

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Wictor Gomes de Oliveira

**DBALapisco - Sistema de Detecção de Direção Anormal para Veículos
Autônomos e Cidades Inteligentes**

Fortaleza – CE

15 de agosto de 2022

Wictor Gomes de Oliveira

DBALapisco - Sistema de Detecção de Direção Anormal para Veículos Autônomos e Cidades Inteligentes

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Inteligência Artificial

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

15 de agosto de 2022



Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)
Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Wictor Gomes de Oliveira

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, sendo aprovada pela Coordenação do Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará e pela banca examinadora:

**Orientador: Prof. Dr. Pedro Pedrosa Rebouças
Filho**

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

**Prof. Dr. Carlos Maurício Jaborandy de Mattos
Dourado Júnior**

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

Prof. Dr. Fabrício Gonzalez Nogueira
Universidade Federal do Ceará (UFC)

Fortaleza – CE
15 de agosto de 2022

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

- O48d Oliveira, Wictor Gomes de.
 DBALapisco - Sistema de Detecção de Direção Anormal para Veículos Autônomos e Cidades Inteligentes /
 Wictor Gomes de Oliveira. - 2022.
 77 f. : il. color.
- Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus
 Fortaleza, 2022.
 Orientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.
1. Direção Anormal. 2. Comportamento do Motorista. 3. Veículos Autônomos. 4. Validação de Segurança. 5.
 Cidades Inteligentes. I. Título.

CDD 004

*Este trabalho é dedicado ao sotaque e ao humor nordestino,
símbolos da cultura de meu povo.*

*Este trabalho é dedicado às pessoas que
perderam entes queridos em acidentes de trânsito.*

Agradecimentos

Agradeço a meus pais, Vandey e Tânia. Vocês me encheram com mais do que apenas os recursos básicos para a sobrevivência: o amor e a esperança de um futuro cada vez melhor.

Agradeço à minha madrinha Gilvânia. Obrigado pela única coisa que forçou a fazer: ir para a biblioteca estudar enquanto me preparava para se candidatar.

Agradeço ao meu tio Valdeberto. Obrigado pelas contribuições intelectuais na formulações dos conceitos dessa pesquisa. De todos os conselhos agradeço em especial pelo único que me foi imposto: não desistir.

Agradeço à minha avó Dona Vânia. A senhora providenciou mais do que minha educação básica: a formação de meu caráter.

Agradeço à minha avó Dona Socorro. A senhora demonstra, sem ter que me dizer quase nada, o imenso apoio na maior empreitada que um ser humano pode tentar realizar: tornar-se o que se é.

Agradeço ao meu orientador, professor e mentor Pedro Pedrosa. Teus direcionamentos me mostram mais do que o que devo escrever: como um líder se comporta.

Agradeço aos professores Carlos Maurício e Fabrício Gonzalez pelas imensas contribuições a este trabalho enquanto membros da banca examinadora.

Agradeço ao meu mentor Bruno Carvalho. O seu apoio transformou a única coisa que eu tinha, a ingenuidade, em algo muito maior: a capacidade.

Agradeço ao meu mentor Edson Dantas. Além dos seus direcionamentos busco carregar também uma de suas importantes características: o entusiasmo.

Agradeço a todos os meus familiares e amigos. Gostaria de escrever o nome de cada um de vocês aqui. Agradeço a todos os meus professores no IFCE, UniFanor e JBC. Obrigado pelo conhecimento repassado com tanto zelo.

Agradeço à comunidade do Lapisco pelas contribuições. Espero ainda colaborar com alguma parcela do que absorvi. Agradeço à comunidade do IFCE e do PPGCC pelo imenso apoio em uma época de pandemia, em que a superação não é evidente.

Agradeço a Robert Krajewski e à toda equipe de pesquisa da RWTH Aachen University na Alemanha por ceder permissão de uso das bases de dados aqui utilizadas.

Agradeço à sociedade brasileira. Espero retornar parte do que me foi proporcionado.

A todos vocês afirmo: essa conquista pertence mais a vocês do que a mim.

*"A ciência conhece um único comando: contribuir com a ciência."
(Bertolt Brecht)*

Resumo

Atualmente, as maiores ameaças para a segurança rodoviária estão relacionadas à presença de motoristas bêbados, cansados ou distraídos, que chamamos de direção anormal. Nesta dissertação, desenvolvemos um sistema capaz de detectar a direção anormal através dos padrões de trajetórias dos veículos, contribuindo assim com o treinamento e validação de veículos autônomos e com o monitoramento de tráfego para cidades inteligentes. Para tal, utilizamos dados de trajetórias coletadas via drone em diversos segmentos rodoviários e situações de tráfego na Alemanha. Após processarmos devidamente os dados, definimos quantitativamente a direção anormal através de uma métrica de anormalidade, definimos classes de direção e treinamos uma rede neural para detectar a direção anormal em tempo real. Todos os passos do nosso método foram codificados em linguagem de programação *python* para formar o sistema *DBALapisco*, que pode ser utilizado como plugin por outros softwares no auxílio da tomada de decisão e ser operado via interface gráfica para operações rotineiras de engenharia.

Palavras-chave: Direção Anormal, Comportamento do Motorista, Veículos Autônomos, Validação de Segurança, Cidades Inteligentes, Monitoramento de Tráfego.

Abstract

The greatest hazards for traffic safety nowadays are related to driving under the influence of alcohol, fatigue, and distraction, which we call abnormal driving. In this dissertation, we developed a system for detecting abnormal driving through the trajectory patterns of vehicles, contributing to the training and validation of autonomous vehicles and smart cities' traffic monitoring systems. To do so, we used drone-collected trajectory data from various road segments and traffic situations in Germany. After properly processing the data, we quantitatively defined abnormal driving through an abnormality index, defined classes of driving, and trained a neural network for real-time detection of abnormal driving. All steps of our method were coded in *python* to form the *DBALapisco* system, which can be used as a plugin to aid other decision-making softwares and be operated through its interface for daily routine engineering operations.

Keywords: Abnormal Driving, Driver Behavior, Autonomous Vehicles, Safety Validation, Smart Cities, Traffic Monitoring.

Lista de ilustrações

Figura 1 – Caracterização da presença de direção anormal pela velocidade e posicionamento na faixa em função de suas causas e das condições do ambiente/tráfego.	25
Figura 2 – Possíveis formas captura de imagens para detecção de direção anormal utilizando o <i>DBALapisco</i>	27
Figura 3 – Esquema de coleta de dados via drone na base de dados <i>HighD</i>	37
Figura 4 – Exemplos de trechos rodoviários e total de veículos de cada base de dados.	39
Figura 5 – Representação dos eixos em relação ao veículo e à estrada.	40
Figura 6 – Métrica de anormalidade λ em função de cada atributo. Demonstração da influência diretamente proporcional de σVx em λ	43
Figura 7 – Métrica de anormalidade λ em função de cada atributo. A influência diretamente proporcional de σVx em λ é atenuada. O processo é realizado antes da definição de classes.	44
Figura 8 – <i>Pairplot</i> para a base de dados de trechos retos normalizada com o <i>Standard Scaler</i>	45
Figura 9 – <i>Pairplot</i> para a base de dados normalizada com o <i>Quantile Transformer</i>	46
Figura 10 – Ilustração da mediana geométrica (em azul) em relação aos atributos dos demais veículos.	48
Figura 11 – Boxplot dos atributos de λ do trecho rodoviário reto na situação de tráfego em que não ocorrem mudanças de faixa.	50
Figura 12 – Boxplot de λ (detalhado).	51
Figura 13 – Histograma de λ dos <i>outliers</i> do trecho rodoviário reto sem mudanças de faixa.	52
Figura 14 – Interface <i>DBALapisco</i>	53
Figura 15 – Boxplot da métrica de anormalidade λ para cada trecho rodoviário.	55
Figura 16 – Matriz de confusão para uma realização de classificações do trecho reto sem mudanças de faixa.	57
Figura 17 – Caracterização de manobras para a detecção visual de motoristas intoxicados.	69
Figura 18 – Caracterização de manobras para a detecção visual de motoristas intoxicados (casos adicionais).	70
Figura 19 – Matriz de confusão para uma realização de classificações do trecho reto sem mudanças de faixa.	73
Figura 20 – Matriz de confusão para uma realização de classificações do trecho reto com uma mudança de faixa.	73

Figura 21 – Matriz de confusão para uma realização de classificações do trecho reto com duas mudanças de faixa.	74
Figura 22 – Matriz de confusão para uma realização de classificações do trecho de entradas e saídas de rodovias.	74
Figura 23 – Matriz de confusão para uma realização de classificações do trecho de interseções urbanas.	75
Figura 24 – Matriz de confusão para uma realização de classificações do trecho de rotatórias.	75

Lista de tabelas

Tabela 1	–	Comparação dos desvios padrão da posição lateral (σPy) entre veículos com número de mudanças de faixa (nMF) diferentes.	41
Tabela 2	–	Acurácias de classificação por trecho rodoviário (n representa cada realização de classificações do conjunto de teste).	56
Tabela 3	–	Estudos referentes à detecção de direção anormal.	58

Lista de abreviaturas e siglas

ADAS	Sistemas Avançados de Assistência à Direção - do inglês <i>Advanced Driver Assistance Systems</i>
AV	Veículos Autônomos - do inglês <i>Autonomous Vehicles</i>
DBA	Análise do Comportamento de Direção - do inglês <i>Driving Behavior Analysis</i>
DBALapisco	Sistema de Análise do Comportamento de Direção do Laboratório de Processamento de Imagens, Sinais e Computação Aplicada
MLP	Perceptron Multicamadas - do inglês <i>Multi-Layer Perceptron</i>
NHTSA	Administração de Segurança do Tráfego de Rodovias Nacionais (nos Estados Unidos da América), do inglês <i>National Highway Traffic Safety Administration</i>
ODD	Domínio Operacional de Projeto - do inglês <i>Operational Design Domain</i>
OEDR	Deteção e Resposta a Objetos e Eventos - do inglês <i>Object and Event Detection and Response</i>
WHO	Organização Mundial da Saúde - do inglês <i>World Health Organization</i>

Lista de símbolos

λ	Métrica de Anormalidade
σ	Desvio padrão
ϕ	Fator para cálculo da Mediana Geométrica.
Ax	Aceleração do veículo no eixo x
Ay	Aceleração do veículo no eixo y
n	Total de veículos na base de dados
nMF	Número de mudanças de faixa
$Veículo_i$	Conjunto de atributos (com desvio padrão) de um veículo, na posição i da base de dados, para toda a trajetória percorrida
$Veículo_f$	Conjunto de atributos de um veículo em um determinado frame f
Vx	Velocidade do veículo no eixo x
Vy	Velocidade do veículo no eixo y
Py	Posição do veículo no eixo y

Sumário

1	INTRODUÇÃO	25
1.1	Motivação para a Dissertação	27
1.2	Objetivos Geral e Específicos	28
1.3	Produção científica	28
1.4	Estrutura da Dissertação	28
2	ANÁLISE BIBLIOGRÁFICA	31
2.1	Análise do Comportamento de Direção	31
2.2	Detecção de Direção Anormal	32
2.3	Validações de Segurança Baseadas em Cenários	34
2.4	Bases de Dados	35
2.4.1	HighD, ExiD, InD e RounD	37
3	MÉTODO	39
3.1	Processamento dos dados	40
3.1.1	Normalização dos dados	42
3.1.2	Uma Métrica de Anormalidade	47
3.2	Classes de Direção Anormal	48
3.3	Rede Neural MLP	49
4	DBALAPISCO E RESULTADOS	53
4.1	Resultados de Classificação	54
4.2	Comparações dos Resultados	58
5	CONCLUSÃO	61
5.1	Fronteiras Científica e Tecnológica	62
5.2	Trabalhos Futuros	62
	REFERÊNCIAS	63
	APÊNDICES	67
	APÊNDICE A – DETECÇÃO VISUAL DE MOTORISTAS INTO- XICADOS (NHTSA, 2010)	69

APÊNDICE B – MATRIZES DE CONFUSÃO POR TRECHO RO-	
DOVIÁRIO	73

1 Introdução

A análise do comportamento de direção (DBA, do inglês *Driving Behavior Analysis*) tem aberto espaço para inovações no desenvolvimento de veículos autônomos¹ (AVs, do inglês *Autonomous Vehicles*), cidades inteligentes, segurança rodoviária e aumento da eficiência energética veicular (AZADANI; BOUKERCHE, 2021). Inserido neste campo de estudo está a análise de direção anormal, caracterizada por motoristas bêbados, com sono, distraídos ou sob outras condições que diminuem a capacidade de dirigir apropriadamente.

A presença de direção anormal é definida pelo efeito apresentado nas métricas de trajetória, como variações de velocidade e posicionamento na faixa, em função das causas da anormalidade e das condições do ambiente ou do tráfego. A figura 1 representa este conceito.

Figura 1 – Caracterização da presença de direção anormal pela velocidade e posicionamento na faixa em função de suas causas e das condições do ambiente/tráfego.



Fonte: (OLIVEIRA; REBOUÇAS FILHO; SILVA JUNIOR, 2022)

A figura 1 apresenta um amplo conceito de direção anormal, considerando também as condições do ambiente e do tráfego. Neste sentido, condições climáticas específicas

¹ Neste trabalho, o termo veículo autônomo faz referência a um veículo de automação nível 5 na escala da SAE J3016.

podem causar alterações no comportamento dos motoristas que podem também se refletir em variações de velocidade e posicionamento na faixa. Outros fatores como as condições do tráfego (AL-SULTAN; AL-BAYATTI; ZEDAN, 2013), a qualidade da estrada, a presença de ciclistas, pedestres e animais, e até mesmo o dia e horário podem também influenciar as métricas de velocidade e posicionamento na faixa.

Estudos de segurança rodoviária apontam que a grande maioria dos acidentes de trânsito estão relacionados às causas de direção anormal listadas na figura 1 (NHTSA, 2010), com destaque para os motoristas alcoolizados, cansados e distraídos, o que realça a importância do desenvolvimento de métodos para lidar com tais casos. Até então, o estudo da detecção de direção anormal tinha seu foco em fornecer soluções embarcadas nos veículos, como avisos sonoros de alerta ao motorista. Esses métodos que utilizam sensores instalados no próprio veículo em que ocorre um caso de direção anormal não podem ser replicados para veículos autônomos ou aplicações em cidades inteligentes, pois não se tem acesso aos sensores instalados em todos os carros do tráfego.


Para garantir a segurança, os AVs são treinados e validados com uma quantidade gigantesca de cenários (WEBER et al., 2019), que pode facilmente se tornar uma tarefa computacionalmente inviável. Estudos apontam que dados de bilhões de milhas de direção são necessários para treinar e validar a segurança dos AVs (RIEDMAIER et al., 2020; WEBER et al., 2019). Filtrar esses cenários em casos em que há participantes do tráfego com indícios de direção anormal representa um importante passo para a viabilidade da validação dessa tecnologia.

Dentro do campo de estudo das validações de segurança de AVs baseadas em cenários poucos são os trabalhos focados na detecção de direção anormal. As bases de dados utilizadas nessa dissertação estão sendo constantemente exploradas pela comunidade no contexto da análise do comportamento de direção, porém, para o melhor do conhecimento do autor, este é o primeiro trabalho a utilizá-las especificamente para a detecção de direção anormal. Isso se deve ao fato de termos desenvolvido um método inovador que nos possibilitou a utilização de dados naturalísticos.

Nesta dissertação, desenvolvemos o *DBALapisco*², um sistema capaz de identificar em tempo real a presença de direção anormal para veículos no tráfego. Dessa forma, os AVs podem tomar decisões que minimizem a possibilidade de se envolver em acidentes; cidades inteligentes podem tomar ações de gerenciamento de tráfego e automaticamente acionar autoridades; assim como órgãos de segurança rodoviária podem ser auxiliados no monitoramento de vias para tomada de ações imediatas. A figura 2 mostra possíveis formas de captura de imagens para detecção de direção anormal através do sistema proposto nesta dissertação, o *DBALapisco*.

² Sistema de Análise do Comportamento de Direção do Laboratório de Processamento de Imagens, Sinais e Computação Aplicada

Figura 2 – Possíveis formas captura de imagens para detecção de direção anormal utilizando o *DBALapisco*



Fonte: Autor

A figura 2 mostra veículo comum (em vermelho) sendo dirigido por um motorista apresentando anormalidades em sua trajetória. A coleta das imagens pode então ser realizada através de um drone, um equipamento de infraestrutura e/ou outro veículo, todos equipados com câmeras. Os dados de trajetória são então analisados pelo sistema *DBALapisco* para estimar uma classe de anormalidade.

Esta dissertação explora a fundo uma de duas possíveis vertentes de aplicação do nosso sistema: a direção anormal. No outro extremo está a direção normal, que, por exemplo, pode ser utilizada para planejar trajetórias e manobras confortáveis para o ser humano, passageiro de um AV, assim como na extração de atributos para planejamento de fluxo de tráfego em cidades inteligentes.

1.1 Motivação para a Dissertação

Os fatores que nos motivaram para a elaboração desta dissertação contemplam as principais causas dos acidentes de trânsito, os principais aspectos da análise do comportamento dos motoristas que necessitam de melhorias, validações de segurança de veículos autônomos e aplicações em cidades inteligentes.

Quanto aos acidentes de trânsito, estes são uma das maiores causas de morte no mundo, e a maior entre a faixa etária de 5 a 29 anos (WHO, 2018). Neste cenário, é largamente aceito e comprovado que a presença de direção anormal, conforme as causas consideradas nesta dissertação, representa a maior causa de tais acidentes. Logo, uma de nossas principais motivações é amenizar esta cruel realidade.

Um outro fator motivacional é que a análise do comportamento de direção necessita de soluções escaláveis e computacionalmente eficientes (AZADANI; BOUKERCHE, 2021).

No âmbito dos veículos autônomos, nos motiva o fato de que uma das principais abordagens para o desenvolvimento dos AVs é a validação por cenários críticos, que pode ser otimizada através da detecção de direção anormal.

No âmbito das cidades inteligentes, nos motiva o fato de que nosso sistema pode ser utilizado para fins de prevenção dos acidentes, além de análises de fluxo de tráfego, detecção de acidentes ou quase acidentes.

1.2 Objetivos Geral e Específicos

O objetivo geral desta dissertação é desenvolver um sistema de detecção de direção anormal. Buscamos realizar as classificações em tempo real, ou seja, com um baixo custo algorítmico, para garantir a aplicabilidade. Buscamos também possibilitar uma rápida atualização dos resultados à medida que mais dados estiverem disponíveis, assim como tornar o método facilmente replicável para outros cenários de tráfego, para garantir a escalabilidade do sistema.

Como objetivo específico, buscamos tornar o sistema operacionalizável via interface gráfica para otimizar atividades rotineiras de engenharia, como treinamento de novas redes neurais.

1.3 Produção científica

Durante o processo de desenvolvimento desta dissertação, os seguintes trabalhos científicos foram desenvolvidos:

- W. G. Oliveira, P. P. Reboucas Filho, E. T. Silva Junior, "**Driver Behavior Analysis: Abnormal Driving Detection Using MLP Classifier Applied to Outdoor Camera Images**," 21st International Conference on Intelligent Systems Design and Applications (ISDA), 2022.
- W. G. Oliveira, P. P. Reboucas Filho, "**DBALapisco - An Abnormal Driving Detection System for Safety Validation of Autonomous Vehicles**." Journal of Information Assurance and Security (JIAS), 2022. (Aceito)

1.4 Estrutura da Dissertação

O capítulo 2 traz o embasamento teórico desta dissertação. O capítulo 3 traz os detalhes do método utilizado na nossa detecção de direção anormal. O capítulo 4 apresenta

o sistema *DBALapisco*, os resultados de classificação da rede neural MLP³ em todas as bases de dados analisadas e a discussão dos resultados. O capítulo 5 apresenta nossas conclusões, o impacto científico e trabalhos futuros.

³ MLP - Perceptron Multicamadas, do inglês *Multi-Layer Perceptron*.

2 Análise Bibliográfica

2.1 Análise do Comportamento de Direção

A análise do comportamento de direção (DBA) pode ser descrita como a caracterização de diversos aspectos do comportamento do motorista humano sob diversas condições. Aplicações são vistas na customização de desempenho veicular, análise de estilos de direção, identificação de motoristas e avaliações de risco (AZADANI; BOUKERCHE, 2021).

Importantes trabalhos de revisão de literatura foram publicados pela comunidade no campo da DBA. Azadani e Boukerche (2021) apresentam o estado da arte categorizando a pesquisa quanto à forma com que os dados são coletados, a tarefa que se pretende realizar e o modelo dos algoritmos utilizados. Os autores apresentam também tópicos relevantes que ainda necessitam de avanços.

Em seu estudo, Azadani e Boukerche (2021) apontam que o poder computacional e o custo dos algoritmos utilizados precisam ser tratados como prioridade em aplicações de tempo real, uma vez que esses sistemas tomam decisões baseadas em grandes quantidades de dados.

Abbas e Alsheddy (2020) realizaram uma revisão da literatura com foco na detecção de motoristas em estado de cansaço. Uma de suas constatações foi de que, na prática, os autores do estado da arte focaram na implementação de tecnologia assistiva, com o intuito de auxiliar os motoristas a detectar os seus momentos de distração produzindo sinais de alerta.

Schagen e Sagberg (2012) definem um estudo de direção naturalística como um estudo realizado para analisar o comportamento de motoristas em situações rotineiras de tráfego, coletando dados de forma não intrusiva. Isso é muito importante, pois a presença dos dispositivos de coleta de dados instalados nos veículos pode fazer com que o motorista mude o seu comportamento.

Os estudos de direção naturalística são ainda categorizados em estudo de motorista individual e coletivo. No individual, sensores são instalados no próprio veículo para coletar o comportamento de direção. Enquanto em um estudo coletivo, dados naturalísticos são coletados em uma localidade específica utilizando sensores instalados nas facilidades próximas à rodovia (SINGH; KATHURIA, 2021).

Singh e Kathuria (2021) publicaram uma revisão de literatura abordando os dispositivos e instrumentos, fatores que afetam o comportamento de direção e estratégias para melhorar a segurança nas vias. Os autores apontam que os estudos de direção

naturalística revelam fatores que influenciam o comportamento dos motoristas, como a distração e características do ambiente. A partir de sua extensa revisão de literatura, os autores concluem que esses fatores afetam a performance lateral e longitudinal do veículo.

Dessa forma, as conclusões e oportunidades de melhoria apresentadas por estas importantes pesquisas de análise do comportamento de direção foram de muita importância na concepção do sistema proposto nesta dissertação.

2.2 Detecção de Direção Anormal

A respeito da detecção de direção anormal, primeiramente destacamos sua importância para a segurança rodoviária. A Organização Mundial da Saúde (WHO¹) chamou a atenção da sociedade com dados da segurança das rodovias globais. WHO (2018) aponta que os acidentes de trânsito são a maior causa de morte no mundo na faixa etária de 5 a 29 anos e a oitava maior quando consideradas todas as faixas etárias. Ao todo, 1.35 milhões de mortes ocorrem anualmente devido a acidentes rodoviários, sendo que no Brasil ocorrem cerca de 40.000. Este cenário piora consideravelmente quando consideramos lesões sérias, que frequentemente levam à invalidez.

O relatório de WHO (2018), intitulado "relatório do estado global da segurança rodoviária", apresenta também uma série de recomendações e boas práticas adotadas por países ao redor do globo para redução de acidentes. Dentre as principais recomendações e boas práticas está a tomada de medidas para a redução de motoristas alcoolizados, sob o efeito de outras drogas e distraídos.

Os acidentes de trânsito relacionados ao consumo de álcool representam algo entre 5 e 35% do total de acidentes (WHO, 2018), a depender do país que reporta os dados. A discrepância entre esse número se deve à forma com os que os diversos países coletam (ou não) tais informações, assim como a divergências socioeconômicas entre os países.

É evidente na literatura que as principais causas dos acidentes de trânsito estão relacionadas a fatores que causam redução na habilidade dirigir, como o consumo de álcool, o cansaço e a distração (WHO, 2018; SKOG, 2003). Os fatores causadores de redução na habilidade de dirigir foram agrupados no termo "direção anormal" (OLIVEIRA; REBOUÇAS FILHO; SILVA JUNIOR, 2022) e seu conceito amplo está ilustrado na figura 1, na introdução deste trabalho.

Neste trabalho, embora busquemos detectar a direção anormal da forma mais ampla possível, não podemos esgotar todos os fatores causadores de direção anormal, pois isso depende da disponibilidade de dados contemplando especificamente os casos em questão.

As pesquisas de NHTSA (2010), Dozza, Flannagan e Sayer (2015), Zhang et al.

¹ Do inglês *World Health Organization*.

(2019), Morgenstern, Schott e Krems (2020) e Singh e Kathuria (2021) suportam a teoria de que um motorista sob uma ou mais condições relacionadas às causas de direção anormal apresentam mudanças na trajetória percorrida quando comparado com motoristas em condições normais. Outros indícios da presença de direção anormal são variações bruscas de velocidade e aceleração, assim como um reflexo lento (HANCOCK; LESCH; SIMMONS, 2003). O apêndice A traz uma série de "sintomas" elencados por NHTSA (2010), que podem ser visualmente detectados para a caracterização de direção anormal.

Na literatura, diversos trabalhos exploraram a detecção de direção anormal.

Shirazi e Rad (2014) realizaram a detecção de motoristas alcoolizados através dos dados de esterçamento do volante, coletados utilizando um simulador de tráfego. Ao todo, 10 motoristas foram envolvidos no processo. Os motoristas utilizaram *Fatal Vision Goggles*² para simular a concentração de álcool no sangue. A acurácia das classificações foi de 77%.

Também em um ambiente de simulação, Chen e Chen (2017) conduziram um estudo para distinguir motoristas bêbados de sóbrios. Os autores utilizaram SVM³ para predizer uma das duas classes. Os autores utilizaram dados fisiológicos e de performance de direção dos motoristas.

Os sensores utilizados por Chen e Chen (2017) para coleta de dados fisiológicos dos motoristas foram o EMG⁴, EDA⁵ e PPG⁶. Para representar motoristas bêbados, os participantes consumiram uma quantidade controlada de álcool antes do experimento. Um total de 16 motoristas foram envolvidos no estudo. A acurácia obtida nas classificações foi de 70%.

Também utilizando dados fisiológicos, Rosero-Montalvo, López-Batista e Peluffo-Ordóñez (2020) analisaram a temperatura facial do motorista, a dilatação da pupila e a concentração de álcool no interior do veículo. Os autores utilizaram sensores de temperatura e gás e câmeras. Uma acurácia de 98% foi obtida.

Hu et al. (2017) se dispuseram a detectar a direção anormal através da análise dos padrões normais do comportamento de direção. Os autores utilizaram as métricas de velocidade e posição dos pedais de aceleração e freio. As condições dos motoristas simuladas foram a fadiga (ou cansaço), consumo de álcool, imprudência e uso de celular. Um índice

² Óculos especiais capazes de simular os efeitos de diferentes níveis de álcool no sangue, como dificuldade para andar em linha reta.

³ Máquina de Vetores de Suporte, do inglês *Support Vector Machine*. É um método de aprendizado para o projeto de redes de retroalimentação com uma única camada oculta de nós não lineares. Como o nome sugere, o seu projeto se baseia na extração de um subconjunto de dados de treino que serve de vetores de suporte representando uma característica estável dos dados (HAYKIN, 2010).

⁴ Sensor de Eletromiografia. Mede a resposta muscular, ou atividade elétrica, em resposta a estímulos musculares do sistema nervoso.

⁵ Resposta Galvânica da Pele, do inglês *Electro-Dermal Activity*.

⁶ Fotopletismografia, do inglês *Photoplethysmogram*. Análise de mudanças volumétricas de sangue na circulação periférica.

de anormalidade foi proposto baseado nestas métricas e causas de direção anormal. Os autores demonstraram que diferentes estilos de direção influenciam consideravelmente o comportamento observado.

Yao et al. (2019) conduziram um estudo com 22 motoristas que foram submetidos a dirigir em um simulador com diferentes níveis de álcool no sangue (0.02%, 0.05%, e 0.08%) ou em estado de cansaço. Os indicadores de performance utilizados foram a média e o desvio padrão da velocidade longitudinal e o posicionamento na faixa. A geometria da estrada também foi levada em consideração (segmentos retos, raio e direção das curvas). Os autores realizaram a classificação separadamente para os casos "em alerta" vs. "anormal" e "cansado" vs. "bêbado" com os diferentes níveis de álcool. A acurácia obtida foi de 90.9% para alerta vs. "anormal" e de 94.4% para "cansado" vs. "bêbado". A acurácia para a detecção dos níveis específicos de álcool foi relativamente baixa e inconsistente, variando consideravelmente nos diferentes segmentos de estrada.

Xiong, Zhou e Chen (2022) realizaram a detecção de direção anormal através de câmeras de vigilância. Os autores propuseram a utilização da tecnologia de reconstrução esparsa⁷. A performance do método proposto foi testado em duas bases de dados, que contemplam situações de estacionamento e de parada no sinal. Uma acurácia de 93.3% foi obtida nas classificações de direção anormal nas manobras de estacionamento e 96.7% em parada no sinal. Os resultados foram então comparados com cinco métodos clássicos, demonstrando uma maior acurácia do método proposto.

2.3 Validações de Segurança Baseadas em Cenários

O maior desafio da avaliação de segurança de um AV está no fato de que uma quantidade infinita de diferentes situações de tráfego podem ocorrer. Logo, uma prova absoluta de sua segurança não é possível. Porém, algumas abordagens práticas estão sendo desenvolvidas visando atestar a sua segurança (RIEDMAIER et al., 2020).

Validações de segurança baseadas em cenários é uma abordagem promissora da ciência para lidar com esta importante questão: é possível comprovar a segurança da operação de veículos autônomos?

Um cenário de tráfego é uma sequência temporal das ações e eventos de todos os elementos do tráfego (ULBRICH et al., 2015). Nessa abordagem, elementos do tráfego de baixa importância para a avaliação de risco são omitidos, como a presença de um veículo muito distante, o que reduz o escopo de situações de tráfego (RIEDMAIER et al., 2020).

Em contraste, utilizando-se de uma abordagem de validação baseada exclusivamente

⁷ O princípio básica da tecnologia de reconstrução esparsa é que quaisquer amostras podem ser aproximadamente representadas através de uma combinação linear de amostras de treino, e então resolver o problema de minimização em uma norma-10 (AMALDI; KANN, 1998)

em distâncias relativas nos campos de teste, para que se possa afirmar com suficiente precisão que o AV supera o motorista humano em segurança por algum fator, estima-se que algo entre 6 e 11 bilhões de milhas devem ser dirigidas (KALRA; PADDOCK, 2016; WACHENFELD; WINNER, 2016), uma tarefa economicamente inviável. Logo, a redução lógica de escopo trazida pela validação de segurança baseada em cenários é uma ótima saída.

Em seu estudo, Riedmaier et al. (2020) elencou uma série de abordagens para o problema das validações de segurança de veículos autônomos e consolidou de forma clara as características da abordagem de validações de segurança baseadas em cenários.

Neste contexto, OEDR⁸ é um conceito que define a capacidade de um veículo de detectar objetos e eventos, e então executar uma ação/resposta apropriada. Isto deve ser checado para o completo domínio operacional de projeto (ODD⁹) (NHTSA, 2016; THORN et al., 2018).

Uma outra abordagem presente na literatura é o teste baseado em funcionalidades. Neste caso, todas as funcionalidades do sistema devem ser definidas e posteriormente testadas nas estradas ou em simuladores. Esta abordagem funciona bem para os dispositivos ADAS, mas é difícil de ser replicada para os AVs porque não é possível definir o conjunto de funcionalidades requeridas para todas possíveis situações de tráfego (RIEDMAIER et al., 2020).

Portanto, Riedmaier et al. (2020) propuseram a utilização da abordagem das validações de segurança baseadas em cenários para lidar com o problema da segurança de modo geral e a utilização da abordagem de verificação formal¹⁰ para lidar com o planejamento de decisões. Nessa dissertação, buscamos considerar as principais causas de acidentes atuais para auxiliar a filtragem de cenários lógicos para validações de segurança de veículos autônomos, assim como o auxílio na tomada de decisão.

2.4 Bases de Dados

Nos últimos anos, diversas bases de dados foram desenvolvidas no campo da visão computacional com o intuito generalizado de realizar a detecção de objetos do tráfego. Podemos citar a base de dados *KITTI* (GEIGER; LENZ; URTASUN, 2012), a *Cityscapes* (CORDTS et al., 2016) e a *Oxford Robotcar* (MADDERN et al., 2017), que juntas contemplam uma enorme quantidade de dados, entre imagens e vídeos, em diversas

⁸ OEDR - Detecção e Resposta a Objetos e Eventos, do inglês *Object and Event Detection and Response*

⁹ ODD - do inglês *Operational Design Domain*

¹⁰ Verificação formal é um método matemático no qual a segurança dos sistemas pode ser formalmente comprovada em todo o domínio operacional de projeto. A verificação formal demonstra a eficácia dos sistemas, mas não possui escalabilidade capaz de acompanhar a complexidade dos sistemas autônomos (RIEDMAIER et al., 2020).

condições climáticas e de tráfego.

Algumas bases de dados para estudo específico do comportamento de motoristas também estão disponíveis. *UAH-Driveset* (ROMERA; BERGASA; ARROYO, 2016) é uma base de dados pública que tem como intuito a análise do comportamento de direção. Os dados foram capturados pelo aplicativo *DriveSafe*. A *UAH-Driveset* foi desenvolvida com base em 6 motoristas e veículos diferentes executando diversos comportamentos de direção em dois tipos de estradas, resultando em mais de 500 minutos de direção real em gravações em vídeo.

Ramanishka et al. (2018) catalogaram 104 horas de direção em ambientes reais na região de São Francisco–CA, utilizando um veículo equipado com diferentes sensores. O desenvolvimento dessa base de dados teve o objetivo explícito de aprender como humanos interagem com outros participantes do tráfego.

As bases de dados citadas acima foram importantes para esta dissertação. Embora elas não tenham sido aqui utilizadas de forma direta (por fatores como a forma com que os dados foram coletados e a quantidade de dados), em algum momento elas foram importantes para o desenvolvimento de algoritmos de visão computacional para detecção de objetos de tráfego ou de outros trabalhos que embasam os nossos conceitos.

Para coincidir com o objetivo dessa dissertação, precisamos então de uma base de dados maciça contendo trajetórias naturalísticas¹¹ de veículos. Utilizamos então 4 bases de dados que se complementam por englobarem diferentes trechos rodoviários e situações de tráfego, são elas as bases *HighD*, *ExiD*, *InD* e *RounD*, exploradas mais a fundo na subseção 2.4.1.

Uma das mais importantes bases de dados que também se encaixa nessa descrição é a NGSIM (ALEXIADIS et al., 2004), que tem o seu foco em modelagem microscópica de fluxo de tráfego¹², descrevendo também interações entre os veículos e considerando dispositivos de controle do tráfego, congestionamento e condições climáticas. Porém, estudos demonstram que existem casos falsos positivos de colisões e situações fisicamente ilógicas (COIFMAN; LI, 2017), por isso esta base de dados não foi inserida em nosso estudo.

Então, as bases de dados apresentadas a seguir possibilitaram o desenvolvimento do nosso sistema de detecção de direção anormal, com a vantagem de possuírem abundância de dados e uma diversidade de trechos rodoviários e situações de tráfego.


¹¹ Trajetórias naturalísticas: coletadas diretamente do tráfego, sem interferir em nenhuma das condições, que se mantém reais e espontâneas.

¹² Modelagem microscópica de fluxo de tráfego: representa propriedades de veículos separadamente, como posição e velocidade, em contraste com a modelagem macroscópica, que representa conjuntos de veículos como um todo.

2.4.1 HighD, ExiD, InD e Round

A *HighD* é uma base de dados de larga escala contendo trajetórias de veículos em rodovias alemãs de uma perspectiva aérea (KRAJEWSKI et al., 2018). Ela categoriza mais de 110.000 veículos, em um total de 45.000km de distância percorrida, utilizando um drone equipado com uma câmera de alta resolução cobrindo 420m de rodovia (KRAJEWSKI et al., 2018). A figura 3 representa a coleta de dados via drone na base de dados *HighD*.

Figura 3 – Esquema de coleta de dados via drone na base de dados *HighD*.



Fonte: Krajewski et al. (2018)

Aproximadamente, dos 110.000 veículos presentes na base de dados *HighD*, 90.000 são carros e 20.000 são caminhões. O tempo total de gravação é de 16.5h, que equivalem a 447 horas dirigidas (KRAJEWSKI et al., 2018).

O mesmo princípio do sistema de coleta de dados da base *HighD* para trechos retos de rodovias pôde ser escalado para outros trechos rodoviários. O esquema descrito para a *HighD* foi escalado para as bases *ExiD* (MOERS et al., 2022), *Ind* (BOCK et al., 2020) e *RounD* (KRAJEWSKI et al., 2020), que contemplam respectivamente os trechos de entrada e saída de rodovias, interseções urbanas e rotatórias. A base de dados *ExiD* contempla um total de 67.677 trajetórias. A base de dados *InD* contempla um total de 13.599 trajetórias. A base de dados *RounD* contempla um total de 13.259 trajetórias.

Tais bases de dados contém dados de trajetórias naturalísticas juntamente com anotações do tráfego. Os vídeos foram gravados em resolução 4K (4096x2160) a 20 fps. O tamanho de um pixel no chão é 10x10cm. As gravações foram feitas em dias ensolarados e de pouco vento, uma desvantagem para o propósito dessa pesquisa, pois isso exclui a possibilidade de levar em consideração possíveis diferenças de comportamento nos motoristas durante a noite ou em outras condições climáticas.

Tais bases foram propostas para o estudo da validação de segurança de sistemas de direção automatizados. Desde que desenvolvidas, os autores as usaram para propósitos

tais como o projeto e validação de dispositivos ADAS e AVs, predição de trajetória de veículos, modelagem de manobras, tomada de decisão e gerenciamento de risco.

Dentre os atributos relacionados à trajetória do veículo, estão a posição, velocidade e aceleração longitudinais e laterais e o número de mudanças de faixa. Utilizamos esses atributos para representar o comportamento do motorista perante aquela situação de tráfego, com intuito de detectar direção anormal.

Atributos relacionados ao tráfego também estão presentes, como o número de carros e caminhões por gravação, distância mínima à frente e tempo mínimo de colisão, assim como atributos relacionados ao ambiente, como a identificação do local em que ocorreu a gravação, o limite de velocidade, mês, dia e horário da gravação.

Então, nos propomos a desenvolver um sistema de detecção de direção anormal que também fosse escalável e facilmente alimentado com novos dados de novos cenários. O capítulo 3 demonstra o método empregado.

3 Método


Para o desenvolvimento desta dissertação, utilizamos as bases de dados *HighD*, *ExiD*, *InD* e *Round*, que juntas representam as trajetórias de mais de 200 mil veículos em diversas situações de tráfego na Alemanha.

Realizamos a análise do comportamento de direção separadamente em cada uma dessas bases de dados, por contemplarem trechos rodoviários específicos. Isso foi feito com o intuito de esclarecer os modos específicos da direção anormal dentro de cada trecho, bem como para a adequação do método de detecção de direção anormal baseado em trajetórias. A figura 4 mostra exemplos dos trechos rodoviários contemplados em cada uma dessas bases de dados.


Figura 4 – Exemplos de trechos rodoviários e total de veículos de cada base de dados.




(a) HighD - Trechos retos de rodovias. Total de veículos: 110.516.



(b) ExiD - Entradas e saídas de rodovias. Total de veículos: 67.677.



(c) InD - Interseções urbanas. Total de veículos: 13.599.



(d) Round - Rotatórias. Total de veículos: 13.259.


Fonte: Autor.

A subseção 3.1 explica como os dados foram processados. A subseção 3.2 explica como foram definidas as classes de direção anormal. A subseção 3.3 contempla a estrutura e o projeto de redes neurais utilizadas na detecção de direção anormal. Os passos descritos neste capítulo foram então codificados em linguagem *python* para formar o *DBALapisco*, um sistema de detecção de direção anormal, apresentado no próximo capítulo.

3.1 Processamento dos dados

Para iniciar o processamento das bases citadas, foram selecionados os atributos mais relevantes para o nosso objetivo geral: detectar veículos que apresentem direção anormal. Os atributos relacionados diretamente ao veículo foram a posição no eixo y (Py), a velocidade e a aceleração nos eixos x e y (Vx , Vy , Ax , Ay). Os eixos estão representados na figura 5.

Figura 5 – Representação dos eixos em relação ao veículo e à estrada.



Fonte: Adaptado de (NHTSA, 2010)

A posição do veículo no eixo y representa o posicionamento lateral do veículo, ou seja, o seu movimento entre as faixas da rodovia. Os dados de velocidade e aceleração, coletados nos dois eixos, trazem mais informações a respeito do comportamento do motorista durante a trajetória percorrida.

Para o conjunto de atributos selecionados até então, possuímos uma medição para cada frame de vídeo. A equação 3.1 representa o agrupamento dos dados para um veículo em um determinado frame f .

$$Veículo_f = [Py, Vx, Vy, Ax, Ay] \quad (3.1)$$

Para atingir uma definição de classes de direção anormal, buscamos um conjunto de atributos que pudessem representar os padrões de variação dos dados relacionados à trajetória. Para isso, calculamos o desvio padrão de cada atributo. A equação 3.2, mostra o conjunto de atributos com os desvios padrão para toda a trajetória do veículo em questão.

$$Veículo_i = [\sigma Py, \sigma Vx, \sigma Vy, \sigma Ax, \sigma Ay] \quad (3.2)$$

Em que $Veículo_i$ representa o veículo na posição i da base de dados e o prefixo σ representa o desvio padrão.

Dessa forma, temos agora, para cada veículo, um conjunto de atributos que representa as variações da posição lateral, velocidade e aceleração nos dois eixos.

Um dos atributos mais importantes na análise é o posicionamento do veículo na faixa. Porém, a comparação dos desvios padrão da posição y (σPy) entre dois veículos com diferentes quantidades de mudanças de faixa perde bastante sentido. Isso se deve ao fato de que, para mudar de faixa, é necessário que ocorra variação lateral de posição, o que aumenta σPy .

A tabela 1 ilustra o fenômeno da variação de σPy . A média da métrica σPy de todos os veículos na base de dados *HighD* por número de mudanças de faixa (nMF) é mostrada como exemplo. Podemos observar que, se nMF cresce, σPy também cresce. A tabela 1 mostra também o número total de veículos em cada caso, de modo que todos os veículos da base de dados *HighD* estão representados.

Tabela 1 – Comparação dos desvios padrão da posição lateral (σPy) entre veículos com número de mudanças de faixa (nMF) diferentes.

nMF	σPy (média)	Veículos
0	0,17	97.184
1	1,22	12.731
2	1,62	585
3	2,02	16

Pela tabela 1 vemos claramente a tendência diretamente proporcional de σPy e nMF . Então, o número de mudanças de faixa realizadas pelo veículo foi considerado na análise de modo a evitar conclusões equivocadas provocadas por esse fenômeno. Isso ocorre especificamente para a base de dados *HighD*, pois as demais não contemplam casos de mudança de faixa.

Logo, a base de dados *HighD* foi dividida em 3, de acordo com o número de mudanças de faixa, que pode ser 0, 1 ou 2. Os casos em que ocorreram 3 mudanças de faixa (apenas 16 veículos) foram desconsiderados, pois não há dados suficientes para retirar conclusões significativas através da aplicação de redes neurais. Os casos de duas mudanças de faixa (585 veículos) foram mantidos com a ressalva de cautela extra.

Uma vez obtidos os atributos mostrados na equação 3.2 para cada veículo de cada base de dados, realizamos a normalização dos dados conforme o tópico 3.1.1. Então,

podemos definir uma métrica para definir classes de direção anormal, conforme apresentado no tópico 3.1.2.

3.1.1 Normalização dos dados

Em ciência de dados, a forma de tratar dados são diversas e específicas para cada aplicação. Porém, é bastante comum que a base de dados seja normalizada imediatamente antes da aplicação de classificadores de redes neurais. De fato, esse passo é importante para evitar que as diferentes dimensões dos atributos não enviesem as predições das redes neurais.

Mas em nossa aplicação notamos que o conjunto de atributos relacionados à equação 3.2 deve ser normalizado antes da definição de classes. Podemos normalizar os dados apenas ao treinar as redes neurais para detectar a direção anormal, porém isso possibilita que as variações de velocidade do veículo no eixo x (σVx) tendencie a definição de classes. Isso é especialmente preocupante por se tratar de um passo anterior à detecção de direção anormal.

As variações de velocidade no eixo x são mais comuns do que no eixo y , pois, natural e logicamente, o veículo se movimenta a maior parte do tempo para frente, necessitando de mais ajustes em sua velocidade no eixo x .

Conforme será esclarecido no tópico 3.1.2, a definição de classes de direção anormal ocorre através de uma métrica de anormalidade (λ). A figura 6 ilustra o fenômeno da influência de σVx em λ . Os valores de λ foram plotados em função de cada atributo considerado na análise para a base de dados *HighD*. Eles contemplam a população de zero mudanças de faixa. A base de dados é deixada para ser normalizada somente antes da previsão de classes.


Pela figura 6, podemos ver claramente a tendência diretamente proporcional de σVx no valor de λ . Isso é um forte indício de que a dimensão de σVx , maior do que os demais atributos, causou um viés em λ .

Então, com a normalização realizada na etapa de processamento, conseguimos minimizar consideravelmente o enviesamento de λ por σVx na definição de classes de direção anormal. A figura 7 mostra o novo comportamento de λ em função de cada atributo.

Em ciência de dados, podemos tratar os dados para induzir uma influência benéfica atribuindo pesos. Mas, caso não seja esse o objetivo, tendenciar deve ser evitado.

O método de normalização aplicado foi o *Standard Scaler*. Este método tem a vantagem de manter a proporção dos *outliers* em relação à média da população. Isto é importante para nossa aplicação, pois buscamos posteriormente detectar os casos anormais. Logo, uma normalização que minimize o impacto dos *outliers* vai na contramão do objetivo.

Figura 6 – Métrica de anormalidade λ em função de cada atributo. Demonstração da influência diretamente proporcional de σVx em λ .




Fonte: Autor.

Para auxiliar a visualização e análise do nosso método de normalização, o gráfico do tipo *pairplot* foi plotado na figura 8 para a base de dados de trechos retos normalizada com o *Standard Scaler*.

Na figura 8, podemos ver a forma com que os atributos se correlacionam entre si, e principalmente a presença dos *outliers*, ou pontos fora da curva, isolados, representando padrões de direção anormal.

Para comparação, analisamos também o método de normalização *QuantileTransformer*. Este método transforma os atributos para seguir uma distribuição normal, ou uniforme. Logo, para um dado atributo, essa transformação tende a estender os valores

Figura 7 – Métrica de anormalidade λ em função de cada atributo. A influência diretamente proporcional de σVx em λ é atenuada. O processo é realizado antes da definição de classes.




Fonte: Autor.

mais frequentes e reduzir o impacto de *outliers*. A figura 9 mostra então o gráfico *pairplot* para a base normalizada com o *Quantile Transformer*.

Na figura 9 podemos ver a distribuição uniforme dos dados. Por consequência, a diminuição do impacto dos *outliers*, que, para nossa aplicação em específico, significaria perda de informação importante.

Isso não quer dizer que seria impossível utilizar o método *Quantile Transformer*, mas as redes neurais teriam que aprender os padrões de direção anormal com dados menos representativos.

Figura 8 – *Pairplot* para a base de dados de trechos retos normalizada com o *Standard Scaler*.




Fonte: Autor.

Uma vez normalizados, pudemos então definir uma métrica de anormalidade, conforme a seção 3.1.2 e então definir classes de direção anormal conforme a seção 3.2.

Para concluir essa subseção, refletimos no fato de que, a todo momento, o nosso

Figura 9 – *Pairplot* para a base de dados normalizada com o *Quantile Tranformer*.



Fonte: Autor.

sistema estará auxiliando a tomada de decisão baseada no aprendizado extraído de uma grande variedade de enormes bases de dados. Tratar corretamente esses dados pode ser a chave para garantir a segurança, a efetividade e a viabilidade computacional.

3.1.2 Uma Métrica de Anormalidade

Como uma forma de definir classes de direção anormal, inicialmente propomos a utilização de uma métrica de anormalidade (λ) para comparação das trajetórias de um motorista aos demais utilizando a distância euclidiana média. Para obtê-la, calcula-se a média da distância euclidiana do conjunto de atributos de um veículo aos demais veículos presentes na base de dados.

Partindo da equação 3.2, podemos formular o cálculo de λ pela distância euclidiana média para um dado veículo i , conforme a equação 3.3.

$$\lambda_i = \frac{\sum_{j=1}^n ||Veículo_i - Veículo_j||_2}{n} \quad (3.3)$$

Em que $Veículo_i$ representa os atributos do veículo para o qual está sendo calculado λ , $Veículo_j$ representa um veículo na posição j da base de dados e n representa o total de veículos contidos na base de dados. λ , nossa métrica de anormalidade, é um escalar de distância entre vetores do R^5 .

Os atributos contidos em $Veículo_i$ representam o padrão do comportamento de direção apresentado durante sua trajetória. Logo, λ nos diz se o comportamento demonstrado está dentro dos padrões esperados para casos normais, que são a maioria dos casos.

Além de ser capaz de detectar a direção anormal, é essencial para o nosso sistema fazê-lo em tempo real, para uma tomada de decisão no ato. Matematicamente, a métrica λ inicialmente proposta através da distância euclidiana média é eficaz. Computacionalmente, seu custo é alto e ineficiente. Então, este custo computacional pode se tornar alto demais para aplicações em tempo real.

Então propomos nesta dissertação mais uma forma de calcular λ , matematicamente equivalente e computacionalmente mais eficiente, através da mediana geométrica.

Em processamento de dados, uma simples mudança de perspectiva pode representar imensas vantagens computacionais. Para tomada de decisão em aplicações de tempo real com redes neurais, não se faz necessário consultar as bases de dados. Acessar o conhecimento extraído delas é suficiente.

Então, a equação 3.4 demonstra o cálculo de λ para um determinado veículo i utilizando o método aqui proposto: a mediana geométrica.


$$\lambda_i = Veículo_i - \sum_{j=1}^n ||Veículo_j - \phi||_2 \quad (3.4)$$

Tal que $\phi \in R^n$.

Em que o segundo termo do lado direito da equação, contendo ϕ , representa o ponto em que a soma de todas as distâncias euclidianas a todos os demais pontos é

minima. Uma vez encontrado esse ponto, basta carregarmos ele conosco para a detecção de direção anormal, e atualizá-lo sempre que julgarmos necessário. Por vezes, é difícil para nós entender o significado de determinados conceitos perante abstrações geométricas. Porém, a nossa mediana geométrica é semelhante ao ponto em azul ilustrado na figura 10.

Figura 10 – Ilustração da mediana geométrica (em azul) em relação aos atributos dos demais veículos.



Fonte: Autor.

A figura 10 ilustra a mediana geométrica em azul. Os demais pontos representam o conjunto de atributos dos demais veículos das bases de dados. As linhas representam as distâncias entre os pontos. As cores referentes aos pontos dos veículos representam a escala de cores relacionada à distância à mediana geométrica, sendo o verde, mais perto, o amarelo, a meia distância, e o vermelho, muito distante. Entenda estes pontos como no espaço tridimensional ao invés de um plano. Na nossa aplicação, esta ideia é aplicada ao espaço R^5 .

Então, podemos utilizar λ para realizar a definição de classes de direção anormal.

3.2 Classes de Direção Anormal

Na definição de classes de direção anormal a partir de λ , é importante ressaltar que um valor de λ próximo de zero significa que há uma proximidade para a maioria dos demais veículos da base de dados. Quanto maior for o valor de λ , mais distante dos demais veículos estarão os atributos de trajetória do veículo em questão.

Definimos então classes de direção anormal de acordo com a distribuição normal dos dados de λ . O boxplot é especialmente útil por separar os *outliers* do restante da população. Os *outliers* representam aqueles veículos mais distantes dos padrões normais.

Portanto, podemos dizer que esses motoristas estão apresentando comportamento anormal no tráfego.

Conforme dito anteriormente, realizamos as nossas análises de detecção de direção anormal em diferentes bases de dados. Porém, para ilustrar nosso método, iremos utilizar como exemplo a base de dados *HighD* (trecho rodoviário reto) na situação de tráfego em que não ocorrem mudanças de faixa. Para não causar confusões e seguir os termos utilizados pela literatura, utilizamos o termo *trecho rodoviário* para nos referir a uma localização específica de rodovia e *situação de tráfego* para nos referir à ocorrência de uma determinada manobra, que nesse caso é a mudança de faixa. A figura 11 apresenta o boxplot dos atributos e de λ da base de dados *HighD* na situação de tráfego em que não ocorrem mudanças de faixa.

A distribuição normal de λ , a nossa métrica de anormalidade, foi então utilizada para separar os outliers e as classes de direção normal. A figura 12 mostra o boxplot de λ contendo os pontos que separam os quartis e o limiar dos outliers.

As classes de direção consideradas normais foram então separadas em 4, uma para cada quartil do boxplot (*qt1*, *qt2*, *qt3* e *qt4*). As classes de direção consideradas anormais foram então definidas de acordo com a distribuição crescente de λ .

Para auxiliar na separação das classes de direção anormal, utilizamos o histograma para visualizar a distribuição dos dados. A figura 13 mostra o histograma de λ para os *outliers* da base de dados do trecho rodoviário reto sem mudanças de faixa.

Pela análise da figura 13, conforme esperado, quanto maior λ , mais raras são ocorrências. Então, as classes de direção anormal foram separadas de acordo com a escala de λ : quanto maior, mais anormal. Dividimos o espectro em 5 classes de direção anormal, do nível 1 ao 5 (*lv1*, *lv2*, *lv3*, *lv4*, *lv5*). Analisando os histogramas, as classes de direção anormal foram separadas na proporção 60, 33, 5, 1.5 e 0.5%.


Em resumo, 9 classes de direção foram consideradas nesta dissertação, sendo 4 classes de direção normal (*qt1*, *qt2*, *qt3* e *qt4*) e 5 classes de direção anormal (*lv1*, *lv2*, *lv3*, *lv4*, *lv5*).

É muitas vezes difícil para nós enxergar o significado nos dados perante abstrações geométricas (como é o caso da mediana geométrica no R^5). Mas as redes neurais lidam muito bem com essa tarefa. O tópico 3.3 aborda então a aplicação da rede neural MLP.


3.3 Rede Neural MLP

A rede neural Multi-Layer Perceptron (MLP) foi treinada para classificar as bases de dados *HighD*, *InD*, *RounD* e *ExiD*, após realizarmos o processamento dos dados e definirmos as classes de direção, conforme as seções 3.1 e 3.2, respectivamente.

Figura 11 – Boxplot dos atributos de λ do trecho rodoviário reto na situação de tráfego em que não ocorrem mudanças de faixa.




- (a) Toda a área gráfica é mostrada. Aqui é possível visualizar todos os *outliers* em relação a todos os atributos e à λ .



- (b) Aproximação. Aqui é possível visualizar a população normal e a separação dos quartis.

A escolha da arquitetura se teve após fazermos variações nos parâmetros como número de nós da camada interna e diferentes funções de ativação. Comparando-se então os diversos resultados entre as arquiteturas testadas, chegamos à arquitetura final (5-48-1) de 48 nós na camada interna com a função de ativação *tangente hiperbólica*. Após uma aleatorização, o conjunto de teste (20%) foi separado em *holdout*. Foi utilizada uma taxa de aprendizagem constante de 0.001 e um número máximo de 1000 iterações de atualização

h]

Figura 12 – Boxplot de λ (detalhado).


de pesos. Em nenhum dos casos houve o encerramento do treinamento por número máximo de iterações.

Para o nosso caso específico, chegamos a uma rede neural MLP treinada que nos dá acurácias da ordem de 97%. Desse modo, podemos então direcionar os esforços para a validação dos resultados em diferentes trechos rodoviários, frente a otimizar excessivamente uma rede neural e buscar a melhor arquitetura possível.


Para a validação do método de detecção de classes, o sistema *DBALapisco* possui uma funcionalidade utilizada para a detecção de direção anormal: O *DBALapisco - Real Time Detection*.

O sistema recebe os dados de trajetória de cada frame de vídeo e retorna em tempo real a estimativa de uma classe de direção através dos desvio padrão da posição, velocidade e aceleração de um dado veículo em diversos trechos rodoviários. Essa eficiência computacional se deve também ao fato de a rede neural MLP ter extraído das bases de dados o conhecimento necessário para uma rápida classificação de novas novas amostras.

Figura 13 – Histograma de λ dos *outliers* do trecho rodoviário reto sem mudanças de faixa.



- (a) Toda a área gráfica é mostrada para representar até onde existem outliers.



- (b) Aproximação. Vemos que as classes de nível menor possuem mais ocorrências.


4 DBALapisco e Resultados

As etapas de processamento dos dados, a definição de classes de direção e o treinamento da rede neural MLP, conforme descrito na seção método, foram codificadas em linguagem de programação *python* para formar o sistema *DBALapisco*. O sistema foi desenvolvido de tal modo que possa ser plugado em softwares de desenvolvimento e validações de segurança de veículos autônomos, assim como para o monitoramento automático de tráfego em cidades inteligentes.

O sistema *DBALapisco* recebe como entrada dados da trajetória de um veículo e retorna uma classe de direção, que poderá então ser considerada na tomada de decisão. Logo, o *DBALapisco* possibilita uma análise em tempo real do comportamento dos motoristas no tráfego quanto à presença de direção anormal.

Adicionalmente, o sistema pode ser operado via interface gráfica para operações rotineiras de engenharia, como classificações de novas amostras, processamento de novas bases de dados e plotagem de gráficos. A figura 14 mostra a interface.

Figura 14 – Interface DBALapisco.



Fonte: Autor.

A funcionalidade *Real Time Detection* permite carregar dados de trajetória de um veículo e estimar em tempo real a presença de direção anormal de acordo com o trecho rodoviário. A funcionalidade *Processing and Learning* permite processar novas bases de dados e treinar novas redes à medida com que mais dados são coletados. A funcionalidade

Plots, permite plotar todos os gráficos presentes nesta dissertação (pairplots, dispersão de λ , boxplots, histogramas e matrizes de confusão).

4.1 Resultados de Classificação

Conforme descrito no capítulo 3, a nossa detecção de direção anormal ocorreu utilizando bases de dados de diversos trechos rodoviários. São eles: trechos retos de rodovias, entradas e saídas de rodovias, interseções urbanas e rotatórias. A base de dados de trecho reto foi dividida em três, de acordo com o número de mudanças de faixa, que pode ser 0, 1 ou 2.

Para cada um destes trechos, estimamos a métrica de anormalidade (λ) e separamos as classes de direção. O gráfico boxplot foi utilizado para separar as classes de direção consideradas normais e anormais. A figura 15 mostra o boxplot de λ para cada trecho rodoviário e situação de tráfego.


Pela figura 15 podemos ver o limiar que separa as classes de direção normais das classes de direção anormais (*outliers*). Observamos que o limiar de λ assumiu valores entre 3.7 e 4.3 a depender do trecho rodoviário e da situação de tráfego. Lembrando que λ é um escalar de distância entre vetores do R^5 e a mediana geométrica. Estes valores são importantes para definir a presença de direção anormal por trecho rodoviário. Um veículo que apresente uma métrica λ acima do limiar (*outlier*) é considerado como um caso de direção anormal dentro de um espectro de 5 classes (*lv1*, *lv2*, *lv3*, *lv4* e *lv5*). Um veículo abaixo do limiar de λ é considerado um caso de direção normal dentro de um dos quadrantes do boxplot (*qt1*, *qt2*, *qt3*, *qt4*).

A disposição dos valores de λ no boxplot nos permite retirar informações a respeito das características de cada trecho rodoviário.


Um boxplot cuja caixa é muito estreita, como é o caso do trecho reto sem mudanças de faixa e do trecho de entradas e saídas de rodovias (figuras 15a e 15d), nos informa que as trajetórias de diferentes motoristas tendem a ser mais similares nestes trechos. Um boxplot cuja caixa é mais larga, como nos trechos de interseções urbanas e de rotatórias (figuras 15e e 15f), nos informa que há uma maior divergência entre as trajetórias comparadas de diferentes motoristas.

Inferimos que este fenômeno ocorra devido à complexidade da manobra executada no trecho. Seguir reto em uma rodovia sem mudar de faixa é uma manobra mais simples do que passar por uma rotatória, o que faz com que as trajetórias de diferentes motoristas sejam mais parecidas no trecho reto.


Essa diferença visual dos gráficos boxplot de λ nos dá um bom indício de que a análise de cada trecho rodoviário em separado é importante para obtenção de resultados

Figura 15 – Boxplot da métrica de anormalidade λ para cada trecho rodoviário.


(a) Trechos retos de rodovias - 0 mudanças de faixa.




(b) Trechos retos de rodovias - 1 mudança de faixa.




(c) Trechos retos de rodovias - 2 mudanças de faixa.



(d) Entradas e saídas de rodovias



(e) Interseções urbanas.



(f) Rotatórias.

Fonte: Autor.

mais representativos e uma acurácia maior.

Uma vez definidas as classes de direção anormal conforme descrito na seção 3,

treinamos a rede neural MLP e analisamos a acurácia de classificação de novas amostras. A tabela 2 mostra as acurácias de detecção das classes de direção para cada trecho rodoviário.

Tabela 2 – Acurácias de classificação por trecho rodoviário (n representa cada realização de classificações do conjunto de teste).

n	Retas(0)	Retas(1)	Retas(2)	Acessos Rodoviários	Interseções Urbanas	Rotatórias
1	0.970	0.935	0.667	0.981	0.956	0.962
2	0.969	0.939	0.701	0.980	0.965	0.962
3	0.969	0.940	0.709	0.979	0.961	0.956
4	0.969	0.935	0.692	0.978	0.964	0.960
5	0.971	0.932	0.701	0.979	0.961	0.959
6	0.969	0.944	0.667	0.979	0.965	0.966
7	0.970	0.939	0.752	0.979	0.962	0.952
8	0.972	0.941	0.615	0.978	0.964	0.955
9	0.971	0.934	0.735	0.979	0.963	0.952
10	0.973	0.938	0.718	0.980	0.965	0.950
média	0.970	0.938	0.696	0.979	0.962	0.957
σ	0.001	0.003	0.037	0.001	0.003	0.005

Fonte: Autor.

A tabela 2 considera 10 realizações da rede neural MLP, em que cada realização utiliza 20% dos dados para teste em *holdout*.

Inicialmente nos chama a atenção os resultados de acurácia do trecho reto com duas mudanças de faixa, representado pela coluna 'Retas(2)', que atingiu apenas 69,6% de acurácia. A causa mais óbvia é a quantidade de dados disponíveis para esta situação, que é de apenas 585 amostras de trajetórias. Concluímos então que, para esta situação, precisamos obter mais dados para atingir acurácias de classificação maiores.


Nos chama a atenção também os resultados de acurácia do trecho reto com uma mudança de faixa, representado pela coluna 'Retas(1)', que está inferior aos demais, com 93,8% de acurácia e 0.3% de desvio padrão. Neste caso, a quantidade de amostras de trajetória disponíveis (12.731) é condizente com os trechos de interseções urbanas e de rotatórias. Isso nos dá um bom indício de que podemos melhorar os nossos resultados de classificação com uma otimização mais refinada da rede neural para esta situação de tráfego.

Nos demais trechos rodoviários, atingimos acurácias da ordem de 93.8% a 97.0% e desvio padrão entre 0.1 e 0.5%.

Para cada trecho rodoviário, plotamos também a matriz de confusão para uma realização de classificações do conjunto de teste. A figura 16 mostra a matriz de confusão

para uma realização no trecho reto sem mudanças de faixa.

Figura 16 – Matriz de confusão para uma realização de classificações do trecho reto sem mudanças de faixa.



Fonte: Autor.

A figura 16 representa uma realização de 96,2% de acurácia. O conjunto de teste contém 19.431 amostras, em que 91% são casos de direção normal (classes *qt1*, *qt2*, *qt3* e *qt4*) e 9% são casos de direção anormal (classes *lv1*, *lv2*, *lv3*, *lv4* e *lv5*).

De modo geral, observamos que as amostras classificadas incorretamente estão próximas da fronteira de decisão, um comportamento desejável. Uma exceção a isto são 3 amostras classificadas como *normal - quadrante 1 (qt1)*, cujas classes corretas eram *anormal - nível 3 (lv3)* e *anormal - nível 4 (lv4)*. Casos excepcionais como estes não prejudicam significativamente os resultados de acurácia, mas se tratando de segurança veicular, os engenheiros devem estudá-los a fundo. Todavia, uma análise mais aprofundada de casos excepcionais foge ao escopo desta dissertação.

Analisando especificamente os 9% dos casos de direção anormal, que representam 1.758 amostras, 1.628 (92,6%) foram classificados corretamente e 130 (7,4%) foram classificados incorretamente. Logo, concluímos que a nossa detecção da classe específica de direção anormal possui uma acurácia aceitável em relação ao do total do conjunto, que foi de 96,2%. Isso é importante, pois a maioria das amostras são de casos de direção normal. Então, caso o nosso método detectasse os casos de direção normal com alta acurácia e os casos de direção anormal com baixa acurácia, ainda assim a média da acurácia do conjunto

de teste permaneceria alta, mas não estaríamos detectando bem a direção anormal, a qual nos propomos.

Por conveniência, as matrizes de confusão associadas aos demais trechos rodoviários e situações de tráfego estão mostradas no apêndice B.

4.2 Comparações dos Resultados

Para ressaltar o impacto do nosso trabalho no conhecimento científico, comparamos os nossos resultados de detecção de direção anormal com o estado da arte. A tabela 3 mostra diversos estudos de detecção de direção anormal encontrados na literatura. Informações tais quais o objetivo da detecção, sensores e métricas utilizadas e acurácia das classificações são apresentadas.

Tabela 3 – Estudos referentes à detecção de direção anormal.

Autor	Objetivo de detecção	Sensores/Métricas	Acurácia
(a)	Motoristas bêbados	Simulador./ Padrões de esterçamento do volante.	77%
(b)	Motoristas bêbados	Simulador./ Performance de direção e dados fisiológicos.	70%
(c)	Direção anormal	Modelagem matemática./Posição da marcha e dos pedais de aceleração e freio.	n/a
(d)	Motoristas bêbados e/ou cansados	Simulador/Velocidade e posicionamento na faixa.	94%
(e)	Motoristas bêbados	Sensores de gás, temperatura e câmeras internas./Performance de direção e dados fisiológicos.	98%
(f)	Direção Anormal	Câmeras de vigilância/ Trajetórias dos veículos.	94/97%

(a) Shirazi e Rad (2014) (b) Chen e Chen (2017) (c) Hu et al. (2017) (d) Yao et al. (2019) (e) Rosero-Montalvo, López-Batista e Peluffo-Ordóñez (2020) (f) Xiong, Zhou e Chen (2022)

Fonte: Adaptado de Oliveira, Rebouças Filho, Silva Júnior, 2022.

Conforme mostra a tabela 3, alguns trabalhos possuem o objetivo de detectar alguma causa específica da direção anormal, como motoristas bêbados ou cansados, por exemplo. Outros visam detectar a direção anormal de forma mais ampla, conforme propomos nesta dissertação, podendo a direção anormal estar associada a uma diversidade de causas, tais como o uso de álcool e drogas, cansaço, distração, carga emocional, imprudência e até falta de habilidade.

Para o nosso sistema, detectar a direção anormal relacionada a várias causas é uma

importante vantagem, pois o objetivo principal da operação de veículos autônomos e do monitoramento inteligente do tráfego é evitar acidentes. Logo, todas as causas relacionadas à direção anormal devem ser consideradas, conforme propomos nesta dissertação.

Embora todos os trabalhos listados na tabela 3 visem detectar a direção anormal, raros são os estudos que visam a detecção de direção anormal com foco direcionado especificamente para as nossas aplicações. Como podemos perceber na tabela 3, os autores em (a), (b), (c) e (e) utilizam uma abordagem de sensores embarcados nos veículos. Abordagens como estas são maioria na literatura. Tais métodos nos ajudam a compreender diversas características do comportamento anormal, porém é difícil aplicá-los no contexto dos veículos autônomos, por fatores como a criação de grandes bases de dados.

Para estes casos, criar grandes bases de dados estaria condicionado à participação de uma quantidade enorme de voluntários. Volutários estes que talvez precisem se submeter ao consumo de diversas quantidades de álcool para se adequar aos métodos propostos. Para estes casos, o número de motoristas considerados nos estudos raramente passa de algumas dezenas. Em contraste, o nosso método nos possibilitou utilizar grandes bases de dados, pois não são necessários motoristas voluntários e não houve necessidade da consideração do nível de álcool no sangue, por exemplo.

Realizar a detecção de direção anormal com sensores instalados nos veículos representa um avanço para as tecnologias semiautônomas, como os dispositivos ADAS, alertando os motoristas em momentos de distração por exemplo. Porém, para um veículo de automação nível cinco, tal abordagem se torna inviável, pois acessar a informação de sensores instalados em outros veículos depende fortemente do consenso dos demais motoristas em fornecer seus dados, o que é improvável principalmente para motoristas bêbados. Ademais, acessar tais informações em tempo real facilmente se torna uma atividade laboriosa, cara e tecnologicamente ineficaz.

Por esse motivo, nos propomos a detectar a direção anormal aprendendo muito bem os padrões de direção normal. Dessa maneira, fomos capazes de apontar quais motoristas não estão dentro desses padrões. Isso faz com que consigamos trabalhar com abundância de dados, pois é mais fácil coletar dados de motoristas sob condições normais, uma vez que esses são maioria no trânsito e arriscam "menos" a vida das pessoas.

O autor considerado na tabela 3 - linha (c), utilizou um princípio semelhante: a aprendizagem de um modelo de direção normal para caracterização de direção anormal. Porém, os autores utilizaram métricas como o posicionamento dos pedais, que só pode ser obtido com acesso aos dados do veículo em questão. Ademais, os autores não apresentaram uma acurácia de seu método testado em alguma base de dados.

Outros autores utilizaram abordagens de detecção de direção anormal sem utilizar de sensores embarcados. Estes trabalhos são visivelmente mais raros na literatura. A

tabela 3 traz como exemplo o autor na linha (d), que analisou as métricas de velocidade e posicionamento na faixa. Porém, apenas 22 motoristas voluntários, submetidos a diferentes níveis de álcool, foram considerados no estudo. Um outro ponto é que os autores utilizam um simulador, perdendo assim a característica dos dados naturalísticos.

É consenso na literatura que o uso de dados naturalísticos é preferível na análise do comportamento de motoristas. Neste caso, os motoristas não são influenciados por fatores intrínsecos às análises, como a presença de sensores. Os dados naturalísticos representam da melhor forma as situações reais que serão encontradas pelos veículos autônomos nas ruas. Métodos que utilizam de simuladores podem obviamente atingir resultados expressivos, mas as chances da ocorrência de vieses no aprendizado derivados de uma má representatividade dos dados são maiores.

Na tabela 3, os autores em (f), analisaram as trajetórias de veículos coletadas por câmeras de vigilância, o que se alinha com os conceitos até aqui levantados para as possíveis aplicações em veículos autônomos e cidades inteligentes, em termos de que as trajetórias coletadas para as análises não são intrusivas e não utilizam de simuladores, logo, são trajetórias naturalísticas. Neste caso, os autores analisaram as situações de tráfego referentes à parada no sinal e estacionamento. De modo geral, a vantagem do nosso estudo está na utilização de dados coletados via drone, que, para fins de desenvolvimento, é mais vantajoso para obter trajetórias de veículos, pois não há oclusão de um veículo por outros.

De modo geral, a nossa acurácia de detecção de direção anormal se manteve mais alta ou em linha com o estado da arte. Porém, embora todos estes estudos tratem da detecção de direção anormal de alguma forma, é importante ressaltar que estas acurácias não são totalmente comparáveis e intercambiáveis. As principais razões são que os autores possuíam diferentes métricas e objetivos dentro da detecção de direção anormal, que pode ainda ser considerada um campo incipiente da ciência.

Desenvolvemos também um estudo visando abordar outros trabalhos que utilizaram as mesmas bases de dados dessa dissertação. Embora tais autores também foquem em suprir informações importantes para uma tomada de decisão mais segura, suas abordagens raramente consideram o fato de que motoristas sob condições de direção anormal são os maiores causadores de acidentes. Ao levarmos esse fator em consideração, utilizamos de dados estatísticos para mostrar que existe uma possibilidade menor de que o veículo autônomo se envolva em acidentes uma vez detectados os casos de direção anormal.

Dessa forma, o nosso método inovador nos possibilitou a utilização de tais bases de dados para a detecção de direção anormal. Para o melhor do nosso conhecimento, fomos os primeiros a utilizar as bases de dados *HighD*, *ExiD*, *InD* e *RounD* para a detecção de direção anormal.

5 Conclusão

A partir da análise de padrões de trajetórias, desenvolvemos o *DBALapisco*, um sistema escalável, eficiente e prático para detecção de direção anormal.

Fomos capazes de estimar uma métrica de anormalidade, definir classes de direção anormal, treinar uma rede neural para classificar novas amostras e codificar o sistema para que possa ser utilizado em softwares de desenvolvimento e validações de segurança de veículos autônomos e monitoramento de tráfego em cidades inteligentes.

Adicionalmente, os engenheiros podem acessar o sistema via interface gráfica para realizar detecções em tempo real, atualizar os resultados atuais e expandir a detecção de direção anormal para outros trechos rodoviários à medida com que mais dados estiverem disponíveis.

Quanto à acurácia de classificação de novas amostras, atingimos 97.9% com 0.1% de desvio padrão no nosso melhor caso, o trecho de acessos rodoviários.

De modo geral, os nossos resultados de acurácia para os demais trechos rodoviários se mantiveram entre 94 e 97%, e desvio padrão entre 0.1 e 0.5%, que são valores alinhados, ou superiores, aos verificados na literatura. Nosso pior resultado de acurácia, referente ao trecho reto com duas mudanças de faixa, atingiu apenas 69.6%. Nesse caso, inferimos que a quantidade de dados disponíveis para essa situação de tráfego não foi suficiente para a obtenção de uma alta acurácia.

Comparado com outras abordagens presentes na literatura, o nosso método detecta a direção anormal de forma mais ampla, podendo a anormalidade estar relacionada a várias causas. Isso contrasta com o fato de que a grande maioria dos trabalhos atualmente visam detectar alguma causa específica, como o motorista alcoolizado.

O poder de processamento e o custo dos algoritmos utilizados dentro do campo da análise do comportamento dos motoristas tem sido tratados como prioridade em aplicações de tempo real (AZADANI; BOUKERCHE, 2021), pois tais sistemas necessitam tomar decisões rápidas baseadas em grandes quantidades de dados. Logo, ao propor a detecção de direção anormal baseada na mediana geométrica dos padrões de trajetórias, o nosso método otimiza o custo computacional de detecções em tempo real.

As maiores causas de acidentes estão relacionadas à direção anormal (WHO, 2018). Logo, a tecnologia de veículos autônomos fortemente se beneficia da detecção de direção anormal para uma tomada de decisão mais segura, assim como cidades inteligentes se beneficiam do monitoramento automático do tráfego. Dessa forma, nosso trabalho representa um importante ponto de partida para o conhecimento científico neste campo.

5.1 Fronteiras Científica e Tecnológica

O nosso trabalho expande as fronteiras científicas no âmbito da direção automatizada para veículos autônomos e no monitoramento automático do tráfego para cidades inteligentes.

Pela nossa métrica de direção anormal (λ), contribuimos com a ciência com uma definição simples e quantitativa de direção anormal.

Pelo processamento das bases de dados originais, ou seja, o desenvolvimento de novas bases de dados derivadas daquelas originais, contribuimos com a ciência com a quantidade e variedade dos dados.

Pela codificação de todos os passos do nosso método em *python*, estendemos a fronteira tecnológica com o desenvolvimento de um sistema de detecção de direção anormal, o *DBALapisco*.

5.2 Trabalhos Futuros

Para trabalhos futuros, pretendemos utilizar o módulo *DBALapisco - Real Time Detection* para realizar simulações de cenários de tráfego críticos.

Pretendemos desenvolver estudos visando uma detecção eficiente da classe de direção anormal no mínimo espaço de trajetória possível. Atualmente, o nosso método analisa em média 420 metros de trajetória para cada veículo.

Pretendemos desenvolver novas bases de dados em diferentes trechos rodoviários dos já analisados, assim como coletar dados regionais, para uma maior representatividade em aplicações locais.

Uma vez que o cenário de tráfego é uma função de diversos fatores que interagem entre si, pretendemos analisar como outros fatores (e.g. clima, presença de pedestres) influenciam o comportamento de direção.

Pretendemos formar parcerias com órgãos de trânsito para realizar a detecção de direção anormal em tempo real e uma posterior abordagem dos motoristas para a obtenção de um mínimo de dados rotulados com as anormalidades observadas na abordagem, assim como a criação de bases de dados em simuladores.

Pretendemos explorar as implicações do uso da nossa métrica de anormalidade (λ) no planejamento de manobras confortáveis.

Pretendemos também explorar outros fatores de alta importância para a tomada de decisão baseada na interpretação de cenários, como a detecção de objetos do tráfego, planejamento de rotas e análise de incertezas.

Referências

- ABBAS, Q.; ALSHEDDY, A. Driver fatigue detection systems using multi-sensors, smartphone, and cloud-based computing platforms: A comparative analysis. *Sensors*, MDPI, v. 21, n. 1, p. 56, 2020. Citado na página 31.
- AL-SULTAN, S.; AL-BAYATTI, A. H.; ZEDAN, H. Context-aware driver behavior detection system in intelligent transportation systems. *IEEE Transactions on Vehicular Technology*, v. 62, n. 9, p. 4264–4275, 2013. Citado na página 26.
- ALEXIADIS, V. et al. The next generation simulation program. *Institute of Transportation Engineers. ITE Journal*, Institute of Transportation Engineers, v. 74, n. 8, p. 22, 2004. Citado na página 36.
- AMALDI, E.; KANN, V. On the approximability of minimizing nonzero variables or unsatisfied relations in linear systems. *Theoretical Computer Science*, v. 209, n. 1, p. 237–260, 1998. ISSN 0304-3975. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304397597001151>>. Citado na página 34.
- AZADANI, M. N.; BOUKERCHE, A. Driving behavior analysis guidelines for intelligent transportation systems. *IEEE Transactions on Intelligent Transportation Systems*, p. 1–19, 2021. Citado 4 vezes nas páginas 25, 28, 31 e 61.
- BOCK, J. et al. The ind dataset: A drone dataset of naturalistic road user trajectories at german intersections. In: IEEE. *2020 IEEE Intelligent Vehicles Symposium (IV)*. [S.l.], 2020. p. 1929–1934. Citado na página 37.
- CHEN, H.; CHEN, L. Support vector machine classification of drunk driving behaviour. *International journal of environmental research and public health*, Multidisciplinary Digital Publishing Institute, v. 14, n. 1, p. 108, 2017. Citado 2 vezes nas páginas 33 e 58.
- COIFMAN, B.; LI, L. A critical evaluation of the next generation simulation (ngsim) vehicle trajectory dataset. *Transportation Research Part B: Methodological*, Elsevier, v. 105, p. 362–377, 2017. Citado na página 36.
- CORDTS, M. et al. The cityscapes dataset for semantic urban scene understanding. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 3213–3223. Citado na página 35.
- DOZZA, M.; FLANNAGAN, C. A.; SAYER, J. R. Real-world effects of using a phone while driving on lateral and longitudinal control of vehicles. *Journal of safety research*, Elsevier, v. 55, p. 81–87, 2015. Citado 2 vezes nas páginas 32 e 33.
- GEIGER, A.; LENZ, P.; URTASUN, R. Are we ready for autonomous driving? the kitti vision benchmark suite. In: IEEE. *2012 IEEE conference on computer vision and pattern recognition*. [S.l.], 2012. p. 3354–3361. Citado na página 35.
- HANCOCK, P. A.; LESCH, M.; SIMMONS, L. The distraction effects of phone use during a crucial driving maneuver. *Accident Analysis & Prevention*, Elsevier, v. 35, n. 4, p. 501–514, 2003. Citado na página 33.

- HAYKIN, S. *Neural networks and learning machines*, 3/E. [S.l.]: Pearson Education India, 2010. Citado na página 33.
- HU, J. et al. Abnormal driving detection based on normalized driving behavior. *IEEE Transactions on Vehicular Technology*, IEEE, v. 66, n. 8, p. 6645–6652, 2017. Citado 2 vezes nas páginas 33 e 58.
- KALRA, N.; PADDOCK, S. M. Driving to safety: How many miles of driving would it take to demonstrate autonomous vehicle reliability? *Transportation Research Part A: Policy and Practice*, Elsevier, v. 94, p. 182–193, 2016. Citado na página 35.
- KRAJEWSKI, R. et al. The highd dataset: A drone dataset of naturalistic vehicle trajectories on german highways for validation of highly automated driving systems. In: IEEE. *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*. [S.l.], 2018. p. 2118–2125. Citado na página 37.
- KRAJEWSKI, R. et al. The round dataset: A drone dataset of road user trajectories at roundabouts in germany. In: *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*. [S.l.: s.n.], 2020. p. 1–6. Citado na página 37.
- MADDERN, W. et al. 1 year, 1000 km: The oxford robotcar dataset. *The International Journal of Robotics Research*, SAGE Publications Sage UK: London, England, v. 36, n. 1, p. 3–15, 2017. Citado na página 35.
- MOERS, T. et al. The exid dataset: A real-world trajectory dataset of highly interactive highway scenarios in germany. In: *2022 IEEE Intelligent Vehicles Symposium (IV)*. [S.l.: s.n.], 2022. p. 958–964. Citado na página 37.
- MORGENSTERN, T.; SCHOTT, L.; KREMS, J. F. Do drivers reduce their speed when texting on highways? a replication study using european naturalistic driving data. *Safety science*, Elsevier, v. 128, p. 104740, 2020. Citado 2 vezes nas páginas 32 e 33.
- NHTSA. *The Visual Detection of DWI Motorists*. [S.l.]: National Highway Traffic Safety Administration, 2010. 19 p. Citado 7 vezes nas páginas 23, 26, 32, 33, 40, 69 e 70.
- NHTSA. *Federal automated vehicles policy: Accelerating the next revolution in roadway safety*. [S.l.]: US Department of Transportation, 2016. Citado na página 35.
- OLIVEIRA, W. G.; REBOUÇAS FILHO, P. P.; SILVA JUNIOR, E. T. Driver behavior analysis: Abnormal driving detection using mlp classifier applied to outdoor camera images. *International Conference on Intelligent Systems Design and Applications*, 2022. Citado 2 vezes nas páginas 25 e 32.
- RAMANISHKA, V. et al. Toward driving scene understanding: A dataset for learning driver behavior and causal reasoning. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2018. p. 7699–7707. Citado na página 36.
- RIEDMAIER, S. et al. Survey on scenario-based safety assessment of automated vehicles. *IEEE access*, IEEE, v. 8, p. 87456–87477, 2020. Citado 3 vezes nas páginas 26, 34 e 35.
- ROMERA, E.; BERGASA, L. M.; ARROYO, R. Need data for driver behaviour analysis? presenting the public uah-driveset. In: IEEE. *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*. [S.l.], 2016. p. 387–392. Citado na página 36.

- ROSETO-MONTALVO, P. D.; LÓPEZ-BATISTA, V. F.; PELUFFO-ORDÓÑEZ, D. H. Hybrid embedded-systems-based approach to in-driver drunk status detection using image processing and sensor networks. *IEEE Sensors Journal*, IEEE, v. 21, n. 14, p. 15729–15740, 2020. Citado 2 vezes nas páginas 33 e 58.
- SCHAGEN, I. van; SAGBERG, F. The potential benefits of naturalistic driving for road safety research: Theoretical and empirical considerations and challenges for the future. *Procedia-social and behavioral sciences*, Elsevier, v. 48, p. 692–701, 2012. Citado na página 31.
- SHIRAZI, M. M.; RAD, A. B. Detection of intoxicated drivers using online system identification of steering behavior. *IEEE Transactions on Intelligent Transportation Systems*, IEEE, v. 15, n. 4, p. 1738–1747, 2014. Citado 2 vezes nas páginas 33 e 58.
- SINGH, H.; KATHURIA, A. Analyzing driver behavior under naturalistic driving conditions: A review. *Accident Analysis & Prevention*, Elsevier, v. 150, p. 105908, 2021. Citado 2 vezes nas páginas 31 e 33.
- SKOG, O.-J. r. Alcohol consumption and fatal accidents in canada, 1950–98. *Addiction*, Wiley Online Library, v. 98, n. 7, p. 883–893, 2003. Citado na página 32.
- THORN, E. et al. *A framework for automated driving system testable cases and scenarios*. [S.l.], 2018. Citado na página 35.
- ULBRICH, S. et al. Defining and substantiating the terms scene, situation, and scenario for automated driving. In: IEEE. *2015 IEEE 18th international conference on intelligent transportation systems*. [S.l.], 2015. p. 982–988. Citado na página 34.
- WACHENFELD, W.; WINNER, H. The release of autonomous vehicles. In: *Autonomous driving*. [S.l.]: Springer, 2016. p. 425–449. Citado na página 35.
- WEBER, H. et al. A framework for definition of logical scenarios for safety assurance of automated driving. *Traffic injury prevention*, Taylor & Francis, v. 20, n. sup1, p. S65–S70, 2019. Citado na página 26.
- WHO. *Global status report on road safety 2018*. [S.l.]: World Health Organization, 2018. 403 p. p. Citado 3 vezes nas páginas 27, 32 e 61.
- XIONG, Q.; ZHOU, S.; CHEN, Q. Abnormal driving behavior detection based on kernelization-sparse representation in video surveillance. *Multimedia Tools and Applications*, Springer, v. 81, n. 4, p. 4585–4601, 2022. Citado 2 vezes nas páginas 34 e 58.
- YAO, Y. et al. Classification of fatigued and drunk driving based on decision tree methods: a simulator study. *International journal of environmental research and public health*, Multidisciplinary Digital Publishing Institute, v. 16, n. 11, p. 1935, 2019. Citado 2 vezes nas páginas 34 e 58.
- ZHANG, L. et al. Effect of using mobile phones on driver's control behavior based on naturalistic driving data. *International journal of environmental research and public health*, Multidisciplinary Digital Publishing Institute, v. 16, n. 8, p. 1464, 2019. Citado 2 vezes nas páginas 32 e 33.

Apêndices

APÊNDICE A – Detecção Visual de Motoristas Intoxicados (NHTSA, 2010)

A NHTSA¹ apresentou uma série de manobras que caracterizam o comportamento de motoristas intoxicados no tráfego. Por motoristas intoxicados, entende-se motoristas sob efeito de álcool ou outras drogas que causam alterações na capacidade de dirigir. A figura 17 traz algumas dessas manobras, que são contempladas nesta dissertação.


Figura 17 – Caracterização de manobras para a detecção visual de motoristas intoxicados.




(a) Trajetória Ondulada



(b) Drift (Escorregamento)



(c) Correções abruptas



(d) Curva com raio longo.

Fonte: Adaptado de NHTSA, 2010.

A figura 17 elenca a trajetória ondulada, drift (ou escorregamento), correções


¹ Do inglês *National Highway Traffic Safety Administration* (Administração Nacional da Segurança do Tráfego das Rodovias, nos Estados Unidos da América.)

abruptas de trajetória (como ao perceber que o veículo está saindo dos limites das faixas) e curva com raio longo. Estas são algumas manobras que caracterizam a direção anormal por motoristas intoxicados. O foco de NHTSA (2010) está em representar as manobras que podem ser "visualmente" detectadas, ou seja, por um humano.

Embora a detecção de direção anormal proposta nessa dissertação não seja necessariamente "visual", por ser realizada através de algoritmos de redes neurais com dados provenientes de câmeras, ela utiliza dos mesmos princípios: perturbações de trajetória e velocidade.

NHTSA (2010) traz ainda mais alguns fatores característicos da direção anormal que podem ser utilizados na detecção visual, mas que não estão contemplados nessa dissertação, pois também não estão representados nas nossas bases de dados. A figura 18 traz esses casos.


Figura 18 – Caracterização de manobras para a detecção visual de motoristas intoxicados (casos adicionais).




(a) Parada após o limite



(b) Sinalização inconsistente com a ação



(c) Contramão



(d) Curva ilegal.


Fonte: Adaptado de NHTSA, 2010.

Conforme a figura 18, outros indícios da presença de direção anormal por motoristas

intoxicados são a parada após os limites, a sinalização incondizente com a ação executada, a tomada de contramão e a curva ilegal.


APÊNDICE B – Matrizes de Confusão por Trecho Rodoviário

Figura 19 – Matriz de confusão para uma realização de classificações do trecho reto sem mudanças de faixa.




Fonte: Autor.

Figura 20 – Matriz de confusão para uma realização de classificações do trecho reto com uma mudança de faixa.




Fonte: Autor.

Figura 21 – Matriz de confusão para uma realização de classificações do trecho reto com duas mudanças de faixa.




Fonte: Autor.

Figura 22 – Matriz de confusão para uma realização de classificações do trecho de entradas e saídas de rodovias.




Fonte: Autor.

Figura 23 – Matriz de confusão para uma realização de classificações do trecho de interseções urbanas.



Fonte: Autor.

Figura 24 – Matriz de confusão para uma realização de classificações do trecho de rotatórias.



Fonte: Autor.