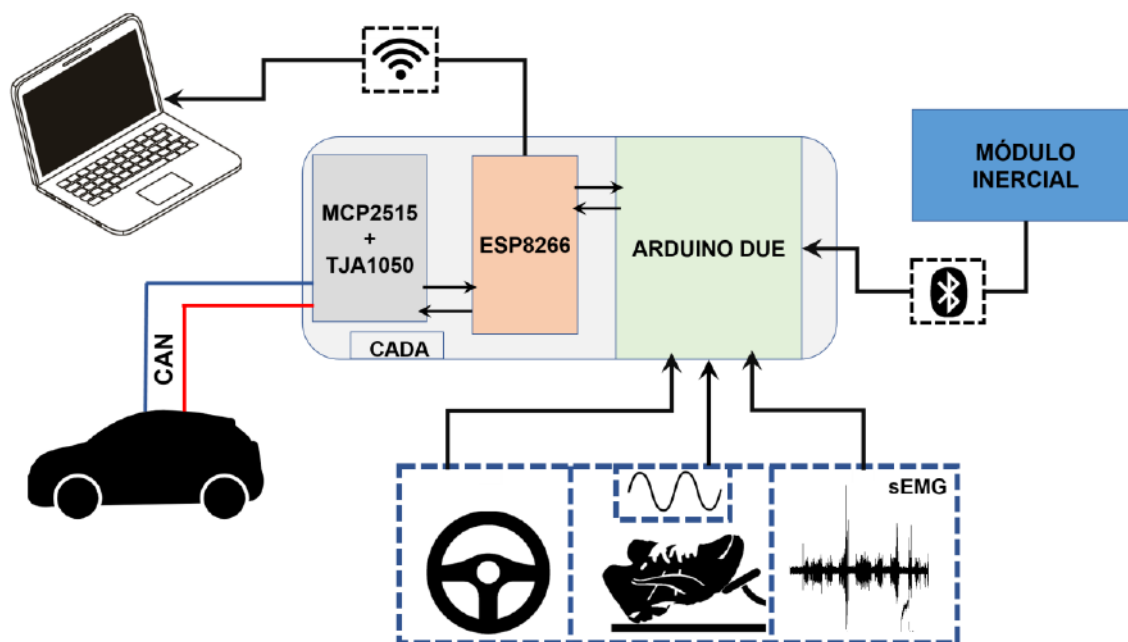
A segunda parte corresponde ao microcontrolador AT91SAM3X8E (Arduino DUE) que realiza a aquisição dos dados analógicos por meio de um conversor A/D de 12 *bits*, com níveis de tensão entre 0 e 3,3 V, a uma taxa de 1 kHz que atende ao recomendado para leitura de certos sinais biológicos, como o Eletrocardiograma e o Eletromiograma. Além disso, este microcontrolador é o responsável por receber e empacotar os dados provenientes do módulo de sensoriamento inercial.

O módulo inercial conta com uma unidade de medição inercial MPU6050 com acelerômetros e giroscópios triaxiais e é gerenciado por um microcontrolador Arduino Pro Mini (ATMEGA 328p) que opera a aquisição a uma taxa de 100 Hz. Já a comunicação entre este microcontrolador e o Arduino DUE ocorre via Bluetooth® por meio de um módulo HC-05, e todo o conjunto é alimentado por bateria para manter a característica de sem fio assim como ocorre com a comunicação.

A terceira parte é formada pelo microcontrolador ESP8266 NodeMCU, que é responsável pelo controle do conjunto de aquisição dos dados do veículo pelo MCP2515, e também de ser a interface entre o Arduino DUE, que realiza o gerenciamento dos dados, com o computador via Wifi® por meio de uma rede própria com IP definido e uma porta liberada no *firewall*.

A Figura 5 ilustra o diagrama de blocos da CADA, destacando sua aplicação dentro deste projeto, em especial, da captura de sinais externos da CAN provindos de sensores inerciais, de instrumentação do volante, do pedal de freio e também de sinais de sEMG oriundos da perna do motorista.

**Figura 5 – Diagrama de blocos do funcionamento da CADA e demais sensores. As conexões não especificadas são físicas.**



Fonte: Autoria própria (2021).

Todas as partes envolvidas nas aquisições de dados passaram pelo processo de escalonamento para garantir que as tarefas são realizadas sem prejuízo aos dados coletados, como é esperado em um sistema em tempo real confiável. Após os testes realizados por Farinelli (2019), pode-se afirmar que o sistema atende as necessidades impostas pelo presente trabalho, uma vez que possui confiabilidade na operação, é capaz de realizar a leitura dos dados da rede CAN e também dos sinais biológicos provenientes da eletromiografia de superfície.

A CADA nos testes foi fixada no console do veículo, conforme apresentado na Figura 6, para evitar contatos do motorista e do operador do sistema além de diminuir os riscos de mau contato nos cabos provenientes dos sensores e do conector OBD-II. Os sensores de posição do pedal de freio e do volante também foram previamente fixados e mantidos para que todas as coletas apresentassem a mesma faixa possível de variação.



**Figura 6 – Posicionamento da CADA no veículo durante a realização dos testes.**



**Fonte: Autoria própria (2021).**

Em todas as coletas, a CADA foi conectada em um computador portátil para o arquivamento dos dados. Para evitar que a bateria do computador utilizado esgotasse durante alguma coleta e os dados fossem perdidos, optou-se por instalar na tomada 12 V do veículo um inversor de tensão para fornecer uma tomada com tensão alternada de 127 V onde era conectada a fonte de alimentação do computador. Por fim, todos os cabos e conectores eram checados antes de cada coleta para garantir o correto funcionamento.

### 3.2.2 Instrumentação do Condutor

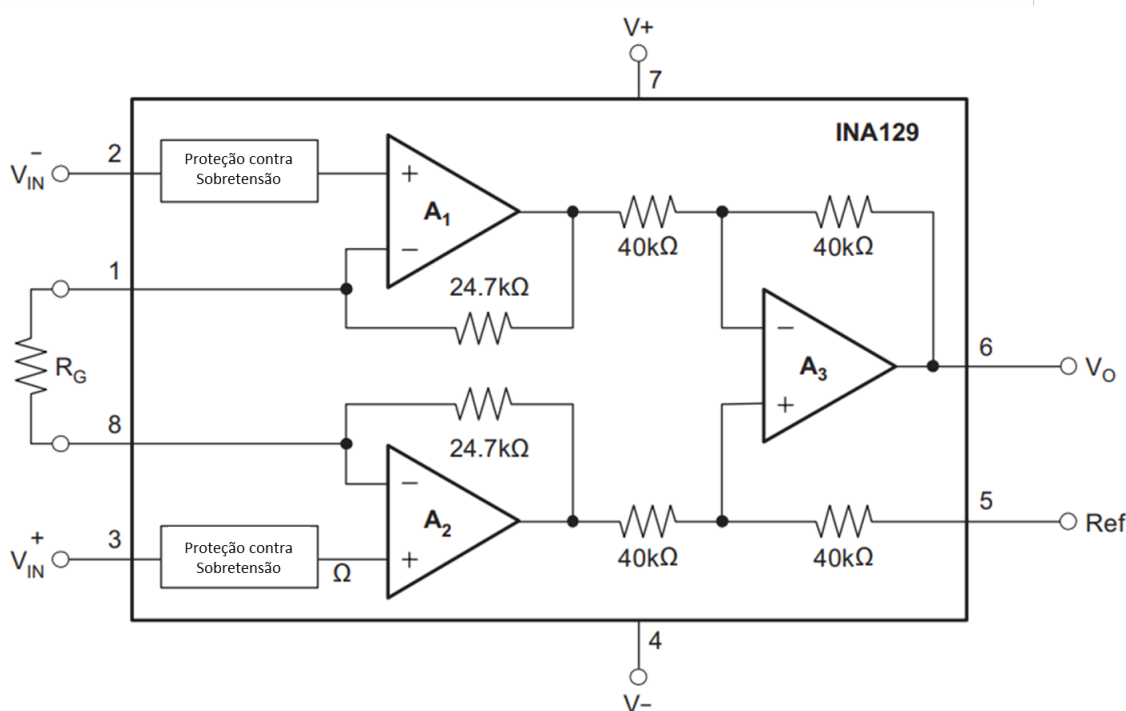
As coletas de dados realizadas na Fase 1 monitoravam, além do veículo, sinais advindos do motorista. Com a finalidade de verificar a possibilidade de relacionar dados biológicos do condutor com os sensores do veículo foram desenvolvidos circuitos que auxiliaram no processo de aquisição de sEMG, detalhados a seguir.

#### 3.2.2.1 Circuito de Aquisição de sEMG

O projeto do circuito de aquisição de sinais de sEMG para essa aplicação é composto de três estágios: amplificação, filtragem e condicionamento.

Como amplificador de instrumentação, utilizou-se o circuito integrado INA129, fabricado pela *Texas Instruments*, o qual possui baixo consumo de energia e precisão necessária para essa aplicação. Além disso, esse circuito pode fornecer um ganho de até 10000 vezes, o que torna o seu uso viável para a aplicação de aquisição de sinais de sEMG. Sua utilização dá-se conforme apresentado na Figura 7.

**Figura 7 – Esquemático interno do INA129 e suas ligações para a aquisição dos sinais de sEMG.**



Fonte: Adaptado de Burr Brown (1995).

O ganho fornecido ( $G$ ) pelo INA129 pode ser calculado a partir da equação

$$G = 1 + \frac{49,4k\Omega}{R_G}, \quad (12)$$

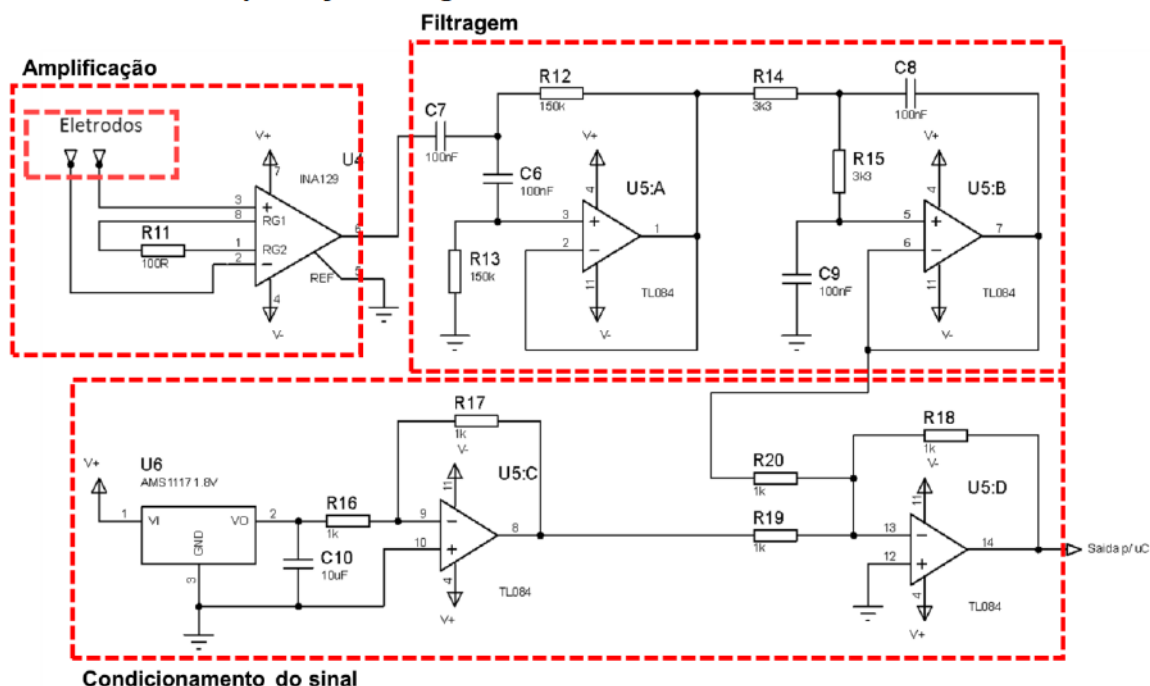
em que  $R_G$  é o valor do resistor de ganho, em  $\Omega$ .

Considerando que o sinal de sEMG tem variação entre 0 e 10 mV, foi projetado um ganho aproximado de 500, sendo utilizado um resistor com valor de 100  $\Omega$ . Este valor foi considerado devido as baixas amplitudes do sinal de sEMG; sendo o valor real de ganho igual a 495.

Para reduzir a influência de ruídos no sinal medido, foi projetado um filtro ativo passa alta, com aproximação *Butterworth* (SEDRA; SMITH, 2007), de 2ª ordem com frequência de corte de 10 Hz. Em sequência, foi projetado um filtro ativo passa baixa, também de aproximação *Butterworth*, de 2ª ordem, com frequência de corte de 500 Hz. Essas frequências foram escolhidas devido a estarem na dentro da faixa de sEMG. O ganho dos filtros para essa aplicação foi definido como unitário, já que a etapa de amplificação realiza esse processo.

Mesmo depois de amplificado e filtrado, o sinal necessita de ajustes para possibilitar a sua leitura pelo microcontrolador, pois as entradas analógicas da CADA são capazes de realizar a leitura de valores de tensão entre 0 V a 3,3 V, sendo necessária a etapa de condicionamento do sinal. O sinal medido é alternado e possui variação entre valores negativos e positivos; logo, ao sinal original é somada uma tensão de 1,8 V proveniente do regulador de tensão AMS1117, que apresenta precisão de saída e baixo consumo de energia, deslocando o nível médio de tensão que era de 0 V para 1,8 V. Como a tensão proveniente do sEMG possui variação de 2 Vpp aproximadamente, ao ser somada à tensão de referência de 1,8 V, a tensão de saída passa a possuir valores dentro da faixa de leitura do microcontrolador. Neste caso, utilizou-se de um amplificador inversor (com ganho unitário), para inverter o valor da tensão e inseri-lo em um somador unitário para acrescentar o sinal de sEMG com esse deslocamento (ou *offset*). Todas essas etapas, em que foram necessários 4 amplificadores operacionais, foram desenvolvidas utilizando um circuito integrado TL084 e estão presentes na Figura 8.

**Figura 8 – Esquemático do circuito de aquisição de sEMG, envolvendo as etapas de amplificação, filtragem e condicionamento do sinal com *offset*.**




Fonte: Autoria própria (2021).

A alimentação do circuito de sEMG foi realizada utilizando-se um circuito adicional que tem por função gerar uma tensão *dual supply* (que consiste em tensões positivas e negativas com um referencial em comum), a partir de uma alimentação *single supply*. Dessa forma, a partir de uma bateria é possível obter tensão positiva e negativa, necessárias para alimentar o amplificador operacional, enquanto seriam necessárias 2 baterias para obter o mesmo resultado com a associação convencional mostrado no esquemático da Figura 9.

Foram utilizadas baterias de íon de lítio (modelo 18650), devido a facilidade de aquisição e de recarga bem como autonomia satisfatória para o emprego no circuito utilizado, o qual apresenta consumo de corrente inferior a 40 mAh. Cada bateria totalmente carregada possui tensão de 4,2 V e 3,7 V (valor último quando a mesma está descarregada), sendo associadas duas baterias em série para elevar a tensão de alimentação do circuito. Caso fosse utilizado o método convencional de associação seriam necessárias 4 baterias para possibilitar a alimentação do circuito. A utilização de baterias se deve a dois fatores, sendo o primeiro a necessidade de isolar o voluntário do circuito do veículo por questão de segurança devido ao risco de choque elétrico. O outro fator é a atenuação de ruídos que, apesar da existência de filtros no circuito, interferissem no sinal medido.

**Figura 9 – Esquemático do circuito de alimentação do sistema de aquisição, baseado no circuito 555 que converte a tensão de uma bateria em uma fonte de tensão *dual supply*.**




**Fonte: Autoria própria (2021).**

Com a definição dos valores dos componentes empregados no circuito, partiu-se para a construção do protótipo em placa de circuito impresso, que compreendeu desde o design da placa, empregando técnicas que visam a redução de ruídos, até a soldagem dos componentes. Para reduzir o tamanho da placa optou-se pela utilização de componentes SMD (*surface mounted components*) por possuírem tamanho reduzido quando comparados aos convencionais, sem prejuízo ao funcionamento do circuito. A Figura 10 apresenta o modelo das placas dos circuitos impressos com a sua respectiva montagem.

Após a montagem, o comportamento do circuito foi verificado antes de ser inserido na superfície da pele. Tal medida faz-se necessária para garantir que o circuito implementado atende aos requisitos definidos na etapa de projeto. Para simular o sinal a ser inserido no circuito de aquisição foi utilizado um gerador de funções. Primeiramente foi verificada a resposta em amplitude do circuito e após isso, a resposta em frequência, estando a saída do circuito ligada em um osciloscópio. Para a resposta em amplitude, a frequência no gerador foi definida como 100 Hz (dentro da faixa dos filtros do circuito) e a amplitude foi variada entre 1 e 10 mV, sendo verificada a amplitude de saída do circuito. Após isso, foi definida uma amplitude dentro dos limites operacionais de 4 mV e a frequência foi alterada entre 0,5 Hz até 600 Hz, os quais estão entre os limites das frequências de corte.

**Figura 10 – Vista frontal dos circuitos desenvolvidos, sendo (a) do circuito de aquisição de sEMG e (b) a fonte utilizando o circuito integrado 555.**




**Fonte: Autoria própria (2021).**

Após a verificação do funcionamento dos sistemas por ondas simuladas, o sinal foi testado em um músculo do membro inferior, ao qual o mesmo é alocado. Nesse caso, o circuito foi alocado na região do músculo tibial.

Primeiramente, o circuito de aquisição de sEMG foi simulado e a Figura 11 apresenta os resultados obtidos pela simulação. Para a entrada do circuito em análise CC, uma onda senoidal com 1 mV de amplitude e 100 Hz de frequência foi empregada na entrada do amplificador de instrumentação, sendo apresentada na Figura 11a. A Figura 11b. apresenta a amplitude do sinal obtida na saída do circuito. Nota-se que o sinal possui o deslocamento (*offset*), devido a ação do circuito somador e do regulador de tensão, sendo este próximo a 1,8 V. Por sua vez, a Figura 11c apresenta a resposta em frequência para o circuito, sendo delimitada entre 1 a 1 kHz. Pode-se notar que as faixas das frequências de corte são similares as frequências calculadas para o circuito, com amplitude máxima de 54 dB.

**Figura 11 - Resultado da simulação do circuito de aquisição de sEMG. Em (a) é apresentado o sinal de entrada para o circuito, em (b) apresenta a resposta para em amplitude, com o deslocamento no eixo Y do sinal do circuito e em (c) a resposta em frequência do circuito.**




**Fonte: Autoria própria (2021).**

O comportamento do circuito de captura do sinal de sEMG é apresentado na Figura 12. Os testes foram conduzidos para verificar como o circuito se comportaria com a variação de amplitude e da frequência, permitindo analisar as suas regiões de operação, conforme descrito no capítulo anterior.

Com relação aos valores de amplitude (Figura 12a), pode-se perceber que o ganho obtido variou entre 53,5 a 54 dB para valores de amplitude entre 2 mV e 10 mV. A maior exceção foi o valor de 1 mV, que devido a interferências e ruídos, obteve um ganho maior que a faixa de operação. Para a análise de frequência (Figura 12b), nota-se o comportamento dos filtros na delimitação da banda de frequência. As frequências menores que 10 Hz e acima de 500 Hz são atenuadas, sendo estas as frequências de corte calculadas. Pode-se perceber que nestas frequências há atenuação de metade do valor de amplitude, o que corresponde a uma atenuação de -3 dB.

**Figura 12 – Comportamento do circuito de aquisição de sEMG. Em (a) é apresentada a resposta em amplitude do circuito e em (b) a resposta em frequência do circuito.**




**Fonte: Autoria própria (2021).**

### 3.2.2.2 Posicionamento dos eletrodos de EMG no condutor (Fase 1)

O motorista inicialmente foi orientado a ajustar o banco e espelhos do veículo conforme sua necessidade e então iniciava-se a instalação dos sensores utilizados na coleta. Inicialmente, foi solicitado ao motorista, permissão para fixar um par de eletrodos na face frontal da perna com espaçamento de 2 cm entre eles. Em seguida, os sensores de sEMG eram instalados nestes eletrodos, além de um eletrodo adicional utilizado como referência de potencial para os circuitos, conforme apresentado na Figura 13.



**Figura 13 – Posicionamento do sensor de aquisição de sEMG no músculo tibial dos condutores e o eletrodo de referência alocado na região do joelho (fase 1).**



Fonte: Autoria própria (2021).

### 3.2.2.3 Posicionamento do módulo inercial no pé do condutor (Fase 1)

O módulo inercial, que integra a CADA, foi fixado sobre o pé direito do condutor com o auxílio de uma tira de velcro para não atrapalhar o processo de direção, como apresentado na Figura 14, em seguida todos os circuitos eram alimentados e ligados, e aguardava-se o pareamento entre os módulos com a central e a conexão com o computador via Wi-fi®. Então, realizava-se uma coleta teste com duração de 20 segundos para garantir que os sensores de sEMG, do pedal de freio e inercial estavam funcionando como esperado, assim como que os dados provenientes da CAN estavam sendo coletados e armazenados. Após isso, as coletas poderiam ser iniciadas.

Figura 14 – Posicionamento do sensor inercial nos condutores (fase 1).



Fonte: Autoria própria (2021).

### 3.2.3 Instrumentação do veículo

Além dos dados já disponíveis na CAN, para o desenvolvimento deste trabalho foi necessária a instalação de sensores adicionais no veículo visando a aquisição de dados complementares. A seguir tem-se o detalhamento da instrumentação empregada no pedal do freio e no volante do veículo, e do uso do sensor inercial no veículo.

#### 3.2.3.1 Instrumentação do Pedal do Freio

Para o monitoramento do freio, fez-se necessário instrumentá-lo, ou seja, construir de um sensor capaz de fornecer a posição do pedal quando este for acionado. Tal medida foi necessária pois, usualmente, há somente a informação se o freio está ou não acionado pelo acendimento da luz de freio do veículo. Além disso, a informação presente sobre o pedal do freio está na forma de um sinal binário, ou seja, se ele está acionado ou não, não havendo uma informação analógica de quanto o pedal está acionado.

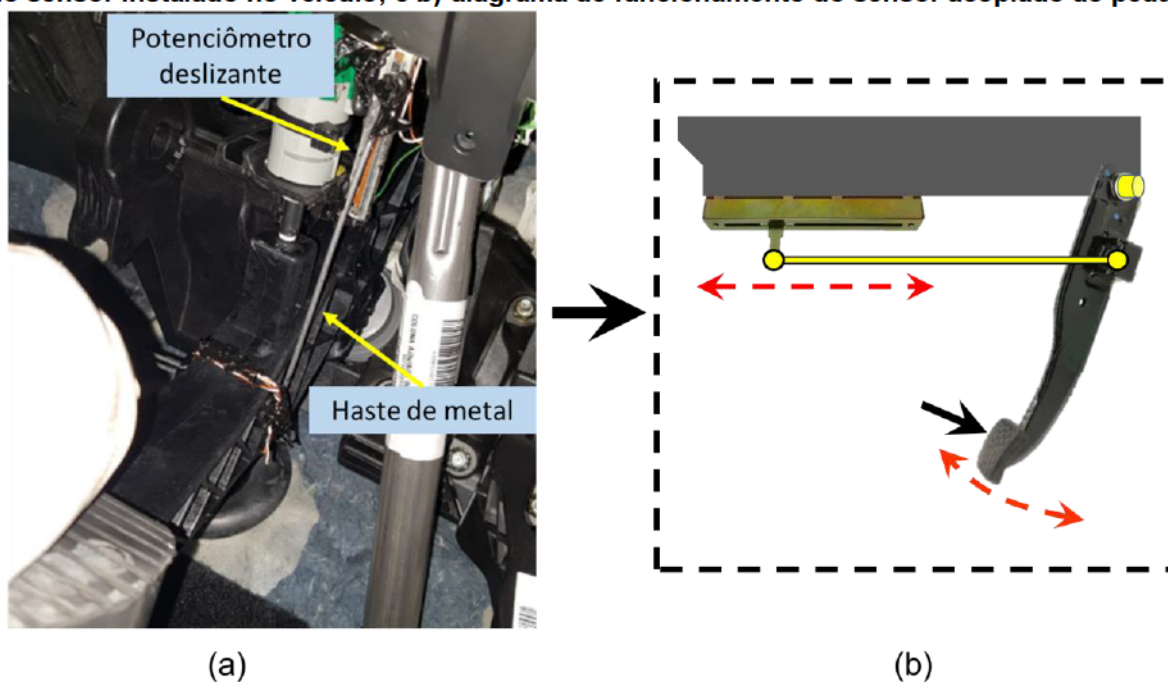
Para poder adquirir essa informação analógica, utilizou-se um potenciômetro deslizando com curso de 70 mm, fixado sob o painel do veículo e com uma haste de

metal conectada ao pedal. Dessa forma, quando há movimentação no freio, há também o deslocamento do potenciômetro, que retorna uma tensão analógica correspondente à sua posição.

Para garantir uma tensão mínima constante de 3,3 V de alimentação para o potenciômetro, foram usadas duas baterias associadas em série e um regulador de tensão AMS1117 de 3,3 V. Assim, há uma tensão constante de alimentação para o potenciômetro, mesmo com a queda de tensão ocasionada pela redução da carga nas baterias e garantir a relação entre posição do pedal e tensão, além de que se garantiu que a tensão máxima de 3,3 V do conversor analógico-digital da CADA não fosse ultrapassada.

Após a instalação do sensor no freio, conforme mostrado na Figura 15, realizaram-se testes para confirmar o correto funcionamento, e em seguida a saída de tensão foi conectada à CADA.

**Figura 15 –Instrumentação do freio, em que foi utilizado um potenciômetro deslizante. a) foto do sensor instalado no veículo; e b) diagrama de funcionamento do sensor acoplado ao pedal.**

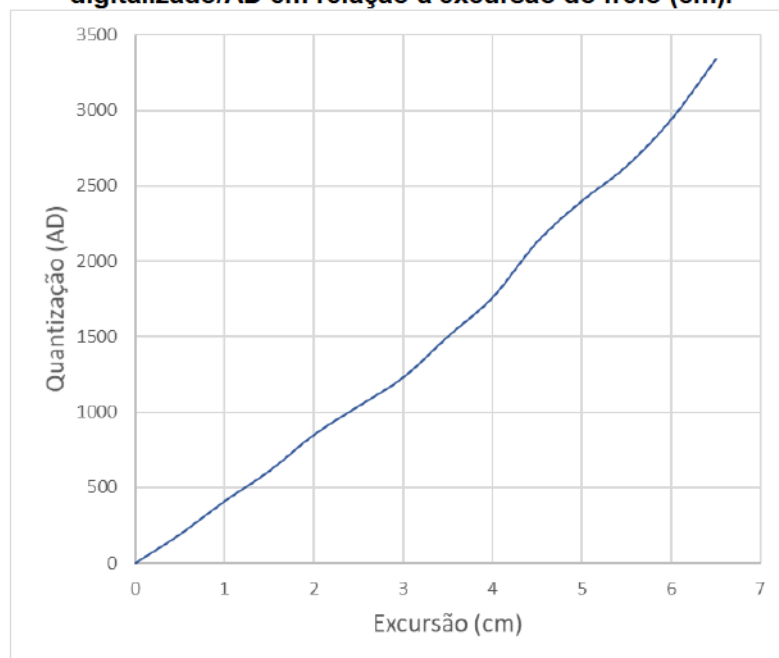


Fonte: Autoria própria (2021).

O comportamento do sensor acoplado no freio é apresentado na Figura 16. Foram feitas quatro medições de excursões totais entre os deslocamentos lineares

(eixo x, em centímetros) e o eixo y, relacionado à quantização dos sinais AD do sistema de aquisição.

**Figura 16 – Caracterização da instrumentação do pedal do freio. Quantização do sinal digitalizado/AD em relação a excursão do freio (cm).**



**Fonte: Autoria própria (2021).**

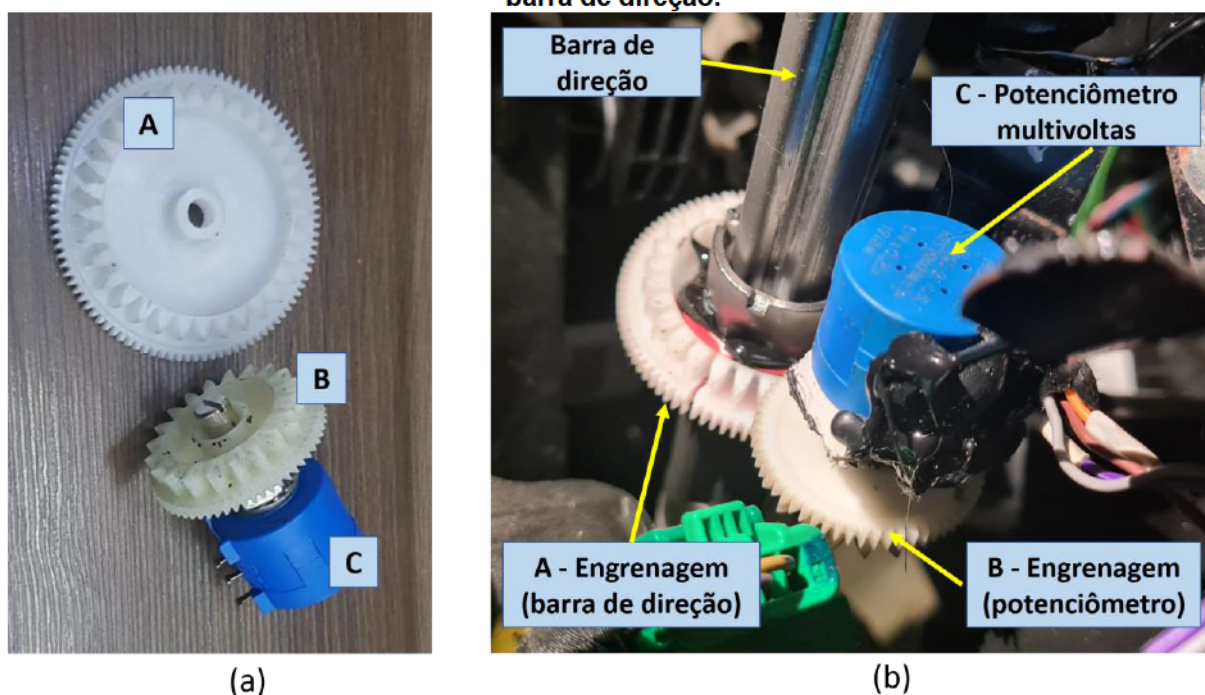
### 3.2.3.2 Instrumentação do Volante

De maneira análoga ao pedal do freio, optou-se por realizar no volante a instrumentação com um sensor adicional, uma vez que a informação da posição do volante na maioria dos veículos não existe ou não é de fácil obtenção na CAN por conta da codificação. Para o monitoramento da posição do volante utilizou-se um potenciômetro rotativo multivoltas com uma engrenagem acoplada a seu eixo, sendo instalada uma outra engrenagem na barra de direção do veículo para conectá-las, apresentado na Figura 17.

O potenciômetro foi ajustado na metade de seu curso, possibilitando a mesma quantidade de voltas para ambos os lados, então foi fixado ao veículo conforme a Figura 17b. Dessa forma, quando o volante é movimentado, há a rotação na barra de direção, ocasionando a rotação no potenciômetro e, por consequência, a variação da tensão de saída deste.

A alimentação do potenciômetro deu-se com o auxílio de baterias e um regulador de tensão de 3,3 V para garantir uma tensão constante de entrada, e a tensão de saída, após ser verificado seu correto funcionamento, foi conectada ao conversor analógico-digital da CADA para aquisição dos valores. Assim, pode-se obter um valor correspondente em tensão para cada posição do volante.

**Figura 17 - Instrumentação do volante, em que foi utilizado um potenciômetro rotativo multivoltas associado a engrenagens. Em (a) potenciômetro multivoltas (C) e engrenagens utilizadas (A para a barra de direção e B para o potenciômetro), e em (b) o sensor instalado na barra de direção.**

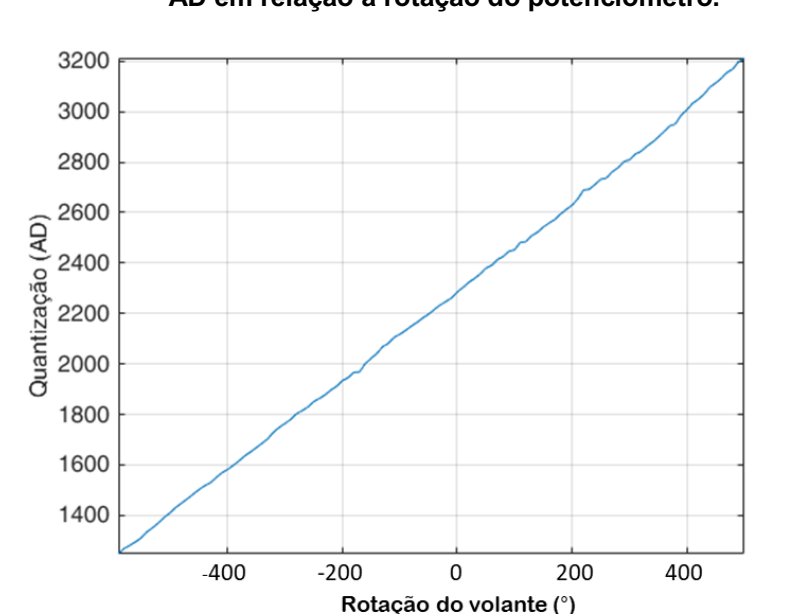


Fonte: Autoria própria (2021).

O comportamento do sensor acoplado ao volante foi caracterizado e está apresentado na Figura 18, sendo a relação entre a quantização do sinal AD e o valor da rotação do potenciômetro alocado no eixo da barra de direção. Para caracterizar a excursão do potenciômetro em função do esterçamento do volante, linhas auxiliares fixados próximos ao volante e um potenciômetro foram utilizados. Desta forma, foi aquisitados uma medida digitalizada a cada 10° de esterçamento do volante, realizando o movimento no sentido horário, de um limite (final de curso) ao outro. Verificou-se que o esterçamento do volante foi de aproximadamente 520° para cada sentido (horário e anti-horário).

O comportamento apresentado do sensor demonstra que o sistema pode ser linearizado, com uma relação direta entre a rotação do volante e da barra de direção. Nota-se que não há efeito de histerese do sinal em função do sensor ser linear (potenciômetro resistivo).

**Figura 18 - Média das aquisições dos sinais da excursão do volante, sendo a quantização do AD em relação a rotação do potenciômetro.**




**Fonte: Autoria própria (2021).**

### 3.2.4 Instalação do inercial no centro de massa do veículo (para Fase 2)

Para o segundo teste o módulo inercial, que na fase 1 era utilizado no pé do condutor, agora foi fixado no interior do veículo entre os bancos dianteiros, junto ao console central, aproximadamente no centro de massa do veículo, conforme apresentado na Figura 19, de modo a oferecer informações equivalentes ao sensor de *yaw rate* (REPPICH; WILLIG, 1995) presente em algumas versões veiculares.


Figura 19 – Módulo do sensor inercial fixado no veículo.



Fonte: Autoria própria (2021).

A Figura 20 apresenta um panorama do veículo, apontando onde foram instalados os sensores adicionais durante cada uma das fases.

Figura 20- Disposição dos sensores adicionais instalados no veículo.



Fonte: Autoria própria (2021).

### 3.3 Procedimento experimental específico – fase 1

A coleta de dados foi desenvolvida em ambiente controlado, cujo trajeto contava com itens que simulavam situações cotidianas no trânsito. Para avaliar o comportamento dos condutores, foram inseridos trechos em que o motorista deveria realizar ações como curvas, trocas simples de faixas, e trocas sequenciais (movimentos de zigue-zague) e paradas.

Para avaliação dos testes da Figura 3a, foram convidados 8 motoristas, devidamente habilitados, sendo desenvolvidos os mesmos procedimentos para que não houvesse influência dos dados obtidos.

Conforme dito, foram definidos dois padrões de comportamento: o modo “cauteloso” e o modo “menos cauteloso”, sendo o motorista orientado a realizar as manobras de forma suave para o primeiro, já no segundo deveria realizá-las de maneira brusca. No primeiro teste, o condutor era sugerido a trafegar no modo de direção denominado “cauteloso” inicialmente, tendo ele o intervalo de 250 s para percorrer todo o percurso enquanto a CADA realizava a coleta e a gravação dos dados no computador. No modo de direção denominado “menos cauteloso” o intervalo para percorrer o mesmo trecho foi de 200 s. Ao fim de cada trecho o condutor permanecia com o veículo parado até que o sistema emitisse um aviso sonoro do fim do período da coleta, e então os dados coletados eram verificados visualmente antes de iniciar a próxima coleta, a fim de garantir que não ocorreram falhas durante a aquisição. As coletas com o mesmo motorista eram realizadas de maneira sequencial, sendo inicialmente realizadas 3 vezes no modo “cauteloso” e, em seguida, 3 no modo “menos cauteloso”, totalizando 6 coletas para cada condutor.

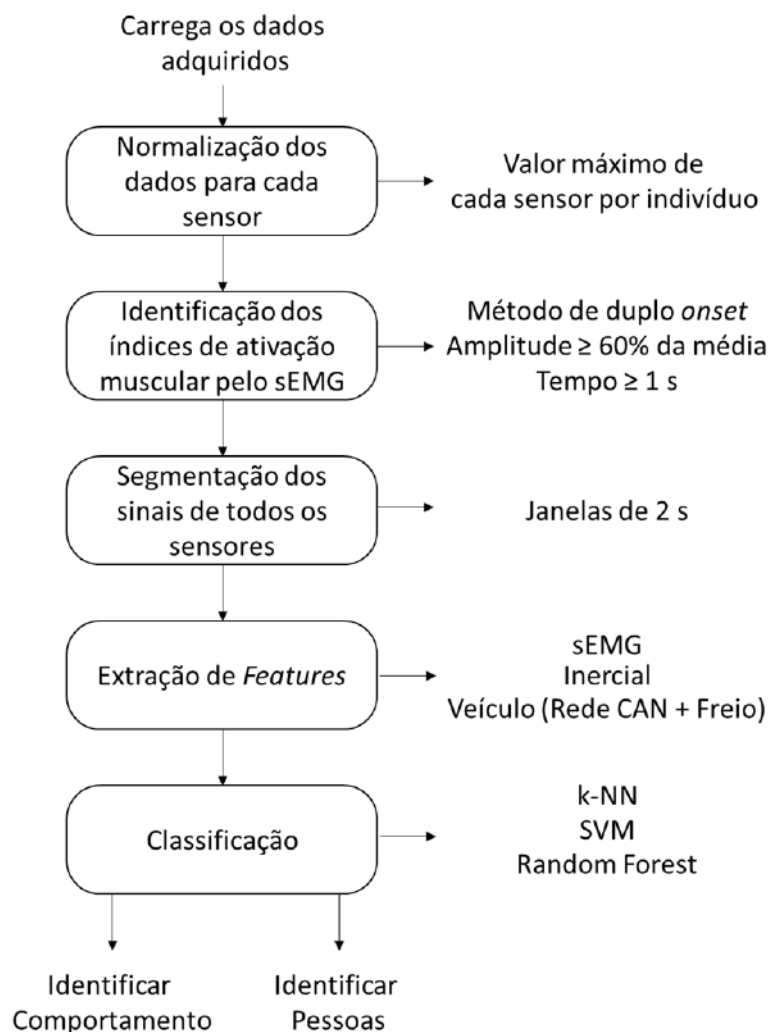
A Figura 21 apresenta o trajeto utilizado para a realização dos testes, com o detalhamento dos elementos a que os condutores foram submetidos durante a condução do veículo.





móvel e os sinais foram comparados quando ultrapassam um valor limite de limiar equivalente a 60% acima da média de toda a distribuição e que fossem constantes acima de uma janela determinada de tempo.

**Figura 22 – Etapas do processamento dos dados da FASE 1 - análise envolvendo os sensores no motorista e no veículo.**




**Fonte: Autoria própria (2021).**

A Figura 23 apresenta este processo para reduzir as interferências e ruídos do sinal de sEMG. A técnica de detecção de *onset* foi aplicada para identificação das ativações musculares, como apresentado na Figura 23a. Ativação é considerada quando a amplitude do sinal de sEMG ultrapassa um valor de limiar e é mantido por um determinado período de tempo. O limiar de amplitude foi definido como um valor acima de 60% da média de todos os dados e o limiar de tempo foi de 1 segundo. Para eliminar os ruídos de sEMG, os sinais, após identificadas as ativações musculares,

foram mantidas as amostras nos trechos segmentados e as demais foram consideradas como valores nulos, iguais a zero. Esse processo é apresentado na Figura 23b.

**Figura 23 – Processamento do sinal de sEMG para eliminar ruídos para o estágio de segmentação. Em (a) são apresentadas as detecções de ativações musculares por meio da técnica de *onset* e em (b) são apresentados os valores selecionados das respectivas ações musculares.**



**Fonte: Autoria própria (2021).**

Deve-se ressaltar que os sinais de sEMG são indicativos de ação do motorista e fornecem a direção de quando os sinais da rede CAN devem ser segmentados. Pelas ativações musculares e com os vetores de características já extraídas, iniciou-se o processo de classificação para a identificação entre os voluntários (pessoas) e do seu comportamento. As *features* extraídas para cada um dos sensores estão apresentadas na Tabela 5.

**Tabela 5 - Atributos extraídos de cada um dos sensores para a entrada dos classificadores, na fase 1.**

Sensor	Atributos
sEMG	Média do Valor Absoluto (MAV)
Acelerômetro	Moda de cada eixo (X, Y, Z)
Giroscópio	Moda de cada eixo (X, Y, Z)
Freio	Moda, Média, Máximo e Mediana
Velocidade	Moda, Média e Mediana
RPM	Moda, Média e Mediana
Acelerador	Máximo e Mediana

**Fonte: Autoria própria (2021).**

Estando os inícios das ativações musculares identificados, os dados de todos os sensores e indivíduos foram segmentados em janelas de 2 segundos. Esse valor foi definido empiricamente pela análise do comportamento do motorista de alternar o pé entre o acelerador e o freio. Ressalta-se que as variáveis possuem frequências de amostragem diferentes (conversores AD, 1 kHz; sensores inerciais, 100 Hz; dados da rede CAN, 10 Hz), os sinais possuem tamanhos e dimensões diferentes.

Para o sinal de sEMG, foi extraída a característica do valor médio absoluto (MAV), amplamente utilizada em sistemas de processamento de sinais de sEMG (PHINYOMARK *et al.*, 2013; PHINYOMARK; N. KHUSHABA; SCHEME, 2018). Nos sensores inerciais (acelerômetros e giroscópios), foram extraídas a moda para um dos três eixos. Os demais parâmetros obtidos da rede CAN do carro e do pedal do freio (pelo conversor AD) foram obtidos por parâmetros estatísticos, como moda, média, mediana e valores máximos.

O próximo passo foi o uso dos classificadores anteriormente mencionados. Para isso, os classificadores *k*-NN, SVM e *Random Forests* foram usados nessa aplicação. Quanto a parametrização dos classificadores, estes foram desenvolvidos como se segue. O *k*-NN foi programado com o valor de 5 vizinhos próximos e a distância euclidiana como parâmetro de distância. Para o SVM, devido à natureza não-linear dos dados, foi escolhida uma função de *kernel* polinomial do tipo quadrática. As *Random Forests* foram programadas em formato de *Bagged Trees*, contendo como restrição o número de 30 árvores e 189 nós máximos por árvore, e de *Complex Tree* com máximo de 20 nós por árvore. Em todo o processo, foi realizado o método de validação cruzada no estilo *k-fold*, separando em 10 conjuntos todas amostras de dados.

Entre as saídas dos classificadores, os rótulos foram analisados de duas formas. A primeira delas foi a verificação do comportamento do motorista (entre

cauteloso e menos cauteloso) levando em consideração todo o conjunto de dados, sem fazer a identificação ou a separação por indivíduos. A segunda forma foi fazer o reconhecimento pela pessoa, ou seja, os dados de cada pessoa foram separados e para cada indivíduo, foram classificados os estados de condução “calma” e “apressada”.

Os desempenhos dos classificadores foram avaliados tanto por meio da acurácia (quanto as classes foram corretamente classificadas) e da especificidade (qual a influência dos falsos positivos das classes durante o reconhecimento) das classes. Para as duas aplicações (reconhecimento da identidade dos motoristas e do perfil de condução), foi avaliada a contribuição dos conjuntos de atributos de entrada no processo de classificação. Ressalta-se que os processos de classificação foram desenvolvidos nas bibliotecas de classificação do *software* MATLAB® 2019. As três condições de escolhas de conjuntos de atributos foram: utilização de todas as características (tanto do condutor quanto do veículo), os atributos pertencentes apenas ao condutor e atributos pertencentes apenas aos dados adquiridos da rede CAN do veículo.

A Tabela 6 indica algumas das combinações de atributos os quais foram utilizados na avaliação para verificar a influência nos resultados quando dados adicionais eram inseridos. A sequência de combinações foi definida para análise inicialmente dos dados do veículo de maneira individualizada, com o acréscimo gradativo de parâmetros combinados, até todos os parâmetros do veículo estarem associados.

Posteriormente o mesmo ocorreu com os dados do condutor, com inserção individualizada dos dados do sensor inercial e de sEMG, e depois associados. Na sequência, avaliou-se o resultado com todos os dados combinados – condutor mais o veículo, e a influência do freio e do sensor inercial.

**Tabela 6 – Conjuntos de atributos selecionados para avaliação da classificação da primeira análise.**

Teste N°	Origem:	Atributos selecionados:
1	Veículo	Velocidade
2	Veículo	RPM
3	Veículo	Velocidade + RPM
4	Veículo	Acelerador
5	Veículo	Velocidade + RPM + Acelerador
6	Veículo	Freio
7	Veículo	Velocidade + RPM + Acelerador + Freio
8	Veículo	Acelerador + Freio
9	Veículo	Acelerador + Freio (mediana)
10	Veículo	Velocidade + RPM + Acelerador + Freio (mediana)
11	Condutor	Inercial
12	Condutor	sEMG
13	Condutor	Inercial + sEMG
14	Veículo	Velocidade + RPM + Freio
15	Veículo + Condutor	Velocidade + RPM + Acelerador + Inercial + sEMG
16	Veículo + Condutor	Velocidade + RPM + Acelerador + Freio + Inercial + sEMG

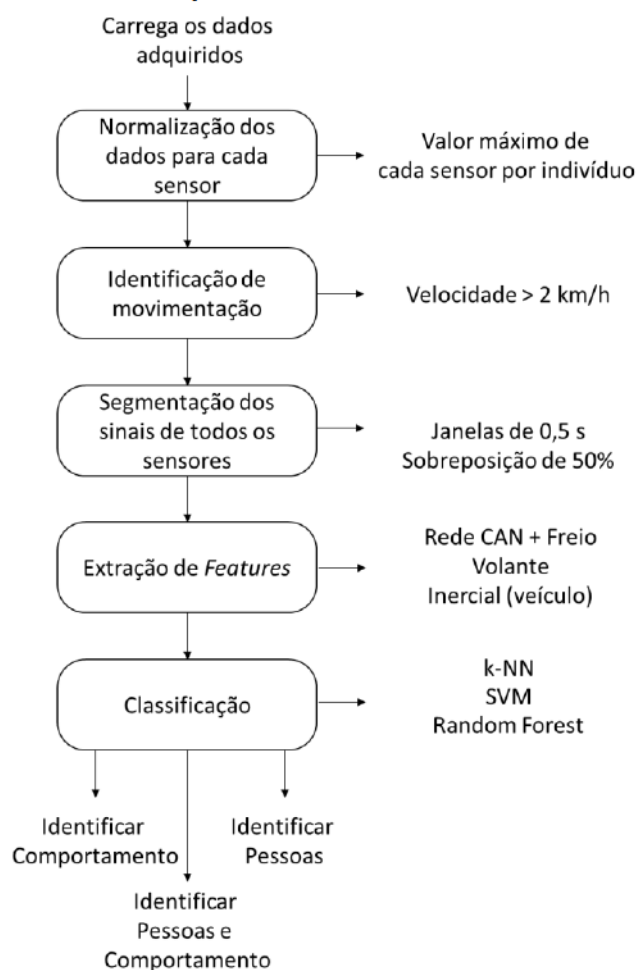
Fonte: Autoria própria (2021).

### 3.4 Procedimento experimental específico – fase 2

O segundo teste foi desenvolvido com 10 condutores conforme ilustrado na Figura 3b. Foram realizadas 3 coletas no modo “menos cauteloso” e 2 coletas no modo “cauteloso”, com um intervalo de tempo de 120 s e 150 s para a realização do trajeto, respectivamente. O tempo de cada coleta de ambas as fases foi definido, com o auxílio de um cronômetro, a partir da condução pelo trecho definido com o acréscimo de uma margem de aproximadamente 10% do valor cronometrado em segundos.

Os estágios do processamento de dados para essa etapa são apresentados na Figura 24. Pode-se perceber que houve poucas modificações entre as etapas, tal como apresentado anteriormente na Figura 23, sendo as mais relevantes na segmentação, extração de características e forma de classificação.

**Figura 24 - Estágios e características da etapa de processamento de sinais para a FASE 2 - análise dos sinais apenas com os sinais do veículo.**



**Fonte: Autoria própria (2021).**

Para a segmentação dos dados, como não há mais dados do motorista, o critério de identificação dos sinais foi feito a partir da alteração da velocidade. Quando o veículo estava parado, isso significou que, como não há movimento, nenhuma característica relevante pode ser extraída do sistema (tanto quanto por não haver movimentação quanto por estar em instantes iniciais ou finais de aquisição). Para evitar falsos positivos, utilizou-se um sinal de corte de 2 km/h obtido por meio do sensor da rede CAN para identificar quando os sinais deveriam ser segmentados.

Após a identificação do instante de segmentação, os dados foram segmentados por meio de segmentação cega (*blind segmentation*). Nessa etapa, os sinais foram segmentados em janelas de 500 ms, contendo 50% de sobreposição entre elas. Esse processo foi determinado porque o veículo deverá estar em movimento para que se possa reconhecer o perfil de condução e o tipo do motorista.

Dessa forma, como não há a segmentação por apenas um parâmetro (como havia na análise anterior referente a presença ou não de sinal muscular), constantemente o veículo deverá monitorar os sinais provenientes do automóvel desenvolvidos pelo condutor.

Após a segmentação, as características foram extraídas dos diferentes sinais, conforme apresentado na Tabela 7. As características definidas foram escolhidas devido à natureza de cada sinal, ampliando as análises vistas no capítulo anterior. Foram acrescentadas a amplitude do sinal do acelerador (desvios entre os valores máximos e mínimos dos parâmetros divididos por dois), os valores obtidos por meio da instrumentação do volante e os sinais inerciais acoplados apenas no veículo. Para os sensores inerciais, foram extraídas informações referentes à média, à entropia amostral do sinal e da variabilidade das amostras (sendo obtida por meio da variância do sinal). Os sinais foram normalizados pelos valores máximos obtidos em cada sensor.

**Tabela 7 – Atributos extraídos de cada um dos sensores/fontes de dados para a entrada dos classificadores, na fase 2.**

<b>Origem do sinal</b>	<b>Características Extraídas</b>
CAN	Média da Velocidade
	Média da RPM
	Máxima da Posição do Acelerador
	Média da Posição do Acelerador
Freio	Amplitude do Acelerador
	Máxima Posição do Freio
	Integral do Freio
Volante	Média do Volante
	Inclinação do Volante
	Amplitude do Volante
Inerciais	Média Absoluta dos eixos X, Y e Z
	Entropia Amostral dos eixos X, Y e Z
	Variância dos eixos X, Y e Z

**Fonte: Autoria própria (2021).**

As características foram agrupadas nos conjuntos apresentados na Tabela 8, nas quais foram consideradas as combinações mais comuns de informações.



**Tabela 8 – Conjunto de características selecionadas para avaliação da classificação na fase 2.**

<b>Teste</b>	<b>Origem:</b>	<b>Parâmetros selecionados:</b>
1	Veículo	Todas as características
2	Veículo	Parâmetros da CAN
3	Veículo	Parâmetros CAN + Freio + Volante
4	Veículo	Parâmetros CAN + Inerciais
5	Veículo	Freio + Volante

**Fonte: Autoria própria (2021).**

Com a segmentação desta fase sendo baseada na velocidade, a quantidade de trechos submetidos para análise nos classificadores foi superior aos obtidos na primeira fase, em que a segmentação era baseada em sEMG. Dessa forma, o tempo de processamento e classificação foi maior, e considerando as análises realizadas anteriormente com os atributos isolados apresentando baixo desempenho no resultado, optou-se pela análise de menos testes, mas com agrupamentos de maior relevância.

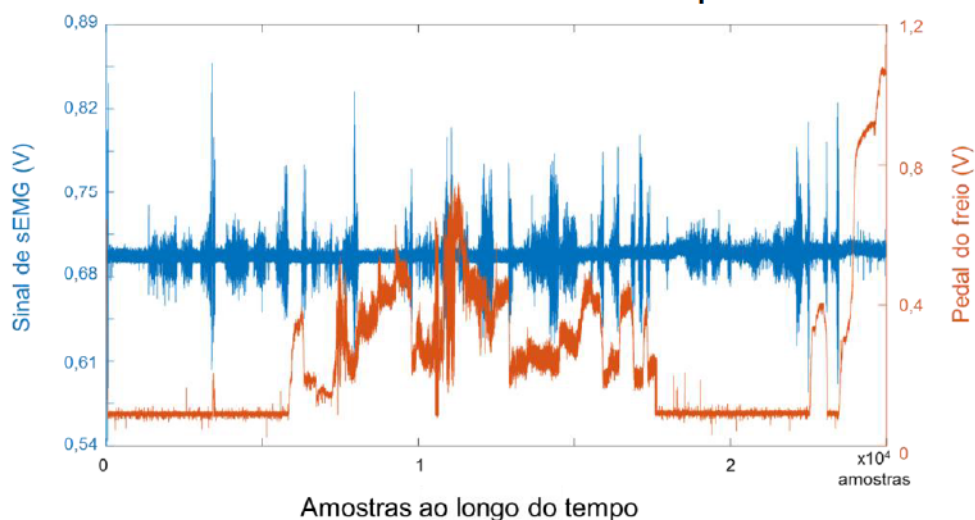
Para verificar o desempenho dos diferentes classificadores empregados e dos diferentes conjuntos de *features* foi utilizado o Teste estatístico de Friedman (HOFFMAN, 2019) e, posteriormente, o Teste Post-hoc de Tukey. O teste estatístico de Friedman, o qual é uma extensão do teste estatístico de Wilcoxon, é um método que se utiliza de atribuição de postos (*ranks*, em inglês) nas observações para verificar se amostras são pertencentes a uma mesma observação. O teste post-hoc de Tukey permite verificar quais são as equivalências entre os grupos, identificando em um gráfico contendo as variáveis em análise no eixo y e a média dos postos observados para cada variável no eixo x. Com estes testes é possível verificar a equivalência das acurácias dos classificadores e conjuntos de *features* que apresentarem os melhores resultados. Se as distribuições possuírem distribuições equivalentes, os intervalos possuirão distribuições concomitantes nos seus postos (mantendo um intervalo de confiança de 95%).

### **3.5 Exemplo dos sinais coletados**

Para exemplificar o comportamento dos sinais adquiridos nas aquisições, são apresentados nessa seção como estes são coletados pela CADA. A Figura 25 apresenta o sinal de sEMG em uma das coletas junto com o sinal obtido pelo potenciômetro alocado na região do pedal do freio com o motorista em modo

agressivo. Foram analisadas um conjunto inteiro de aquisição, a qual é equivalente a  $2,5 \cdot 10^4$  pontos (ou 250 s). Pode-se notar que existem regiões em que há ativação do sinal de sEMG quando o pedal de freio passa do estado de pressionado para o estado de repouso. Isso ocorre porque são nessas regiões em que o músculo tibial, em que o canal de sEMG está alocado, são ativadas, no momento em que o motorista retira o pedal do freio. Essas regiões no percurso estão relacionadas com os trechos onde o motorista deve reduzir a sua velocidade.

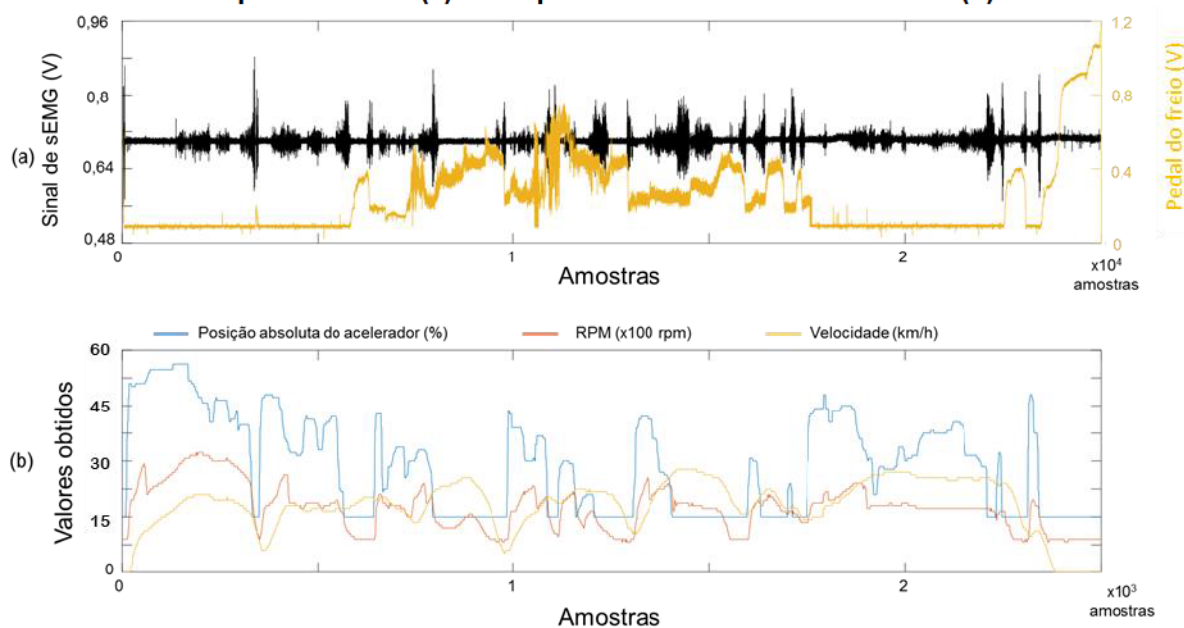
**Figura 25 – Exemplo de sinal de sEMG coletado durante uma aquisição completa do motorista no percurso em modo agressivo e o sinal obtido pelo potenciômetro no pedal do freio. Os valores dos conversores AD foram convertidos em seus respectivos valores em tensão.**



**Fonte: Autoria própria (2021).**

Para uma aquisição envolvendo o motorista dirigindo em modo calmo, a Figura 26 apresenta um exemplo dos sinais que são obtidos. A relação que existe entre os sinais do pedal do freio e de sEMG (Figura 26a) é a mesma como observada na Figura 25. Em especial, na Figura 26b, pode-se verificar os sinais obtidos na rede CAN: a posição absoluta do acelerador em porcentagem (%), a rotação do motor (dada em RPM), e a velocidade do carro (em km/h). Estes sinais possuem valores próprios, com suas próprias unidades e conforme apresentado anteriormente, possuem uma taxa de amostragem diferente do que os sinais obtidos pelo pedal do freio e de sEMG. Além disso, nota-se uma certa relação entre estes sinais e os obtidos da rede CAN do automóvel, pois referem-se a sua movimentação. Devido à complexidade destes sinais é que as estratégias de processamento devem ser direcionadas.

**Figura 26 – Exemplos de sinais em uma aquisição em modo calmo com os sinais de sEMG e do pedal do freio (a) e dos parâmetros obtidos da rede CAN (b).**

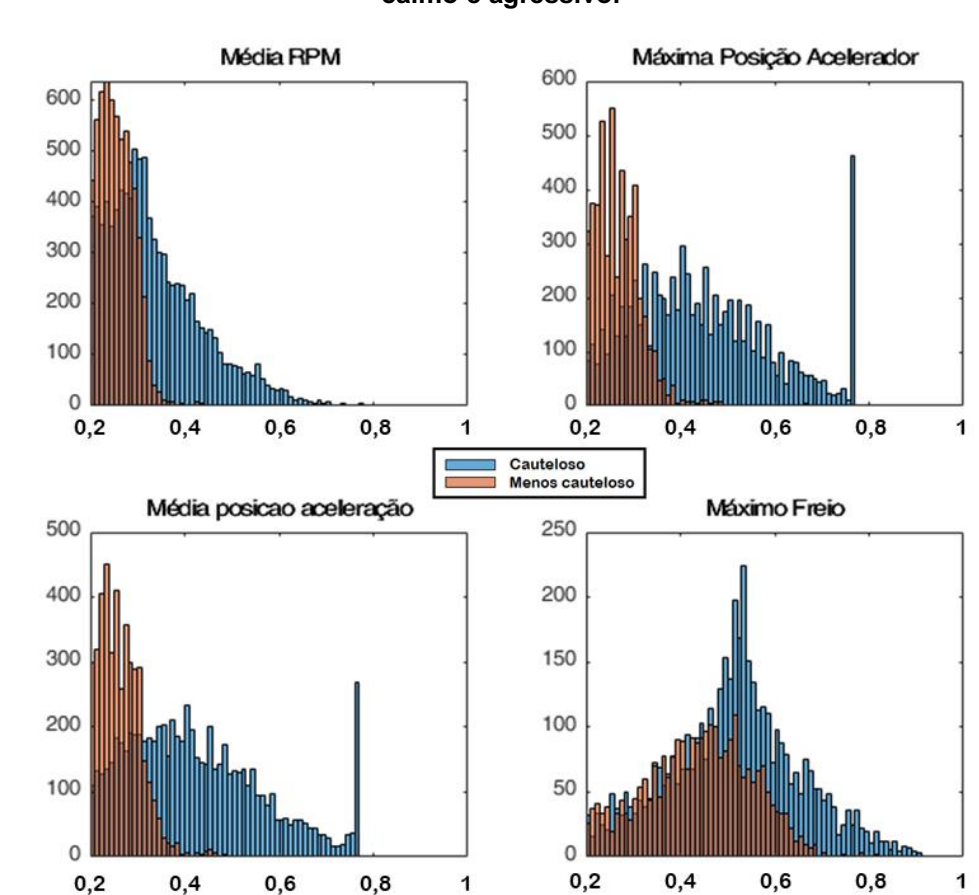


Fonte: Autoria própria (2021).

### 3.6 Avaliação estatística

Para poder avaliar a separabilidade e a dispersão dos atributos extraídos frente as classes, a Figura 27 apresenta a probabilidade de distribuição para as duas classes de comportamento (cauteloso e menos cauteloso) para a segunda aquisição. As características escolhidas para essa análise foram: a média do valor RPM obtido pela CAN, a máxima posição do acelerador, a média da posição do acelerador e a máxima posição do freio. Pode-se notar que para o comportamento adotado do tipo menos cauteloso, todos os valores possuem valores concentrados nas regiões de distribuição de probabilidade entre 0,2 a 0,4 (normalizado com o máximo), sendo que o comportamento cauteloso possui uma distribuição caudal mais longa, distribuída em torno de toda a concentração dos dados.

**Figura 27 - Distribuição de probabilidade para as características média RPM, máxima posição do acelerador, média posição de aceleração e máximo valor freio para os comportamentos calmo e agressivo.**



Fonte: Autoria própria (2021).

Assim, salienta-se a dificuldade de classificação por não haver margens claras de separação, ocasionando grande sobreposição entre as características para ambas as classes.

## 4 RESULTADOS E ANÁLISES

A apresentação dos resultados e análises está dividida para as duas fases, sendo a primeira com a utilização de sensores no condutor, e a segunda visando a utilização apenas de dados do veículo, ambas buscando avaliar comportamento do motorista.

A primeira fase teve por objetivo verificar se é possível correlacionar os dados coletados do condutor com os dados provenientes dos sensores do automóvel. Uma vez havendo uma alta correlação dos resultados entre estes dados, pode-se responder a primeira hipótese deste trabalho, a qual visa analisar se é possível avaliar o comportamento do motorista exclusivamente através de informações obtidas do veículo (nativas ou instrumentadas adicionalmente), e com isso não utilização de instrumentação no motorista (sem nada vestível e/ou coleta de sEMG), o que por si só dificultaria a aplicabilidade cotidiana do protótipo proposto.

Uma vez a primeira hipótese avaliada, a segunda fase contou com a inserção de um sensor na coluna do volante para monitorar o esterçamento deste e a instalação do sensor inercial próximo ao centro de massa do veículo, com objetivo de adicionar ao estudo informações de taxas de guinada (movimentação). Dessa forma, o processo de classificação foi direcionado à análise mais minuciosa dos dados obtidos a partir do veículo apenas. Os resultados apresentados a seguir são provenientes das análises realizadas com base nos procedimentos metodológicos descritos nas seções 3.2 e 3.3, e dão suporte para avaliação do atendimento, ou não, dos objetivos propostos neste trabalho.

### 4.1 Fase 1 – análise com sensores instrumentados no veículo e no condutor

Para a primeira análise com o objetivo de avaliar a possibilidade de identificação do perfil do motorista e a identidade do condutor, foram considerados os sinais obtidos na rede da CAN, do pedal do freio, sEMG e dos sensores inerciais inseridos na região do pé do condutor. Os diferentes conjuntos de atributos estão ilustrados na Tabela 6, na metodologia deste trabalho (seção 3.3, pág. 72), a qual está aqui replicada para uma melhor associação com os resultados.

**Tabela 6 – Conjuntos de atributos selecionados para avaliação da classificação da primeira análise.**

Teste N°	Origem:	Atributos selecionados:
1	Veículo	Velocidade
2	Veículo	RPM
3	Veículo	Velocidade + RPM
4	Veículo	Acelerador
5	Veículo	Velocidade + RPM + Acelerador
6	Veículo	Freio
7	Veículo	Velocidade + RPM + Acelerador + Freio
8	Veículo	Acelerador + Freio
9	Veículo	Acelerador + Freio (mediana)
10	Veículo	Velocidade + RPM + Acelerador + Freio (mediana)
11	Condutor	Inercial
12	Condutor	sEMG
13	Condutor	Inercial + sEMG
14	Veículo	Velocidade + RPM + Freio
15	Veículo + Condutor	Velocidade + RPM + Acelerador + Inercial + sEMG
16	Veículo + Condutor	Velocidade + RPM + Acelerador + Freio + Inercial + sEMG

Fonte: Autoria própria (2021).

A partir das combinações definidas organizou-se uma planilha com os valores de acurácia e especificidade para as simulações realizadas, mostrados na Tabela 9. São apresentados os dados de acurácia (A) e especificidade (S) na análise de identificação da identidade do condutor.

**Tabela 9 - Valores de acurácia (A) e especificidade (S) para os classificadores utilizados para identificação da identidade do motorista.**

Teste	Complex Tree		SVM Linear		Quadratic SVM		Fine k-NN		Bagged Tree	
	A	S	A	S	A	S	A	S	A	S
1	0,52	0,69	0,56	0,88	0,49	0,76	0,47	0,61	0,48	0,62
2	0,5	0,66	0,56	0,87	0,5	0,74	0,44	0,58	0,46	0,6
3	0,53	0,67	0,56	0,85	0,52	0,77	0,5	0,63	0,52	0,65
4	0,68	0,8	0,69	0,82	0,69	0,81	0,67	0,8	0,69	0,81
5	0,71	0,81	0,68	0,81	0,69	0,8	0,71	0,81	0,74	0,83
6	0,88	0,93	0,59	0,79	0,72	0,82	0,84	0,9	0,9	0,94
7	<b>0,92</b>	<b>0,95</b>	0,76	0,85	0,84	0,9	0,8	0,88	<b>0,92</b>	<b>0,96</b>
8	0,92	0,95	0,77	0,86	0,8	0,88	0,85	0,91	0,93	0,96
9	0,88	0,92	0,7	0,81	0,72	0,83	0,84	0,91	0,88	0,93
10	0,89	0,93	0,69	0,8	0,79	0,86	0,79	0,87	0,89	0,93
11	0,82	0,89	0,85	0,91	0,86	0,91	0,84	0,9	0,86	0,92
12	0,88	0,93	0,82	0,89	0,83	0,9	0,87	0,92	0,87	0,92
13	<b>0,95</b>	<b>0,97</b>	0,91	0,95	0,94	0,96	0,94	0,96	<b>0,96</b>	<b>0,98</b>
14	0,9	0,94	0,57	0,77	0,78	0,86	0,73	0,83	0,91	0,95
15	0,97	0,99	0,95	0,97	0,97	0,98	0,96	0,98	0,98	0,99
16	<b>0,98</b>	<b>0,99</b>	0,96	0,97	<b>0,98</b>	<b>0,99</b>	0,96	0,98	<b>0,99</b>	<b>0,99</b>

Fonte: Autoria própria (2021).

Foram destacados em negrito os classificadores que obtiveram melhor desempenho em 3 diferentes testes: somente dados do veículo (Teste 7), somente dados do condutor (Teste 13), e com todos os atributos (Teste 16). Dessa forma pode-se verificar a influência das *features* no resultado obtido.

Para os 3 testes, os classificadores baseados em árvores de decisão – *Complex Tree* e *Bagged Tree* - apresentaram os melhores valores de acurácia e especificidade, e quando testados todos os parâmetros os demais classificadores tiveram valores elevados, destacando-se o *SVM Quadratic* que ficou semelhante às árvores.

Na Tabela 10 são apresentados os dados de acurácia (A) e especificidade (S) na análise de identificação do comportamento do condutor.

**Tabela 10 - Valores de acurácia (A) e especificidade (S) para os classificadores utilizados para identificação do comportamento do motorista.**

Teste	<i>Complex Tree</i>		<i>SVM Linear</i>		<i>Quadratic SVM</i>		<i>Fine k-NN</i>		<i>Bagged Tree</i>	
	A	S	A	S	A	S	A	S	A	S
1	0,77	0,74	0,79	0,74	0,68	0,67	0,73	0,71	0,77	0,73
2	0,62	0,56	0,62	0,5	0,55	0,51	0,56	0,53	0,59	0,54
3	0,78	0,76	0,79	0,73	0,83	0,79	0,76	0,74	0,8	0,77
4	0,67	0,59	0,65	0,56	0,68	0,59	0,65	0,56	0,66	0,58
5	0,79	0,77	0,81	0,76	0,84	0,79	0,79	0,76	0,81	0,78
6	0,66	0,65	0,64	0,55	0,55	0,52	0,68	0,66	0,69	0,67
<b>7</b>	0,81	0,79	0,83	0,79	<b>0,86</b>	<b>0,83</b>	0,81	0,79	<b>0,84</b>	<b>0,82</b>
8	0,73	0,71	0,64	0,56	0,69	0,63	0,7	0,68	0,74	0,71
9	0,67	0,62	0,59	0,5	0,47	0,48	0,67	0,62	0,68	0,64
10	0,79	0,77	0,79	0,74	0,79	0,74	0,77	0,75	0,82	0,8
11	0,66	0,62	0,62	0,5	0,65	0,56	0,66	0,62	0,68	0,65
12	0,83	0,82	0,58	0,6	0,51	0,5	0,83	0,81	0,83	0,81
<b>13</b>	<b>0,87</b>	<b>0,86</b>	0,72	0,67	0,79	0,76	0,8	0,77	<b>0,89</b>	<b>0,87</b>
14	0,77	0,76	0,82	0,78	0,85	0,82	0,8	0,78	0,83	0,81
15	0,91	0,9	0,82	0,78	0,88	0,86	0,87	0,84	0,94	0,93
<b>16</b>	<b>0,9</b>	<b>0,89</b>	0,83	0,8	0,89	0,87	0,88	0,87	<b>0,93</b>	<b>0,92</b>

Fonte: Autoria própria (2021).

Na avaliação de comportamento, quando avaliados somente os parâmetros do veículo, o classificador *Quadratic SVM* teve desempenho levemente superior ao *Bagged Tree*. Já para os testes que avaliaram somente o condutor e a associação de todos os atributos, os classificadores baseados em árvore foram os que apresentaram melhor resultado.

Para melhor analisar esses resultados, 4 análises são apresentadas, comparando-os em relação à acurácia e especificidade para identificação da pessoa (motorista) ou do comportamento dele.

- a) Todos os atributos no processamento no reconhecimento da identidade do motorista e do seu comportamento;
- b) os atributos de entrada apenas com os dados do veículo no processamento;
- c) os atributos de entrada apenas com os dados do condutor no processamento;
- d) apenas os dados de EMG com os dados do condutor no processamento.

A primeira análise apresenta as acurácias e as especificidades para os três classificadores com maior acurácia considerando a utilização de todas os atributos de entrada (provenientes dos condutores e do veículo), ilustrada na Figura 28. Para a avaliação da identificação do indivíduo, nota-se que o uso de todos os atributos de entrada permite altas taxas de acerto, com valores acima de 0,95 (o que representa 95%) nos três classificadores. Com relação ao desempenho individual dos classificadores, nota-se que o primeiro destaque é o classificador do tipo *Bagged Tree*, possuindo as mais altas acurácias e especificidades. Sobre estas duas métricas, os sistemas que possuem especificidades maiores que as acurácias são capazes de melhor discernir as amostras entre as classes.

Com relação ao comportamento dos condutores utilizando todas as características, obteve-se semelhança do classificador com melhor desempenho, sendo este o classificador do tipo *Random Forest*, com máximas de 0,93 para o *Bagged Tree*. As acurácias nessa análise foram maiores que as especificidades, demonstrando que para a aplicação de análise de comportamento são mais sensíveis as ações das classes. O que se pode observar de uma forma geral é que para a aplicação envolvendo todas as *features*, os classificadores conseguem distinguir sem grandes diferenças tanto o comportamento quando o indivíduo.



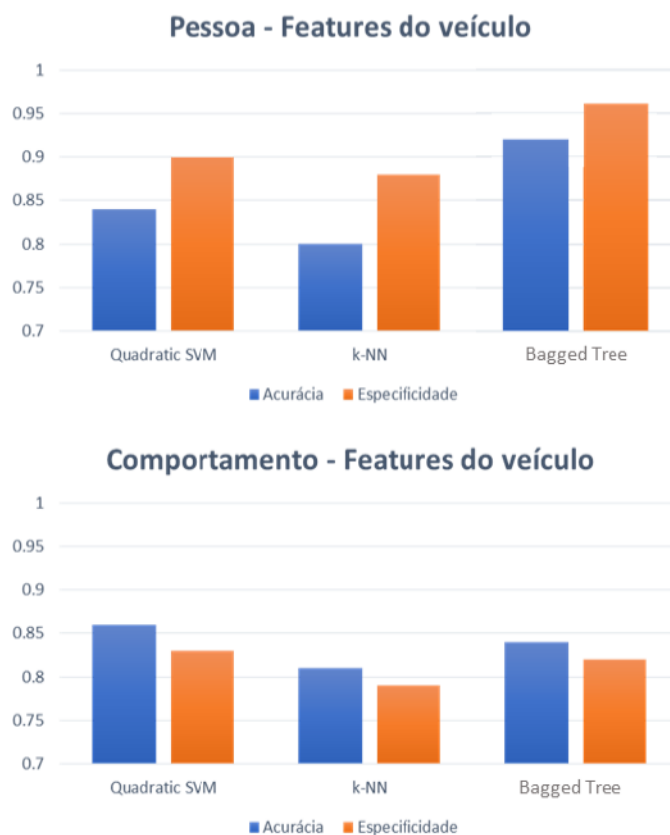
**Figura 28 – Resultados de acurácia e especificidade para os classificadores *Quadratic SVM*, *k-NN* e *Bagged Tree* para o caso envolvendo todas as características no processamento no reconhecimento da identidade do motorista e do seu comportamento.**



**Fonte: Autoria própria (2021).**

Na segunda análise foi relacionada à utilização de atributos pertencentes ao veículo, ou seja, os dados obtidos da rede CAN e do pedal do freio. Tanto para a classificação da identificação do condutor quanto do comportamento da direção, todos os classificadores, exceto um caso específico de *Bagged Tree* que foi superior, apresentaram acurácias e especificidades na faixa de 80 a 90%, abaixo da configuração anterior, como mostrado na Figura 29. O mesmo comportamento de acurácias e especificidade para as aplicações de reconhecimento de pessoas e do comportamento de condução se mantiveram as mesmas: há maior especificidade em reconhecer quem é o indivíduo do que identificar o padrão do seu comportamento.

**Figura 29 – Resultados de acurácia e especificidade para os classificadores *Quadratic SVM*, *k-NN* e *Bagged Tree* para o caso envolvendo os atributos de entrada apenas com os dados do veículo no processamento.**



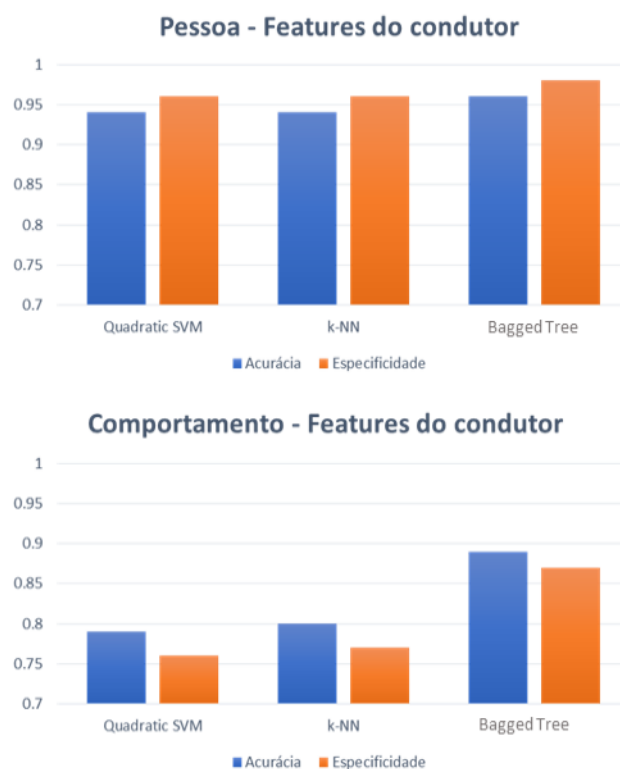
**Fonte: Autoria própria (2021).**

Neste caso, o melhor classificador para a aplicação de reconhecimento dos indivíduos foi o modelo de *Bagged Tree* e para identificar o comportamento dos condutores foi o classificador *Quadratic SVM*. Dessa forma, pode-se observar que apenas com os dados pertencentes ao veículo, como velocidade, rotação e posição dos pedais pode-se avaliar tanto o comportamento quanto o condutor.

Na terceira análise, com relação aos atributos pertencentes ao condutor, como os sinais adquiridos dos sensores de sEMG e dos sensores inerciais, tem as suas acurácias e especificidades apresentadas na Figura 30. Para a aplicação envolvendo a identificação do condutor, todos os classificadores apresentaram altas métricas superiores a 90%. Isso ocorre porque os sinais que são utilizados para o reconhecimento dos indivíduos são provenientes dos próprios condutores e parâmetros biológicos, como as características do sinal de sEMG e padrões da utilização dos sensores inerciais, podem ser captados e utilizados mais facilmente. Porém, com estes sinais, não é possível obter altas taxas de acerto para identificar o

comportamento do condutor, como é o caso da análise posterior. Pode-se perceber que apenas os modelos de *Bagged Tree* apresentaram taxas de acerto acima de 80% para a identificação do padrão de direção do condutor, como mostrado na Figura 30.

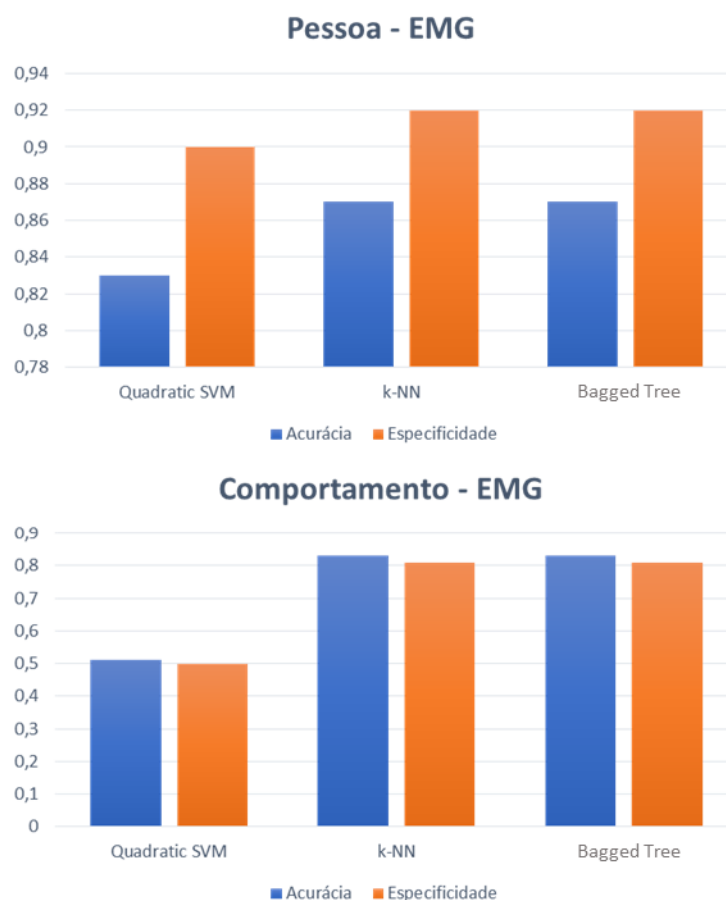
**Figura 30 – Resultados de acurácia e especificidade para os classificadores *Quadratic SVM*, *k-NN* e *Bagged Tree* para o caso envolvendo os atributos de entrada apenas com os dados do condutor no processamento.**



**Fonte: Autoria própria (2021).**

Na quarta e última análise, avaliou-se apenas a ação do sEMG, para a qual a Figura 31 apresenta as acurácias e as especificidades obtidas para os classificadores. Em um panorama geral, pode-se perceber que o apenas o sEMG não é um descritor que consiga taxas de acerto maiores que o uso dos conjuntos de atributos anteriores. Dessa forma, o sinal de sEMG pode ser utilizado em conjunto, mas não apenas sozinho. Com relação aos classificadores, *Bagged Tree* e *k-NN* apresentaram altas taxas de acerto, estando em casos empatados tanto para a análise da identidade dos condutores e o comportamento dos indivíduos.

**Figura 31 – Resultados de acurácia e especificidade para os classificadores *Quadratic SVM*, *k-NN* e *Bagged Tree* para o caso envolvendo apenas os dados de EMG com os dados do condutor no processamento.**



**Fonte: Autoria própria (2021).**

Avaliando os cenários e as escolhas de conjuntos de atributos dos condutores, dos veículos e dos classificadores, pode-se perceber que o classificador que venceu em um maior número de cenários foi o classificador *Bagged Tree*, baseado em modelos *Random Forest*, e dos classificadores escolhidos, o classificador *k-NN* apresentou as menores taxas de acerto (acurácia e especificidade). Sobre as informações disponíveis das características, percebe-se que mesmo avaliando as características presentes no veículo podem ser obtidas altas taxas de acerto para a identificação do condutor do veículo sem a necessidade da alocação de sensores no próprio motorista, como é o caso do sEMG e do sensor inercial.

A partir das Tabela 9 e Tabela 10 apresentadas com os resultados obtidos a partir de diferentes combinações de atributos de entrada nos classificadores, de onde foram extraídos os dados apresentados nos gráficos deste capítulo, pode-se verificar que os parâmetros quando analisados de forma individual não apresentam resultados

satisfatórios, porém quando combinados geram melhores taxas de classificação, por exemplo com os dados de acelerador e freio separados e posteriormente associados. Verifica-se também a influência positiva do sensor inercial instalado nas taxas de classificação, porém quando são analisados os dados do veículo e do freio associados são obtidas taxas satisfatórias apesar de inferiores.

#### 4.1.1 Considerações a respeito da Fase 1.

Ainda que os sinais do sEMG foram adquiridos, sua aquisição possui certa dificuldade devido ao posicionamento dos eletrodos e a sua orientação. Mesmo a sEMG oferecendo alta taxa de acerto para a identificação dos indivíduos, uma das contribuições deste trabalho está no reconhecimento de parâmetros individuais dos condutores (como quem é o condutor e o seu modo de direção) apenas com os dados obtidos do carro.

Além disso, em contraste com os demais trabalhos similares, nesta dissertação estão sendo aplicados ao processo de reconhecimento e classificação os sinais provenientes do pedal do freio, apresentando a importância do monitoramento deste dado de maneira analógica quando leva-se em conta a influência que proporciona na classificação.

Para análise do comportamento do condutor, que teve taxas menores de classificação comparadas as de identificação do motorista, verifica-se a possibilidade de realizar novas avaliações adicionais a partir da separação dos dados de cada condutor e, posteriormente, da classificação do seu modo de direção. Assim, espera-se que as taxas de classificação de comportamento sejam melhores.

Com a comparação dos dados obtidos nos Testes 7 e 16 – com atributos apenas do veículo (Velocidade + RPM + Acelerador + Freio) e com todos os atributos do estudo considerando veículo e condutor (Velocidade + RPM + Acelerador + Freio + Inercial + sEMG), respectivamente – pode-se verificar que nos dois testes as taxas de acurácia e especificidade obtidas para identificação do indivíduo foram superiores a 90% para o melhor classificador (*Bagged Tree*), e superiores a 80% na identificação do comportamento. Estes valores foram semelhantes aos obtidos também para o teste 12, onde foram analisados apenas dados do motorista (Inercial + sEMG). Apesar do resultado ser superior quando empregados todos os atributos na classificação, a

utilização apenas dos dados do veículo mostrou-se satisfatória, confirmando a correção dos atributos do veículo e do motorista, possibilitando assim, analisar com confiabilidade apenas os atributos do veículo para avaliar o comportamento do motorista.

Dessa forma, visando uma melhor aplicabilidade do estudo, focou-se no aprimoramento das análises de atributos e ferramentas de classificação de comportamento do motorista através de uma maior instrumentação do veículo, inserindo novos atributos e realizando coletas de dados com um protocolo experimental mais bem desenvolvido (fase 2).

#### 4.2 Fase 2 - análise com sensores instrumentados apenas no veículo

Após a verificação de que os sinais obtidos a partir do motorista podem ser suprimidos tanto para a identificação do perfil do comportamento e da identidade do motorista, foi avaliada a possibilidade de uso apenas dos sinais disponíveis no carro. Esse capítulo visa apresentar os resultados obtidos com essa análise.

Os diferentes conjuntos de atributos estão ilustrados na Tabela 8, na metodologia deste trabalho (seção 3.4, pág. 75), a qual está aqui replicada para uma melhor associação com os resultados.

**Tabela 8 – Conjunto de características selecionadas para avaliação da classificação na fase 2.**

Teste	Origem:	Atributos selecionados:
1	Veículo	Todas os atributos disponíveis (CAN + instrumentados)
2	Veículo	Parâmetros da CAN
3	Veículo	Parâmetros CAN + Freio + Volante
4	Veículo	Parâmetros CAN + Inerciais
5	Veículo	Freio + Volante

**Fonte: Autoria própria (2021).**

Foram aplicados os mesmos classificadores que os utilizados no capítulo anterior, porém com uma diferença relacionada à saída. A identificação teve como foco tanto identificar o perfil de comportamento, os condutores e uma junção entre identificar primeiramente quem é o condutor e posteriormente o seu comportamento. Na Tabela 11 são apresentados os dados obtidos a partir da análise do perfil de comportamento do motorista.

Tabela 11 - Valores de acurácia e especificidade para os classificadores utilizados para identificação do comportamento do motorista.

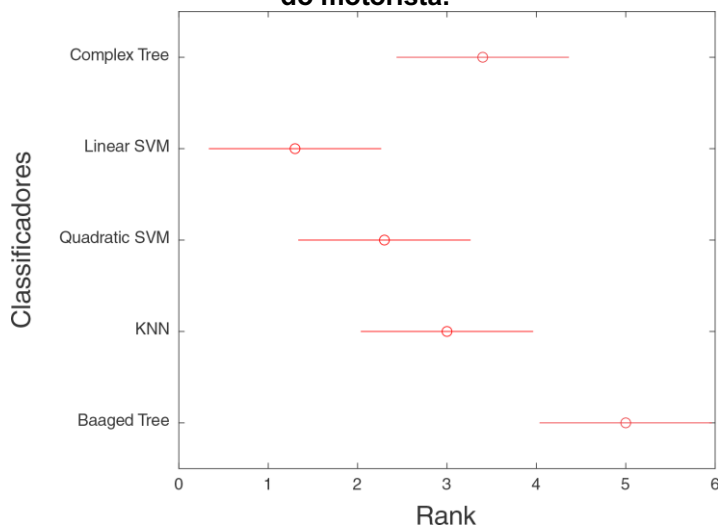
Teste	<i>Complex Tree</i>		<i>SVM Linear</i>		<i>Quadratic SVM</i>		<i>Fine k-NN</i>		<i>Bagged Tree</i>	
	A	S	A	S	A	S	A	S	A	S
1	<b>0,84</b>	<b>0,85</b>	0,81	0,82	<b>0,87</b>	<b>0,87</b>	0,82	0,83	<b>0,91</b>	<b>0,91</b>
2	0,8	0,8	0,72	0,73	0,42	0,42	0,77	0,77	0,81	0,81
3	<b>0,84</b>	<b>0,85</b>	0,8	0,8	<b>0,84</b>	<b>0,85</b>	0,85	0,85	<b>0,91</b>	<b>0,91</b>
4	0,83	0,84	0,8	0,8	0,85	0,86	0,81	0,81	0,89	0,89
5	0,65	0,65	0,55	0,5	0,5	0,48	0,58	0,58	0,73	0,72

Fonte: Autoria própria (2021).

Os resultados apresentados na Tabela 11 ilustram que o comportamento do motorista pôde ser classificado com acurácia superior a 90%, utilizando o classificador *Bagged Tree*, para as situações 1 e 3, para os quais, além dos parâmetros da CAN estão presentes o monitoramento do esterçamento do volante e do pedal de freio. Adicionalmente, percebe-se que somente estes dois parâmetros (Teste 5) não são suficientes para obter uma boa acuraria. Estes resultados indicam o quanto estes dois sinais são importantes para a classificação do comportamento do motorista, em especial o do pedal do freio, que não é um sinal comumente instrumentado e disponível nos veículos.

Posteriormente, foram avaliados os desempenhos dos diferentes classificadores empregados e dos diferentes conjuntos de *features* a partir do Teste estatístico de Friedman e, posteriormente, o Teste Post-hoc de Tukey, para verificação da equivalência entre eles. A Figura 32 apresenta a equivalência entre as distribuições dos resultados apresentados na Tabela 11. Pode-se perceber que os classificadores baseados em *SVM* foram os que apresentaram distribuições semelhantes com as menores acurácias. Os demais classificadores (*Random Forest: Complex Tree* e *Bagged Tree*) obtiveram distribuições semelhantes, como pode ser visto pela Figura 32, pois as distribuições dos seus postos são semelhantes. Nota-se uma leve acurácia superior do classificador *Complex Tree*, porém, seus postos são equivalentes ao *k-NN* e ao *Bagged Tree*.

**Figura 32 – Comparativo de desempenho dos classificadores para análise do comportamento do motorista.**



**Fonte: Autoria própria (2021).**

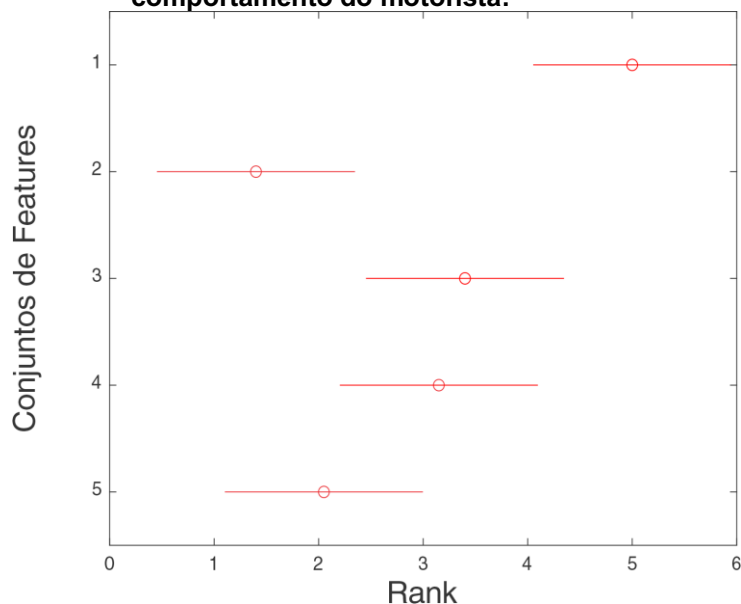
Com os mesmos dados das distribuições que forneceram os resultados da Tabela 11, foram avaliados os dados em função dos testes desenvolvidos. A Figura 33 apresenta o mesmo teste estatístico desenvolvido anteriormente com a análise dos grupos anteriormente mencionados. Como o Teste 1 apresentou os melhores desempenhos, retoma-se o fato de que estes dados se referem ao uso de todos os atributos para a classificação. Em função da semelhança das distribuições, pela Figura 33 pode-se perceber que as suas acurácias possuem as mesmas distribuições que os Testes 3 e 4, já que as suas distribuições dos seus postos do teste de Friedman são equivalentes. Os Testes 2 e 5 possuíam as menores acurácias (Tabela 11) e também distribuições com a média dos postos semelhantes.

Em relação ao melhor resultado (obtido com o Teste 1) referente ao comportamento do motorista, nota-se que a utilização de todas as características fornece uma maior quantidade de dados para a classificação e por isso a acurácia tende a um alto valor. Como a aquisição de diversas características pode se tornar impraticável, a redução da quantidade de *features* com distribuições similares em suas acurácias é um dos pontos de interesse nesse tipo de análise. Por isso, mesmo com uma leve diferença em suas acurácias em comparação com o Teste 1, os Testes 3 e 4 apresentaram postos com distribuições semelhantes, o que indica que a utilização de um destes testes em detrimento ao outro não acarreta significância estatística. E como se deseja uma menor quantidade de atributos, as análises envolvendo os dados



referentes a CAN, freio e volante possuem os mesmos resultados que todos os demais dados extraídos e analisados para verificação do comportamento do motorista.

**Figura 33 - Comparativo de desempenho dos conjuntos de *features* para análise do comportamento do motorista.**



Fonte: Autoria própria (2021).

Na Tabela 12 são apresentados os dados obtidos a partir da análise da identificação do motorista, para os conjuntos de atributos (testes) indicados na Tabela 8.

**Tabela 12 - Valores de acurácia e especificidade para os classificadores utilizados para identificação do motorista.**

Teste	<i>Complex Tree</i>		<i>SVM Linear</i>		<i>Quadratic SVM</i>		<i>Fine k-NN</i>		<i>Bagged Tree</i>	
	A	S	A	S	A	S	A	S	A	S
1	0,85	0,53	0,72	0,3	0,84	0,51	0,78	0,4	<b>0,94</b>	<b>0,74</b>
2	0,59	0,2	0,49	0,12	0,48	0,13	0,63	0,25	0,69	0,31
3	0,83	0,49	0,49	0,13	0,63	0,24	0,76	0,38	<b>0,93</b>	<b>0,73</b>
4	0,71	0,32	0,69	0,28	0,8	0,43	0,76	0,38	0,86	0,54
5	0,81	0,45	0,49	0,11	0,41	0,1	0,66	0,28	0,86	0,55

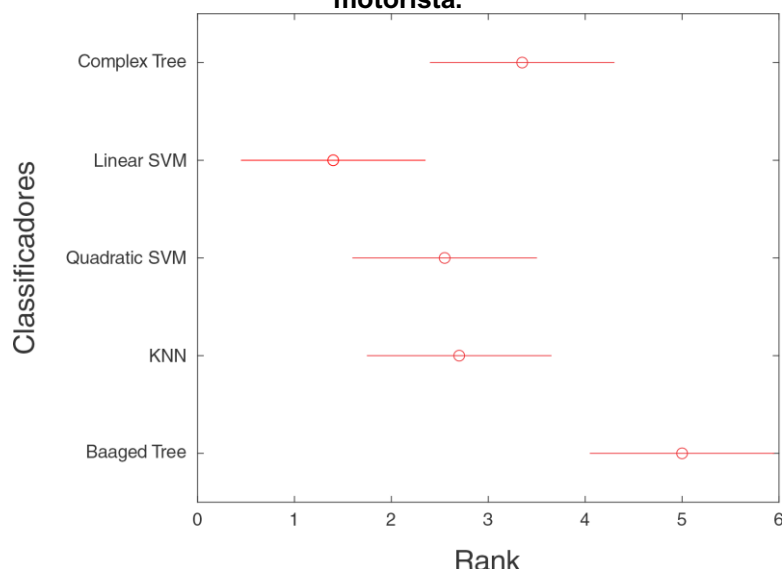
Fonte: Autoria própria (2021).

Ao analisar a Tabela 12, verifica-se que os dados analisados obtiveram acurácias superiores a 93% tanto para o Teste 1 quanto para o Teste 3, para os quais, além dos parâmetros da CAN estão presentes o monitoramento do esterçamento do

volante e do pedal de freio. De forma semelhante à análise de comportamento, apenas estes dois atributos não são suficientes para a classificação do motorista.

Para analisar se há significância estatística entre os classificadores para a identificação do motorista, a Figura 34 apresenta o diagrama obtido pela análise de post-hoc de Tuckey do teste de Friedman, verificando as relações existentes entre os classificadores. Como na Tabela 12, os classificadores *Complex Tree* e *Bagged Tree* apresentaram os melhores desempenhos (em especial o classificador *Bagged Tree*), percebe-se que pela Figura 34, seus postos possuem distribuições equivalentes. Os demais classificadores possuíram distribuições equivalentes entre si, exceto o classificador *Bagged Tree*.


**Figura 34 - Comparativo de desempenho dos classificadores para análise da identificação do motorista.**



Fonte: Autoria própria (2021).

O mesmo teste estatístico foi aplicado para a verificação dos conjuntos de dados para identificação do motorista, sendo apresentado na Figura 35. Pode-se perceber que a mesma tendência da Figura 33 foi alcançada, pois as maiores acurácias e os grupos com os postos que mais se destacam são aqueles que possuem os dados referente à condição do Teste 1. Porém, em relação aos postos, percebe-se que o Teste 3 possui distribuições similares com o Teste 1, apresentando que a utilização dos sinais provenientes da rede CAN, do freio e do volante são capazes de identificar os motoristas com a mesma precisão que a utilização da extração de todos os parâmetros, conforme apresentado anteriormente.

**Figura 35 – Comparativo de desempenho dos conjuntos para análise da identificação do motorista.**



**Fonte: Autoria própria (2021).**

Por último, analisou-se a classificação de reconhecimento do motorista e do comportamento, de forma simultânea. A Tabela 13 apresenta os valores de acurácia obtidos a partir da análise do comportamento do motorista quando associados dois fatores, primeiramente a identificação do motorista e, posteriormente, o seu comportamento. Foi empregado nesta análise o classificador *Bagged Tree*, que obteve o melhor desempenho dentre os 5 utilizados nesta análise.

**Tabela 13 - Valores de acurácia para o comportamento dos motoristas por meio do sistema de reconhecimento de motorista e de comportamento simultaneamente.**

Teste	Acurácia
1	0,993
2	0,970
3	0,992
4	0,986
5	0,972

**Fonte: Autoria própria (2021).**

Pode-se verificar que para todos os conjuntos houve um resultado satisfatório, com valor de acurácia superior a 0,97 em todos os testes, e superior a 99% quando volante e freio são monitorados em conjunto com os outros parâmetros da CAN. Dessa forma, a identificação prévia do condutor e posteriormente a classificação de seu comportamento mostrou-se um método eficaz de análise.

## 5 CONCLUSÕES

Este trabalho teve como objetivo inicial avaliar o monitoramento de variáveis veiculares e instrumentação automotiva para verificar padrões de comportamento de motoristas. Esta tarefa possui sua importância para o desenvolvimento de estratégias e plataformas de auxílio ao condutor, pois identificando o perfil de condução e o condutor, pode-se aumentar a segurança tanto veicular quanto do condutor e passageiros. Para isso, três hipóteses foram testadas.

Para responder a primeira hipótese, que questionava ser possível identificar o comportamento do motorista através de dados já intrínsecos aos veículos modernos (através no monitoramento da rede CAN), os movimentos do pé direito do motorista foram instrumentados e uma plataforma de monitoramento da rede CAN foi utilizada. Dessa forma, a verificação dos dados pertencentes exclusivamente ao motorista ou do veículo pode ser averiguada, indicando uma relação existente entre elas e a não exigência da instrumentação do motorista. Os resultados obtidos apontaram uma acurácia superior a 90% após a aplicação de diferentes técnicas de reconhecimento de padrões.

A segunda hipótese respondida neste trabalho era referente à relevância dos dados existentes da rede CAN em comparação aos dados não comumente existentes (a citar, o monitoramento contínuo do pedal de freio). Nessa análise, instrumentou-se o pedal de freio de um veículo e também se monitoraram os movimentos de esterçamento do volante e de guinada do veículo através de sensores externos à CAN. Um novo protocolo experimental foi desenvolvido para que as ações de direção mais claras e controladas fossem realizadas e, novamente, os dados foram submetidos às técnicas de reconhecimento de padrões. Os resultados ilustraram que o classificador *Bagged Tree* obteve o melhor desempenho, com acurácias acima de 90%, para dois panoramas, os quais continham parâmetros monitorados pela rede CAN, pelo esterçamento do volante e do pedal do freio. Por meio destes resultados, foi confirmada a importância destes sensores.

A terceira hipótese relacionava a possibilidade de identificar o motorista e o seu respectivo comportamento durante o processo de condução. Neste processo, os resultados apresentaram acurácias superiores a 90% para os panoramas em que, além dos dados monitorados da rede CAN, também o esterçamento do volante e o monitoramento do pedal de freio foram incluídos no reconhecimento de padrões.

Também foi avaliada a precisão do sistema de identificação do motorista baseado em seu comportamento por meio de uma análise conjunta em que ocorreu, em um primeiro momento, a classificação baseada na identificação do motorista e, em sequência, a classificação de seu comportamento. Esta análise apresentou acurácias superiores a 97%, sendo que para os casos onde estão presentes o monitoramento do volante e do pedal de freio, o sistema de reconhecimento atingiu acurácias superiores a 99,2%.

A partir da avaliação dos resultados obtidos, verificou-se a importância da instrumentação do pedal do freio e utilização dos dados por ele fornecidos para análises complementares. Além disso, o reconhecimento de padrões empregado para identificação do modo de condução se mostrou uma ferramenta eficaz, que pode ser implementada em sistemas embarcados nos automóveis.

As principais limitações encontradas na execução deste trabalho foram a dificuldade de obtenção de alguns dados da CAN devido à codificação do fabricante do veículo, sendo necessária a instrumentação adicional do volante e da utilização do sensor inercial, e a impossibilidade de realização de testes e coletas de dados em trechos de rua por questões de segurança, que traria um caráter mais natural de condução cotidiana se comparado ao ambiente controlado.

Como trabalhos futuros, sugere-se a análise pormenorizada da atuação do pedal de freio em relação a outros parâmetros, bem como avaliar outros padrões de comportamento e outros classificadores. Ainda pode-se realizar a instalação de outros sensores, câmeras por exemplo, e a utilização de uma maior quantidade de dados já disponibilizados na CAN para análise dos padrões de interesse.

## REFERÊNCIAS

- AAA FOUNDATION FOR TRAFFIC SAFETY. **Prevalence of Self-Reported Aggressive Driving Behavior**: United States. 2014. Disponível em: <https://aaafoundation.org/wp-content/uploads/2017/12/Prevalence-of-Aggressive-Drivig-2014.pdf>. Acesso em: 20 jan. 2020.
- AHMAD, U. *et al.* Securing smart vehicles from relay attacks using machine learning. **The Journal of Supercomputing**, v. 76, n. 4, p. 2665–2682, abr. 2020.
- ALSHAQAQI, B. *et al.* Vision based system for driver drowsiness detection. In: 2013 11th International Symposium on Programming and Systems (ISPS), abr. 2013, Algiers, Algeria. **Anais eletrônicos [...]**. Algiers, Algeria: IEEE, abr. 2013. p. 103–108. Disponível em: <https://ieeexplore.ieee.org/document/6581501/>. Acesso em: 31 out. 2021.
- ANGKITITRAKUL, P. *et al.* Evaluation of driver-behavior models in real-world car-following task. In: 2009 IEEE International Conference on Vehicular Electronics and Safety (ICVES), 2009, Pune, India. **Anais eletrônicos [...]**. Pune, India: IEEE, 2009. p. 113–118. Disponível em: <http://ieeexplore.ieee.org/document/5400201/>. Acesso em: 31 out. 2021.
- ANWARY, A. R.; YU, H.; VASSALLO, M. Optimal Foot Location for Placing Wearable IMU Sensors and Automatic Feature Extraction for Gait Analysis. **IEEE Sensors Journal**, v. 18, n. 6, p. 2555–2567, 15 mar. 2018.
- BOSCH SENSORTEC. **BMI160 Small, low power inertial measurement unit**. 2018. Disponível em: <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bmi160-ds000.pdf>. Acesso em: 17 mar. 2020.
- BOSCH SENSORTEC. **BMI270 6-axis, smart, low-power inertial measurement unit for high-performance applications**. 2019. Disponível em: <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bmi270-ds000-2.pdf>. Acesso em: 17 mar. 2020.
- BRASIL. **Lei n. 11.910, de 18 de março de 2009**. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/\\_ato2007-2010/2009/lei/l11910.htm](https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/lei/l11910.htm). Acesso em: 16 ago. 2020.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- BRUCE, A.; BRUCE, P. **Estatística Prática Para Cientistas de Dados: 50 Conceitos Essenciais**. Editora Alta Books, 2019.
- CARR, J. J.; BROWN, J. M. **Introduction to Biomedical Equipment Technology**. 4. ed. Upper Saddle River, New Jersey: Prentice Hall, 2001.
- CHEN, C. T.; CHEN, Y. S. Real-time approaching vehicle detection in blind-spot area. In: 2009 12th International IEEE Conference on Intelligent Transportation

Systems (ITSC), out. 2009, St. Louis. **Anais eletrônicos [...]**. St. Louis: IEEE, out. 2009. p. 1–6. Disponível em: <http://ieeexplore.ieee.org/document/5309876/>. Acesso em: 31 out. 2021.

CHOWDHURY, R. H. *et al.* Surface Electromyography Signal Processing and Classification Techniques. **Sensors**, v. 13, n. 9, p. 12431–12466, 17 set. 2013. Disponível em: <http://www.mdpi.com/1424-8220/13/9/12431>. Acesso em: 20 ago. 2020.

CIBERLIN, J. *et al.* Object detection and object tracking in front of the vehicle using front view camera. In: 2019 Zooming Innovation in Consumer Technologies Conference (ZINC), maio 2019, Novi Sad, Serbia. **Anais eletrônicos [...]**. Novi Sad, Serbia: IEEE, maio 2019. p. 27–32. Disponível em: <https://ieeexplore.ieee.org/document/8769367/>. Acesso em: 31 out. 2021.

COHEN, A. Biomedical Signals: Origin and Dynamic Characteristics; Frequency-Domain Analysis. In: BRONZINO, J. D. **Biomedical Engineering Handbook**. Boca Raton, Florida: CRC Press, 2000. v. 1. p. 3189.

CONTRAN. **Resolução n. 311, de 03 de abril de 2009**. Disponível em: [https://www.gov.br/infraestrutura/pt-br/assuntos/transito/conteudo-contran/resolucoes/resolucao\\_contran\\_311\\_09.pdf](https://www.gov.br/infraestrutura/pt-br/assuntos/transito/conteudo-contran/resolucoes/resolucao_contran_311_09.pdf). Acesso em: 16 ago. 2020.

DARIUS, J. P. **O impacto das políticas públicas sobre o portfólio da Volkswagen Brasil no primeiro mandato da presidente Dilma Rousseff**. 2015. 55 f. UFRGS, Porto Alegre, 2015.

DE FABRITIIS, C.; RAGONA, R.; VALENTI, G. Traffic Estimation And Prediction Based On Real Time Floating Car Data. In: 2008 11th International IEEE Conference on Intelligent Transportation Systems (ITSC), out. 2008, Beijing, China. **Anais eletrônicos [...]**. Beijing, China: IEEE, out. 2008. p. 197–203. Disponível em: <http://ieeexplore.ieee.org/document/4732534/>. Acesso em: 31 out. 2021.

DE LUCA, C. Electromyography. In: WEBSTER, J. G. **Encyclopedia of Medical Devices and Instrumentation**. 2. ed. New York: John Wiley Publisher, 2006. v. 2. p. 3666.

DE LUCA, C. J. The Use of Surface Electromyography in Biomechanics. **Journal of Applied Biomechanics**, v. 13, p. 135–163, 1997.

DETRAN-PR. **Frota de veículos cadastrados por município e tipo, Paraná - posição em dezembro - 2019**. Disponível em: [http://www.detran.pr.gov.br/sites/default/arquivos\\_restritos/files/documento/2020-01/frota\\_dezembro\\_de\\_2019.pdf](http://www.detran.pr.gov.br/sites/default/arquivos_restritos/files/documento/2020-01/frota_dezembro_de_2019.pdf). Acesso em: 16 ago. 2020.

FELIPE ADALBERTO FARINELLI. **Sistema de aquisição e classificação de dados para reconhecimento da presença das mãos do motorista no volante por redes neurais artificiais**. Dissertação (mestrado) - Mestrado em Engenharia Elétrica, UTFPR, Ponta Grossa, 2019.

FERREIRA, J. *et al.* Driver behavior profiling: An investigation with different smartphone sensors and machine learning. **PLOS ONE**, v. 12, n. 4, p. e0174959, 10 abr. 2017.

FILEV, D. *et al.* Real-time driver characterization during car following using stochastic evolving models. In: 2011 IEEE International Conference on Systems, Man and Cybernetics - SMC, out. 2011, Anchorage, AK, USA. **Anais eletrônicos [...]**. Anchorage, AK, USA: IEEE, out. 2011. p. 1031–1036. Disponível em: <http://ieeexplore.ieee.org/document/6083810/>. Acesso em: 31 out. 2021.

FU LI *et al.* Dangerous driving behavior detection using smartphone sensors. In: 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC), nov. 2016, Rio de Janeiro, Brazil. **Anais eletrônicos [...]**. Rio de Janeiro, Brazil: IEEE, nov. 2016. p. 1902–1907. Disponível em: <http://ieeexplore.ieee.org/document/7795864/>. Acesso em: 14 dez. 2020.

FUE, K. *et al.* An Extensive Review of Mobile Agricultural Robotics for Field Operations: Focus on Cotton Harvesting. **AgriEngineering**, v. 2, n. 1, p. 150–174, 4 mar. 2020.

GÉRON, A. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow**. 1ª ed. Editora Alta Books, 2019.

HAKONEN, M.; PIITULAINEN, H.; VISALA, A. Current state of digital signal processing in myoelectric interfaces and related applications. **Biomedical Signal Processing and Control**, v. 18, p. 334–359, abr. 2015. Disponível em: <http://www.sciencedirect.com/science/article/pii/S174680941500021X>. Acesso em: 20 jul. 2020.

HALLAC, D. *et al.* Driver Identification Using Automobile Sensor Data from a Single Turn. **arXiv e-prints**, p. arXiv: 1708.04636, 2017. Disponível em: <http://arxiv.org/abs/1708.04636>. Acesso em: 14 dez. 2020.

HOFFMAN, J. I. E. Analysis of Variance. II. More Complex Forms. **Basic Biostatistics for Medical and Biomedical Practitioners**. Elsevier, 2019. p. 419–441. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/B9780128170847000267>. Acesso em: 13 jan. 2022.

HØYE, A. The effects of Electronic Stability Control (ESC) on crashes—An update. **Accident Analysis & Prevention**, v. 43, n. 3, p. 1148–1159, maio 2011.

HUANG, J.; LUO, X.; PENG, X. A Novel Classification Method for a Driver's Cognitive Stress Level by Transferring Interbeat Intervals of the ECG Signal to Pictures. **Sensors**, v. 20, n. 5, p. 1340, 29 fev. 2020.

HUDGINS, B.; PARKER, P.; SCOTT, R. N. A new strategy for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, v. 40, n. 1, p. 82–94, jan. 1993.

IBGE. **Cidades e Estados**. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/pr.html>. Acesso em: 16 ago. 2020.



INVENSENSE. **ICM-20649 World's First Wide-Range 6-Axis MEMS MotionTracking™ Device for Sports and High Impact Applications**. 2016. Disponível em: <https://invensense.tdk.com/wp-content/uploads/2016/06/DS-000192-ICM-20649-v1.0.pdf>. Acesso em: 17 mar. 2020 (a).

INVENSENSE. **ICM-30670 World's First Dual Interface Optical Image Stabilization (OIS) and 6-axis Motion Tracking Solution**. 2016. Disponível em: <https://invensense.tdk.com/wp-content/uploads/2015/12/DS-000129-ICM-30670-TYP-v1.0-3.pdf>. Acesso em: 17 mar. 2020 (b).

INVENSENSE. **MPU-6000 and MPU-6050 Product Specification Revision 3.4**. 2016. Disponível em: <https://www.invensense.com/wp-content/uploads/2015/02/MPU-6000-Datasheet1.pdf>. Acesso em: 26 set. 2019 (c).

INVENSENSE. **MPU-9250 Product Specification Revision 1.1**. 2016. Disponível em: <https://invensense.tdk.com/wp-content/uploads/2015/02/PS-MPU-9250A-01-v1.1.pdf>. Acesso em: 17 mar. 2020 (d).

IPEA. **Atlas da Violência - Óbitos em acidentes de transporte**. Disponível em: <https://www.ipea.gov.br/atlasviolencia/dados-series/85>. Acesso em: 16 ago. 2020 (a).

IPEA. **Custos dos acidentes de trânsito no Brasil: estimativa simplificada com base na atualização das pesquisas do IPEA sobre custos de acidentes nos aglomerados urbanos e rodovias**. 2020. Disponível em: [https://www.ipea.gov.br/portal/images/stories/PDFs/TDs/td\\_2565.pdf](https://www.ipea.gov.br/portal/images/stories/PDFs/TDs/td_2565.pdf). Acesso em: 16 ago. 2020 (b).

OBUHUMA, J.; OKOYO, H.; MCOYOWO, S. Real-time Driver Advisory Model: Intelligent Transportation Systems. In: **2018 IST-Africa Week Conference (IST-Africa)**. IEEE, 2018. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8417372>. Acesso em: 20 set. 2021.

KAMEN, G.; GABRIEL, D. **Fundamentos da Eletromiografia**. 1ª ed. São Paulo: Phorte Editora, 2015.

KHAN, M. Q.; LEE, S. A Comprehensive Survey of Driving Monitoring and Assistance Systems. **Sensors**, v. 19, n. 11, p. 2574, 6 jun. 2019.

KIM, B.; BAEK, Y. NETTED: Non-Standard CAN ID Extraction System Based on Deep Neural Networks. In: 2018 IEEE 3rd International Conference on Communication And Information Systems (ICCIS), dez. 2018, Singapore, Singapore. **Anais eletrônicos [...]**. Singapore, Singapore: IEEE, dez. 2018. p. 198–202. Disponível em: <https://ieeexplore.ieee.org/document/8644958/>. Acesso em: 31 out. 2021.

KOUTROUMBAS, K.; THEODORIDIS, S. **Pattern Recognition**. 4ª ed. Academic Press, 2008.

KUGE, N. *et al.* A Driver Behavior Recognition Method Based on a Driver Model Framework. **SAE transactions**, p. 469-476, 2000. Disponível em: <https://www.sae.org/content/2000-01-0349/>. Acesso em: 31 out. 2021.

LAKE, D. E. *et al.* Sample entropy analysis of neonatal heart rate variability. **American Journal of Physiology-Regulatory, Integrative and Comparative Physiology**, v. 283, n. 3, p. R789–R797, 1 set. 2002.

LEEN, G.; HEFFERNAN, D.; DUNNE, A. Digital networks in the automotive vehicle. **Computing & Control Engineering Journal**, v. 10, n. 6, p. 257–266, 1 dez. 1999.

LI, N.; JAIN, J. J.; BUSSO, C. Modeling of Driver Behavior in Real World Scenarios Using Multiple Noninvasive Sensors. **IEEE Transactions on Multimedia**, v. 15, n. 5, p. 1213–1225, ago. 2013.

LIU, L.; WANG, Z.; QIU, S. Driving Behavior Tracking and Recognition Based on Multisensors Data Fusion. **IEEE Sensors Journal**, v. 20, n. 18, p. 10811–10823, 15 set. 2020.

LORENA, A. C.; DE CARVALHO, A. C. P. L. F. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 20 dez. 2007.

LU, J. *et al.* From vehicle stability control to intelligent personal minder: Real-time vehicle handling limit warning and driver style characterization. In: 2009 IEEE Workshop on Computational Intelligence in Vehicles and Vehicular Systems (CIVVS), mar. 2009, Nashville, TN, USA. **Anais eletrônicos [...]**. Nashville, TN, USA: IEEE, mar. 2009. p. 43–50. Disponível em: <https://ieeexplore.ieee.org/document/4938722>. Acesso em: 31 out. 2021.

LYNCH, K.; MARCHUK, N.; ELWIN, M. **Embedded computing and mechatronics with the PIC32 microcontroller**. Newnes, 2015 .

MATHWORKS. **FITCTREE**. 2021. Disponível em: <https://www.mathworks.com/help/stats/fitctree.html>. Acesso em: 30 ago. 2021.

MCCALL, J. C.; TRIVEDI, M. M. Driver Behavior and Situation Aware Brake Assistance for Intelligent Vehicles. **Proceedings of the IEEE**, v. 95, n. 2, p. 374–387, fev. 2007.

MELO, V. A. D. O automóvel, o automobilismo e a modernidade no Brasil (1891-1908). **Revista Brasileira de Ciências do Esporte**, v. 30, n. 1, p. 201–203, 2008.

MENDES JUNIOR, J. J. A. *et al.* Feature selection and dimensionality reduction: An extensive comparison in hand gesture classification by sEMG in eight channels armband approach. **Biomedical Signal Processing and Control**, v. 59, p. 101920, 1 maio 2020. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1746809420300768>. Acesso em: 15 mar. 2020.

MERLETTI, R.; HERMENS, H. J. Detection and Conditioning of the Surface EMG Signal. In: MERLETTI, R.; PARKER, P. **Electromyography: Physiology, Engineering, and Noninvasive Applications**. Piscataway, New Jersey: John Wiley & Sons, 2004. p. 494.

MERLETTI, ROBERTO; FARINA, D. (Org.). **Surface Electromyography: Physiology, Engineering, and Applications**. 1<sup>a</sup> ed. Wiley-IEEE Press, 2016.

MÜHLBACHER-KARRER, S. *et al.* A wireless steering wheel gripping sensor for hands on/off detection. In: **2016 IEEE Sensors Applications Symposium (SAS)**. IEEE, 2016. p. 1-5.

NAJARIAN, K.; SPLINTER, R. **Biomedical signal and image processing**. 2. ed. Florida, US: CRC Press, 2012.

NAZMI, N. *et al.* A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions. **Sensors**, v. 16, n. 8, p. 1304, 17 ago. 2016. Disponível em: <http://www.mdpi.com/1424-8220/16/8/1304>. Acesso em: 18 ago. 2020.

NHTSA. **Distracted Driving in Fatal Crashes**, 2017. Disponível em: <https://crashstats.nhtsa.dot.gov/Api/Public/ViewPublication/812700>. Acesso em: 20 jan. 2020.

NHTSA. **Fatalities in Frontal Crashes Despite Seat Belts and Air Bags**. Disponível em: <https://crashstats.nhtsa.dot.gov/Api/Public/ViewPublication/811102>. Acesso em: 15 maio 2020 (a).

NHTSA. **The Long-Term Effect of ABS in Passenger Cars and LTVs**. Disponível em: <https://crashstats.nhtsa.dot.gov/Api/Public/ViewPublication/811182>. Acesso em: 15 maio 2020 (b).

NXP SEMICONDUCTORS. **MMA7361LC -  $\pm 1.5g$ ,  $\pm 6g$  Three Axis Low-g Micromachined Accelerometer**. 2011. Disponível em: <https://www.nxp.com/docs/en/data-sheet/MMA7361LC.pdf>. Acesso em: 17 mar. 2020.

NXP SEMICONDUCTORS. **MMA7455L -  $\pm 2g/\pm 4g/\pm 8g$  Three Axis Low-g Digital Output Accelerometer**. 2009. Disponível em: <https://www.nxp.com/docs/en/data-sheet/MMA7455L.pdf>. Acesso em: 17 mar. 2020.

NXP SEMICONDUCTORS. **MMA8452Q 3-axis, 12-bit/8-bit digital accelerometer**. 2016. Disponível em: <https://www.nxp.com/docs/en/data-sheet/MMA8452Q.pdf>. Acesso em: 17 mar. 2020.

ONE TECHNOLOGY WAY. **ADXL - Small, Low Power, 3-Axis  $\pm 3g$  Accelerometer**. 2009. Disponível em: <https://www.sparkfun.com/datasheets/Components/SMD/adxl335.pdf>. Acesso em: 17 mar. 2020.

PEASE, W. S. Johnson. **Eletromiografia Prática**. 4<sup>a</sup> ed. Di Livros, 2008.

PETRAKI, V.; ZIAKOPOULOS, A.; YANNIS, G. Combined impact of road and traffic characteristic on driver behavior using smartphone sensor data. **Accident Analysis & Prevention**, v. 144, p. 105657, set. 2020.

PHINYOMARK, A. *et al.* EMG feature evaluation for improving myoelectric pattern recognition robustness. **Expert Systems with Applications**, v. 40, n. 12, p. 4832–4840, set. 2013.

PHINYOMARK, A.; N. KHUSHABA, R.; SCHEME, E. Feature Extraction and Selection for Myoelectric Control Based on Wearable EMG Sensors. **Sensors**, v. 18, n. 5, p. 1615, 18 maio 2018.

PHINYOMARK, A.; PHUKPATTARANONT, P.; LIMSAKUL, C. Feature reduction and selection for EMG signal classification. **Expert Systems with Applications**, v. 39, n. 8, p. 7420–7431, jun. 2012.

REBOLLEDO-MENDEZ, G. *et al.* Developing a Body Sensor Network to Detect Emotions During Driving. **IEEE Transactions on Intelligent Transportation Systems**, v. 15, n. 4, p. 1850–1854, ago. 2014.

REPPICH, A.; WILLIG, R. Yaw Rate Sensor for Vehicle Dynamics Control System. In: International Congress & Exposition. **SAE Technical Paper 950537**, 1 fev. 1995. Disponível em: <https://www.sae.org/content/950537/>. Acesso em: 20 nov. 2021.

RICHARDS, P. **A CAN Physical Layer Discussion**. p. 12, 2002. Disponível em: <https://ww1.microchip.com/downloads/en/appnotes/00228a.pdf>. Acesso em 17 mar. 2020.

RODRIGUES, J. G. P. *et al.* A non-intrusive multi-sensor system for characterizing driver behavior. In: 2010 13Th International IEEE Conference on Intelligent Transportation Systems - (ITSC 2010), set. 2010, Funchal, Madeira Island, Portugal. **Anais eletrônicos [...]**. Funchal, Madeira Island, Portugal: IEEE, set. 2010. p. 1620–1624. Disponível em: <http://ieeexplore.ieee.org/document/5625250/>. Acesso em: 14 dez. 2020.

SATHYANARAYANA, A. *et al.* Body sensor networks for driver distraction identification. In: 2008 IEEE International Conference on Vehicular Electronics and Safety (ICVES 2008), set. 2008, Columbus, OH. **Anais eletrônicos [...]**. Columbus, OH: IEEE, set. 2008. p. 120–125. Disponível em: <http://ieeexplore.ieee.org/document/4640876/>. Acesso em: 13 jan. 2022.

SEDRA, A. S.; SMITH, K. C. **Microeletrônica**. 5ª ed. Pearson Universidades, 2007.

SHI, Y.; SHI, Y.; WANG, X. Inertial Body-Worn Sensor Data Segmentation by Boosting Threshold-Based Detectors. In: 2012 16th Annual International Symposium on Wearable Computers (ISWC), jun. 2012, Newcastle, United Kingdom. **Anais eletrônicos [...]**. Newcastle, United Kingdom: IEEE, jun. 2012. p. 114–115. Disponível em: <http://ieeexplore.ieee.org/document/6246155/>. Acesso em: 15 dez. 2019.

SOLNIK, S. *et al.* Teager–Kaiser energy operator signal conditioning improves EMG onset detection. **European Journal of Applied Physiology**, v. 110, n. 3, p. 489–498, out. 2010.

SONG, H. M.; KIM, H. K. Discovering CAN Specification Using On-Board Diagnostics. **IEEE Design & Test**, v. 38, n. 3, p. 93–103, jun. 2021.

STMICROELECTRONICS. **LSM6DSOX - iNEMO inertial module: always-on 3D accelerometer and 3D gyroscope**. 2019. Disponível em: <https://www.st.com/resource/en/datasheet/lsm6dsox.pdf>. Acesso em: 17 mar. 2020.

THEODORIDIS, S. *et al.* **Introduction to Pattern Recognition: A Matlab Approach**. 1ª ed. Burlington, MA: Academic Press, 2010.

TRAN, C.; DOSHI, A.; TRIVEDI, M. M. Modeling and prediction of driver behavior by foot gesture analysis. *Computer Vision and Image Understanding, Special issue on Semantic Understanding of Human Behaviors in Image Sequences*. v. 116, n. 3, p. 435–445, 1 mar. 2012.

ZIEBINSKI, A. *et al.* Review of advanced driver assistance systems (ADAS). In: *Proceedings of The International Conference of Computational Methods in Sciences and Engineering 2017 (ICCMSE-2017)*, 2017, Thessaloniki, Greece. **Anais eletrônicos [...]**. Thessaloniki, Greece: [s.n.], 2017. p. 120002. Disponível em: <http://aip.scitation.org/doi/abs/10.1063/1.5012394>. Acesso em: 13 dez. 2020.