



DANNYLO WITHOR PEREIRA NOGUEIRA

**SISTEMA EMBARCADO DE BAIXO CUSTO PARA
DETECÇÃO DE MANOBRAS SINUOSAS EM VEÍCULOS POR
MEIO DE SENSORES INERCIAIS E GNSS**

LAVRAS – MG

2020

DANNYLO WITHOR PEREIRA NOGUEIRA

**SISTEMA EMBARCADO DE BAIXO CUSTO PARA DETECÇÃO DE MANOBRAS
SINUOSAS EM VEÍCULOS POR MEIO DE SENSORES INERCIAIS E GNSS**

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

Prof. DSc. Danilo Alves de Lima

Orientador

LAVRAS – MG

2020

**Ficha catalográfica elaborada pela Coordenadoria de Processos Técnicos
da Biblioteca Universitária da UFLA**

Nogueira, Dannylo Withor Pereira

Sistema embarcado de baixo custo para detecção de manobras sinuosas em veículos por meio de sensores inerciais e GNSS / Dannylo Withor Pereira Nogueira. 1ª ed. rev., atual. e ampl. – Lavras : UFLA, 2020.

51 p. : il.

Monografia–Universidade Federal de Lavras, 2020.

Orientador: Prof. DSc. Danilo Alves de Lima.

Bibliografia.

1. Sensores Inerciais. 2. Manobras Sinuosas. 3. Telemetria. I. Lima, Danilo Alves de. II. Título.

CDD-808.066

DANNYLO WITHOR PEREIRA NOGUEIRA

**SISTEMA EMBARCADO DE BAIXO CUSTO PARA DETECÇÃO DE MANOBRAS
SINUOSAS EM VEÍCULOS POR MEIO DE SENSORES INERCIAIS E GNSS**

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

APROVADA em 05 de Agosto de 2020.

Prof. DSc. Arthur de Miranda Neto UFLA
Prof. DSc. Rodrigo Moreira Bacurau UNICAMP

Prof. DSc. Danilo Alves de Lima
Orientador

**LAVRAS – MG
2020**

RESUMO

Manobras perigosas são importantes indicadores da performance de condutores, e podem oferecer meios apropriados para a prevenção de situações de risco. Além de serem reconhecidas causadoras de acidentes, o consequente gasto a elas associado, especialmente relacionado a manutenção corretiva e consumo de combustível, afeta diretamente o orçamento do consumidor e das empresas detentoras de grandes frotas. É sabido, porém, que tais impactos podem ser minimizados com o emprego de metodologias de *ecodriving*, que descreve padrões e comportamentos adequados voltados a adoção de um estilo mais seguro e econômico de condução. O presente trabalho visa desenvolver técnicas baseadas no uso de sensores inerciais e de sistema GNSS para monitoração de manobras sinuosas. Para tanto, experimentos foram realizados a bordo de um veículo de passeio utilizando a solução SEVEN GO Smart Edge, dando origem a uma sistema embarcado de baixo custo, fácil utilização e com bom desempenho para a detecção de manobras de *cornering* e *swerving*, além de metodologias para o alinhamento de referenciais entre os sensores e o veículo, e detecção de curvas no trajeto. As técnicas propostas foram validadas em ambiente real, durante um programa de estágio realizado na empresa SEVEN GO.

Palavras-chave: Sensores Inerciais. *Cornering*. *Swerving*.

ABSTRACT

Dangerous maneuvers are important indicators of the driver's performance, and can offer appropriate means for the assesment of risky situations. In addition to being known to cause accidents, the consequent expense associated with them, especially related to corrective maintenance and fuel consumption, directly affects the budget of consumers and companies with large fleets. It is known, however, that such impacts can be minimized with the use of *ecodriving* methodologies, which describe appropriate patterns and behaviors aimed at adopting a safer and more economical driving style. This work aims to develop techniques based on the use of inertial sensors and GNSS system for monitoring winding maneuvers. To this end, experiments were carried out on board a passenger vehicle using the SEVEN GO Smart Edge solution, giving rise to a low-cost, easy-to-use and well-performing embedded system for the detection of *cornering* and *swerving* maneuvers, as well as methodologies for the alignment of references between the sensors and the vehicle, and detection of curves in the path. The proposed techniques were validated in a real environment, during an internship program carried out at SEVEN GO.

Keywords: Inertial Sensors. Cornering. Swerving.

LISTA DE FIGURAS

Figura 2.1 – Distinções entre manobras de <i>swerving</i> e <i>cornering</i>	14
Figura 3.1 – Fluxograma representativo para o algoritmo de detecção.	16
Figura 3.2 – Representação do desalinhamento entre eixos de coordenadas	19
Figura 3.3 – Relação entre eixos de referência do IMU e o vetor movimento.	20
Figura 3.4 – Comportamento da aceleração lateral durante evento de <i>swerving</i>	22
Figura 3.5 – Métricas obtidas a partir da aceleração lateral durante evento de <i>swerving</i> . .	23
Figura 3.6 – Representação dos vetores de movimento estimados via dados de GPS . . .	25
Figura 3.7 – Círculo que cruza três pontos conhecidos	28
Figura 4.1 – Módulo de aquisição de dados adotado.	29
Figura 4.2 – Primeiro percurso realizado para coleta de dados de teste.	31
Figura 4.3 – Segundo percurso realizado para coleta de dados de teste	31
Figura 4.4 – Estacionamento utilizado para coleta de dados de teste.	32
Figura 4.5 – Procedimento de filtragem dos dados coletados.	33
Figura 4.6 – Performance de calibração do algoritmo de alinhamento via estimativa de aceleração longitudinal.	34
Figura 4.7 – Desempenho do algoritmo de detecção de curvas para o percurso 1.	35
Figura 4.8 – Desempenho do algoritmo de detecção de curvas para o percurso 2.	36
Figura 4.9 – Desempenho na estimativa de raio e circunferência de curvas.	37
Figura 4.10 – Desempenho do algoritmo de detecção de <i>cornering</i> junto ao percurso 1. . .	39
Figura 4.11 – Desempenho do algoritmo de detecção de <i>cornering</i> junto ao percurso 2 . .	41
Figura 4.12 – Desempenho do algoritmo de detecção de <i>cornering</i> junto ao percurso 3. .	42
Figura 4.13 – Comparativo entre aceleração lateral e métrica extraída para o percurso 2. .	43
Figura 4.14 – Desempenho do algoritmo de detecção de <i>swerving</i> junto ao percurso 2. . .	44
Figura 4.15 – Comparativo entre aceleração lateral e métrica extraída para o percurso 3. .	45
Figura 4.16 – Desempenho do algoritmo de detecção de <i>swerving</i> junto ao percurso 3. . .	45

SUMÁRIO

1	INTRODUÇÃO	6
1.1	O estágio	8
1.2	Objetivos	9
1.3	Justificativa	9
1.4	Estrutura do trabalho	10
2	REVISÃO DA LITERATURA	11
2.1	Análise comportamental do condutor	11
2.2	Uso de sensores inerciais para detecção de manobras	12
2.2.1	Cornering e swerving	14
3	METODOLOGIA	16
3.1	Coleta de dados	17
3.1.1	Dados de GPS	17
3.1.2	Dados de IMU	17
3.2	Alinhamento de frames	18
3.3	Detecção de swerving	21
3.4	Detecção de curvas	24
3.5	Detecção de cornering	25
4	RESULTADOS	29
4.1	Módulo de aquisição	29
4.2	Ambientes de teste	30
4.3	Filtragem de dados	32
4.4	Alinhamento de frames	33
4.5	Detecção de curvas	35
4.6	Detecção de cornering	38
4.7	Detecção de swerving	42
5	CONCLUSÃO E TRABALHOS FUTUROS	46
	REFERÊNCIAS	49

1 INTRODUÇÃO

O cenário brasileiro de mobilidade e organização urbana é contemporaneamente caracterizado pela grande incidência na adoção de variados e cada vez mais inovadores modais de transporte em áreas metropolitanas, contando com uma frota superior a 47 milhões de veículos em circulação no país (ANTP, 2016). Destes, estima-se que aproximadamente 38 milhões estejam enquadrados em modalidades de transporte individual, dos quais 29 milhões são carros, representando 60% do total.

E essa conjuntura não apresenta sinais de mudança no curto prazo. Não obstante à crise econômica experienciada pela maioria dos países ocidentais nos últimos anos, a média de crescimento anual na venda de veículos no Brasil atingiu o patamar de 10% nos últimos anos, motivada pelo crescimento da economia nacional e incentivos governamentais (POSADA; FAÇANHA, 2015).

Tal distribuição modal, ainda que favorável às necessidades particulares de cada nicho populacional, introduz uma série de desafios para a manutenção da estabilidade do sistema de transporte, em especial no que diz respeito à segurança viária. De acordo a um relatório divulgado pela organização mundial da saúde, até 2030 os acidentes de trânsito se tornarão a quinta maior causa de morte no planeta, já ocupando a segunda posição quando considerados indivíduos entre 5 e 14 anos, e a primeira para jovens com idades entre 15 e 29 anos (VIOLENCE et al., 2009).

Anualmente, mais de 1,35 milhão de pessoas morrem em decorrência de acidentes de trânsito, e outras 50 milhões sofrem ferimentos graves. O Brasil é considerado um dos países com o trânsito mais violento das Américas. Nele, mais de 40 mil pessoas perdem suas vidas todos os anos em decorrências de fatalidades em estradas e rodovias (OMS, 2015). Os custos financeiros associados a tais ocorrências também são significativos, alcançando a surpreendente soma de R\$ 50 bilhões de reais anuais, quando considerados custos hospitalares, para reconstrução de infraestrutura danificada, danos materiais aos veículos envolvidos e perda de produção (IPEA, 2015).

Por mais alarmantes que sejam, essas cifras não são exclusivas de países em desenvolvimento. No ano 2000, mais de 40 mil pessoas foram morreram em decorrência, 5 milhões ficaram feridas e 27 milhões de veículos foram danificados em acidentes de trânsito nos Estados Unidos, provocando despesas da ordem de \$ 230,6 bilhões de dólares, o equivalente a 2% do PIB do país naquele ano. (BLINCOE et al., 2002). Situações semelhantes são observadas

em outros países desenvolvidos, com estimativas para o custo provocado por acidentes atingindo valores referentes a 3,6% do PIB na Austrália, 2,8% na Itália, 0,9% na Suécia e 0,5% na Grã-Bretanha (ELVIK, 2000).

São diversos os fatores que contribuem para estatísticas tão elevadas. Segundo Najm et al. (2002), em aproximadamente 992.000 eventos avaliados em perímetro urbano, as causas mais comuns para a ocorrência de acidentes foram velocidade elevada, responsável por 34% das ocorrências, e uso de substâncias inebriantes antes de assumir a direção, como álcool e drogas. Ao observar a frequência de acidentes relacionados a atitudes inapropriadas durante a condução em quatro cidades americanas - Pensilvânia, Colorado, Tennessee e Washington -, Fell, Hendricks e Freedman (2000) concluíram que os elementos mais influentes foram falta de atenção em 22,7% dos casos, velocidade elevada em 18,7% e consumo de álcool em 18,7%.

Mensurar e coibir os referidos comportamentos são, portanto, tarefas primordiais com vistas à construção de ambientes urbanos mais coesos e apropriados. Apesar de diversas tecnologias já disponíveis atuarem adequadamente no combate à ocorrências de excessos de velocidade, algumas até empregadas rotineiramente em atividades policiais, pouco pode ser dito a respeito da direção sobre efeito de álcool, geralmente identificada por meio de análise física ou comportamental - uma vez que indivíduos podem se recusar a realizar testes de alcoolemia sanguínea. Segundo Dai et al. (2010), uma interessante alternativa para essa problemática é a observação das manobras realizadas com o intuito de reconhecer padrões destoantes, como manobras sinuosas excessivas.

Dois exemplos de comportamentos de relevante interesse nesse sentido são o *swerving* - mudanças abruptas de direção - e *cornering* - realização de curvas de forma agressiva. De importância reconhecida para seguradoras de automóveis (INSURANCE, 2012), é fato conhecido que motoristas que incorrem rotineiramente em tais infrações também estão mais envolvidos em acidentes de trânsito (KLAUER et al., 2009) e recebem mais multas (HONG; MARGINES; DEY, 2014).

Uma vez identificadas tais deficiências, metodologias de base tecnológica com o intuito de detectar fatores de risco podem ser empregadas. A adaptação de sistemas embarcados para tal função não é recente, grande parte dos recursos hoje existentes foram desenvolvidos no Instituto de Tecnologia de Massachussets (MIT) e utilizados pela NASA no final de 1960, durante as primeiras experimentações espaciais com o programa Apollo (HALL, 2009).

Tais equipamentos coletam dados provenientes de diversos sistemas, sejam eles integrados à solução ou provenientes das centrais eletrônicas presentes na maioria dos veículos modernos, e retornam ao usuário informações úteis para cada cenário de atuação, possibilitando ferramentas como controle automático de velocidade (*Cruise Control*), monitoramento de tráfego para prevenção de acidentes (*Pre-crash Systems*), detecção de desvio de faixa (*Lane Departure*), entre outros (SHAOUT; COLELLA; AWAD, 2011).

1.1 O estágio

O presente trabalho foi realizado no âmbito do programa de estágio realizado na SEVEN GO, uma inovadora empresa brasileira que surgiu apoiada por essa demanda, tendo como proposta coletar dados gerados em intervalos de condução e traduzi-los em informações de maior valor agregado. As atividades desenvolvidas durante o período em questão visaram contribuir com alternativas para mitigar o problema levantado, atuando junto a empresa e seus colaboradores de modo a fomentar soluções de base tecnológica.

Um dos produtos oferecidos pela empresa é resultado da análise de uma variedade de informações produzidas durante a atividade de condução e que, na quase totalidade dos casos, não são aproveitadas em todo seu potencial, tais como: perfis temporais de velocidade e aceleração, correta utilização de dispositivos de frenagem, consumo de combustível, métricas inerentes ao desempenho dos diversos elementos do veículo, entre outros. Para tanto, faz-se necessária a adoção de um conjunto de tecnologias coerentes para obtenção e tratamento dos referidos dados, o que é conhecida como telemetria.

A importância de tal funcionalidade enquadra-se na possibilidade de gestão coesa e ininterrupta de veículos, uma vez que avaliar o comportamento e conformidade com os padrões estabelecidos para os motoristas de maneira individual torna a operação altamente monitorável, permitindo ao motorista identificar gastos e riscos excessivos e mitigar seus efeitos já no curto prazo, por meio de metodologias de *ecodriving*. Inserido nesse contexto, o presente trabalho teve como objetivo desenvolver um mecanismo eficaz para a detecção de manobras sinuosas em ambiente urbano por meio da tecnologia de telemática implementada pela SEVEN GO.

1.2 Objetivos

O presente trabalho propõe uma metodologia para detecção de manobras sinuosas em veículos, fazendo para tanto uso de sensores inerciais embarcados e integrados a um sistema GNSS, por meio da solução SEVEN GO Smart Edge. Para tanto, os seguintes objetivos foram definidos:

1. Coletar, filtrar e calibrar corretamente dados provenientes do sistema de aquisição, atentando-se especialmente ao adequado alinhamento entre os diferentes referenciais do sistema.
2. Detectar padrões no universo de dados adquiridos que caracterizem a ocorrência dos eventos desejados.
3. Desenvolver uma solução de classificação que possibilite identificar os eventos desejados em tempo real.
4. Validação do modelo em sistema embarcado em tempo real e operando em ambiente real.

1.3 Justificativa

A adoção de tecnologias assistivas com o intuito de monitorar o comportamento do condutor possui enorme potencial, constituindo importante ferramenta corretiva voltada a melhoria das condições de uso e segurança no trânsito de grandes cidades. De acordo com Bengler et al. (2014), Sistemas Avançados de Assistência à Condução - *Advanced Driver Assistance Systems (ADAS)* - são elementos relevantes na medida em que oferecem mecanismos para aprimorar a segurança no trânsito, constituindo uma abordagem diferente para o aumento da eficiência da mobilidade urbana.

Outro aspecto pertinente associado a sistemas semelhantes ao proposto é sua utilidade no desenvolvimento de novos paradigmas no setor de seguros automotivos, como o Usage-Based Auto Insurance (UBI), no qual as características de cada novo contrato realizado são baseados no comportamento adotado pelo usuário durante a sua condução (HARBAGE, 2010). Cheng et al. (2018) exemplifica um procedimento similar ao propôr um modelo de pontuação individual baseada em tendências extraídas do comportamento de cada condutor, adotando para tanto um sistema de coleta de dados proveniente do OBD - *On-Board Diagnostics*. Dessa forma, motoristas cujo comportamento se mostre seguro e adequado às políticas pré-determinadas recebem

ofertas promocionais e descontos, ajudando a eliminar distorções provocadas pelas análises convencionais.

Em consonância a tais fatores, projetar e desenvolver um sistema tal qual o proposto revisita conceitos fundamentais associados ao exercício da engenharia, exigindo a compreensão e emprego de técnicas multidisciplinares de forma a possibilitar o cumprimento dos objetivos propostos. Além disso, suscita o projeto de sistemas embarcados, demandando sólidos conhecimentos de eletrônica, desenvolvimento de software para sistemas em tempo real e tratamento de sinais, elementos indissociáveis ao profissional da área de controle e automação.

Dessa forma, a importância do presente trabalho fica explícita, tanto no que diz respeito ao potencial social e econômico atrelado aos resultados obtidos, quanto a consolidação da formação técnico-profissional de seu autor.

1.4 Estrutura do trabalho

No Capítulo 2, é apresentada uma revisão da literatura disponível, oferecendo um panorama geral acerca dos mecanismos comumente adotados para análise do comportamento do condutor, salientando suas principais vantagens e dificuldades. A metodologia adotada nesse trabalho é apresentada no Capítulo 3, onde os detalhes dos procedimentos de filtragem, calibração e classificação empregados são visitados. Em seguida, é discutido no Capítulo 4 os resultados experimentais alcançados, fornecendo detalhes acerca do desempenho. Por fim, no Capítulo 5 são discutidas as vantagens oferecidas pela solução proposta, abordando sua robustez em relação ao encontrado na literatura e avaliando as necessidades de ajuste e melhoria em trabalhos futuros.

2 REVISÃO DA LITERATURA

2.1 Análise comportamental do condutor

Mesmo diante da prevista revolução tecnológica para o setor, já sinalizada pelo crescente número de soluções assistivas disponíveis aos condutores, as decisões humanas ainda são predominantes e críticas no que diz respeito à construção e manutenção de padrões de segurança no trânsito. Isso evidencia a importância de se identificar e reportar tendências comportamentais como uma prolífica fonte de melhorias.

Em Reason (1990), esse problema é abordado ao sugerir a aplicação de um formulário - *Driver Behaviour Questionnaire (DBQ)* - com o intuito de verificar comportamentos que possam aumentar o risco de envolvimento em acidentes. Nela foi realizada inclusive a distinção entre falhas cognitivas não intencionais - comumente ocasionadas por distrações - e violações deliberadas das regras convencionadas, fornecendo meios para o desenvolvimento de mais de 150 trabalhos no tópico (WINTER; DODOU, 2010).

Estratégia semelhante é aplicada por French et al. (1993), onde a associação entre o estilo de direção e a frequência de envolvimento em acidentes de trânsito é analisada com base em diversos aspectos comportamentais. A capacidade de decisão e as características de direção de cada um dos mais de 700 participantes da pesquisa foram documentadas via aplicação de formulário, abarcando tanto itens de natureza emocional, como perfeccionismo, idealismo, instinto, autocontrole e resistência psicológica, quanto informações mais específicas, como perfil de velocidade, foco e planejamento de percursos. Os autores descobriram que indivíduos de comportamento menos rigorosos, independente de sexo, idade ou tempo de direção, de fato se envolvem mais frequentemente em acidentes de trânsito. Outros resultados obtidos também suportam a ideia de que o comportamento do condutor impacta diretamente em sua condução e, por consequência, em seu risco de provocar acidentes.

Esses resultados corroboram com o trabalho de Meiring e Myburgh (2015), que investiga o potencial de diversas metodologias para a criação de um identificador para o condutor com base em seu comportamento - numa espécie de assinatura digital de condução. Tal informação se mostra muito útil em diversos setores comerciais, como no caso de revendedoras de veículos e seguradoras. Para tanto, sugere a formação de 4 perfis básicos: condução agressiva, condução desatenta, condução sob o efeito de álcool, e condução segura. Os autores concluíram que, caso a complexidade inerente ao modelo estudado possa ser simplificada, então diversas

técnicas já consolidadas se mostram capazes de traçar a identidade do condutor com base em suas características de direção.

Avanços significativos são vistos em Al-Sultan, Al-Bayatti e Zedan (2013), que parte desse princípio com vistas a formular um modelo probabilístico para classificação do estado de direção. Utilizando uma convenção semelhante para diferenciar perfis - conduções normal, inebriada, fatigada e imprudente -, é proposto uma arquitetura de cinco camadas capaz de capturar informações contextuais acerca das condições nas quais a condução se dá, fazendo uso de informações relacionadas ao veículo - velocidade, aceleração, trajetória, etc. - e ao condutor - movimento dos olhos e pálpebras. Os resultados alcançados sugerem amplamente a validade do método proposto.

Uma abordagem interessante é observada em Oliver e Pentland (2000), que desenvolve uma arquitetura pautada em conceitos de inteligência artificial capaz de até mesmo prever a realização de determinadas manobras. Por meio de um modelo treinado com imagens de câmeras atreladas ao veículo, a posição da cabeça do condutor e campo de visão disponível, bem como informações provenientes de sistemas de aquisição de dados, como velocidade, aceleração e atuação sobre pedais de freio, os pesquisadores conseguiram antecipar em até 1 segundo a decisão a ser executada pelo condutor.

2.2 Uso de sensores inerciais para detecção de manobras

Como visto, o potencial das técnicas para detecção e classificação do comportamento de direção é notável e amplamente explorado. Porém, grande parte dos mecanismos exige a adoção de câmeras, informações acerca dos estados de atuadores presentes nos veículos, ou adota metodologias complexas e computacionalmente dispendiosas. Nesse sentido, os sensores inerciais se destacam como uma alternativa viável para o cumprimento da tarefa, reduzindo significativamente o custo e a complexidade dos modelos.

Uma promissora fonte de recursos para fomentar análises semelhantes é o *smartphone*. Dotados de popularidade sem precedentes na última década, tais equipamentos coletam e processam continuamente uma ampla gama de informações potencialmente úteis. Em Paefgen et al. (2012), a possibilidade da adoção de sensores inerciais provenientes de *smartphones* com o intuito de gerar alternativas mais acessíveis é avaliada. Para tanto, é comparada a capacidade de detecção destes com equipamentos mais sofisticados no que diz respeito a identificação de manobras críticas, visando abarcar situações comumente observadas no ambiente de trânsito

urbano. Ainda que significativamente afetados pelas limitações da plataforma, sendo estas previsíveis uma vez que o equipamento não foi desenvolvido com esse propósito, os resultados obtidos demonstram grande potencial no uso da técnica.

Em outra aplicação, Stoichkov (2013) desenvolve um aplicativo para o sistema Android capaz de avaliar aspectos da qualidade de condução e fornecer dicas aos usuários, também adotando apenas os sensores inerciais disponíveis no *smartphone*. Uma vez realizados os procedimentos de calibração, o equipamento identifica eventos de aceleração e desaceleração abrupta, curvas fechadas e mudança abrupta de faixa, e desenvolve um sistema de pontuação de modo a fornecer ao usuário uma classificação geral relacionada ao seu desempenho no percurso.

Uma abordagem semelhante é adotada por Ly, Martin e Trivedi (2013), que faz uso dos sensores inerciais provenientes do barramento CAN de um veículo com o intuito de construir um perfil do motorista, realizando distinções entre eventos de aceleração, frenagem e curva. Os autores descobriram que, apesar de os eventos de aceleração tomados individualmente não fornecerem indicativos suficientes quanto a natureza do indivíduo, associar eventos de frenagem e curva via métodos de aprendizado supervisionado de fato possibilita identificar e diferenciar entre os estilos de direção de dois motoristas distintos.

A eficácia dos métodos de detecção de manobras também podem ser amplificados quando utilizados em consonância a outras tecnologias. Em Carmona et al. (2015), um sistema baseado em fusão sensorial de informações provenientes do barramento CAN, GPS e dados inerciais é proposto, culminando em resultados muito robustos.

Um problema recorrente ligado ao uso dos sensores inerciais é a necessidade de calibração prévia. Em especial no caso de aquisições provenientes de *smartphones*, não há como garantir que durante todo o percurso a orientação dos sensores inerciais é a mesma daquela adotada para o corpo do veículo no qual as manobras são executadas, requerendo então o conhecimento do relacionamento entre ambos os referenciais (WAHLSTRÖM; SKOG; HÄNDEL, 2015b). Calibrar ou alinhar o sistema significa determinar os ângulos sob os quais o referencial móvel deve ser rotacionado com o intuito alinhá-lo ao referencial inercial, o que pode ser devidamente executado via ângulos de Euler (GROVES, 2015).

São diversas as técnicas aplicáveis com vistas a solucionar tal dificuldade. Em Hamel e Mahony (2006), os ângulos de orientação são obtidos via aplicação de filtro complementar sobre as leituras dos sensores inerciais disponíveis. Oliveira, Kuga e Lopes (2009), por sua vez, desenvolve um filtro de Kalman para realizar fusão sensorial entre dados de acelerômetro

e GPS e estimar os ângulos de Euler. Já Yang et al. (2017) realiza o processo de alinhamento por meio de um filtro complementar entre os dados provenientes dos sensores inerciais aliados a um magnetômetro.


2.2.1 Cornering e swerving

Figura 2.1 – Distinções entre manobras de *swerving* e *cornering*.



(a) Exemplo de manobra de *cornering*.

Fonte: (4WD, 2020)



(b) Exemplo de manobra de *swerving*.

Fonte: (NHTSA, 2012)

Manobras de *cornering* dizem respeito a realização de curvas acima da velocidade ideal para as mesmas de modo a gerar riscos para os condutores, como visto na Figura 2.1 (a), enquanto ocorrências de *swerving* se referem a guinadas laterais abruptas durante a condução, como visto na Figura 2.1 (b). A literatura relacionada a detecção de tais eventos é vasta, e tem se mostrado crescente dada a popularização de sensores presentes em *smartphones*, fomentando dezenas de novas aplicações de baixo custo capazes de aferir adequadamente tais manobras (WAHLSTRÖM; SKOG; HÄNDEL, 2017). Em geral, a classificação de uma curva como normal ou agressiva - *cornering* - parte de limitações de velocidade extraídas de análises cinemáticas do evento de forma a garantir a condição de não escorregamento e impedir que o veículo seja lançado para fora da curva (WAHLSTRÖM; SKOG; HÄNDEL, 2015a). Enquanto isso, segundo Wahlström, Skog e Händel (2017) a detecção de eventos de *swerving* está muito mais comumente associada à aplicação de limiares sobre a aceleração lateral experimentada.

Em Castignani et al. (2015), é avaliado como sensores tipicamente encontrados em *smartphone* podem ser utilizados para detectar manobras perigosas de direção e sugerem a plataforma *SenseFleet*, que adota um sistema Fuzzy para gerar notas para diferentes motoristas.

Aqui, eventos de cornering são corretamente identificados via medições de giroscópio usadas com o objetivo de estimar a velocidade angular do veículo durante a execução de manobras.

De maneira similar, Dai et al. (2010) adota a tecnologia para monitorar se condutores encontram-se ou não sob a influência de álcool. Para tanto, a solução desenvolvida estima continuamente as acelerações observadas pelo veículo e as compara com aquelas típicas de motoristas inebriados - constantes eventos de swerving, cornering, velocidades acima do limite, frenagens abruptas, etc. -, obtidos via testes experimentais. Quando uma ocorrência é detectada, o aplicativo alerta o motorista quanto aos riscos da prática ou até mesmo contata a polícia. Os resultados obtidos mostraram que a técnica é vulnerável aos movimentos aleatórios do equipamento no momento da execução de manobras abruptas, o que suscita a possibilidade de melhorias futuras, mas ainda assim consegue atingir bom desempenho experimental.

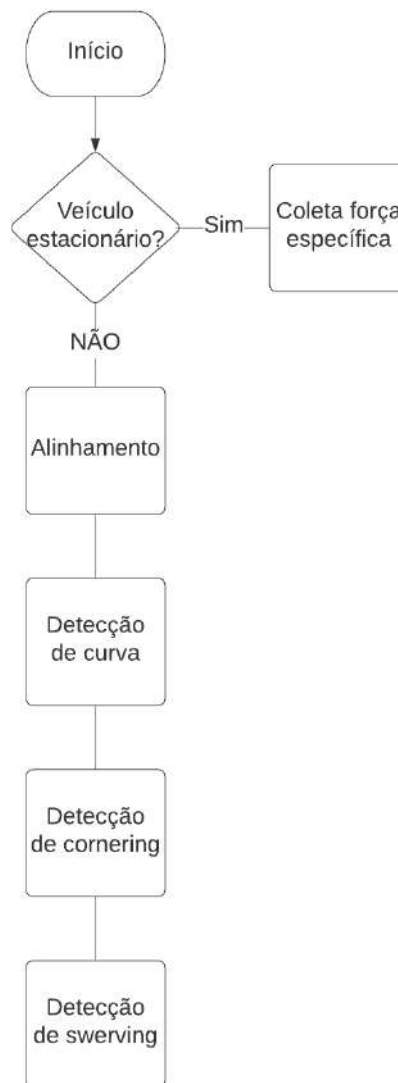
Já Johnson e Trivedi (2011) identifica estilos de direção agressiva ao fazer uso de uma miríade de sensores - acelerômetros, giroscópios, magnetômetros, GPS e câmeras - por meio de um algoritmo de *Dynamic Time Warpin* (DTW), tendo sido capazes de detectar corretamente curvas normais e agressivas - *swerving* - para direita e esquerda, mudanças de faixa normais e agressivas - *swerving* - para direita e esquerda, acelerações e frenagens abruptas, e excesso de velocidade. Enquanto a adoção de medidas individuais resultou em taxas de detecção corretas de aproximadamente 23% para o caso do acelerômetro e 46% para o caso do giroscópio, a aplicação do DTW produziu detecções corretas em 97% dos eventos avaliados.

S. Polavarapu S. (2012), por sua vez, desenvolve um sistema embarcado voltado a veículos em ambiente urbano com o intuito de permitir aos motoristas ter conhecimento em primeira mão acerca de sua performance, sugerindo um índice de segurança que reflete a confiabilidade de cada usuário na condução de automóveis em prolongados períodos de tempo. De maneira similar às demais implementações, limiares de segurança são impostos à aceleração lateral do veículo de forma a caracterizar e monitorar a ocorrência de manobras abruptas. Nesse trabalho, é reforçada sua utilidade como ferramenta de incentivo a aprendizagem e melhoria contínua, indicando aplicabilidades para motoristas novatos e escolas de direção, bem como em situações rotineiras com o intuito de reduzir a ocorrência de acidentes.

3 METODOLOGIA

Este capítulo apresentará a metodologia proposta para o algoritmo de detecção de manobras sinuosas. Ele é organizado em 4 etapas básicas e sucessivas, projetadas de forma a contribuir individualmente para o cumprimento dos objetivos propostos. A Figura 3.1 sumariza os procedimentos realizados e evidencia sua hierarquia.

Figura 3.1 – Fluxograma representativo para o algoritmo de detecção.



Fonte: Própria

A etapa de coleta de dados, como sugerido por sua denominação, consiste em recuperar as leituras dos sensores presentes na solução de telemetria, obedecendo às suas frequências de aquisição. As leituras de GPS são as mais lentas e ocorrem a uma taxa de 1 Hz, enquanto as leituras provenientes da IMU ocorrem a uma taxa de 10 Hz.

Uma vez coletadas as leituras de força específica fornecidas pelos sensores atrelados ao veículo de testes, deve-se realizar o alinhamento entre os eixos do referencial onde os dados foram adquiridos e aqueles no referencial do veículo, de forma a garantir que os comportamentos observados de fato representem adequadamente as características de condução reais. Para tanto, como discutido adiante, fez-se uso das forças normais à aceleração gravitacional e da direção estimada do movimento para recuperar os ângulos de orientação do sistema embarcado em relação ao veículo.

Em seguida, são realizadas análises sobre a aceleração lateral computada com vistas a possibilitar a detecção das manobras propostas. Para tal, adotou-se técnicas baseadas em limites de aceleração máxima adequados para cada situação, determinados com base em limites físicos de condução e na literatura existente. Nas demais seções deste capítulo, os procedimentos inerentes à cada etapa são apresentados e discutidos mais detalhadamente.

3.1 Coleta de dados

3.1.1 Dados de GPS

Como já ressaltado, em função de suas características construtivas e consequentes limitações, as leituras provenientes do sistema GNSS embarcado são realizadas a uma taxa de 1 Hz, ou seja, 1 leitura por segundo. Ainda que as manobras objetivadas em geral possuam componentes de frequência superiores a esta, sugerindo a possibilidade de perda de informações, deve-se observar este mecanismo apenas determina o conjunto de vetores de deslocamento, não interferindo então na taxa com a qual as manobras em si são observadas.

Outro ponto importante acerca de seu uso é o pré-processamento aplicado sobre as leituras recebidas. Uma vez que, em geral, a solução de localização é fornecida em termos curvilíneos - latitude e longitude -, aplica-se uma transformação para a projeção Universal Transversa de Mercator (UTM), mais vantajosa para a presente aplicação por estar referenciada em um plano cartesiano de unidades métricas (SNYDER, 1987), o que facilita significativamente os procedimentos posteriores.

3.1.2 Dados de IMU

No que diz respeito às leituras provenientes da IMU, observa-se que este sensor apresenta frequência significativamente superior a do GPS - nesta aplicação em específico, a IMU

adotada possui frequência de aquisição de 10 Hz -, o que justifica seu emprego com o intuito de monitorar e classificar em tempo real o comportamento do perfil de aceleração do condutor. Salienta-se, porém, que tais medições podem ser facilmente afetadas por ruídos inerentes ao processo, tais como vibrações.

De forma a mitigar o efeito de tais fontes de ruído sobre a detecção das manobras objetivadas, aplica-se uma metodologia de filtragem baseada em um filtro passa-baixas. Nele, a estimativa do estado X_t é influenciada de maneira ponderada pelo estado anterior, atenuando o impacto de oscilações em alta frequência, como se segue:

$$X_t = \sigma_1 X_t + \sigma_2 X_{t-1}. \quad (3.1)$$

Onde $\sigma_1 + \sigma_2 = 1$, e representam as constantes que modulam o relacionamento entre o valor atual e o valor anterior, escolhidas de forma a fornecer desempenho satisfatório para a presente aplicação.


3.2 Alinhamento de frames

Uma vez que a detecção dos perfis de condução erráticos objetivados são relativos ao corpo do veículo, é de se esperar que as medições sobre as quais se aplicam os métodos de detecção propostos estejam referenciados de maneira semelhante. É sabido, porém, que essa não é uma suposição aplicável à todas as circunstâncias, uma vez que não há maneira viável de garantir o perfeito sincronismo entre o referencial da IMU e do corpo de teste em todos os veículos alvos da tecnologia em questão.

Acontece que, seja em razão de uma eventual instalação incorreta do sistema embarcado ou mesmo de um deslocamento provocado pelas vibrações do percurso, deve-se partir do princípio de que ambos os referenciais encontram-se inicialmente desalinhados, e a aplicação de técnicas voltadas a aproximá-los se torna necessária a fim de minimizar os erros provenientes desse aspecto. A Figura 3.2 sintetiza o problema em questão, evidenciando o desalinhamento entre os frames que representam os triedros formados pelos eixos fixos ao corpo do veículo e ao corpo da IMU.

Dentre as muitas soluções propostas na literatura com o propósito de solucionar tal questão, aquela que melhor atende as necessidades impostas enquanto mantém-se consonante aos recursos disponíveis é a técnica de *self-alignment* (GROVES, 2015). Nessa técnica, os ângulos

Figura 3.2 – Representação do desalinhamento entre eixos de coordenadas



Fonte: (BEINSTEIN et al., 2018)

de Euler - representativos das rotações a serem aplicadas em cada um dos eixos de modo a promover o alinhamento necessário - são derivados do relacionamento existente entre as forças específicas atuantes sobre o veículo estacionário e propriedades físicas conhecidas, em processos chamados de *leveling* e *gyrocompassing*.

A etapa de *leveling* justifica-se pelo fato de que quando estacionário ou trafegando em velocidade constante, a única força específica atuando sobre o veículo que é visível pela IMU é a reação à gravidade, que aponta na direção *down* negativa do referencial de navegação local quando na superfície da terra. Desse modo, a relação compreendida entre o vetor força específica aferida pela IMU e o vetor gravidade nesse ponto é dada unicamente por uma matriz de transformação escrita em termos de ângulos de Euler, tornando sua obtenção uma questão de solucionar um sistema linear da forma:

$$\begin{pmatrix} f_x \\ f_y \\ f_z \end{pmatrix} = \begin{pmatrix} \sin \theta \\ -\cos \theta \sin \phi \\ -\cos \theta \cos \phi \end{pmatrix} g_d, \quad (3.2)$$


onde ϕ e θ são os ângulos de *roll* e *pitch*, $[f_x, f_y, f_z]$ é o vetor força específica proveniente da IMU e g_d é o componente da gravidade no eixo *down*. Sendo esse um problema sobredeterminado, os dois ângulos presentes podem ser encontrados sem o conhecimento do vetor gravidade e assumem a forma:

$$\theta = \arctan \frac{-f_x}{\sqrt{(f_y)^2 + (f_z)^2}}, \quad (3.3)$$

$$\phi = \arctan2(-f_y, -f_z). \quad (3.4)$$

Vê-se, porém, que tal procedimento não fornece os meios para a determinação do ângulo ψ , ou *yaw*, que representa a rotação relativa ao eixo Z, evidenciando a necessidade da etapa de *gyrocompassing*. Nessa, a taxa de rotação da terra é usada de maneira semelhante ao caso anterior, possibilitando a elaboração de um conjunto de equações facilmente solucionáveis para os ângulos de Euler. No entanto, para que essa metodologia seja corretamente aplicada é requerido o uso de giroscópios de resolução significativa a ponto de aferir confortavelmente a taxa de rotação do planeta, o que não é o caso presente. Por tanto, uma solução alternativa para a estimação do ângulo *yaw* é implementada.

Figura 3.3 – Relação entre eixos de referência do IMU e o vetor movimento.



Fonte: Própria

Partindo do princípio de que o veículo trafega em linha reta por uma região plana, então pode-se assumir que as forças específicas atuantes sobre o mesmo se resumem à força normal exercida pela reação à aceleração gravitacional e à aceleração inerente ao deslocamento, sempre considerada na direção do eixo X do veículo em função de suas limitações construtivas. Sabendo que a influência da força normal pode ser minimizada ao subtrair das leituras

suas estimativas coletadas quando o veículo está estacionário, então as grandezas sobressalentes representam apenas o vetor que descreve o movimento do veículo nesse intervalo de tempo.

Uma vez que o eixo X da IMU é conhecido, dado pelo canônico $(1, 0, 0)$, o ângulo *yaw* pode ser então estimado como a diferença angular entre a direção do vetor movimento e o eixo X da IMU. Na Figura 3.3 essa relação é apresentada, onde os eixos X e Y representam a projeção dos eixos da IMU no plano 2D enquanto V representa o vetor movimento. No que diz respeito a implementação, as coordenadas $[V_x, V_y, V_z]$ que definem o vetor V podem ser recuperados por meio das leituras de GPS, de forma que:

$$V_x = X_t - X_{t-1}, \quad (3.5)$$

$$V_y = Y_t - Y_{t-1}, \quad (3.6)$$

$$V_z = H_t - H_{t-1}. \quad (3.7)$$

E o ângulo ψ é obtido via produto vetorial entre X e V, como:

$$\psi = \arccos \frac{\langle X, V \rangle}{|X||V|}. \quad (3.8)$$

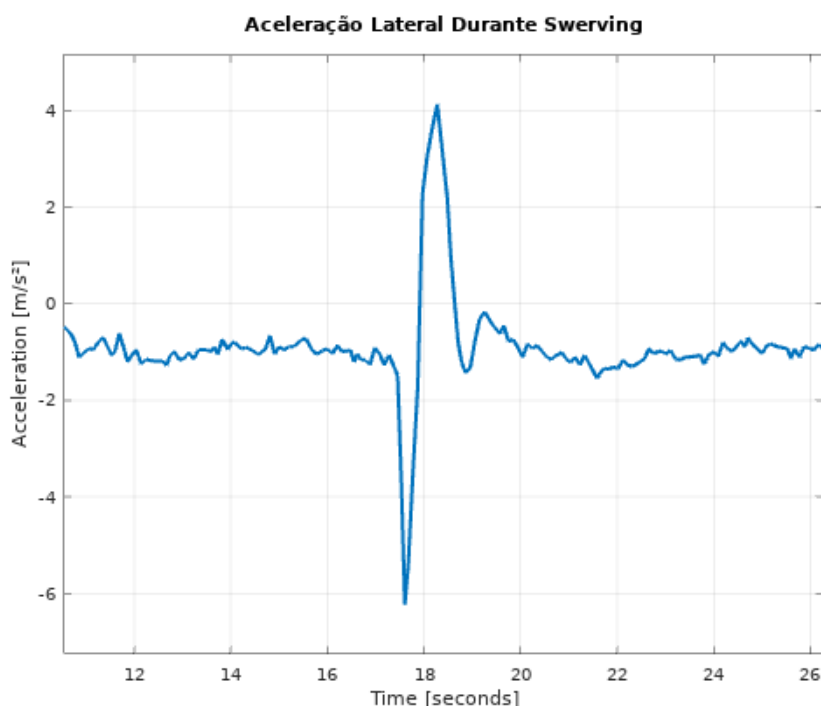
3.3 Detecção de swerving

A detecção dos eventos de *swerving* envolve a análise do comportamento da aceleração lateral exercida sobre o veículo durante o intervalo de condução e sua classificação como adequada ou discrepante em relação aos limites comumente esperados.

A partir do monitoramento das tendências associadas aos dados coletados em veículos submetidos à referida manobra, percebe-se que sua ocorrência promove efeitos perceptíveis nas tendências de aceleração lateral. A Figura 3.4 explicita tal relacionamento, apresentando os dados coletados no momento em que um evento de *swerving* foi realizado.

Observa-se que a aceleração lateral adota uma tendência sinuosa no momento do evento, o que de fato mostra-se apropriado em função da natureza do movimento. Ao submeter-se a uma rápida mudança de direção como aquela experimentada em casos de *swerving* - para desviar de situações inesperadas numa estrada, por exemplo -, o veículo experimenta uma aceleração

Figura 3.4 – Comportamento da aceleração lateral durante evento de swerving.



Fonte: Própria

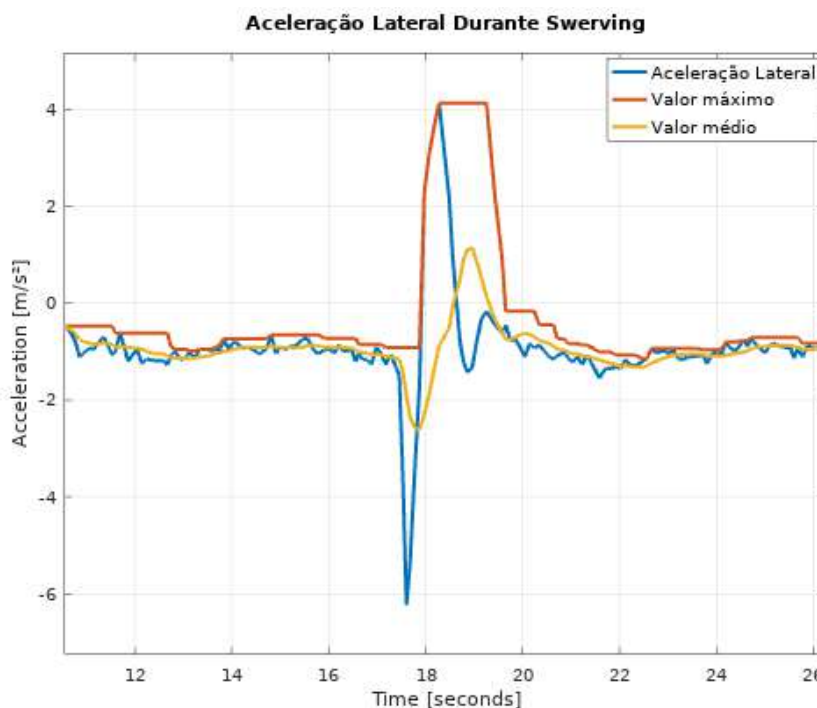
abrupta no sentido do movimento, e logo em seguida uma aceleração de magnitude próxima mas de sentido oposto ao finalizar o deslocamento anormal e retomar a trajetória em linha reta.

A tarefa de detecção pode então ser sumarizada pela identificação de padrões de aceleração lateral semelhantes ao retratado ao longo de toda viagem. À primeira vista, imagina-se que uma simples classificação por limiar superior produziria resultados significativos, uma vez que o pico de aceleração observado durante o evento é claramente superior ao observado em momentos de condução normal. No entanto, diagnósticos experimentais levam a crer que essa metodologia está fadada ao fracasso, já que desconsidera o formato característico dos dados coletados e os reduz ao seu valor máximo, influenciado por diversos outros fatores.

Diante das características do sinal em questão, uma abordagem inicial consiste em utilizar janelas temporais com o intuito de extrair outras métricas relevantes, de forma a aumentar a dimensionalidade do problema e torná-lo consequentemente mais simples. A Figura 3.5 mostra os valores médios e máximos calculados sobre janelas temporais de 10 amostras por vez. Esse valor deve ser ajustado de acordo à taxa de aquisição em uso, de maneira a evitar que uma janela se prolongue por muito tempo, o que provocaria distorções no valor médio.

Note que as novas métricas incorporam informações importantes ao ambiente de decisão, possibilitando inclusive uma interpretação individualizada para cada etapa do evento.

Figura 3.5 – Métricas obtidas a partir da aceleração lateral durante evento de swerving.



Fonte: Própria

Nesse sentido, enquanto o valor médio absorve em sua construção a influência do vale provocado pela movimentação inicial no sentido negativo do eixo Y, o valor máximo o ignora completamente e apenas mantém sua condição anteriormente aferida.

Dessa forma, em períodos de condução normal, ambos os sinais mostram-se proporcionalmente próximos, já que não há variabilidade suficiente no movimento para provocar diferença entre os valores médio e máximo do sinal. Na ocorrência de eventos de *swerving*, por sua vez, a mudança abrupta de direção promove discrepância justificada pelo rápido aumento do valor máximo em contraste ao comportamento mais atenuado do valor médio.

A solução para a detecção de eventos de *swerving* advém então do monitoramento da relação entre os valores máximo e médio das janelas de aceleração lateral a cada nova iteração do sistema. Para tanto, os limiares ρ_{max} e ρ_{mean} são definidos e um evento é considerado *swerving* caso as condições $Max \geq \rho_{max}$ e $Mean \leq \rho_{mean}$ sejam satisfeitas em simultâneo. Salienta-se que a qualidade da detecção está diretamente relacionada a adequada determinação dos parâmetros inerentes ao modelo - ρ_{max} , ρ_{mean} e tamanho da janela de análise. Para a presente aplicação, as definições foram feitas de tal modo que $\rho_{max} = 3,5$, $\rho_{mean} = 0,5$ e $n = 10$, onde n é o tamanho da janela. O desempenho do algoritmo não foi testado para outras dimensões de janela.

3.4 Detecção de curvas

O sistema concebido para a detecção de curvas baseia-se no contínuo monitoramento da trajetória descrita pelo veículo para identificar discrepâncias associadas à colinearidade de novos trechos em relação aos anteriores, obedecendo a um limiar definido anteriormente. Para tanto, faz-se necessário conhecer a posição do veículo em relação ao ambiente no qual ele trafega, informação esta que pode ser recuperada com frequência de aquisição adequada por meio da solução GNSS embarcada.

Conhecendo a sequência de pontos que define o trajeto percorrido pelo veículo em cada instante de tempo, a estratégia encontrada consiste em estimar a direção de movimento por meio de vetores conectando dois pontos consecutivos pertencentes ao caminho em questão, de modo que a mudança de orientação de tais vetores pode ser tomada como indicativo da natureza da manobra realizada.

Dessa forma, se vetores consecutivos mantêm orientações parecidas, pode-se concluir que, dentro do intervalo compreendido pelos pontos que os compõe, o veículo manteve trajetória aproximadamente retilínea. De mesmo modo, caso vetores consecutivos apresentem significativa variação de orientação entre si, pode-se concluir que uma curva foi realizada durante esse intervalo. Uma representação da aplicação de tal procedimento pode ser observada na Figura 3.6.


Considere que os pontos representados - daqui em diante chamados de a , b e c , respectivamente -, consistam em leituras de posição sequenciais provenientes do sistema GNSS, indicando o trajeto futuro que o veículo executará - Na Figura 3.6 o veículo foi posicionado no início do percurso com o intuito de facilitar a compreensão do procedimento -, onde é possível perceber que os vetores \vec{ab} e \vec{bc} são da forma:

$$\vec{ab} = [X_b - X_a, Y_b - Y_a], \quad (3.9)$$

$$\vec{bc} = [X_c - X_b, Y_c - Y_b], \quad (3.10)$$

a partir dos quais o ângulo θ pode ser estimado com base no produto interno entre ambos, de modo que:

Figura 3.6 – Representação dos vetores de movimento estimados via dados de GPS



Fonte: Própria

$$\langle \vec{ab}, \vec{bc} \rangle = |\vec{ab}| |\vec{bc}| \cos \theta, \quad (3.11)$$

$$\theta = \arccos \frac{\langle \vec{ab}, \vec{bc} \rangle}{|\vec{ab}| |\vec{bc}|}. \quad (3.12)$$

Visto que todas as variáveis requeridas são acessíveis, o ângulo θ pode ser calculado em todos os instantes de tempo. Por consequência, a tarefa de classificação fica resumida a determinar um limiar a ser aplicado sobre tal grandeza de modo que valores superiores a ele sejam considerados curvas. Sustentado pela realização de experimentos por meio dos dados coletados em campo, bons valores para o limiar ficam em torno de 10° a 15° .

3.5 Detecção de cornering

Uma vez adquiridos os meios para correta e confiável identificação das curvas realizadas, detectar episódios de *cornering* consiste em estabelecer perfis adequados de direção compatíveis com cada situação e avaliar a observância do motorista a estes fatores limitantes. Nesse

sentido, evidencia-se a importância da elaboração de uma métrica capaz de quantificar o risco associado às curvas efetuadas, permitindo classificá-las como eventos de *cornering* ou não.

Da física newtoniana clássica, é sabido que durante o intervalo no qual a curva acontece, mesmo que sob regime de velocidade constante, o veículo experimenta uma aceleração decorrente da força centrípeta F_c responsável por provocar a mudança de direção do vetor velocidade, que pode ser escrita como:

$$F_c = \frac{mv^2}{R}, \quad (3.13)$$

onde m e v correspondem a massa do objeto que realiza o percurso e sua velocidade, respectivamente, e R é o raio da curva. Sabe-se também que, em circunstâncias onde não há superelevação significativa - o que engloba grande parte dos cenários possíveis -, a força resultante é também igual à força de atrito experienciada pelo veículo de modo a evitar que este derrape e seja lançado para fora da estrada.

Isso se dá em razão do consequente aumento dos ângulos de escorregamento dos pneus em razão da significativa força lateral a qual são expostos durante a realização de curvas em alta velocidade, deformando as condições cinemáticas atreladas a geometria de Ackermann, que oferece condições ideais para curvas em baixas velocidades (BOYALI; MITA; JOHN, 2018). Pode-se então dizer que:

$$F_c = F_r = mg\mu, \quad (3.14)$$

$$\frac{mv^2}{R} = mg\mu, \quad (3.15)$$

$$v = \sqrt{Rg\mu}, \quad (3.16)$$

o que nos fornece a velocidade crítica com a qual uma curva pode ser executada sem levar a derrapagem, considerando o coeficiente de atrito cinético μ .

Por consequência, sendo possível verificar a velocidade do veículo em todos os instantes da trajetória dada a aquisição de dados pelo sistema embarcado, a métrica para definir o nível de risco associado a realização de uma curva pode ser estabelecida como a relação entre a velo-

cidade mensurada no instante do evento e a velocidade máxima estabelecida por suas restrições físicas. Uma maneira simples de definir tal fator é:

$$K_{cornering} = \frac{v_{curv}}{v_{max}}. \quad (3.17)$$

Contudo, resolver a equação anterior exige o conhecimento de v_{max} , que por sua vez é dependente de duas variáveis ainda desconhecidas: o coeficiente de atrito cinético μ e o raio de curvatura R . Embora a primeira delas se mostre de fácil estimativa - uma rápida pesquisa em qualquer das muitas fontes amplamente acessíveis revelará que um coeficiente de 0,7 é uma aproximação adequada para a situação de atrito entre pneu e asfalto seco (PERSSON et al., 2005) -, o raio de curvatura introduz certa dificuldade, eventualmente, de modo complementar, obtida do Mapa Digital. Uma alternativa viável para contornar tal empecilho encontra-se nos já conhecidos pontos a , b e c que definem o percurso seguido.


Uma vez identificada uma curva no trecho determinado pelos vetores que conectam os três pontos - o que é válido sempre que se faz necessário verificar a ocorrência de *cornering*, do contrário tal procedimento não faz sentido -, é seguro supor que ambos estão localizados sobre o perímetro de um círculo cujo arco define o trajeto percorrido pelo veículo durante a execução da curva, de modo que o raio de curvatura desejado é aproximadamente o raio desse círculo. Coincidentemente, o problema de ajustar um círculo que passa por três pontos possui solução única, e pode ser resolvido de forma analítica.

A metodologia utilizada para realizar essa tarefa foi a apresentada por Bourke (1999), e baseia-se no fato de que o centro do círculo é a intersecção das duas linhas perpendiculares aos vetores formados, passando por seus pontos intermediários. Com vistas a seguir o algoritmo sugerido, inicialmente deve-se encontrar a inclinação dos vetores em questão. Com o intuito de tornar a resolução mais simples e legível, os vetores \vec{ab} e \vec{bc} serão aqui chamados de \vec{a} e \vec{b} , respectivamente. As inclinações $m_{\vec{a}}$ e $m_{\vec{b}}$ podem então ser escritas como:

$$m_{\vec{a}} = \frac{(Y_b - Y_a)}{(X_b - X_a)}, \quad (3.18)$$

$$m_{\vec{b}} = \frac{(Y_c - Y_b)}{(X_c - X_b)}. \quad (3.19)$$

Figura 3.7 – Círculo que cruza três pontos conhecidos



Fonte: (BOURKE, 1999)

Para uma reta perpendicular a outra de inclinação m tem necessariamente inclinação $\frac{-1}{m}$, então as equações das retas perpendiculares aos pontos intermediários dos vetores $m_{\vec{a}}$ e $m_{\vec{b}}$ podem ser escritas simplesmente como

$$y_1 = -\frac{1}{m_{\vec{a}}} \left(X_1 - \frac{X_a + X_b}{2} \right) + \frac{Y_a + Y_b}{2}, \quad (3.20)$$

$$y_2 = -\frac{1}{m_{\vec{b}}} \left(X_2 - \frac{X_b + X_c}{2} \right) + \frac{Y_b + Y_c}{2}. \quad (3.21)$$

Sabendo-se que as retas se interceptam no centro, nesse ponto tem-se $X_1 = X_2 = X_{centro}$ e $Y_1 = Y_2 = Y_{centro}$, de modo que o sistema de equações pode ser resolvido para qualquer uma das variáveis, e a outra é então encontrada reaplicando a fórmula obtida. Resolvendo o sistema anterior para X , obtemos:

$$X = \frac{m_{\vec{a}} m_{\vec{b}} (Y_a - Y_c) + m_{\vec{b}} (X_a + X_b) - m_{\vec{a}} (X_b + X_c)}{2(m_{\vec{b}} - m_{\vec{a}})}. \quad (3.22)$$

Em posse das coordenadas que definem o centro da circunferência e dos pontos localizados em seu perímetro, obter o raio do mesmo é feito calculando-se a distância euclidiana entre o centro e qualquer um dos pontos em questão.

4 RESULTADOS

4.1 Módulo de aquisição

Com o intuito de viabilizar o cumprimento dos objetivos propostos, o módulo de aquisição de dados adotado foi a solução SEVEN GO Smart Edge, um robusto sistema de telemetria composto por uma ampla gama de sensores voltados a tarefas de localização e monitoramento. O equipamento apresentado pela empresa incorpora informações provenientes da rede CAN veicular com um módulo IMU e um sistema GNSS de modo a propiciar ao usuário final uma vasta seleção de aplicações.

Figura 4.1 – Módulo de aquisição de dados adotado.



Fonte: SEVEN GO

Uma característica relevante da solução apresentada é o fato desta se mostrar capaz de coletar, tratar e processar recursos provenientes do sistema de telemetria à taxas muito altas, viabilizando aplicações mais sensíveis e complexas, dependentes de dados confiáveis. Em função dessa disponibilidade, técnicas de mineração e classificação são empregadas de forma a monitorar ocorrências de eventos de interesse para o condutor ou responsável pelo veículo, bem como fornecer *feedback* quanto a adequação das tendências de direção ao estipulado pelo usuário, incentivando economia no consumo de combustível e melhor utilização dos recursos disponíveis.

O equipamento é composto por um módulo conectado a porta CAN e um pacote comercial de sensores que contempla as soluções inerciais e de GNSS, de modo que a captação e processamento de dados ocorrem em tempo real e já no mecanismo embarcado, monitorando

os eventos de interesse e os enviando para uma plataforma *web* que permite apresentação mais adequada para o usuário final. Dentre as métricas observáveis encontram-se a ocorrência de aceleração e frenagem excessivas ou constantes, períodos de *idling*, monitoração de velocidade e taxa de rotação do motor, consumo de combustível, estimativa contínua da inclinação do terreno, entre outros. A partir destes, um bom indicativo quanto a adequação dos padrões de direção a limites recomendáveis pode ser recuperado, fomentando aplicações de *ecodriving*.

Os dados de maior interesse para o presente trabalho são aqueles provenientes do módulo IMU - capaz de aferir a força específica, a taxa de modificação angular e a orientação do corpo ao qual se encontra acoplado -, e do sistema GNSS – Global Navigation Satellite System, um sistema global de navegação que faz uso da tecnologia de GPS com o intuito de fornecer em tempo real a posição geográfica do veículo. A solução de fusão sensorial GPS + IMU proposta pela SEVEN GO fornece precisão inferior a 4,0 m em condições ideais.

4.2 Ambientes de teste

Os dados utilizados para o desenvolvimento e validação das propostas de trabalho foram coletados em três percursos distintos no interior do campus da Universidade Federal de Lavras, com um veículo da marca *Hyundai*, modelo HB20s. As coletas referentes a eventos de *cornering* e *swerving* foram realizadas em duas viagens diferentes, de modo a evitar a ocorrência de possíveis interferências ou confusões nas identificações dos eventos. O número de manobras de *cornering* e *swerving* efetuadas em cada um dos percursos encontra-se sumarizado na Tabela 4.1.

Tabela 4.1 – Natureza dos eventos coletados em cada percurso.

	Cornering	Swerving	Número de Curvas
Percurso 1	4	-	6
Percurso 2	4	3	6
Percurso 3	4	3	-

Fonte: Própria

O percurso 1 pode ser visto na Figura 4.2 e corresponde a um trajeto de 1,4 km, contendo 5 curvas convencionais e 1 curva suave. Neste ambiente, foram realizadas manobras de *cornering* em 4 das 5 curvas convencionais registradas, ao passo que não foram realizadas manobras de *swerving* por se tratar de um percurso de intensa movimentação de veículos, e tais manobras acabariam provocando risco para os demais condutores.

Figura 4.2 – Primeiro percurso realizado para coleta de dados de teste.



Fonte: Google Earth

O percurso 2 pode ser visto na Figura 4.3 e corresponde a um trajeto de 2,35 km, contendo 5 curvas convencionais e 1 curva suave. De mesmo modo, neste ambiente foram realizadas manobras de *cornering* em 4 das 5 curvas convencionais registradas, ao passo que por contemplar regiões menos exploradas e ainda distantes das avenidas conhecidas por seu intenso fluxo de veículos, 3 manobras de *swerving* foram realizadas em sua extensão.

Figura 4.3 – Segundo percurso realizado para coleta de dados de teste



Fonte: Google Earth

O percurso 3 pode ser visto na Figura 4.4, e corresponde ao estacionamento do pavilhão pertencente a ABI - Engenharias da UFLA que, por se tratar de uma construção relativamente recente, geralmente apresenta pouco movimento e confere a segurança necessária para a realização dos experimentos. Neste ambiente, foram registradas 4 manobras de *cornering* e 3 manobras de *swerving*. O caminho executado para cada teste foi dependente de sua natureza, e por isso será representado junto aos respectivos resultados.

Figura 4.4 – Estacionamento utilizado para coleta de dados de teste.



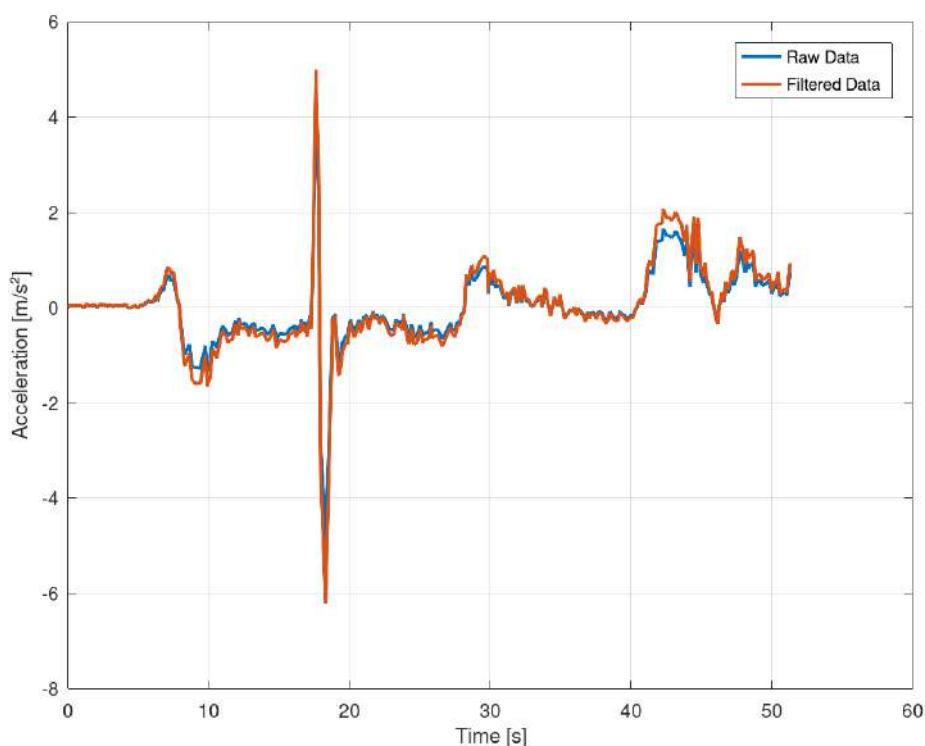
Fonte: Google Earth

4.3 Filtragem de dados

Uma vez que as leituras aferidas por meio de acelerômetros são usualmente poluídas por ruídos aleatórios e sistemáticos, um filtro passa-baixas foi aplicado sobre os dados coletados com o intuito de mitigar seus efeitos. Os parâmetros do filtro foram determinados de forma que sua ação não modificasse significativamente as tendências dos dados de entrada, já que estas reproduzem informações de interesse, mas tão somente as atenuem de forma a minimizar o efeito do ruído. O comparativo entre os dados filtrados e originais de aceleração lateral para um trecho do percurso pode ser visto na Figura 4.5.

Verifica-se que, conforme o esperado, o efeito do filtro não modifica o as tendências apresentadas pelos dados de entrada, mas atenua em certa medida sua magnitude e reduz a influência de oscilações muito abruptas, incompatíveis com o real movimento do veículo.

Figura 4.5 – Procedimento de filtragem dos dados coletados.



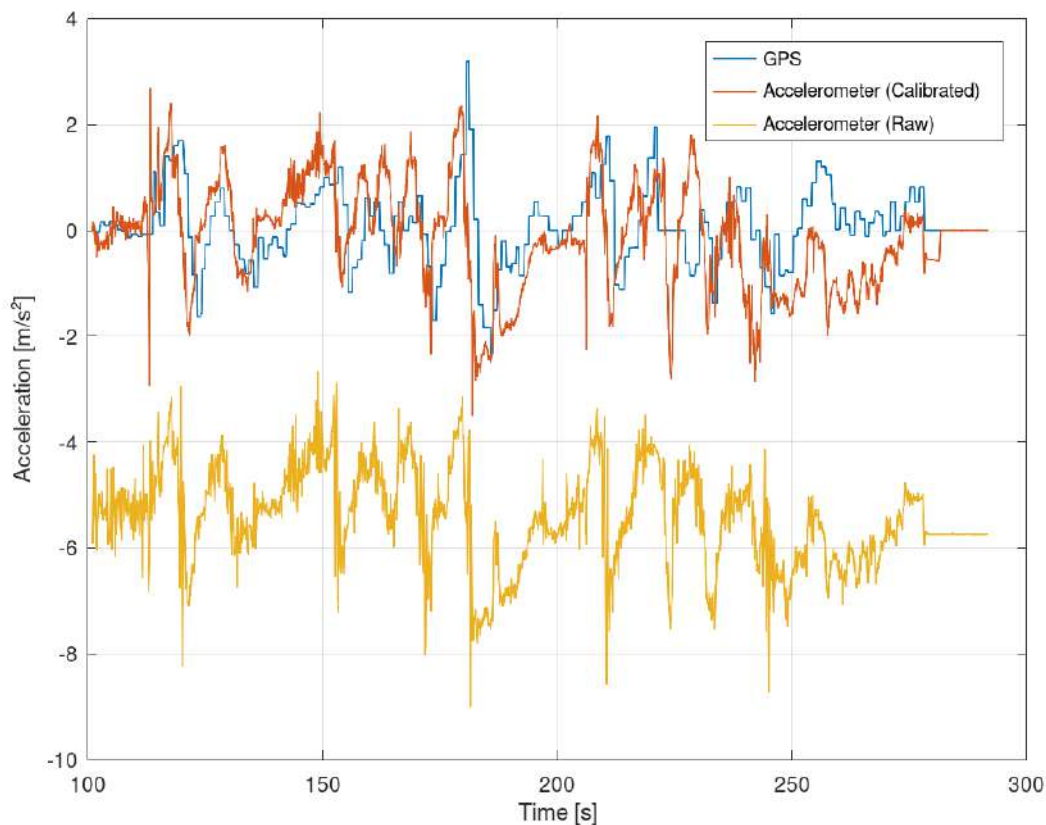
Fonte: Própria

4.4 Alinhamento de frames

A eficácia de metodologia sugerida para alinhamento dos frames do referencial da IMU e do veículo é avaliada conforme observado na Figura 4.6. Nessa, as leituras provenientes da IMU embarcada são utilizadas para estimar a aceleração longitudinal do veículo, adotando-se o sensor GPS como *ground-truth* da grandeza em questão - deve-se ressaltar que o GPS fornece informações relativas a posição do veículo no tempo, de modo que as acelerações aqui apresentadas são fruto de uma operação de dupla derivação, o que introduz uma potencial fonte de erro em relação a aceleração longitudinal realmente experienciada.

A melhoria na performance obtida para a estimativa da aceleração longitudinal com o uso de acelerômetros após o procedimento de alinhamento é evidente quando comparada a sua contraparte não tratada. Observa-se que os dados puros apresentam significativo desvio associado ao seu valor médio e representam um perfil de movimentação completamente discrepante daquele sugerido pelo *ground-truth*, enquanto as estimativas provenientes das leituras submetidas ao alinhamento acompanham bem a referência e fornecem uma aproximação muito mais adequada de seu comportamento.

Figura 4.6 – Performance de calibração do algoritmo de alinhamento via estimativa de aceleração longitudinal.



Fonte: Própria

Ainda que a dificuldade da IMU de replicar os dados de aceleração provenientes do GPS seja perceptível, é importante salientar que a técnica aqui apresentada não tem o objetivo de resolver o problema delineado de forma ótima e nem mesmo rivalizar às soluções estado-da-arte, mas propiciar alinhamento adequado para posterior utilização da IMU, bem como fornecer uma estimativa grosseira de orientação a ser refinada por técnicas mais elaboradas, tarefas estas que cumprem excepcionalmente bem. Contudo, deve-se ressaltar que embora a metodologia apresentada forneça bons resultados, algumas limitações a ela inerentes podem aumentar a complexidade de sua aplicação prática. A mais significativa delas diz respeito a necessidade de se conhecer previamente o vetor de acelerações correspondentes a ação da gravidade sobre o veículo para realizar o procedimento de *leveling*, informação essa nem sempre acessível de maneira confiável em sistemas embarcados menos robustos.

4.5 Detecção de curvas

Uma vez implementado o algoritmo sugerido para detecção de curvas, sua validade foi verificada tomando por base os dados coletados durante os percursos 1 e 2. O desempenho obtido para o caso do percurso 1 pode ser observado na Figura 4.7, onde o trajeto realizado é apresentado em amarelo, enquanto as curvas identificadas pelo sistema aparecem em branco.

Figura 4.7 – Desempenho do algoritmo de detecção de curvas para o percurso 1.



Fonte: Google Earth

Observe que o algoritmo foi capaz de identificar 6 curvas no trajeto percorrido, o que corresponde exatamente ao número de curvas previstas para o percurso 1, como visto na Tabela 4.1. Contudo, vê-se que apenas 5 destas correspondem a uma classificação correta, uma vez que a manobra mais suave presente no trajeto não foi adequadamente caracterizada, ao passo que a identificação 4 visualmente não corresponde a uma curva, e possivelmente se deu em razão do sistema de telemetria não se encontrar rigidamente fixo ao veículo durante a etapa de testes.

Outra característica relevante é o fato de algumas curvas aparecerem levemente deslocadas em relação ao ponto onde realmente ocorreram no mapa, comportamento esse atribuído à janela de valores utilizados pois a ativação do algoritmo ocorre sempre após já realizado o movimento. O desempenho obtido para a identificação de curvas junto aos dados coletados no percurso 2 pode ser observado na Figura 4.8.

De forma semelhante ao caso anterior, o algoritmo foi capaz de identificar 6 curvas no trajeto percorrido, porém novamente incorrendo em um falso negativo na curva suave vista logo acima da curva 1. Tais inconsistências surgem em razão da limitação associada ao tamanho da janela adotada para armazenar as leituras consecutivas de GPS, uma vez que a taxa de aquisição

Figura 4.8 – Desempenho do algoritmo de detecção de curvas para o percurso 2.



Fonte: Google Earth

do equipamento é de apenas 1 Hz e a distância entre os pontos coletados depende diretamente da velocidade do veículo, em trechos de curvatura suaves percorridos muito rapidamente apenas 3 pontos não se mostram capazes de capturar o formato da trajetória de maneira adequada o suficiente para permitir classificá-la como uma curva. De mesmo modo, trechos de curvatura acentuada percorridos lentamente podem levar a um acúmulo de pontos coletados para a mesma região e provocar detecções duplas.

Uma alternativa para contornar tal dificuldade é a expansão da metodologia apresentada de modo a contemplar uma janela de tamanho móvel e proporcional à velocidade do veículo. Dessa forma, quando em velocidades mais altas o sistema passaria a fazer uso de uma janela maior de maneira a coletar mais informações acerca do trajeto, ao passo que usaria janelas menores para situações de baixa velocidade. Outra possibilidade é o melhor ajuste do limiar aplicado sobre o ângulo de curvatura, tornando-o mais genérico e propício para um maior universo de casos.

Ainda assim, dado o bom desempenho apresentado pelo algoritmo sugerido para o presente percurso corroborado pela quase totalidade de identificações corretas, o mesmo foi considerado válido e suficientemente adequado para a posterior utilização na detecção de eventos de *cornering*.

Uma vez identificadas corretamente as curvas existentes no percurso, o passo seguinte consiste em estimar os centros das circunferências que descrevem a extensão do arco de curvatura executado durante a manobra, variáveis essenciais para a determinação da velocidade

Figura 4.9 – Desempenho na estimativa de raio e circunferência de curvas.



Fonte: Google Earth

crítica com que a curva pode ser seguramente executada. O desempenho do sistema pode ser visto na Figura 4.9, onde a marcação amarela representa o trajeto descrito, os pontos brancos representam as curvas identificadas, os pontos vermelhos representam os centros estimados e os círculos traçados possuem o raio obtido.

Note que as predições se encaixam bem nas curvas apontadas, descrevendo claramente uma aproximação do movimento que realizariam dada a manutenção da direção corrente. A posição dos centros das curvaturas também se mostram adequados em relação ao esperado dada a direção do veículo nesse ponto do percurso. Resultados mais precisos podem ser obtidos se consideradas as limitações estabelecidas pela geometria de Ackermann, uma vez acessíveis as velocidades de giro das rodas.

Verificam-se pequenas inconsistências quanto às posições das curvas em relação à pista, porém tais discrepâncias não são significativas e se enquadram na variância esperada para so-

luções de GPS. Ressalta-se que por se tratarem de elementos variáveis de acordo ao trajeto executado pelo motorista em determinada ocasião e puramente estimados a partir de seu comportamento, não é possível avaliar a precisão dos resultados obtidos a partir da comparação com um *ground-truth* de referência.

A partir da boa performance do algoritmo no que diz respeito a estimativa das métricas em questão, fica então corroborada a validade da metodologia sugerida.

4.6 Detecção de cornering

Sendo capaz de identificar as curvas dos trajetos percorridos e seus respectivos raios de curvatura, torna-se então possível fazer uso da metodologia desenvolvida de modo a detectar ocorrências de *cornering* nos trechos de teste.

Primeiramente deve-se definir um coeficiente K_{corn} coerente para os ambientes em questão. Considerando se tratar de uma localidade urbana de intensa movimentação, verifica-se a necessidade de um limiar conservador a ponto de coibir comportamentos arriscados sem, contudo, gerar penalidades em excesso. Nesse sentido, elegeu-se o limiar de 0,7 como mais adequado no que diz respeito a abarcar coerentemente ambos os critérios.

O desempenho da metodologia então foi avaliado junto aos dados coletados nos três ambientes de testes. A Tabela 4.3 sumariza as métricas de velocidade crítica, velocidade registrada e K_{corn} estimadas pelo algoritmo junto aos dados referentes ao percurso 1, onde as curvas identificadas foram enumeradas de maneira semelhante à Figura 4.7, iniciando na mais inferior e crescendo gradativamente enquanto percorre o trajeto no sentido anti-horário.

Tabela 4.2 – Grandezas aferidas pelo algoritmo de detecção de *cornering* junto ao percurso 1.

	$Vel_{crit} [Km/h]$	$Vel_{reg} [Km/h]$	K_{corn}
Curva 1	27	14	0,52
Curva 2	32,28	25,76	0,71
Curva 3	55,97	41,42	0,74
Curva 4	24,09	14,99	0,62
Curva 5	39,21	19,99	0,51
Curva 6	47,06	38,12	0,81

Fonte: Própria

De acordo aos coeficientes apresentados na Tabela 4.3, em consonância ao valor limite para o coeficiente K_{corn} definido anteriormente, 3 das 6 curvas identificadas foram consideradas *cornering*. Ciente de que a curva 4 não deve ser levada em consideração uma vez que corres-

ponde a um falso positivo, vê-se que o algoritmo foi capaz de fornecer resultados adequados para o presente caso, pois segundo ao especificado na Tabela 4.1 manobras de *cornering* foram realizadas em 4 das 6 curvas presentes nesse trecho. A Figura 4.10 mostra os eventos detectados representados em suas respectivas localizações no mapa do percurso.

Figura 4.10 – Desempenho do algoritmo de detecção de *cornering* junto ao percurso 1.



Fonte: Google Earth

Para melhor avaliar a validade dos coeficientes estimados, o percurso 1 foi novamente realizado porém sem a ocorrência de eventos de *cornering*, em uma situação na qual espera-se que o algoritmo seja capaz de reconhecer a característica mais suave de direção e estimar coeficientes mais baixos, a medida que sugere velocidades críticas semelhantes ao caso anterior, uma vez que as mesmas curvas foram realizadas, porém com intensidades diferentes.

Tabela 4.3 – Grandezas aferidas pelo algoritmo para um trajeto normal junto ao percurso 1.

	$Vel_{crit}[Km/h]$	$Vel_{reg}[Km/h]$	K_{corn}
Curva 1	28,29	19,24	0,68
Curva 2	37,97	15,57	0,41
Curva 3	-	-	-
Curva 4	-	-	-
Curva 5	40,91	20,05	0,49
Curva 6	44,64	38,12	0,56

Fonte: Própria

Vê-se que, conforme o esperado, os coeficientes de *cornering* são significativamente menores para o caso do trajeto 1 percorrido em velocidade normal, e que, de fato, as velocidades críticas estimadas são muito próximas às daquelas vistas no caso anterior, sugerindo um bom

desempenho por parte da técnica em sua determinação. Ressalta-se que as curvas 3 e 4 - que se tratava de um falto positivo - não foram identificadas nesse experimento.

De maneira semelhante ao caso anterior, as métricas de velocidade crítica, velocidade registrada e K_{corn} estimadas pelo algoritmo junto aos dados referentes ao percurso 2 estão sumarizadas na Tabela 4.4, onde as curvas identificadas foram enumeradas de maneira semelhante à Figura 4.8.

Tabela 4.4 – Grandezas aferidas pelo algoritmo de detecção de *cornering* junto ao percurso 2.

	$Vel_{crit}[Km/h]$	$Vel_{reg}[Km/h]$	K_{corn}
Curva 1	48,78	34,76	0,71
Curva 2	42,59	25,13	0,59
Curva 3	41,42	28,25	0,68
Curva 4	33,23	29,58	0,89
Curva 5	45,78	31,78	0,69
Curva 6	63,76	45,91	0,72

Fonte: Própria

Diferentemente do observado nos dados apresentados pela Tabela 4.3, os valores dos coeficientes K_{corn} , com exceção clara para a curva 4, ficam bem próximos do valor limiar, tanto para os casos positivos para a ocorrência de *cornering* quanto para os negativos. Tal tendência mostra um comportamento mais agressivo de direção associada a execução desse percurso, bem como sugere a necessidade do estabelecimento outros critérios para corroborar a atividade de classificação e reduzir a incerteza associada aos coeficientes muito próximos do limiar. Não foram obtidos dados relativos ao trajeto do caminho 1 sem a ocorrência dos eventos de *cornering*.

Conforme visualizado no mapa da Figura 4.11, para o presente caso 3 das 6 curvas identificadas foram consideradas *cornering*, em contraponto às 4 manobras realmente realizadas nesse trecho, conforme informado na Tabela 4.1. Percebe-se que o desempenho do sistema se mantém constante em relação ao obtido no percurso 1, mostrando-se capaz de identificar casos mais exacerbados mas ainda apresentando certa inconsistência na detecção de eventos menos expressivos.

Já no que diz respeito aos dados coletados no terceiro ambiente de testes, não há uma noção bem definida de percurso realizado uma vez que as manobras foram efetuadas aleatoriamente em torno dos obstáculos ali presentes, havendo para fins de validação o número averiguado de eventos de fato registrados no momento do teste. Para este caso, um total de 6

Figura 4.11 – Desempenho do algoritmo de detecção de *cornering* junto ao percurso 2



Fonte: Google Earth

curvas foram identificadas pelo sistema, das quais 3 foram consideradas *cornering*. A Tabela 4.5 sumariza as estimativas obtidas.


Tabela 4.5 – Grandezas aferidas pelo algoritmo de detecção de *cornering* junto ao percurso 3.

	$Vel_{crit} [Km/h]$	$Vel_{reg} [Km/h]$	K_{corn}
Curva 1	31,58	24	0,76
Curva 2	45,32	37,62	0,83
Curva 3	39,34	23,05	0,60
Curva 4	38,37	32,97	0,86
Curva 5	28,32	18,41	0,65
Curva 6	37,36	25,03	0,67

Fonte: Própria

Considerando o fato de que 4 manobras foram realmente realizadas, o desempenho do algoritmo na tarefa de identificação nesse ambiente de testes é tido como igualmente satisfatório. Verifica-se que os coeficientes aqui identificados possuem valores mais elevados do que aqueles vistos nos casos anteriores, comportamento esse perfeitamente adequado e esperado haja vista se tratar de uma localidade mais segura e menos movimentada que as anteriores, conferindo mais liberdade e segurança para a realização de manobras mais abruptas. A visualização dos eventos no mapa do ambiente pode ser encontrada na Figura 4.12.

Figura 4.12 – Desempenho do algoritmo de detecção de *cornering* junto ao percurso 3.



. Fonte: Google Earth


4.7 Detecção de swerving

O algoritmo para a detecção de *Swerving* baseia-se na contínua monitoração da distância entre o valor máximo e médio de uma janela temporal que armazena as acelerações laterais experienciadas pelo veículo nos últimos instantes. A Figura 4.13 mostra o comparativo entre a aceleração lateral coletada e a métrica dada pela diferença em questão para o a viagem executada durante o percurso 2.

Cabe ressaltar que não foram coletados dados de validação para o evento *Swerving* ao longo do percurso 1 em razão da maior movimentação de pedestres e veículos associada a esse caminho, rendendo certa insegurança quanto a execução de atividades tão erráticas e perigosas.

Perceba que a ativação do modelo ocorre sempre no eixo positivo do sistema cartesiano, ainda que os picos de aceleração estejam apontando em direção ao eixo negativo. Essa característica do sinal é intencional e ocorre em função da adoção do módulo da métrica ao invés de seu valor bruto, uma vez que o sinal da aceleração apenas identifica o sentido da aceleração em relação a definição de positivo do vetor y atrelado ao corpo do sensor, o que não influencia na maneira como o evento é avaliado.

Figura 4.13 – Comparativo entre aceleração lateral e métrica extraída para o percurso 2.



Fonte: Google Earth

Outro ponto importante é que, ao contrário do previsto, a métrica apresenta significativa ativação também para o caso da realização de curvas. Esperava-se que o pico de aceleração lateral mais prolongado característico desse movimento elevasse o valor médio da janela na mesma medida do crescimento do valor máximo, levando a uma pequena diferença. Vê-se, porém, que em razão da realização de curvas muito rápidas ou fechadas não há tempo hábil para que isso ocorra, elevando consideravelmente a diferença entre os indicadores calculados e ocasionando na ativação do sistema, chegando a gerar confusão quando comparado a um *swerving* moderado, por exemplo.

No entanto, uma vez que a solução também oferece a possibilidade de detectar as curvas executadas durante o trajeto, tal informação pode ser utilizada de maneira a corroborar as detecções verdadeiras e eliminar os falsos positivos. As localizações das detecções de fato positivas junto aos dados retratados na Figura 4.13 podem ser vistas na Figura 4.14, onde a faixa amarela corresponde ao trecho percorrido e os pontos azuis correspondem aos eventos detectados.

Figura 4.14 – Desempenho do algoritmo de detecção de swerving junto ao percurso 2.




Fonte: Própria

Vê-se que consoante a referência presente na Tabela 4.1, 3 eventos de *swerving* foram identificados para o trecho em questão. Tal desempenho está de acordo também ao comportamento observado para a métrica de ativação da Figura 4.13, o que sugere um bom desempenho do algoritmo no que tange a identificação destas manobras para o ambiente em questão.

O comparativo entre a métrica de ativação e a aceleração lateral registrada para os dados coletados no ambiente 3 podem ser vistos na Figura 4.15. A ativação da métrica para esse caso mostra-se mais consistente do que no caso anterior, uma vez que há apenas um caso onde a realização de uma curva eleva o coeficiente acima do limiar aplicado, gerando um falso positivo. Em contrapartida, todos os 3 eventos de *swerving* previstos para este ambiente conforme especificado na tabela 4.1 foram identificados confiavelmente, haja vista a discrepância no comportamento da métrica em relação ao resto do percurso.


As localizações no mapa das detecções sugeridas pelo comportamento da métrica podem ser vistas na Figura 4.16. O resultado aqui observado novamente corrobora a validade do procedimento, com os 3 eventos esperados de fato identificados para o trecho analisado.

Figura 4.15 – Comparativo entre aceleração lateral e métrica extraída para o percurso 3.



Fonte: Própria

Figura 4.16 – Desempenho do algoritmo de detecção de swerving junto ao percurso 3.



Fonte: Própria

5 CONCLUSÃO E TRABALHOS FUTUROS

O presente trabalho ofereceu algumas contribuições para o problema de monitoração de manobras sinuosas em veículos, adotando para tanto a solução de telemetria desenvolvida pela SEVEN GO. Mesmo frente a grande variedade de aplicações semelhantes presentes na literatura, a técnica apresentada mostrou-se capaz de oferecer bom desempenho nas tarefas propostas por meio de sensores de baixo custo e ampla acessibilidade, tornando-a largamente replicável. O problema abordado foi dividido em 4 partes: alinhamento dos eixos da IMU; a detecção de curvas; detecção de manobras de *swerving*; e detecção de manobras de *cornering*. Com o intuito de validar experimentalmente as técnicas propostas, um veículo de passeio equipado com a solução sistema SEVEN GO Smart Edge foi utilizado para coletar dados das referidas manobras em ambientes reais, na Universidade Federal de Lavras.

O procedimento de alinhamento do referencial do IMU em relação ao referencial do veículo provou-se efetivo a medida que melhorou substancialmente a performance atrelada a estimativa de aceleração longitudinal quando comparada aos dados brutos. Outra vantagem do método é sua simplicidade e baixo custo, não exigindo sensores adicionais para que possa ser replicada. Observa-se, porém, que a estimativa obtida é grosseira e se pode ser consideravelmente beneficiada com a utilização posteriores técnicas de refinamento.

O sistema de detecção de curvas utilizou leituras sequenciais de GPS para estimar a variação de orientação do veículo no decorrer de uma janela lateral e definir um limiar acima do qual uma curva é caracterizada. Nos experimentos realizados, a metodologia mostrou-se capaz de classificar corretamente a maior parte das amostras avaliadas, incorrendo em falsos positivos e falsos negativos a depender da relação estabelecida entre a velocidade do veículo e a natureza da curva.

Ainda que com bom desempenho prático, a técnica apresenta dificuldades significativas no reconhecimento de curvas muito suaves, uma vez que a dimensão da janela temporal aqui adotada não se mostrou eficiente a ponto de extrair informações o bastante para fomentar classificações corretas em duas curvas avaliadas. Este problema pode ser resolvido com a adoção de uma janela de tamanho variável e proporcional a velocidade do veículo, de modo a otimizar sua eficiência de classificação para todos os casos.

Os parâmetros de centro e raio de curvatura estimados a partir das curvas detectados também se mostraram adequados e visualmente estão em conformidade com o esperado para as amostras contidas no experimento, porém suscitam melhores análises com o objetivo de estabe-

lecer uma métrica de qualidade mais eficiente, bem como avaliar a consistência do desempenho apresentado sobre novos dados de teste.

O algoritmo de detecção de *cornering*, por sua vez, também apresentou bom desempenho prático, em especial no que diz respeito aos eventos de maior proeminência, onde a velocidade registrada no momento da curva em muito se aproxima da velocidade crítica estimada. Contudo, mostrou-se suscetível a ocorrência de falsos negativos haja vista a expressiva inconsistência observada para eventos mais sutis, onde o coeficiente de decisão estimado fica muito próximo do limiar de classificação.

Ressalta-se que na atual roupagem tal metodologia foi avaliada tomando por base informações de curvas e raios de curvaturas também estimados e que, apesar do bom desempenho prático, carregam em si incertezas inerentes a seu processo de aquisição. Além disso, tal classificação está diretamente associada a uma série de outros fatores, tais como a ambientação onde o evento se deu, o formato da curva realizada e as características construtivas do veículo, o que torna a determinação de um limiar de classificação adequado uma tarefa delicada. Uma metodologia semelhante e capaz de contornar as dificuldades apresentadas é vista em (GHANDOUR et al., 2012), onde o coeficiente de fricção μ máximo é estimado via a utilização de um observador de estados alimentado com parâmetros relativos a dinâmica do veículo e ao mapa conhecido, e utilizado para a determinação de um indicador de risco das etapas do percurso.

O detector de *swerving* foi desenvolvido com base na diferença entre os valores médio e máximo da janela temporal aplicada ao vetor de acelerações laterais experienciados pelo veículo. A métrica foi assim determinada com o intuito de capturar a natureza abrupta do movimento, que eleva rapidamente o valor máximo da aceleração lateral enquanto apresenta média atenuada pelos dados anteriores. Nos experimentos realizados, porém, observou-se que tal comportamento pode ser reproduzido também por curvas realizadas muito rapidamente, levando o sistema a emitir detecções indevidas ao confundir o padrão de acelerações provocado pela curva com um evento de *swerving*. Porém, incorporando a capacidade de detecção de curvas desenvolvido na etapa anterior, vê-se que a metodologia para detecção de *swerving* passa apresentar ótimo desempenho frente aos dados de teste.

De maneira geral, as aplicações desenvolvidas demonstram bom desempenho prático e cumprem as tarefas a que se propõe, em especial quando considerados os baixos custos requeridos e a simplicidade com a que se apresentam, frente aos métodos mais robustos, mas significativamente mais custosos encontrados em literatura. Apesar disso, tendo em vista as

dificuldades enfrentadas, vê-se que são necessárias análises mais aprofundadas acerca da generalização de sua performance, por meio de testes mais elaborados e abrangentes.

REFERÊNCIAS

- 4WD. *Defensive Driving: Cornering*. 2020. Disponível em: <<https://australian4wd.com.au/defensive-driving/cornering/>>.
- AL-SULTAN, S.; AL-BAYATTI, A. H.; ZEDAN, H. Context-aware driver behavior detection system in intelligent transportation systems. **IEEE transactions on vehicular technology**, IEEE, v. 62, n. 9, p. 4264–4275, 2013.
- ANTP. **Relatório Geral 2016**. [S.l.], 2016. Disponível em: <<http://files.antp.org.br/simob/simob-2016-v6.pdf>>.
- BEINSTEIN, A. et al. **How Uber Beacon Helps Improve Safety for Riders and Drivers**. 2018. Disponível em: <<https://engineeringjobs4u.co.uk/how-uber-beacon-helps-improve-safety-for-riders-and-drivers>>.
- BENGLER, K. et al. Three decades of driver assistance systems: Review and future perspectives. **IEEE Intelligent transportation systems magazine**, IEEE, v. 6, n. 4, p. 6–22, 2014.
- BLINCOE, L. J. et al. **The economic impact of motor vehicle crashes, 2000**. [S.l.], 2002.
- BOURKE, P. **Equation of a Circle from 3 Points (2 dimensions)**. 1999. Disponível em: <<http://paulbourke.net/geometry/circlesphere/>>.
- BOYALI, A.; MITA, S.; JOHN, V. A tutorial on autonomous vehicle steering controller design, simulation and implementation. **arXiv preprint arXiv:1803.03758**, 2018.
- CARMONA, J. et al. Data fusion for driver behaviour analysis. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 15, n. 10, p. 25968–25991, 2015.
- CASTIGNANI, G. et al. Driver behavior profiling using smartphones: A low-cost platform for driver monitoring. **IEEE Intelligent Transportation Systems Magazine**, IEEE, v. 7, n. 1, p. 91–102, 2015.
- CHENG, R. et al. Research on safe driving scoring system and personalized ratemaking of vehicle insurance based on obd data. In: ACM. **Proceedings of the 3rd International Conference on Crowd Science and Engineering**. [S.l.], 2018. p. 7.
- DAI, J. et al. Mobile phone based drunk driving detection. In: IEEE. **2010 4th International Conference on Pervasive Computing Technologies for Healthcare**. [S.l.], 2010. p. 1–8.
- ELVIK, R. How much do road accidents cost the national economy? **Accident Analysis & Prevention**, Elsevier, v. 32, n. 6, p. 849–851, 2000.
- FELL, J.; HENDRICKS, D.; FREEDMAN, M. The relative frequency of unsafe driving acts in serious traffic crashes. In: **PROCEEDINGS OF THE 44TH ANNUAL CONFERENCE OF THE ASSOCIATION FOR THE ADVANCEMENT OF AUTOMOTIVE MEDICINE, CHICAGO, ILLINOIS, USA, OCTOBER 2-4, 2000**. [S.l.: s.n.], 2000.
- FRENCH, D. J. et al. Decision-making style, driving style, and self-reported involvement in road traffic accidents. **Ergonomics**, Taylor & Francis, v. 36, n. 6, p. 627–644, 1993.
- GHANDOUR, R. et al. Risk indicators evaluation based on anticipated vehicle dynamics parameters. **IEEE intelligent systems**, IEEE, v. 27, n. 2, p. 68–73, 2012.

GROVES, P. D. Principles of gnss, inertial, and multisensor integrated navigation systems, [book review]. **IEEE Aerospace and Electronic Systems Magazine**, IEEE, v. 30, n. 2, p. 26–27, 2015.

HALL, E. C. Integrated circuits of the apollo guidance computer. **I nternet: http://klabs.org/history/historL docs/integrated _ circuitslic4-po. pdt: Jan. IS**, 2009.

HAMEL, T.; MAHONY, R. Attitude estimation on so [3] based on direct inertial measurements. In: IEEE. **Proceedings 2006 IEEE International Conference on Robotics and Automation, 2006. ICRA 2006**. [S.l.], 2006. p. 2170–2175.

HARBAGE, R. **Usage-based Auto Insurance (UBI)**. [S.l.]: 0, 2010.

HONG, J.-H.; MARGINES, B.; DEY, A. K. A smartphone-based sensing platform to model aggressive driving behaviors. In: **Proceedings of the SIGCHI Conference on Human Factors in Computing Systems**. [S.l.: s.n.], 2014. p. 4047–4056.

INSURANCE, P. **Linking Driving Behavior to Automobile Accidents and Insurance Rates**. [S.l.]: Jul, 2012.

IPEA. **Estimativa dos custos dos acidentes de trânsito no Brasil com base na atualização simplificada das pesquisas anteriores do Ipea**. [S.l.], 2015. Disponível em: <http://www.ipea.gov.br/portal/images/stories/PDFs/relatoriopesquisa/160516_relatorio_estimativas.pdf>.

JOHNSON, D. A.; TRIVEDI, M. M. Driving style recognition using a smartphone as a sensor platform. In: IEEE. **2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)**. [S.l.], 2011. p. 1609–1615.

KLAUER, S. G. et al. **Comparing real-world behaviors of drivers with high versus low rates of crashes and near crashes**. [S.l.], 2009.

LY, M. V.; MARTIN, S.; TRIVEDI, M. M. Driver classification and driving style recognition using inertial sensors. In: IEEE. **2013 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.], 2013. p. 1040–1045.

MEIRING, G. A. M.; MYBURGH, H. C. A review of intelligent driving style analysis systems and related artificial intelligence algorithms. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 15, n. 12, p. 30653–30682, 2015.

NAJM, W. et al. **Development of test scenarios for off-roadway crash countermeasures based on crash statistics**. [S.l.], 2002.

NHTSA, U. The visual detection of dwi motorists. **US Department of Transportation, Washington, DC**, 2012.

OLIVEIRA, E.; KUGA, H.; LOPES, R. Imu self-alignment on a static platform with kalman filter. In: **Proceedings of 8th Brazilian Conference on Dynamics, Control and Applications**. [S.l.: s.n.], 2009. p. 1–6.

OLIVER, N.; PENTLAND, A. P. Graphical models for driver behavior recognition in a smartcar. In: IEEE. **Proceedings of the IEEE Intelligent Vehicles Symposium 2000 (Cat. No. 00TH8511)**. [S.l.], 2000. p. 7–12.

- OMS. **Global status report on road safety 2018**. [S.l.]: Organização Mundial da Saúde, 2015.
- PAEFGEN, J. et al. Driving behavior analysis with smartphones: insights from a controlled field study. In: **Proceedings of the 11th International Conference on mobile and ubiquitous multimedia**. [S.l.: s.n.], 2012. p. 1–8.
- PERSSON, B. N. et al. Rubber friction on wet and dry road surfaces: The sealing effect. **Physical review B**, APS, v. 71, n. 3, p. 035428, 2005.
- POSADA, F.; FAÇANHA, C. Brazil passenger vehicle market statistics: International comparative assessment of technology adoption and energy consumption. 2015.
- REASON, J. **Human error**. [S.l.]: Cambridge university press, 1990.
- S. POLAVARAPU S., K. Y. C. Integrated computing system for measuring driver safety index. In: **International Journal of Emerging Technology and Advanced Engineering**. [S.l.: s.n.], 2012. p. 1–5.
- SHAOUT, A.; COLELLA, D.; AWAD, S. Advanced driver assistance systems-past, present and future. In: IEEE. **2011 Seventh International Computer Engineering Conference (ICENCO'2011)**. [S.l.], 2011. p. 72–82.
- SNYDER, J. P. **Map projections—A working manual**. [S.l.]: US Government Printing Office, 1987. v. 1395.
- STOICHKOV, R. Android smartphone application for driving style recognition. **Department of Electrical Engineering and Information Technology Institute for Media Technology, July**, v. 20, 2013.
- VIOLENCE, W. H. O. D. of et al. **Global status report on road safety: time for action**. [S.l.]: World Health Organization, 2009.
- WAHLSTRÖM, J.; SKOG, I.; HÄNDEL, P. Detection of dangerous cornering in gnss-data-driven insurance telematics. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 16, n. 6, p. 3073–3083, 2015.
- WAHLSTRÖM, J.; SKOG, I.; HÄNDEL, P. Imu alignment for smartphone-based automotive navigation. In: IEEE. **2015 18th International Conference on Information Fusion (Fusion)**. [S.l.], 2015. p. 1437–1443.
- WAHLSTRÖM, J.; SKOG, I.; HÄNDEL, P. Smartphone-based vehicle telematics: A ten-year anniversary. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 18, n. 10, p. 2802–2825, 2017.
- WINTER, J. D.; DODOU, D. The driver behaviour questionnaire as a predictor of accidents: A meta-analysis. **Journal of safety research**, Elsevier, v. 41, n. 6, p. 463–470, 2010.
- YANG, D. et al. Complete tri-axis magnetometer calibration with a gyro auxiliary. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 17, n. 6, p. 1223, 2017.